



CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS  
GERAIS

CURSO DE BACHARELADO EM ENGENHARIA ELÉTRICA

TRABALHO DE CONCLUSÃO DE CURSO

**DETECÇÃO AUTOMÁTICA DE AFUNDAMENTOS DE  
TENSÃO EM SISTEMAS ELÉTRICOS DE POTÊNCIA  
UTILIZANDO INTELIGÊNCIA COMPUTACIONAL**

Yan Ambrósio de Oliveira

# **DETECÇÃO AUTOMÁTICA DE AFUNDAMENTOS DE TENSÃO EM SISTEMAS ELÉTRICOS DE POTÊNCIA UTILIZANDO INTELIGÊNCIA COMPUTACIONAL**

Trabalho apresentado como requisito parcial para a Conclusão do Curso de Bacharelado em Engenharia Elétrica do Centro Federal de Educação Tecnológica de Minas Gerais

## **COMISSÃO EXAMINADORA**

---

Prof. Márcio Wladimir Santana

---

Prof.<sup>a</sup> Rosana Áurea Tonetti Massahud

---

Prof. Israel Teodoro Mendes

Nepomuceno, 19 de abril de 2021.

## **DEDICATÓRIA**

A Deus, por ser extremamente paciente e piedoso comigo...  
Aos meus pais que foram companheiros em todas as horas...

## AGRADECIMENTOS

Agradeço à Deus, à Nossa Senhora Aparecida e à Nossa Senhora de Fátima, por me darem forças e permitirem chegar até aqui.

Ao meu orientador, Márcio Wladimir Santana, pela excelência na orientação, pelos ensinamentos passados desde o ensino técnico e pelo apoio fundamental na minha formação profissional. Agradeço também pela amizade, tempo e paciência dedicados a mim em todos os momentos.

Aos professores, Rosana Áurea Tonetti Massahud e Israel Teodoro Mendes, pelo apoio e conhecimentos passados, e também por se disporem a participar da banca examinadora.

Ao Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG), pela minha formação profissional e pessoal.

À minha família, em especial à mãe, Eloá Ambrósio Silva, que batalhou muito para me oferecer uma educação de qualidade.

Aos amigos e colegas de curso, pela força e pela vibração em relação a esta jornada.

À todos que, com boa intenção, colaboraram para a realização e finalização deste trabalho.

## EPÍGRAFE

“O temor do Senhor é o princípio da sabedoria,  
e o conhecimento do Santo é prudência”.

Provérbios 9.10

## RESUMO

O termo Qualidade de Energia Elétrica (QEE) tem sido comumente utilizado no setor elétrico nos últimos anos, e é empregado para expressar as mais variadas características da energia elétrica entregue pelas concessionárias aos consumidores. A preocupação com a qualidade de energia elétrica é decorrente, em parte, da reformulação que o setor elétrico vem experimentando, para viabilizar a implantação de um mercado consumidor, no qual o produto comercializado passa a ser a própria energia elétrica. Um dos fatores cruciais relacionado a QEE é a continuidade do serviço prestado, já que qualquer interrupção do fornecimento pode causar transtornos de grande ordem. Não tão evidente, no entanto, está a questão da qualidade da energia elétrica como um produto comercial, mesmo que não ocorram interrupções. Isto, normalmente, só é percebido de forma indireta, por meio de falhas de funcionamento de alguns equipamentos. A necessidade da qualidade da energia elétrica surge a partir do momento em que os consumidores constatarem interrupções no fornecimento. Diante do exposto, fica evidente a importância de criar sistemas de análises e de monitoramento da QEE, visando determinar as causas e as consequências dos distúrbios no sistema. O presente trabalho tem por objetivo aplicar técnicas de inteligência computacional e processamento de sinais para desenvolver um modelo híbrido de detecção automática de afundamentos de tensão, distúrbio no qual ocorre com bastante frequência em Sistemas Elétricos de Potência.

**Palavras-chave:** Qualidade de energia elétrica; Processamento de sinais; Afundamento de tensão; Sistemas elétricos potência.

## SUMÁRIO

|  |           |
|--|-----------|
| <b>1 INTRODUÇÃO .....</b>                                  | <b>8</b>  |
| 1.1 Caracterização do problema .....                       | 9         |
| 1.2 Motivação .....  | 9         |
| 1.3 Objetivos.....   | 10        |
| 1.4 Organização do trabalho .....                          | 10        |
| <b>2 REFERENCIAL TEÓRICO .....</b>                         | <b>11</b> |
| 2.1 Análise da qualidade de energia .....                  | 11        |
| 2.2 Itens de qualidade de energia.....                     | 12        |
| 2.2.1 Variações de curta duração.....                      | 14        |
| 2.2.1.1 Interrupção de curta duração .....                 | 14        |
| 2.2.1.2 Afundamento de tensão de curta duração .....       | 15        |
| 2.3 Reconhecimento de padrões .....                        | 16        |
| 2.4 Filtro de Hodrick e Prescott.....                      | 19        |
| 2.5 Raiz do valor quadrático médio.....                    | 20        |
| 2.6 Transformada rápida de Fourier .....                   | 21        |
| <b>3 CLASSIFICADORES .....</b>                             | <b>22</b> |
| 3.1 Conceitos .....  | 22        |
| 3.2 Redes neurais artificiais: Multi-Layer Perceptron..... | 22        |
| 3.3 Support vector machines .....                          | 25        |
| <b>4 METODOLOGIA.....</b>                                  | <b>27</b> |
| 4.1 Base de dados .....                                    | 27        |
| 4.2 Sistema de reconhecimento de padrões .....             | 28        |
| 4.3 Aplicação do filtro HP.....                            | 29        |
| 4.4 Aplicação do valor eficaz .....                        | 33        |
| 4.5 Aplicação da transformada rápida de Fourier.....       | 34        |
| <b>5 RESULTADOS E DISCUSSÕES .....</b>                     | <b>36</b> |
| 5.1 Classificação de distúrbios .....                      | 36        |
| 5.2 Matriz de confusão .....                               | 38        |
| <b>6 CONCLUSÃO.....</b>                                    | <b>42</b> |
| <b>REFERÊNCIAS .....</b>                                   | <b>44</b> |

## 1 INTRODUÇÃO

O termo Qualidade de Energia Elétrica (QEE) tem sido comumente utilizado no setor elétrico nos últimos anos, e tem por finalidade expressar as mais variadas características da energia elétrica entregue pelas concessionárias aos consumidores (CSPE, 1997; RIBEIRO, 1996). Uma definição abrangente define QEE como sendo uma medida de quão bem a energia elétrica pode ser utilizada pelos consumidores (ONS, 2000; EURELETRIC, 2004). Essa medida inclui características de continuidade de suprimento e de conformidade com certos parâmetros considerados desejáveis para a operação segura, tanto do sistema supridor como das cargas elétricas. Entre os parâmetros a considerar tem-se:

- Distorções;
- Flutuações de tensão;
- Variações de tensão de curta duração;
- Desequilíbrio de sistemas trifásicos;
- Transitórios rápidos.

A preocupação com a Qualidade de Energia Elétrica é decorrente, em parte, da reformulação que o setor elétrico vem experimentando, para viabilizar a implantação de um mercado consumidor, no qual o produto comercializado passa a ser a própria energia elétrica. Parece evidente que o consumidor prefere adquirir a energia que apresenta parâmetros adequados de qualidade ao custo mais baixo possível. Nesse contexto, as operadoras de sistemas elétricos são estimuladas, tanto pelas agências reguladoras, Agência Nacional de Energia Elétrica – ANEEL, por exemplo, como pelo próprio mercado, a prestar informações sobre as condições de operação ou fornecer detalhes acerca de eventos ocorridos e que afetaram os consumidores. Esse é um dos papéis do monitoramento e da análise da qualidade de energia elétrica (DECKMANN; POMILIO, 2020).

Segundo Oliveira (2000), em uma análise inicial preocupa-se com a continuidade do serviço, já que qualquer interrupção do fornecimento pode causar transtornos de grande ordem. Não tão evidente, no entanto, está a questão da qualidade da energia elétrica como um produto comercial, mesmo que não ocorram interrupções. Isto, normalmente, só é percebido de forma indireta, por meio de falhas de funcionamento de alguns equipamentos. A necessidade da qualidade da energia elétrica surge a partir do momento em que os consumidores constatarem interrupções no fornecimento (SANTANA, 2017). À medida que tais consumidores tornam-se mais sofisticados sob o ponto de vista tecnológico, outros fatores começam a ser considerados. Isto se justifica, principalmente, pelos seguintes motivos:

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

## **1.1 Caracterização do problema**

Diante do exposto, fica evidente a importância de criar sistemas de análises e de monitoramento da Qualidade da Energia Elétrica, visando determinar as causas e as consequências dos distúrbios no sistema. Além disso, é importante apresentar medidas técnicas, economicamente viáveis, para minimizar os problemas associados.

Dentre os assuntos mais pesquisados quando se diz respeito a Qualidade de Energia Elétrica são as dificuldades de se detectar e classificar distúrbios elétricos. Dentre os distúrbios existentes, os afundamentos de tensão são um dos mais comuns e que mais causaram 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).

## **1.2 Motivação**

A detecção 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 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 desse distúrbio é fundamental para os sistemas de proteção. Além disso, o detector 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 (NAGATA, 2018).

### 1.3 Objetivos

Este trabalho tem por objetivo aplicar técnicas de inteligência computacional e processamento de sinais para desenvolver um modelo híbrido de detecção automática de afundamentos de tensão. Para a construção do modelo serão utilizados sinais de tensão simulados computacionalmente via *software Matlab* versão de estudante (avaliação *free*), seguindo os padrões do *Institute of Electrical and Electronics Engineers* (IEEE Std 1159-2009).

O modelo permitiu a aplicação em qualquer nível de tensão e a etapa de classificação trouxe uma abordagem de baixa complexidade computacional e de alto desempenho, com rápida resposta. Para tal, foi realizado um pré-processamento das características dos sinais elétricos gerados, objetivando projetar classificadores mais simples e eficientes. Os classificadores serão testados baseados em *Support Vector Machine* (SVM) e Redes Neurais. Para a extração de características indicadoras de presença de afundamentos de tensão foi considerado o modelo híbrido composto pelas seguintes técnicas de análise de sinais: filtro de Hodrick-Prescott, raiz do valor quadrático médio e transformada rápida de Fourier.

### 1.4 Organização do trabalho

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

No capítulo 3 descrevem-se os classificadores que são levados em consideração para tratar o problema de detecção de afundamentos de tensão. São apresentadas as principais informações e características dos classificadores utilizados.

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

No capítulo 5 relacionam-se os resultados obtidos, onde será feita um comparativo entre os classificadores utilizados na detecção dos afundamentos de tensão. Este capítulo apresenta, ainda, avaliações de desempenho, acurácia e complexidade considerando os métodos apresentados e outros métodos da literatura da área.

Por fim, o capítulo 6 apresentará as considerações finais e propostas de trabalhos futuros.

## **2 REFERENCIAL TEÓRICO**

### **2.1 Análise da qualidade de energia**

Conforme Deckmann e Pomilio (2010), identificar e solucionar problemas relacionados à Qualidade de Energia Elétrica não é uma tarefa tão trivial. Como se trata de diagnosticar um problema de compatibilidade eletromagnética, esta pesquisa pode envolver questões que vão além de um simples problema tecnológico:

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

Segundo Deckmann e Pomílio (2010), cada um desses passos requer certo conhecimento ou estudo específico. Quando se tem uma ideia de como os problemas se manifestam, das suas causas, dos seus efeitos e das soluções usuais, fica mais fácil chegar a um diagnóstico correto. Conhecer as condições locais é fundamental para levantar as hipóteses que levam às causas do problema. As circunstâncias locais, muitas vezes, interferem na forma em que os sintomas se apresentam ao observador. Por exemplo, o afundamento da tensão pode ser a causa da falha na partida de um motor (dimensionamento errado do alimentador) ou a consequência (curto-circuito no enrolamento, falta de fase, etc.). Escolher corretamente os instrumentos de medida e os locais mais adequados, para a sua instalação, pode ser decisivo a fim de se conseguir detectar e quantificar o problema.

Eventos intermitentes podem requerer registradores contínuos para a sua detecção. Fenômenos periódicos, como ressonâncias harmônicas ou modulação de amplitude, podem requerer analisadores de espectro em frequência. A interpretação dos dados, muitas vezes, exige certo conhecimento sobre técnicas de medição. Isso é válido, particularmente, aos analisadores

de espectro em razão das limitações impostas pelo truncamento do sinal amostrado (SANTANA, 2017).

Modelos de simulação são úteis para validar encontrar e validar soluções. Modelos físicos ou matemáticos, que permitem realizar simulações computacionais, muitas vezes, ajudam a entender o fenômeno e permitem descobrir em que condições o problema se manifesta. Por outro lado, uma solução simples às vezes só é encontrada depois que o problema foi exaustivamente estudado através de simulação (DECKMANN; POMILIO, 2010; DUGAN et. al., 2003).

## **2.2 Itens de qualidade de energia**

Os 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 1.

Tabela 1 – Características dos principais distúrbios elétricos segundo IEEE.

| Classificação                                  | Conteúdo Espectral Típico | Duração Típica    | Magnitude Típica        |
|--|---------------------------|-------------------|-------------------------|
| <b>1.0 Transientes</b>                         |                           |                   |                         |
| 1.1 Impulsivos                                 |                           |                   |                         |
| 1.1.1 Nanossegundo                             | 5 ns                      | < 50 ns           |                         |
| 1.1.2 Microssegundo                            | 1 $\mu$ s                 | 50 ns – 1 ms      |                         |
| 1.1.3 Milissegundo                             | 0,1 ms                    | > 1 ms            |                         |
| 1.2 Oscilatórios                               |                           |                   |                         |
| 1.2.1 Baixa Frequência                         | < 5 kHz                   | 0,3 – 50 ms       | 0 – 4 pu                |
| 1.2.2 Média Frequência                         | 5-500 kHz                 | 20 $\mu$ s        | 0 – 8 pu <sup>1</sup>   |
| 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> |                           |                   |                         |
| 2.1 Instantânea                                |                           |                   |                         |
| 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            |
| 2.2 Momentânea                                 |                           |                   |                         |
| 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            |
| 2.2.3 Elevação de tensão                       |                           | 30 ciclos – 3 s   | 1,1 – 1,4 pu            |
| 2.3 Temporária                                 |                           |                   |                         |
| 2.3.1 Interrupção                              |                           | > 3 s – 1 min     | < 0,1 pu                |
| 2.3.2 Afundamento de tensão                    |                           | > 3 s – 1 min     | 0,1 – 0,9 pu            |
| 2.3.3 Elevação de tensão                       |                           | > 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 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%<br>0,2 – 2 Pst |
| <b>7.0 Variações de frequência no sistema</b>  |                           |                   |                         |
|  |                           | < 10 s            | $\pm$ 0,10 Hz           |

Fonte: Adaptado de IEEE Std 1159 (2009).

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

Neste trabalho, os distúrbios abordados serão as interrupções de curta duração e os afundamentos de tensão de curta duração (*voltage sags*).

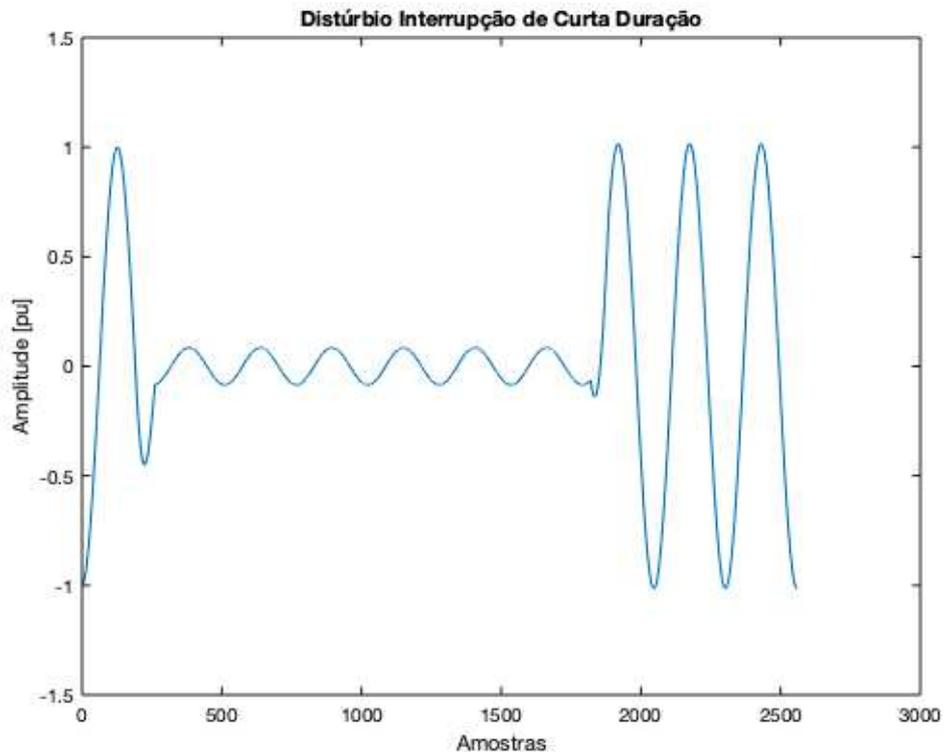
### **2.2.1 Variações de curta duração**

As variações de tensão de curta duração podem ser caracterizadas por alterações instantâneas ou temporárias, dependendo da duração, conforme definido na Tabela 1. Tais variações de tensão são, geralmente, causadas por condições de falta; energização de grandes cargas, as quais requerem altas correntes de partida; ou por faltas intermitentes nas conexões dos cabos de sistema. Dependendo do local e das condições do sistema, a falta pode causar tanto um afundamento de tensão temporária (*sag*) como uma elevação de tensão (*swell*) ou mesmo uma interrupção completa do sistema elétrico (SANTANA, 2017).

#### **2.2.1.1 Interrupção de curta duração**

Uma interrupção de curta duração ocorre, quando a tensão de suprimento decresce para um valor menor que  $0,1pu$ , por um período de tempo não superior a 1 minuto. Este tipo de interrupção pode ser causado por faltas no sistema de energia, falhas de equipamentos e mau funcionamento de sistemas de controle. A duração de uma interrupção, por uma falta no sistema de uma concessionária, é determinada pelo tempo de operação dos dispositivos de proteção. Religadores programados, para operar instantaneamente, geralmente, limitam a interrupção a períodos inferiores a 30 ciclos. Religadores temporizados podem originar interrupções momentâneas ou temporárias, dependendo da escolha das curvas de operação do equipamento (SANTANA, 2017; DUGAN et. al., 2003). A Figura 1 gerada via *software Matlab* mostra uma interrupção momentânea.

Figura 1 - Interrupção de curta duração em decorrência de simulação de um curto-circuito.



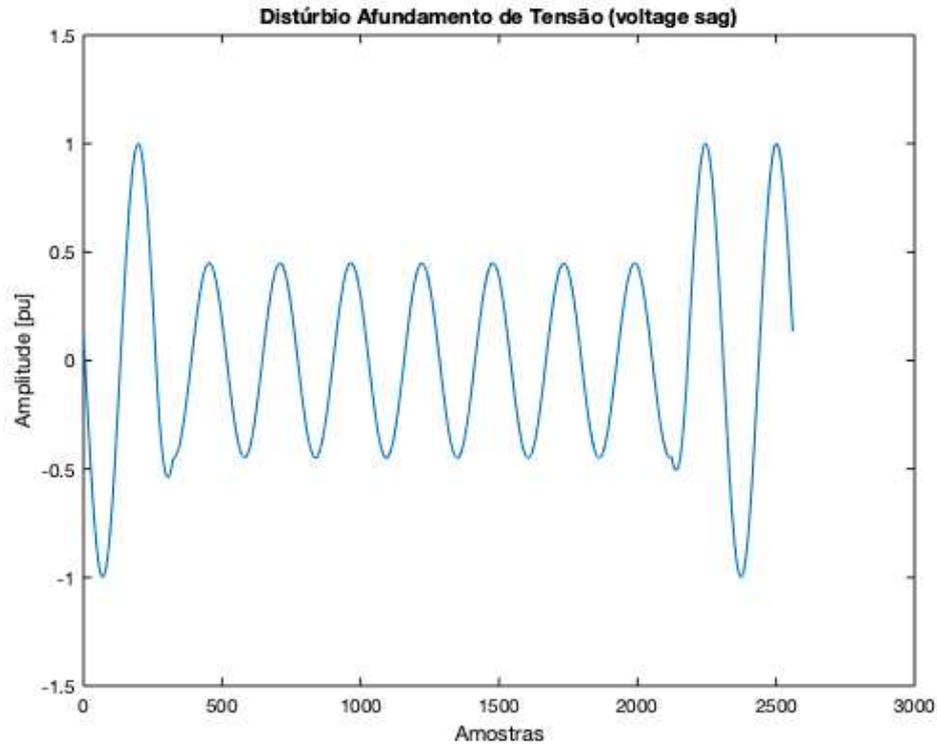
Fonte: Do autor (2021).

### 2.2.1.2 Afundamento de tensão de curta duração

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

Este tipo de distúrbio está associado, principalmente, a curtos-circuitos ocorridos nas redes de distribuição. Porém ele pode também ser causado pela energização de grandes cargas, partida de grandes motores e pela corrente *inrush* de um transformador. A Figura 2 ilustra um afundamento de tensão de curta duração típico, na simulação de uma falta fase-terra (SANTANA, 2017; DUGAN et. al., 2003).

Figura 2 - Afundamento de tensão devido a uma falta fase-terra.



Fonte: Do autor (2021).

As características e o número de afundamentos diante de uma determinada falta dependem de vários fatores como: a natureza da falta, sua posição relativa a outros consumidores ligados na rede e o tipo de filosofia de proteção adotado. Como efeito destes distúrbios, tem-se, principalmente, a má operação de equipamentos eletrônicos, em especial, de computadores. Estes têm sido alvo de preocupações em órgãos de pesquisa em Qualidade de Energia. Entretanto determinar os níveis de sensibilidade de tais equipamentos torna-se uma tarefa difícil, pelo grande número de medições necessárias em coleta de dados e, ainda, pela dificuldade de se ter equipamentos de medição em condições reais de campo (SANTANA, 2017).

### 2.3 Reconhecimento de padrões

Reconhecimento de padrões é uma área da ciência cujo objetivo é a classificação de objetos em um número de categorias ou classes. Dependendo da aplicação, estes objetos podem ser imagens, formas de onda de sinal ou qualquer tipo de medições que necessitam serem distinguidas (THEODORIDIS; KOUTOUMBAS, 1999; SANTANA, 2017).

O reconhecimento de padrões é uma habilidade extremamente desenvolvida nos seres humanos e em alguns animais. O ser humano é hábil em reconhecer faces, vozes, caligrafias e,

até mesmo, estados de humor de pessoas conhecidas. Alguns animais, também, têm essa característica bem desenvolvida, tais como os cães farejadores, que vasculham bagagens em aeroportos em busca de drogas. O grau de refinamento do reconhecimento de padrões, por parte do ser humano, pode chegar ao ponto de distinguir uma pintura de um mestre daquela feita por um falsário ou, adiante, pode tomar decisões em um dia de grande movimento de uma bolsa de valores. Assim sendo, pode-se dizer que padrões são os meios pelos quais o mundo é interpretado e, com base nessa interpretação, tomam-se atitudes e decisões. Percebe-se, também, que, nos exemplos citados, essa facilidade no reconhecimento de padrões está vinculada aos estímulos aos quais o indivíduo foi exposto anteriormente. Isso leva a supor que a estrutura selecionada pela evolução biológica, para desempenhar bem a tarefa de reconhecimento de padrões, incorpora alguma forma de aprendizado e evolui com a experiência. O grande desafio proposto, neste início de século, é o de desenvolver máquinas que tenham esses comportamentos (MARQUES, 1999; SANTANA, 2017).

Entende-se por padrão as propriedades que possibilitam o agrupamento de objetos semelhantes dentro de uma determinada classe ou categoria mediante a interpretação de dados de entrada (TOU; GONZALEZ, 1981). Entende-se por classe ou padrão um conjunto de atributos comuns do objeto de estudo. Assim, reconhecimento de padrões pode ser definido como sendo um procedimento, em que se busca a identificação de certas estruturas, nos dados de entrada em comparação a estruturas conhecidas e sua posterior classificação dentro de categorias. A ideia é de que o grau de associação seja maior entre dados da mesma categoria e menor entre dados de estruturas diferentes. Os dados de entrada são, geralmente, provenientes de sensores e selecionados segundo o conteúdo de informações relevantes para a decisão. Em geral, os dados passam por um processo de redução de dimensionalidade, para que possam ser usados por um classificador, que designará a classe que melhor o representa (MARQUES, 1999; MASCARENHAS, 1987; PRADO; ELFES, 1975; SANTANA, 2017).

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

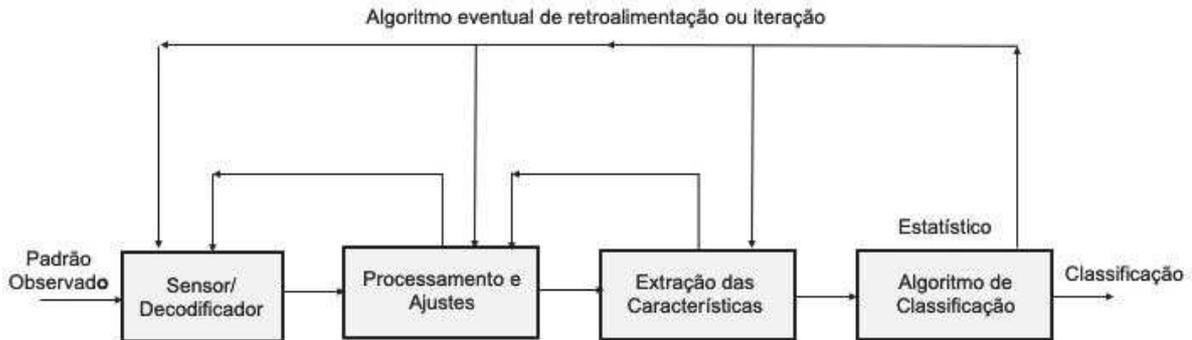
$$x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ \cdot \\ \cdot \\ x_n \end{bmatrix} \quad (1)$$

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

A segunda etapa consiste na extração de características intrínsecas e atributos do objeto e consequente redução da dimensionalidade do vetor padrão. É a fase da extração das características. A escolha das características é de fundamental importância para um bom desempenho do classificador. Esta escolha é feita em vista dos fenômenos que se pretende classificar. Exige-se, portanto um conhecimento específico sobre o problema em estudo. Nesta etapa, os objetivos básicos são: a redução da dimensionalidade do vetor característico, sem que isso implique perda significativa de informação que possa ser relevante à classificação. O objetivo é a redução do esforço computacional e a seleção das características relevantes para a tarefa de classificação (MARQUES, 1999; SANTANA, 2017).

A terceira etapa em reconhecimento de padrões envolve a determinação de procedimentos que possibilitem a identificação e classificação do objeto em uma classe. De modo diferente da segunda etapa, aqui a concepção do classificador pode ser abordada de forma abstrata e independente da natureza do problema. Em outras palavras, os métodos usados em reconhecimento de voz, análise de imagens, processamento de sinais de radar, inspeção de materiais, visão por computador ou detecção de anomalias são, muitas vezes, os mesmos. A aplicação de técnicas de reconhecimento de padrões se dá em contextos variados, sem perda de eficiência. Classificação pressupõe a designação de um objeto a uma determinada classe. O classificador “aprende” a distinguir, entre as classes, aquela à qual o objeto pertence. Padrões de uma mesma classe aglomeram-se em agrupamentos. A Figura 3 apresenta uma estrutura típica de um sistema de reconhecimento de padrões (MARQUES, 1999; SANTANA, 2017).

Figura 3 - Esquema geral de um sistema de reconhecimento de padrões.



Fonte: Schalkoff (1992). Adaptado.

O sistema, ilustrado na Figura 3, consiste de sensores e um procedimento de aquisição e tratamento de dados, um algoritmo de extração de características e um algoritmo de descrição ou classificação, a depender da aplicação. Complementarmente, é usual que alguns dados, que já tenham sido classificados ou descritos, estejam disponíveis para realizar ajustes no sistema. Esse conjunto de dados é chamado de conjunto de treinamento. A validação da eficácia na utilização de um sistema de Reconhecimento de Padrões é testada, a partir de um conjunto de dados, que não foi usado para o treinamento. A grande dificuldade, na implementação de um classificador de padrões, está justamente na escolha da técnica adequada, para que as fases do reconhecimento de padrões ocorram de modo a representar satisfatoriamente os fenômenos do mundo real (MARQUES, 1999; MASCARENHAS, 1987; PRADO; ELFES, 1975; TODESCO, 1995).

## 2.4 Filtro de Hodrick e Prescott

Hodrick e Prescott (1997) propuseram um método, um filtro, conhecido pelas iniciais de seus nomes (HP). A proposta do filtro é decompor o sinal em duas componentes de tendência e cíclica/aleatória. Em essência, removem-se as flutuações de baixa frequência dos sinais ou séries. A hipótese é de que, nessa separação, a variabilidade de baixa frequência representa a tendência em prazo mais longo e a variabilidade de frequência mais alta representa os ciclos mais curtos e/ou aleatórios (SANTANA, 2017).

Atributos extraídos dos sinais decompostos são importantes na distinção entre diferentes tipos de distúrbios. Em um sinal temporal, a componente de tendência é a mudança gradual observada por meio da variação dos valores de amplitude ao longo do tempo. A tendência se mantém ao se remover os componentes de ciclos, sazonalidades e fatores aleatórios. O filtro HP busca extrair a tendência, que é considerada estocástica, mas com variações suaves ao longo

do tempo e não correlacionadas com o ciclo, por meio da minimização com respeito do  $\tau_t$  funcional  $J$  conforme:

$$J = \sum_{t=1}^T C_t^2 + \lambda \sum_{t=2}^{T-1} (\Delta^2 \tau_t)^2 \quad (2)$$

em que  $C_t \triangleq y_t - \tau_t$ ; onde  $y_t$  é o sinal em questão; e  $\Delta^2 \triangleq (1 - L)$ , com  $L$  sendo o operador de defasagem, por exemplo,  $Lx_t = x_t - 1$ . Em (1),  $T$  é a quantidade de amostras de dados em questão, e  $\lambda$  é um parâmetro que penaliza a variabilidade da tendência. O parâmetro  $\lambda$  é o parâmetro de suavidade com o qual se controla a aceleração da componente de tendência, isto é, as variações na taxa de crescimento da componente de tendência. O primeiro termo de (1) é a soma dos desvios da série com respeito à tendência ao quadrado, e é uma medida do grau de ajuste. O segundo termo é a soma de quadrados das segundas diferenças das componentes de tendência, e é uma medida do grau de suavidade.

## 2.5 Raiz do valor quadrático médio

A raiz do valor quadrático médio é uma medida da magnitude de uma quantidade variável. O valor pode ser calculado para uma série de valores discretos ou para uma função contínua. O valor eficaz da tensão de um sinal elétrico é um parâmetro eficiente para detecção de distúrbios de QEE em especial aqueles que geram variações consideráveis na amplitude do sinal, como afundamentos de tensão, elevações de tensão e interrupções curtas (BALOUJI; SALOR, 2016). O valor de um sinal  $x$  para uma coleção de  $N$  valores  $[x_1, x_2, \dots, x_N]$  é dado por:

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3)$$

onde  $N$  é o número de amostras.

Para uma função variável contínua,  $f(t)$ , definida no intervalo  $T_1 \leq t \leq T_2$ , o valor RMS de um sinal  $x$  é dado por:

$$x_{RMS} = \sqrt{\frac{1}{T_2 - T_1} \int_{T_1}^{T_2} [f(t)]^2 dt} \quad (4)$$

## 2.6 Transformada rápida de Fourier

A Transformada de Fourier é uma das ferramentas mais utilizadas na análise de sinais no domínio da frequência. Qualquer sinal periódico pode ser descrito por um somatório de senos e cossenos. Existem duas abordagens para análise do espectro de frequências de um sinal: (i) a análise é feita de posse de uma função contínua; e (ii) somente se dispõe de dados mensurados, isto é, dispõe-se de uma função discreta. Para estes casos, pode-se utilizar a Transformada de Fourier Contínua e Discreta, respectivamente. As relações representam as definições da Transformada Contínua e sua inversa; e concernem às definições da Transformada Discreta e sua inversa (LATHI, 2006).

$$F(j\omega) = \int_0^{\infty} f(t) e^{-j\omega t} dt \quad (5)$$

$$F(j\omega) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(j\omega) e^{j\omega t} d\omega \quad (6)$$

$$TFD(f_n) = \frac{1}{N} \sum_{k=0}^{N-1} x_k e^{-j2\pi f_n k \Delta t} \quad (7)$$

$$x_k = \frac{1}{\Delta t} \sum_{f_n=0}^{(1-N)/T} TFD(f_n) e^{2\pi f_n k \Delta t} \quad (8)$$

onde  $\omega$  é a frequência angular;  $x_k$  é o sinal discreto;  $T$  é o intervalo de tempo total medido;  $\Delta t$  corresponde aos intervalos discretos de tempo;  $N = T / \Delta t$  é o número de amostras; e  $f_n = n/T$ ,  $n = 0, 1, 2, \dots, N - 1$ , são as componentes discretas de frequência.

A Transformada Discreta de Fourier (DFT) é muito utilizada no processamento digital de sinais, com o objetivo de estimar a amplitude e a fase da componente fundamental de um sinal. Esta ferramenta pode extrair características dos espectros dos eventos de qualidade de energia que são interessantes para sua classificação. A Transformada Rápida de Fourier (FFT) é uma implementação eficiente do algoritmo da DFT no qual sua velocidade, resultado de um número menor de operações, é considerada uma importante vantagem. Com esta ferramenta é possível obter uma estimação da amplitude da componente fundamental e dos harmônicos com boa precisão e baixo tempo computacional. O bom desempenho da FFT é observado na estimativa de amplitude, fase e resolução em frequência de sinais estacionários quando considerado uma janela de dados maior para a análise (LATHI, 2006).

### 3 CLASSIFICADORES

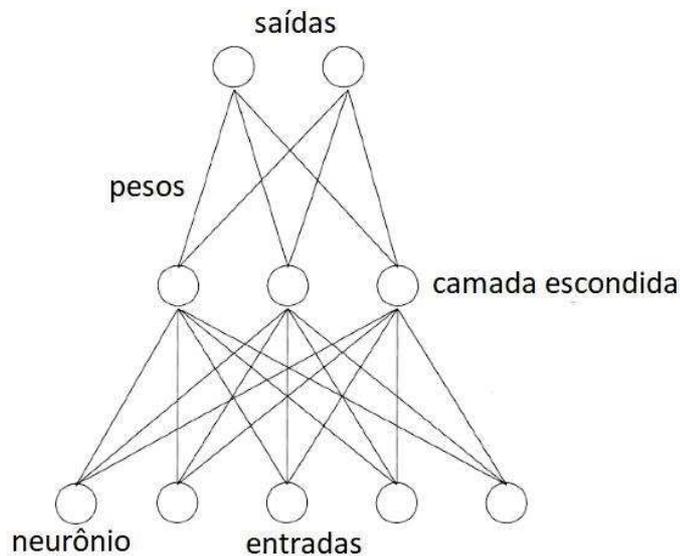
#### 3.1 Conceitos

Algoritmos de classificação ou classificadores são técnicas computacionais de reconhecimento de padrões que permitem distinguir dados em diferentes tipos de classes. Existem diversos tipos de classificadores, entretanto, neste trabalho para efeitos de detecção de afundamentos de tensão em Sistemas Elétricas de Potência utilizou-se apenas dois tipos, sendo eles: redes neurais artificiais *Multi-Layer Perceptron* (MLP) e *Support Vector Machines* (SVM) (VIEIRA et. al, 2013).

#### 3.2 Redes neurais artificiais: *Multi-Layer Perceptron*

Uma rede neural artificial (*Artificial Neural Network*), ou RNA, é uma estrutura que simula o funcionamento de um conjunto de neurônios. Consiste em uma camada de entrada de neurônios (ou nós, unidades), uma ou duas (ou mesmo três) camadas ocultas de neurônios e uma camada final de saída (WANG, 2003).

Figura 4 - Arquitetura de uma rede neural artificial.

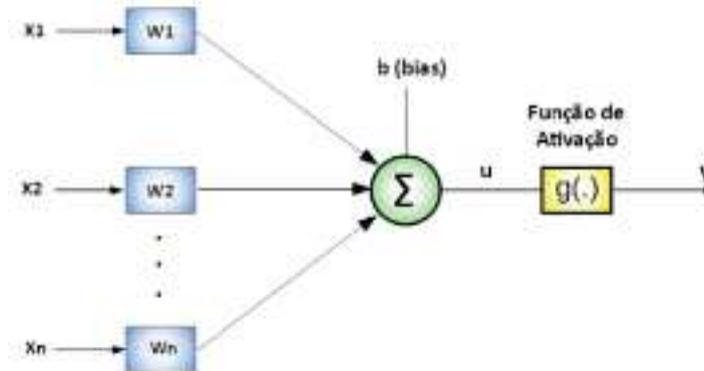


Fonte: Wang, 2003. Adaptado.

A Rede Neural Artificial mais simples é aquela composta de apenas um neurônio, chamada perceptron. Um perceptron possui: diversas entradas com seus respectivos pesos; um valor limite, utilizado para decidir se o perceptron “dispara”, ou seja, se sua saída será igual a 1; valor de saída, que pode ser 0 ou 1. Ao juntar muitos perceptrons, formamos uma rede; uma rede neural artificial. Para treinar um perceptron, comparamos o resultado obtido com o

resultado esperado, e mudamos os pesos das entradas com o objetivo de minimizar o erro obtido. O neurônio artificial é ilustrado pela Figura 5.

Figura 5 – Modelo do neurônio artificial.



Fonte: Cullock, Pitts, 1943.

Os classificadores neurais são baseados em algoritmos de inteligência computacional denominados redes neurais (HAYKIN, 1999; HERTEZ, PALMER, KROUGH, 1998). As redes neurais podem apresentar diversas arquiteturas, dentre elas a *Multi-Layer Perceptron*. Este tipo de rede é formada por neurônios *Perceptron*, que são formados de um vetor de entrada  $x = [x_1, x_2, \dots, x_n]^T$ , um vetor de pesos  $\omega = [\omega_1, \omega_2, \dots, \omega_n]^T$ , um vetor de limiar  $b$  e uma saída  $y$  dada conforme a Equação (9).

$$y = \varphi (x \cdot \omega - b) \quad (9)$$

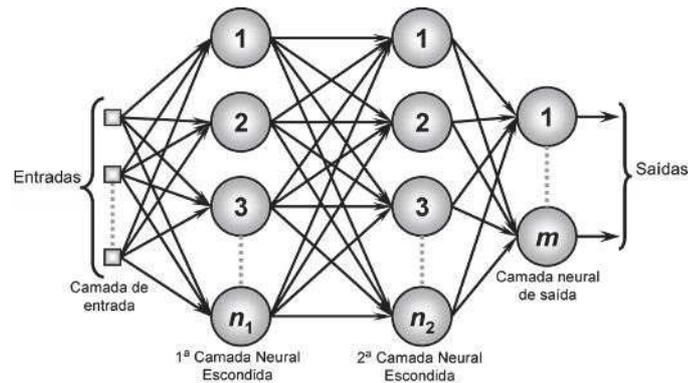
onde  $\varphi$  é a função de ativação da rede neural, onde normalmente adotam-se funções sigmoidais com sigmóide logística ou a tangente hiperbólica.

A capacidade da rede neural de realizar o reconhecimento de padrões provém da etapa de treinamento da mesma, que tem por objetivo modificar os pesos dos neurônios de tal modo que estes realizem a tarefa desejada. A etapa de pré-processamento de dados possui um papel fundamental no desempenho da rede.

A estrutura de uma rede MLP já foi objeto de estudos de muitos autores. No entanto, recentes resultados mostraram que uma camada intermediária é o suficiente para aproximar qualquer função contínua e duas camadas intermediárias são suficientes para aproximar qualquer função matemática, sendo que o número de neurônios por camada oculta deve ser definido empiricamente (CYBENKO, 1988; CYBENKO 1989; HERTEZ, PALMER, KROUGH, 1991).

De acordo com Bonifácio (2010), uma rede MLP consiste de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. E do tipo *feedforward*, ou seja, nenhuma saída de um neurônio de uma camada  $k$  será sinal de entrada para um neurônio de uma camada menor ou igual a  $k$ , e é completamente conectada, tal que cada neurônio fornece sua saída para cada unidade da camada seguinte, conforme Figura 6.

Figura 6 – Estrutura de uma rede MLP.

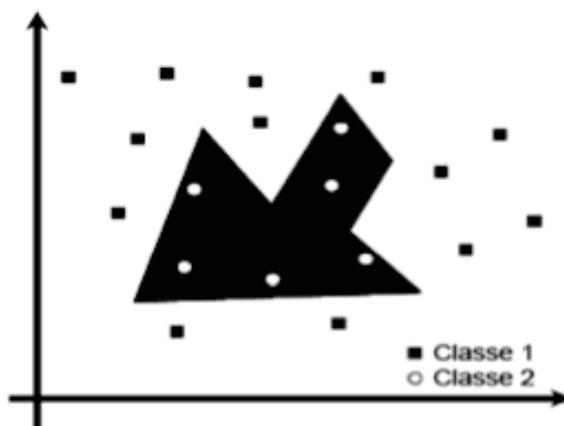


Fonte: Brito, Oliveira, 2020. Adaptado.

De acordo com Bonifácio (2010), à medida que a quantidade de camadas aumenta em uma RNA multicamadas também fica mais complexo determinar qual a função implementada pela RNA e qual o papel de cada camada, o que se pode afirmar é que elas definem como é realizada a divisão do espaço de decisão. Para uma RNA com duas camadas ocultas pode-se dizer que ocorre o seguinte processamento (BRAGA, CARVALHO, LUDERMIR, 2000):

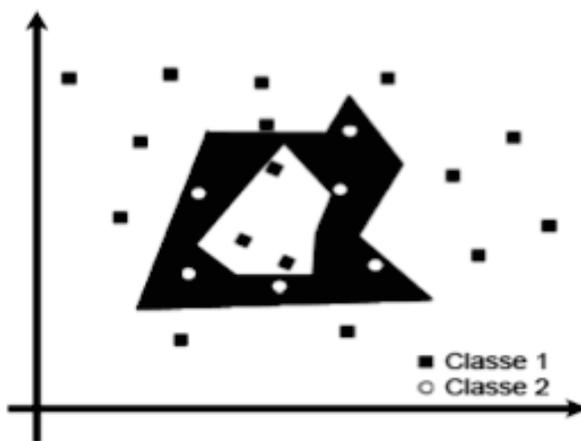
- I. Na primeira camada intermediária cada neurônio traça retas no espaço de padrões de treinamento;
- II. Na segunda camada intermediária cada neurônio combina as retas traçadas pela camada anterior conectados a ele, formando regiões convexas, onde o número de lados é definido pelo número de unidades a ele conectadas (Figura 7);
- III. Na camada de saída cada neurônio forma regiões que são combinações das regiões convexas formadas pela camada anterior, definindo, desta forma, regiões com formatos abstratos (Figura 8).

Figura 7 - Regiões definidas pelo processamento da segunda camada de uma rede MLP de duas camadas ocultas.



Fonte: Braga, Carvalho, Ludermir, 2000. Adaptado por Bonifácio, 2010.

Figura 8 - Regiões definidas pelo processamento da camada de saída de uma rede MLP de duas camadas ocultas.



Fonte: Braga, Carvalho, Ludermir, 2000. Adaptado por Bonifácio, 2010.

Estas características, juntamente com a habilidade de aprender através de treinamento, fazem com que as Redes MLP apresentem um poder computacional muito maior que as RNAs sem camadas ocultas (BONIFÁCIO, 2010).

### 3.3 Support vector machines

Os algoritmos de aprendizagem Support Vector Machines (Máquina de vetores de suporte), tem por objetivo determinar limites de decisões que produzam uma separação ótima entre classes por meio da minimização dos erros (VAPNIK, 1995). O SVM consiste em uma técnica computacional de aprendizado para problemas de reconhecimento de padrão. Introduzida por meio da teoria estatística de aprendizagem por Vapnik (1995), essa classificação é baseada no princípio de separação ótima entre classes, tal que se as classes são separáveis, a solução é escolhida de forma a separar o máximo as classes.

De acordo com Nascimento et. al. (2009), o algoritmo pode ser descrito da seguinte forma: dadas 'D' amostras de treinamento  $\{x_i, y_i\}$ , com  $i = 1, 2, \dots, D$ , onde  $x_i \in \mathfrak{M}^M$  é uma representação vetorial de um conjunto e  $y_i \in \{-1, 1\}$  é sua classe associada. Neste processo existe uma distribuição de probabilidade  $P(x, y)$  desconhecida da qual os dados de treinamento serão retirados. Ou seja, o processo de treinamento consiste em treinar um classificador de forma que este aprenda um mapeamento  $x$  a  $y$  por meio de exemplos (classes) de treinamento  $\{x_i, y_i\}$ , de forma que a máquina seja capaz de classificar um exemplo  $(x, y)$  ainda não visto que siga a mesma distribuição de probabilidade ( $P$ ) dos exemplos de treinamento.

O diferencial do SVM consiste em minimizar a expectativa de erro  $\varepsilon(\zeta)$  em uma classificação tal que  $\varepsilon(\zeta)$  é dado por:

$$\varepsilon(\zeta) = \int \frac{1}{2} |y - f(x, \zeta)| dP(x, y) \quad (10)$$

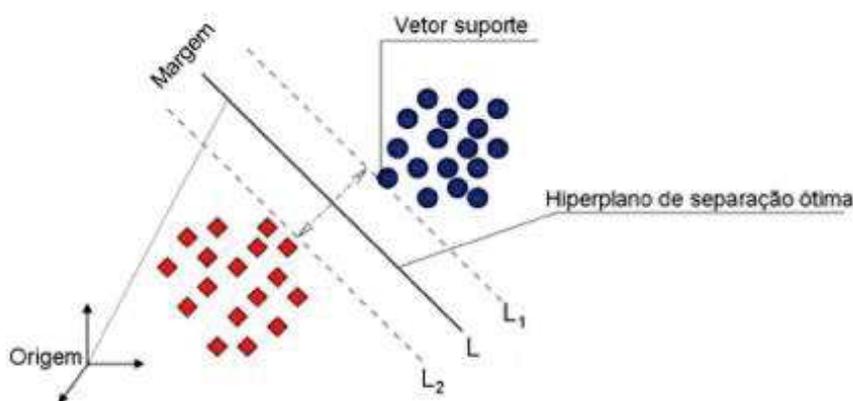
A distribuição de probabilidade  $P(x, y)$  não é conhecida (como discutido acima) não sendo possível então computar esta Equação. Por outro lado, o risco empírico,  $\varepsilon_\psi(\zeta)$ , definido como a média da taxa de erro nos elementos do conjunto de treinamento pode ser definido como:

$$\varepsilon_\psi(\zeta) = \frac{1}{2D} \sum_{i=1}^D |y - f(x_i, \zeta)| \quad (11)$$

onde  $\varepsilon_\psi(\zeta)$  é fixo para um  $\zeta$  arbitrário e um conjunto de treinamento  $\{x_i, y_i\}$ .

A separação ótima entre classes ocorre por meio de um hiperplano condicional  $L$ , conforme Figura 9, tal que este plano é orientado para maximizar a margem (distância entre as bordas,  $L_1$  e  $L_2$ ), e pelo ponto mais próximo de cada classe.

Figura 9 - Esquema de classificação por meio do SVM.



Fonte: Nascimento, 2009. Modificado de Huang et al. (2002) e Melgani e Bruzzone (2004).

O SVM possui quatro funções, sendo elas (i) linear, (ii) quadrática, (iii) polinomial e (iv) função de base radial (NASCIMENTO et. al, 2009). Neste trabalho utilizou-se a função de polinomial (FP).

## 4 METODOLOGIA

### 4.1 Base de dados

Conforme abordado na parte introdutória, os eventos foram gerados seguindo os padrões estabelecidos pelo *Institute of Electrical and Electronics Engineers* (IEEE Std 1159-2009). Para tal, definiu-se uma frequência fundamental ou nominal  $f_n = 60 \text{ Hz}$  e um valor máximo harmônico  $h_{max} = 1$ . A frequência de amostragem ( $f_s$ ) foi calculada a partir da Equação (12):

$$f_s = f_n \cdot NPC \quad (12)$$

onde  $NPC$  é número de pontos por ciclo.

Para este trabalho definiu-se um valor de  $NPC = 256 \text{ pontos por ciclo}$ . Logo, aplicando os valores na Equação (12), obtém-se a frequência de amostragem  $f_s = 15360 \text{ Hz}$ . De acordo com Nyquist (2002), esse valor definido para a taxa de amostragem é suficiente para caracterizar a maior parte dos distúrbios presentes nos Sistemas Elétricos de Potência.

Quando se trata de eventos que envolvem o processamento de dados, é de fundamental importância conhecer as especificações técnicas da máquina utilizada. Sendo assim, segue as especificações técnicas do computador prático utilizado:

- **Modelo:** MacBook Air, 13 polegadas, 2017. Apple;
- **Sistema operacional:** macOS;
- **Processador:** Intel Core i5 de dois núcleos e 1,8 GHz (Turbo Boost de até 2,9 GHz) com cache L3 compartilhado de 3 MB;
- **Armazenamento:** SSD PCIe de 128 GB;
- **Chip gráfico:** Intel HD Graphics 6000.

As informações foram geradas através do *software Matlab* (versão R2019b – estudante). Os sinais sintéticos gerados foram acometidos por ruídos brancos gaussianos com média nula. Na definição, os ruídos brancos são definidos de modo a atender os níveis de sinais ruídos previamente definidos. Portanto, para o cálculo da relação sinal ruído, utilizou-se a Equação (13):

$$SNR = 20 \log \frac{A}{\sqrt{2}\sigma} [dB] \quad (13)$$

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

Neste trabalho, foram consideradas as seguintes relações sinais ruídos (SNR): 10 dB, 30 dB, 50 dB e 70 dB, e teve por objetivo investigar o comportamento do modelo híbrido proposto com a presença de altos níveis de ruído no sinal a ser processado. Na prática, sinais de tensão medidos nos sistemas elétricos possuem relação sinal- ruído entre 50dB e 70dB (TOMIC; KUSLJEVIC; VUJICIC, 2007). Pela definição, quanto menor for a relação sinal-ruído, maior será a potência do ruído presente no sinal e mais difícil é a extração de características. Durante o trabalho, foram geradas 1200 amostras para cada valor de relação sinal-ruído, sendo 400 para cada classe (sinal normal, interrupção curta e afundamento de tensão). Para tal, foi necessário atribuir um número total de pontos de pontos ( $N_{pt}$ ) que é dado através da Equação (14):

$$N_{pt} = NPC \cdot NC \quad (14)$$

onde  $NC$  é o número de ciclos da rotina. No caso do projeto, considerou-se  $NC = 10$ .

Aplicando os valores na Equação (14), obtém-se  $N_{pt} = 2560$  pontos. As características de cada evento, como frequência, amplitude, fase foram atribuídas de maneira aleatória em intervalos com distribuição uniforme. Importante destacar, que visando trabalhar com valores em uma base específica, normalizou-se as amplitudes para o sistema por unidade [pu], ou seja, a tensão de pico para um evento de sinal normal possui um valor unitário. Os valores de fase foram estabelecidos de maneira aleatória, dentro do intervalo estabelecido  $[-\pi; \pi]$  e possuem distribuição uniforme.

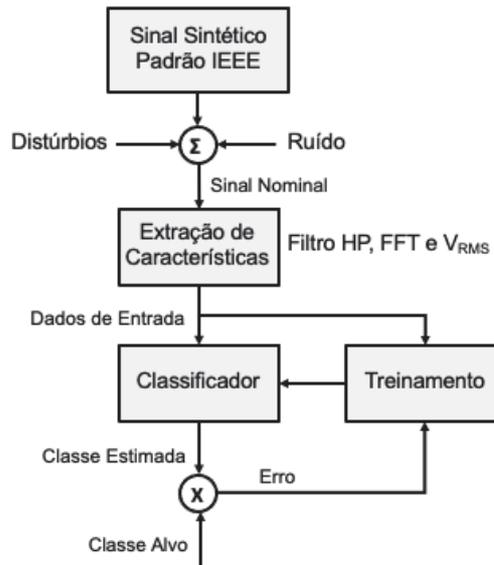
## 4.2 Sistema de reconhecimento de padrões

Conforme o item (2.3), o reconhecimento de padrões, tem por objetivo classificar objetos em um número de categorias ou classes. No caso em específico do trabalho, o objetivo da classificação é diferenciar os eventos de afundamento de tensão (*voltage sag*), dos de sinal normal e interrupção de curta duração. Para a extração das características dos eventos gerados, utilizou-se de ferramentas estratégicas, tais como: filtro Hodrick-Prescott, transformada rápida de Fourier (FFT) e a raiz do valor quadrático médio eficaz ( $V_{RMS}$ ).

O modelo de monitoramento proposto de detecção e classificação pode ser resumido e exemplificado através do fluxograma exibido na Figura 10. O vetor a ser processado pelo classificador é chamado de “Dados de Entrada” resultante do pré-processamento do sinal sintético acrescido de distúrbio e ruído (Sinal Nominal). Após gerar os dados, utilizou-se de um

algoritmo denominado “Embaralha dados”, e que tem por objetivo distribuir de maneira aleatória os três eventos gerados para cada relação de sinal-ruído. Isso se faz necessário, para que no processo de treinamento os classificadores não “decorem” em sequência as características dos sinais gerados. Posteriormente, os dados foram normalizados.

Figura 10 - Modelo de monitoramento proposto.

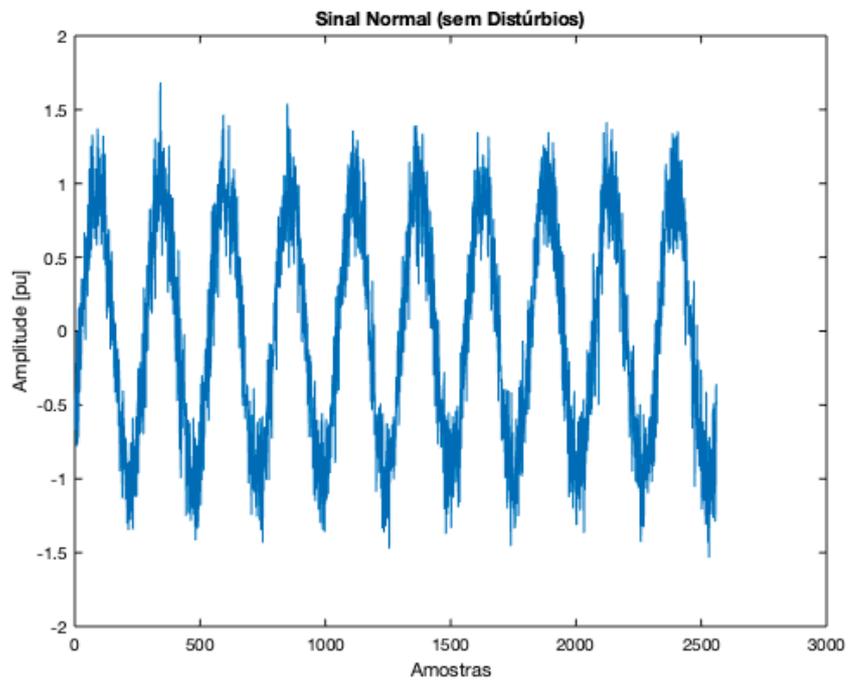


Fonte: Do autor (2021).

### 4.3 Aplicação do filtro HP

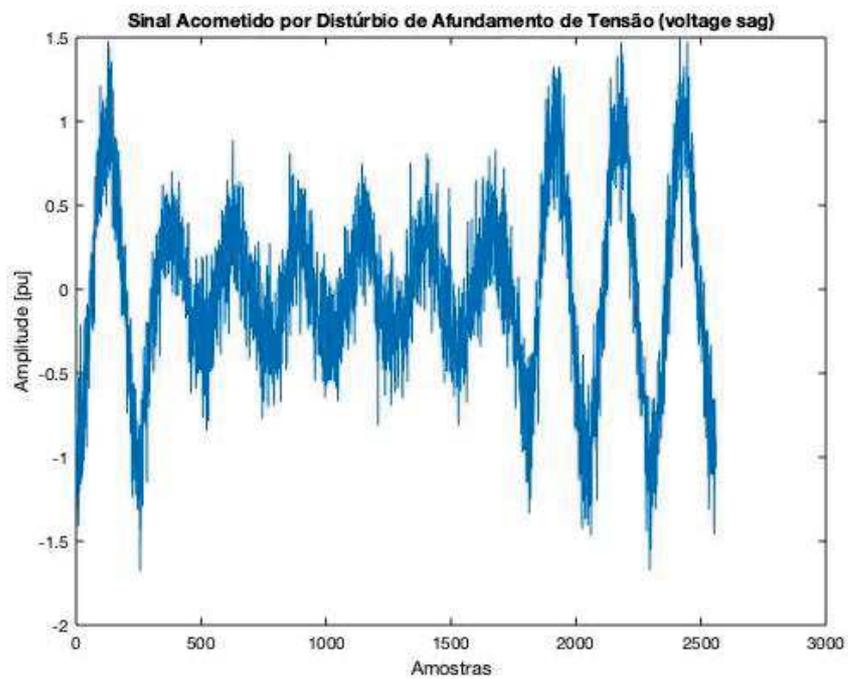
As Figuras 11, 12 e 13 exibem dois sinais elétricos típicos gerados a partir de um determinado evento com frequência fundamental ou nominal  $f_n = 60 \text{ Hz}$ , amplitude de 1 pu e relação de sinal-ruído de 10 dB, visando enfatizar o conceito SNR abordado na seção 4.1. No entanto, os sinais foram acometidos por distúrbios de afundamento de tensão (*voltage sag*) e interrupção de curta duração, respectivamente, e conforme definido na parte introdutória.

Figura 11 – Sinal Normal (sem Distúrbios).



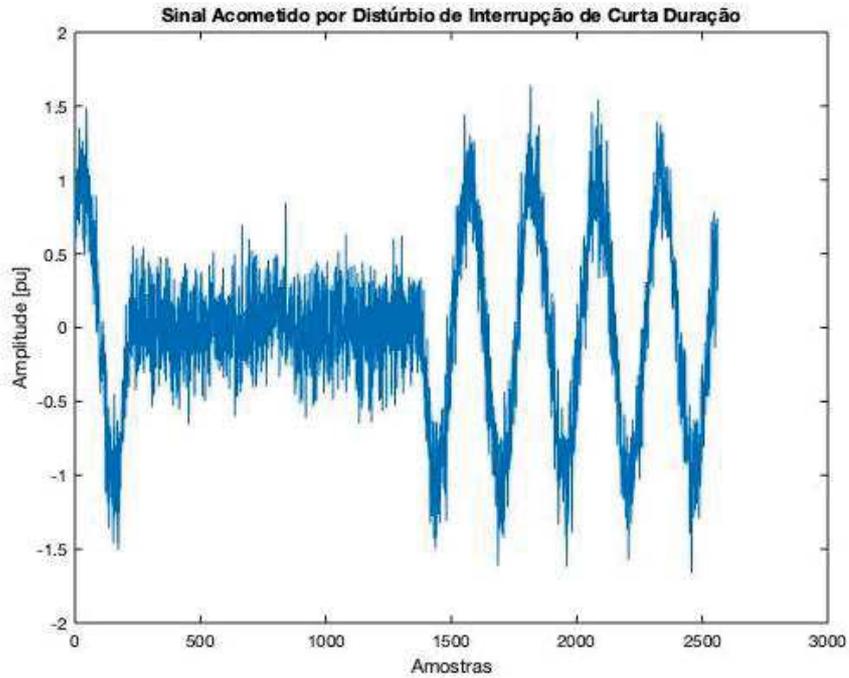
Fonte: Do autor (2021).

Figura 12 - Sinal acometido por distúrbios de afundamento de tensão.



Fonte: Do autor (2021).

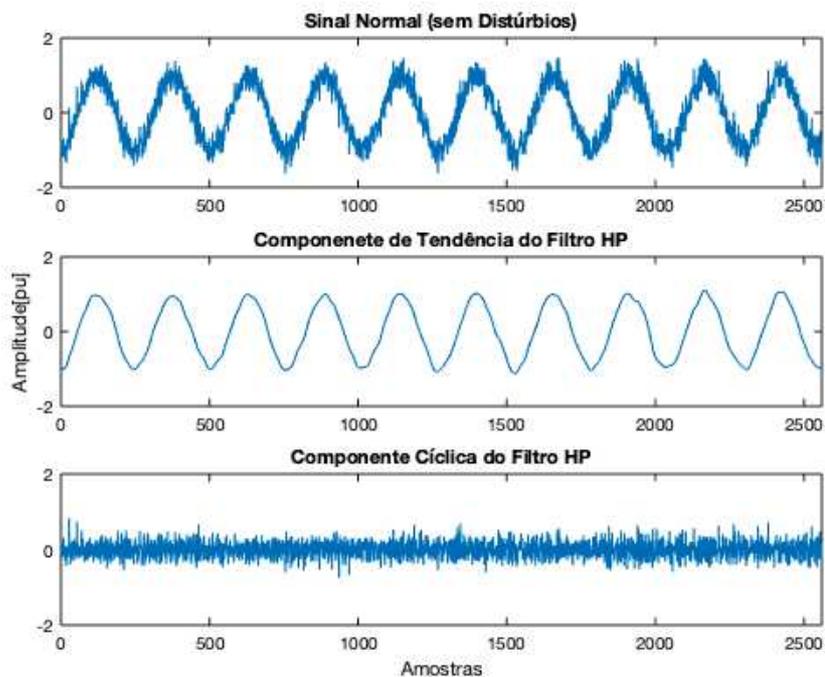
Figura 13 – Sinal acometido por distúrbios de interrupção curta.



Fonte: Do autor (2021).

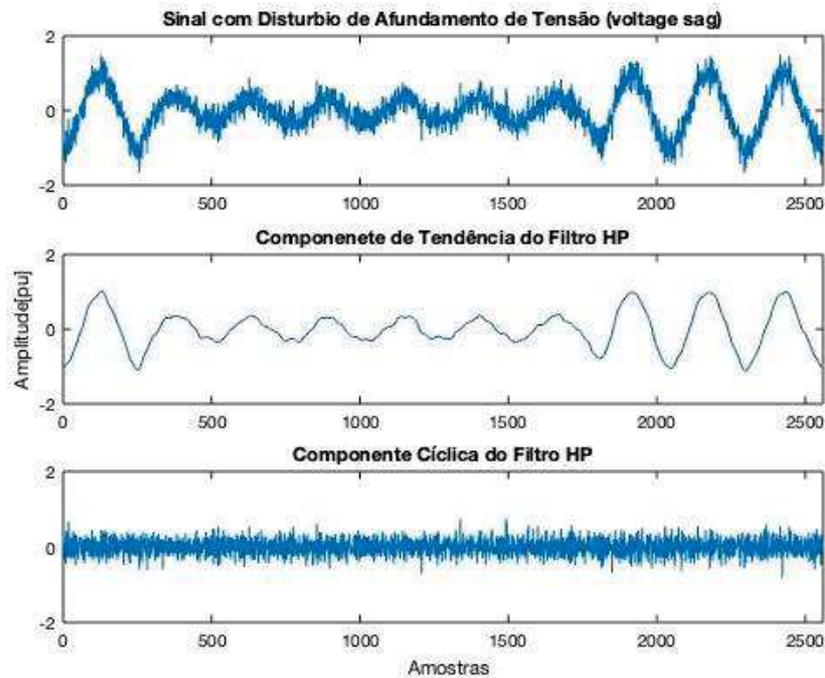
O filtro de Hodrick-Prescott se aplica aos três eventos envolvidos na classificação. Para tal, o filtro HP decompõe os sinais nominais em suas componentes de tendência e cíclica, conforme Figuras 14, 15 e 16.

Figura 14 – Filtro HP aplicado ao sinal normal (sem distúrbios).



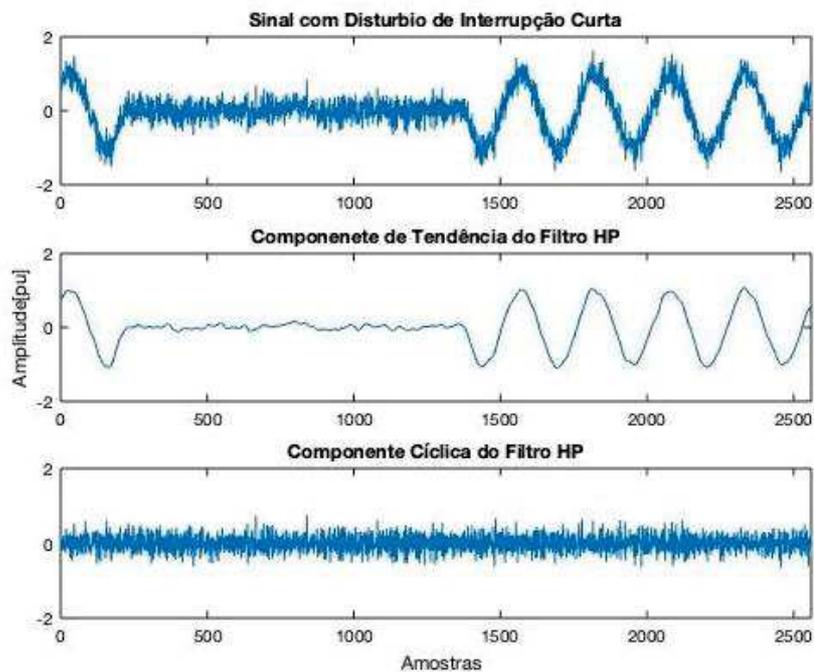
Fonte: Do autor (2021).

Figura 15 – Filtro HP aplicado ao distúrbio de afundamento de tensão.



Fonte: Do autor (2021).

Figura 16 – Filtro HP aplicado ao distúrbio de interrupção de curta duração.



Fonte: Do autor (2021).

Percebe-se através das Figuras 11, 12 e 13, elevados níveis de ruídos nos sinais gerados e a presença dos distúrbios de afundamentos de tensão e interrupção de curta duração, Figuras 10 e 11, previamente esperados. Nota-se também, por meio das Figuras 14, 15 e 16, que a componente de tendência apresentou o sinal de frequência fundamental em 60 Hz sem ruído. É

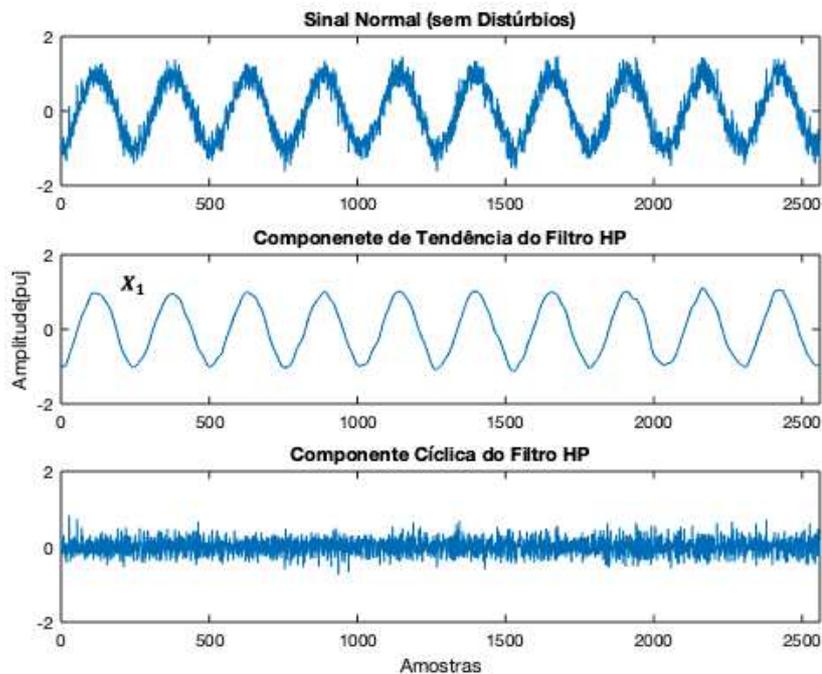
importante destacar que se utilizou de dois distúrbios diferentes para demonstrar e comparar o uso do filtro HP, levando em consideração em ambos os casos, as mesmas condições de relação sinal-ruído e amplitude.

Conforme abordado anteriormente na seção 4.1, verificou-se e comprovou-se que com uma baixa relação sinal-ruído, obtém-se elevados níveis de potência do ruído presente no sinal, dificultando a extração de características. Verificou-se também uma grande similaridade entre eventos gerados, principalmente na componente cíclica do filtro HP.

#### 4.4 Aplicação do valor eficaz

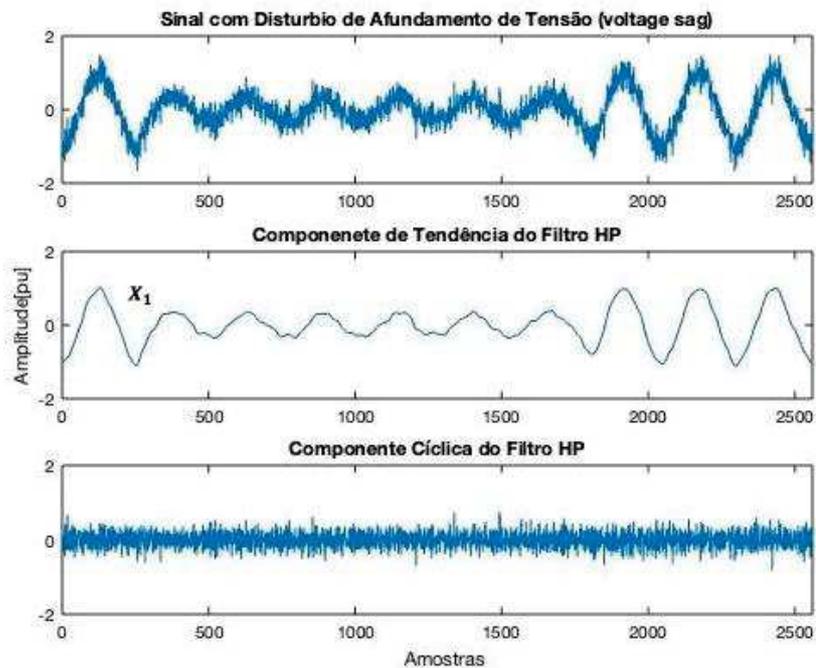
Neste trabalho, utilizou-se dos valores eficazes do sinal nominal ( $V_{RMS}$ ), da componente de tendência do filtro HP como parâmetro de análise do detector/classificador proposto. Sendo assim, definiu-se o primeiro parâmetro do vetor de entrada:  $X_1$ : valor eficaz da componente de tendência do filtro HP. A Figura 17 exibe a aplicação do valor eficaz para o sinal normal. É importante destacar que para sinais com variação da amplitude (afundamento de tensão e interrupção de curta duração), abordados neste trabalho, o valor eficaz da tensão se altera, conforme observado nas Figuras 18 e 19, justificando-se, assim, sua aplicação.

Figura 17 - Valor eficaz aplicado ao sinal normal.



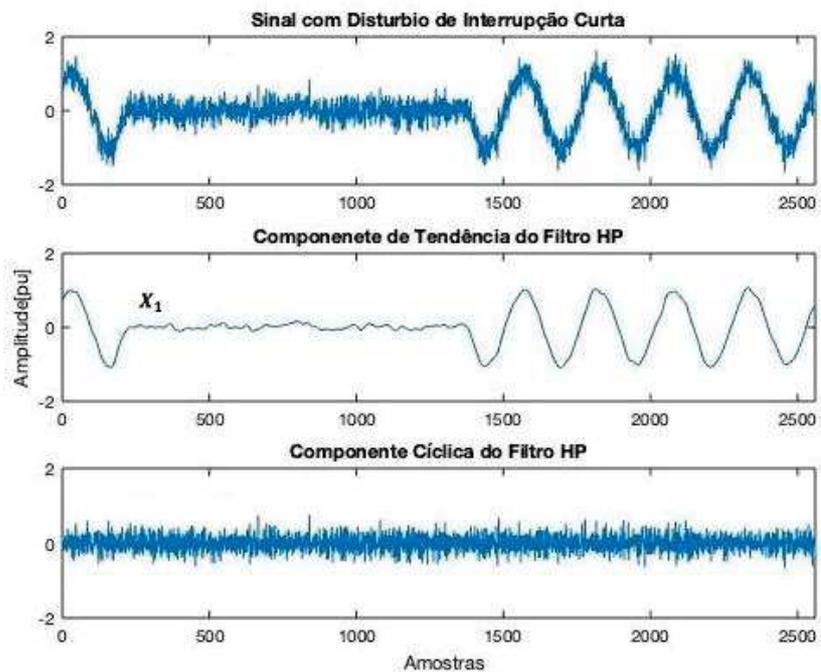
Fonte: Do autor (2021).

Figura 18 - Valor eficaz aplicado ao distúrbio de afundamento de tensão.



Fonte: Do autor (2021).

Figura 19 - Valor eficaz aplicado ao distúrbio de interrupção de curta duração.

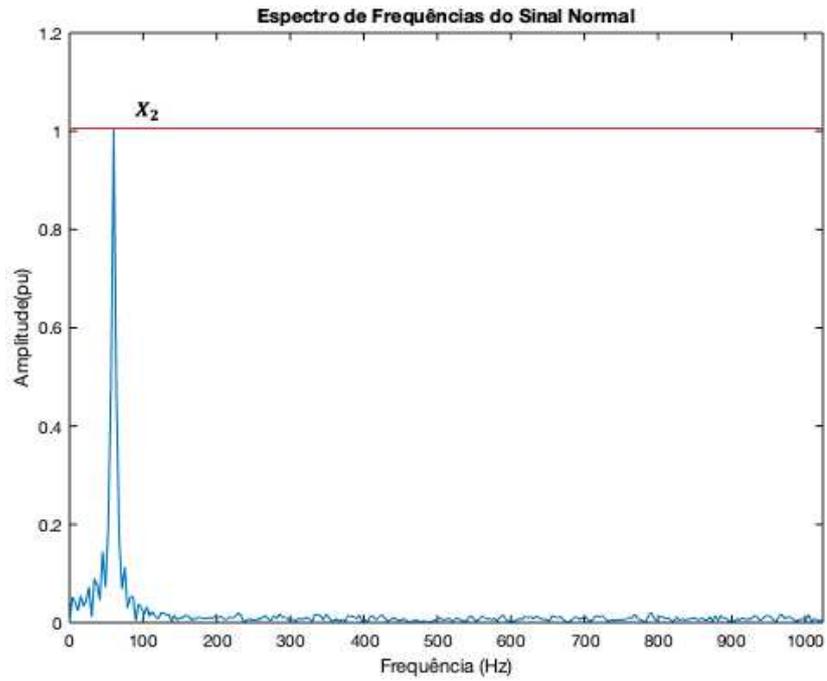


Fonte: Do autor (2021).

#### 4.5 Aplicação da transformada rápida de Fourier

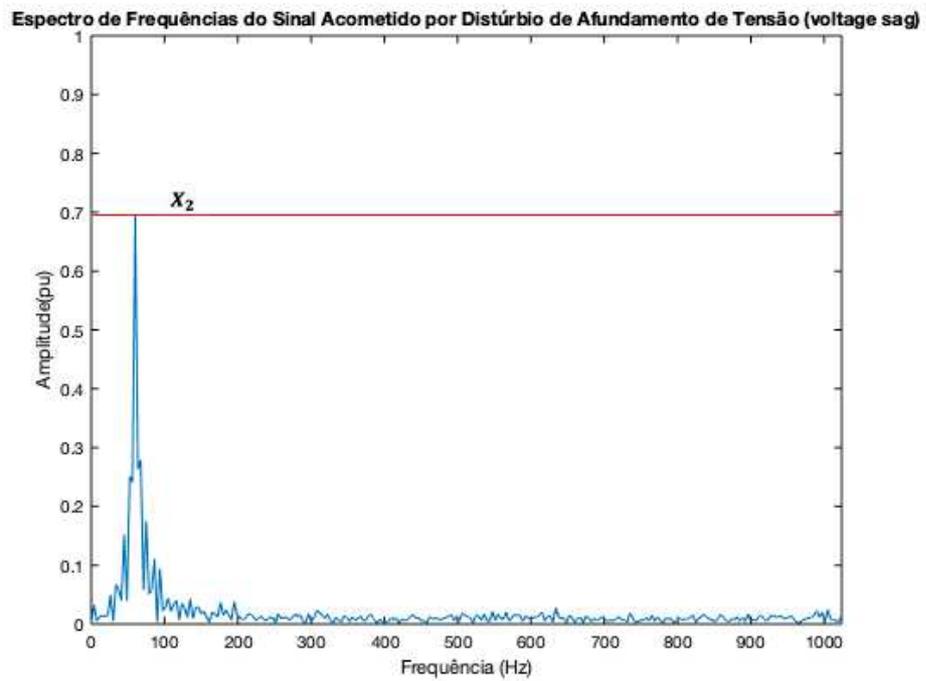
Por fim, a transformada rápida de Fourier (FFT) foi utilizada para extrair o valor máximo da componente fundamental do sinal nominal, Figuras 20, 21 e 22, sendo o segundo ( $X_2$ ) parâmetro do vetor de entrada.

Figura 20 – Transformada rápida de Fourier para o sinal normal.



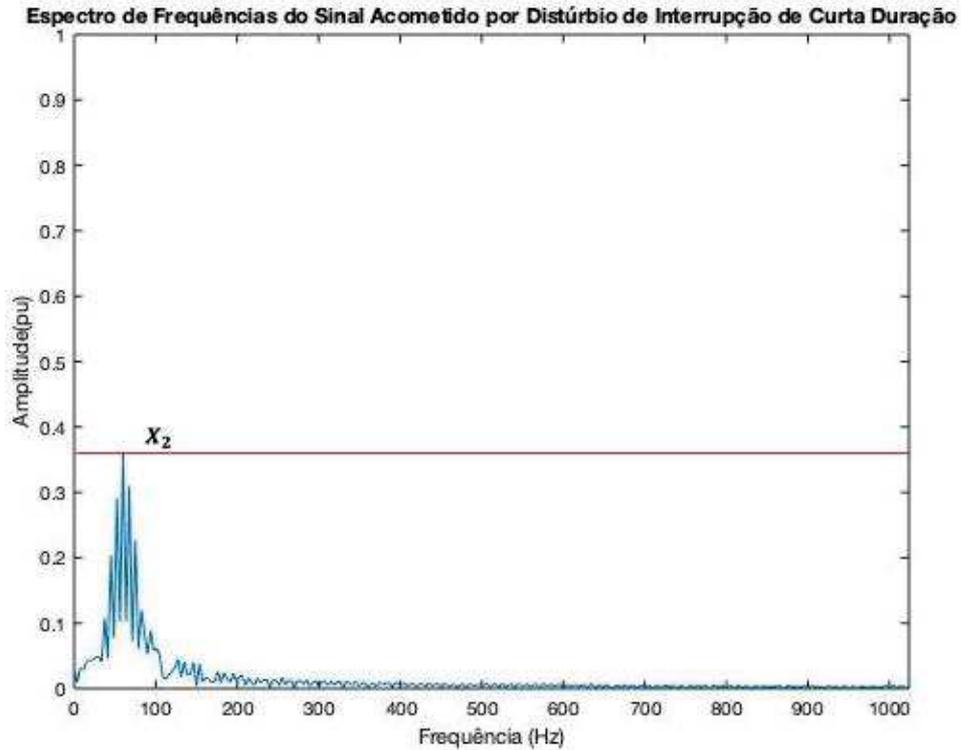
Fonte: Do autor (2021).

Figura 21 – Transformada rápida de Fourier para o distúrbio de afundamento de tensão.



Fonte: Do autor (2021).

Figura 22 – Transformada rápida de Fourier para o distúrbio de interrupção de curta duração.



Fonte: Do autor (2021).

Percebe-se que o valor máximo da componente fundamental do sinal normal, afundamento de tensão e da interrupção são dissemelhantes. Desta forma, consegue-se extrair características diferentes para os distúrbios analisados.

## 5 RESULTADOS E DISCUSSÕES

Nesta seção, será apresentado o método de avaliação do modelo híbrido de detecção e classificação proposto, além da exibição da matriz de confusão de todos os modelos considerados. O sistema é do tipo *offline* e os classificadores foram implementados através do *software* livre *NeuCom Student v0.919* (KASABOV, 2002).

### 5.1 Classificação de distúrbios

Partindo do pressuposto, que há conhecimento a priori dos dados a serem analisados, definiu-se as seguintes classes:

- **Classe 1:** sinal normal;
- **Classe 2:** interrupção de curta duração;
- **Classe 3:** afundamento de tensão.

O índice de desempenho dos classificadores utilizados utilizado para avaliar o modelo proposto é dado pela Equação (14):

$$Acc = \frac{VP + VN}{VP + VN + FP + FN} \cdot 100\% \quad (14)$$

onde,  $Acc$  é a acurácia;  $VP$  e  $VN$  são os verdadeiros positivos e verdadeiros negativos, respectivamente;  $FP$  e  $FN$  são os falsos positivos e falsos negativos, respectivamente.

Para o modelo de classificador Neural (MLP), considerou-se dois parâmetros de entrada ( $X_1, X_2$ ), seis neurônios na camada oculta, três neurônios na camada saída e trezentas épocas de treinamento. Para o outro modelo classificador (SVM), considerou-se um polinômio de grau 3. A Tabela 1 apresenta o desempenho do classificador neural utilizado (MLP) para as classes consideradas em função da relação sinal-ruído, mostrando a acurácia, o tempo computacional requerido em segundos. Por outro lado, a Tabela 2 exhibe os resultados para o outro classificador utilizado (SVM).

**Tabela 1** - Desempenho de classificação e tempo computacional requerido (classificador MLP).

| Base de Dados    | SNR (dB) | Acurácia (%) | Tempo (s) |
|------------------|----------|--------------|-----------|
| Classes 1, 2 e 3 | 70       | 99,00        | 3,25      |
|                  | 50       | 99,42        | 3,33      |
|                  | 30       | 99,25        | 3,41      |
|                  | 10       | 99,00        | 3,55      |

Fonte: Do autor.

**Tabela 2** - Desempenho de classificação e tempo computacional requerido (classificador SVM).

| Base de Dados    | SNR (dB) | Acurácia (%) | Tempo (s) |
|------------------|----------|--------------|-----------|
| Classes 1, 2 e 3 | 70       | 98,75        | 9,23      |
|                  | 50       | 99,17        | 9,21      |
|                  | 30       | 99,08        | 10,60     |
|                  | 10       | 98,17        | 9,52      |

Fonte: Do autor.

Comparando-se os resultados obtidos nas Tabelas 1 e 2, percebe-se que ambos os classificadores conseguiram atingir excelentes níveis de acurácia independente da relação sinal-ruído, no entanto, o modelo SVM exigiu um tempo de processamento maior, se comparado, ao modelo neural MLP. Desta forma evidencia-se a eficácia dos métodos utilizados para extração

de atributos (ou características) na etapa de pré-processamento do sistema de reconhecimento de padrões.

## 5.2 Matriz de confusão

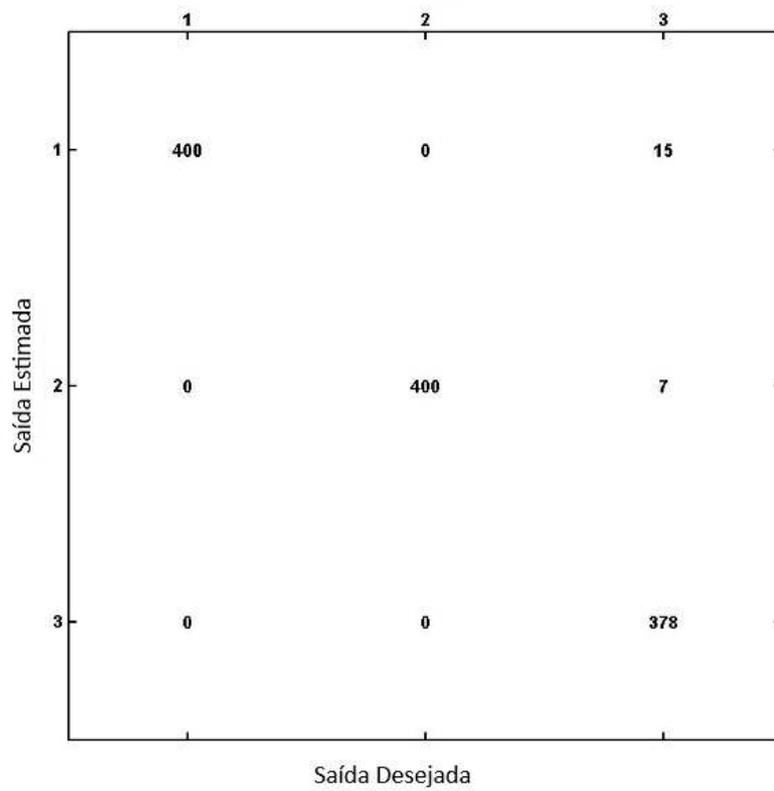
A matriz de confusão apresenta uma maneira de avaliar o modelo de classificação, ao mostrar o número de classificações corretas versus as classificações incorretas para cada classe, sobre um conjunto de  $N$  de exemplo. O nome origina do fato de que ela torna mais fácil visualizar como o sistema está confundindo as classes. Cada coluna da matriz representa as amostras de uma classe previamente definida, enquanto as linhas representam os casos de uma classe estimada pelo modelo. As entradas da matriz são representadas por  $M(C_i, C_j)$ , indicando o número de exemplos  $N$  que são da classe  $C_i$ , mas que foram classificados pela hipótese  $h$  como sendo da classe  $C_j$ , conforme a Equação (15).

$$M(C_i, C_j) = \sum_{\{x,y\} \in N: y=C_i} |h(x) = C_j| \quad (15)$$

De acordo com Tan et. al. (2006), o número de acertos, para cada classe, localiza-se na diagonal principal  $M(C_i, C_i)$  da matriz; os demais elementos  $M(C_i, C_j)$ , para  $i \neq j$ , representam erros na classificação. A matriz de confusão de um classificador ideal possui todos os elementos fora da diagonal iguais a zero uma vez que ele não comete erros. A matriz de confusão possibilita analisar a porcentagem de assiduidade das diversas amostras associadas a uma classe, assim como permite o entendimento e a quantificação das amostras classificadas de forma errada

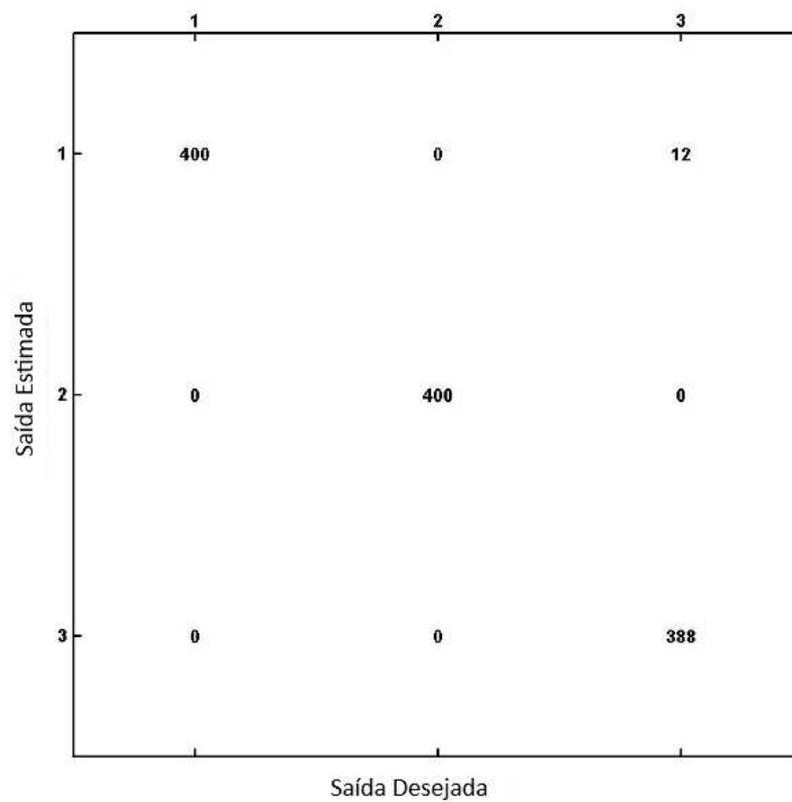
A seguir são apresentadas as matrizes de confusão considerando a relação sinal-ruído em 10 dB, caso mais desafiador, para os modelos classificadores SVM E MLP. Nota-se pela Figura 23 que ocorreu a confusão de classificação somente em uma das três classes de distúrbio. Para o afundamento de tensão 15 eventos foram classificados como sinal normal (classe 1) e 7 eventos foram classificados como o distúrbio de interrupção de curta duração (classe 2). Por outro lado, através da Figura 24, nota-se também que a confusão de classificação ocorreu em somente em uma das três classes de distúrbio. Para o afundamento de tensão 12 eventos foram classificados como sinal normal (classe 1).

Figura 23 - Matriz de confusão para o classificador SVM.



Fonte: Do autor (2021).

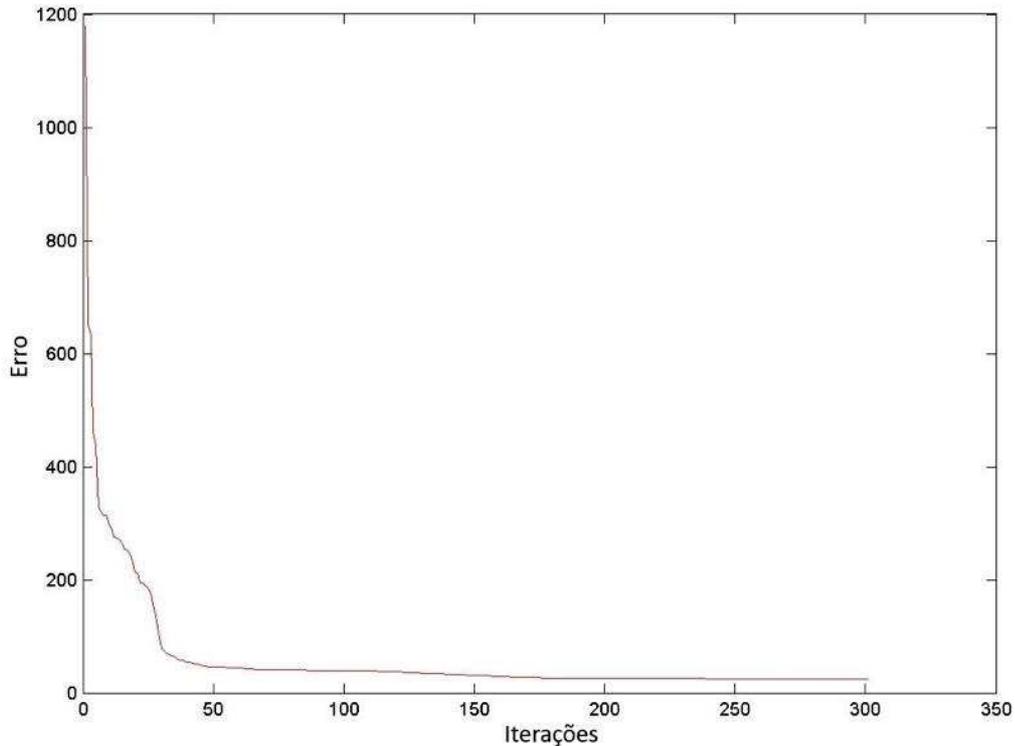
Figura 24 - Matriz de confusão para o classificador MLP.



Fonte: Do autor (2021).

Já a Figura 25, exibe a taxa de aprendizagem do classificador MLP. A taxa de aprendizagem indica a que ritmo os pesos são atualizados. Isso pode ser fixado ou alterado de modo adaptativo. Observe que à medida que o número de iterações aumenta, diminui-se o erro.

Figura 25 – Taxa de aprendizagem do classificador MLP.



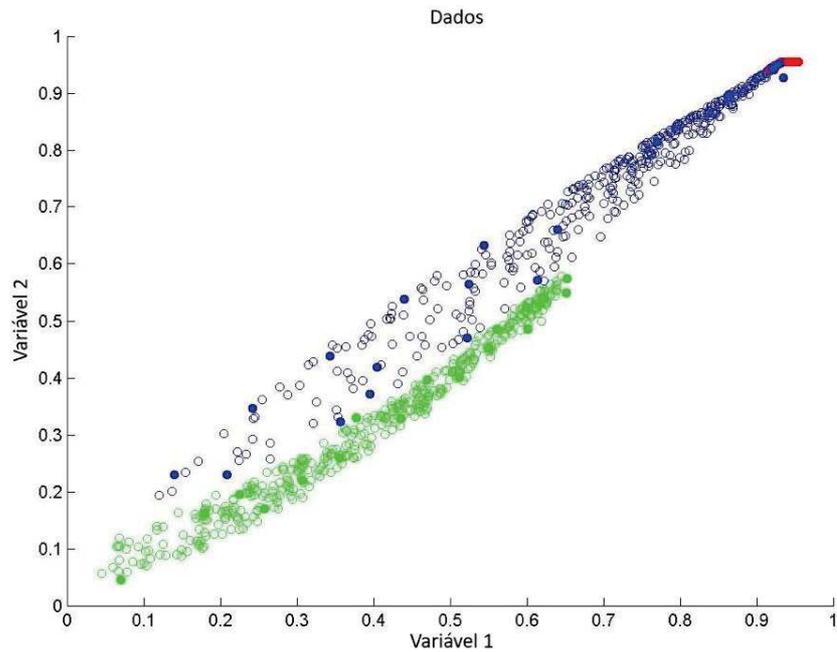
Fonte: Do autor (2021).

Observa-se também, pelas Figuras 23 e 24, que ambos os classificadores acertaram todos os eventos correspondentes as classes 1 e 2. No entanto, tiveram dificuldades para detectar e classificar os eventos da classe 3, os afundamentos de tensão. Este fato pode ser explicado através dos dados plotados dada a mesma SNR, conforme Figura 26.

onde:

- vermelho: classe 1: sinal normal;
- verde: classe 2: interrupção de curta duração;
- azul: classe 3: afundamento de tensão.

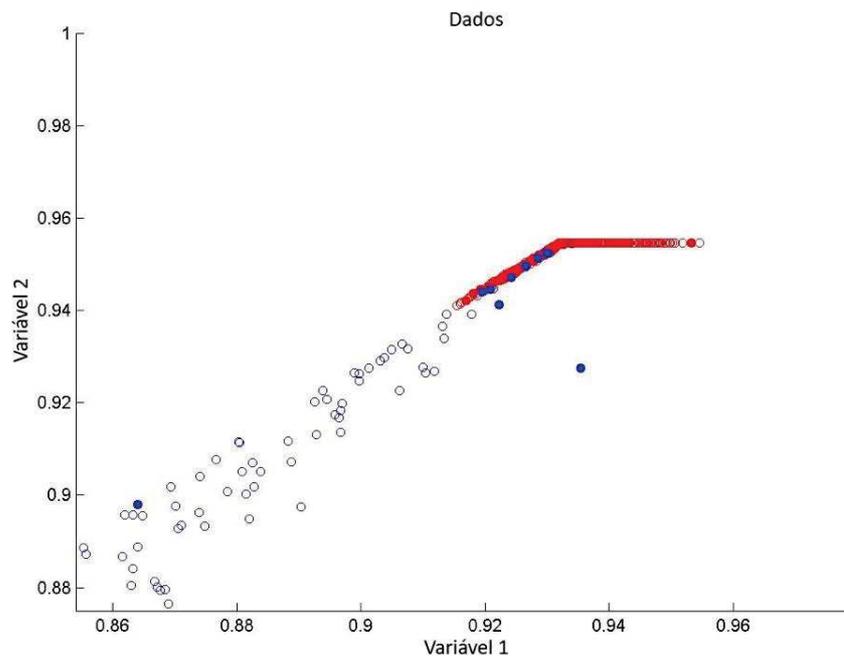
Figura 26 – Distribuição dos eventos.



Fonte: Do autor (2021).

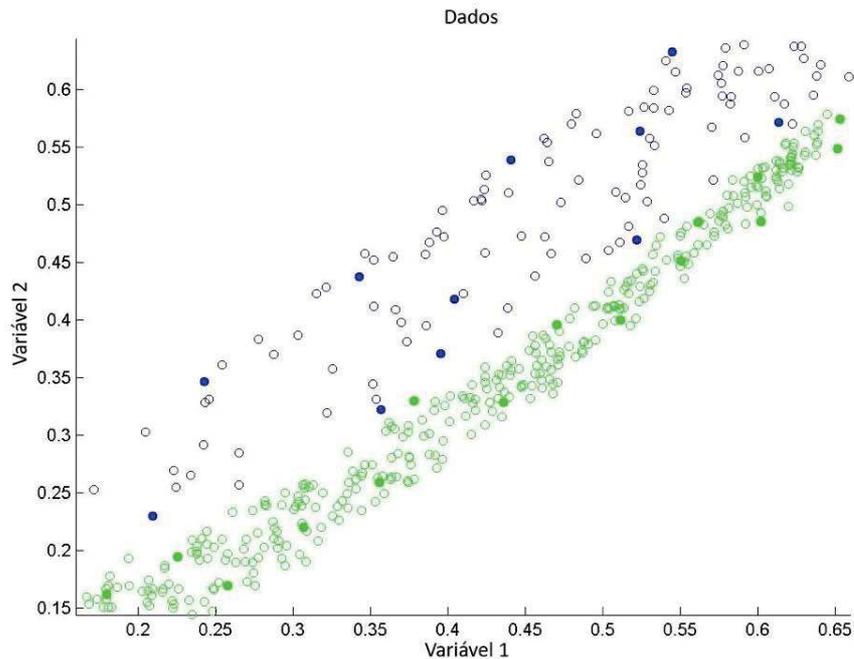
Ampliando a imagem, percebe-se que os afundamentos de tensão estão sendo majoritariamente confundidos com sinais normais, mas também com eventos de interrupção de curta duração, conforme pode ser visto nas Figuras 27 e 28. Observa-se na Figura 27 que há interseções entre as duas classes (sinal normal e afundamento de tensão) e por isso ocorre o erro de classificação.

Figura 27 – Sinal normal e afundamento de tensão.



Fonte: Do autor (2021).

Figura 28 – Interrupção de curta duração e afundamento de tensão.



Fonte: Do autor (2021).

Nota-se pela Figura 28 que existe separação entre as classes 2 e 3, no entanto, é desafiador para os classificadores encontrarem os limites de cada classe. Conforme apresentado nas matrizes de confusão, a rede neural conseguiu encontrar melhor que o SVM os limites entre estas duas classes.

## 6 CONCLUSÃO

Modelos híbridos que utilizam técnicas de reconhecimento de padrões se mostraram bastante eficientes para classificar problemas que envolvem processamento de dados. Neste contexto, este trabalho propôs dois tipos de sistemas MLP e SVM para a detecção de distúrbios de afundamento de tensão. Para extração de características foi considerado um método híbrido composto pelo filtro de Hodrick-Prescott, transformada rápida de Fourier e raiz do valor quadrático médio.

A abordagem proposta, mostrou-se eficiente para a classificação *offline*, mesmo considerando uma baixa relação sinal-ruído. Ambos modelos obtiveram bons níveis de acurácia para todas relações sinal-ruído, no entanto, o classificador neural se mostrou mais eficiente em relação ao tempo de processamento dos dados.

Para trabalhos futuros pretende-se aplicar e avaliar os modelos propostos na detecção de outros tipos de distúrbios, tais como: elevação de tensão, transitórios, harmônicos, dentre outros. Pretende-se considerar também um menor número de ciclos de senoides por janela para a extração de variáveis, a fim de apurar a robustez do método híbrido de seleção de características, pois quanto menor for esse número, mais complexa se torna esta seleção. Essa nova metodologia, levará à necessidade de empregar métodos de aprendizado não supervisionados mais recentes e utilização de novas técnicas de extração de características.

## REFERÊNCIAS

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.

BALOUJI, E.; SALOR, O. **Digital realisation of the IEC flickermeter using root mean square of the voltage waveform**. IET Generation, Transmission & Distribution, v. 10, n. 7, p. 1663-1670, 2016.

BONIFÁCIO, F. N. **Comparação entre as redes neurais artificiais MLP, RBF e LVQ na classificação de dados**. Paraná: Universidade Estadual do Oeste do Paraná, 2010.

BRAGA, A., CARVALHO, A., LUDERMIR, T. **Redes Neurais Artificiais: Teoria e Aplicações**, Livro Técnico e Científico, Rio de Janeiro, 2000.

CSPE. **Qualidade do Fornecimento de Energia Elétrica - Indicadores, Padrões e Penalidades**. Documento Preliminar para Discussão. Versão 2, Jul. 1997.

CULLOCH, W. S; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. Bulletin of Mathematical Biophysics, vol. 5, p. 115 –133, 1943.

CYBENKO, G. **Continuous valued neural networks with two hidden layers are sufficient**. Technical report, Department of Computer Science, Tufts University, 1988.

CYBENKO, G. **Approximation by superpositions of a sigmoid function**. *Mathematics of Control, Signals and Systems*, 2:303-314, 1989.

DE BRITO, Rhyann; DE OLIVEIRA, Adonias. **Análise de Características a Partir do Classificador MLP Para Auxílio no Diagnóstico da COVID-19**. In: Anais da VIII Escola Regional de Computação do Ceará, Maranhão e Piauí. SBC, 2020. p. 89-95.

DECKMANN, Sigmar Maurer; POMILIO, José Antenor. **Avaliação da qualidade da energia elétrica**, Campinas, 2020.

DUGAN, R. C. et al. **Electrical power systems quality**. 2. ed. New York: McGraw-Hill, 2003. 521 p.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. Prentice Hall, 2nd edition, 1999.

HERTZ, J. A.; PALMER, R.G.; KROUGH, A. **Introduction to the Theory of Neural Computation**. Westview, 1st edition, 1998.

HERTZ, J. A.; PALMER, R.G.; KROUGH, A. **Introduction to the Theory of Neural Computation**. Lecture Notes Volume I of Santa Fe Institute Studies in The Science of Complexity. Addison-Wesley, 1991.

HUANG, Chengquan; DAVIS, L. S.; TOWNSHEND, J. R. G. **An assessment of support vector machines for land cover classification**. International Journal of remote sensing, v. 23, n. 4, p. 725-749, 2002.

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

LATHI, B. **Linear systems and signals**. ISBN 13, 554625343, 2006.

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.

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

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

MELGANI, Farid; BRUZZONE, Lorenzo. **Classification of hyperspectral remote sensing images with support vector machines**. *IEEE Transactions on geoscience and remote sensing*, v. 42, n. 8, p. 1778-1790, 2004.

NAGATA, E. A. (2018). **Detecção, Segmentação e Classificação de Afundamentos de Tensão em Sistemas Elétricos de Potência**. 89p. Dissertação (Mestrado em Engenharia de Sistemas e Automação) – U. Federal de Lavras.

NASCIMENTO, R. F. F. et al. **O algoritmo Support Vector Machines (SVM): avaliação da separação ótima de classes em imagens CCD-CBERS-2**. *Simpósio Brasileiro de Sensoriamento Remoto*, v. 14, p. 2079-2086, 2009.

NYQUIST, H. **Certain topics in telegraph transmission theory**. *Proceedings of the IEEE*, v. 90, n. 2, p. 280- 305, 2002.

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

Operador Nacional do Sistema Elétrico – ONS. **Padrões de Desempenho da Rede Básica – Submódulo 2.2**, versão aprovada pelo Conselho Administrativo em outubro de 2000.

**Power Quality in European Electricity Supply Networks - 1 st Edition**, Union of the Electricity Industry – Eurelectric, Feb. 2004.

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

RIBEIRO, P.F. **Qualidade de Energia Elétrica em Sistemas Elétricos**. Workshop no SBQEE - Seminário Brasileiro de Qualidade de Energia Elétrica, Uberlândia, Jun. 1996.

SANTANA, M. (2017). **Agrupamento Incremental de Fluxo de Dados para Análise e Monitoramento da Qualidade de Energia**. 98p. Dissertação (Mestrado em Engenharia de Sistemas e Automação) – U. Federal de Lavras.

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

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

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

TOMIC, J.; KUSLJEVIC, M.; VUJICIC, V. **A new power system digital harmonic analyzer**. IEEE Transactions on Power Delivery, New York, v. 22, n. 2, p. 772–780, Apr. 2007.

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

VAPNIK, V. **The Nature of Statistical Learning Theory**. New York: Springer-Verlag, 1995.

VIEIRA, Vinicius J. D. et al. **Avaliação de Desempenho na Classificação de Patologias Laríngeas por Análise LPC de Sinais de Voz e Redes Neurais MLP**. In: **Anais do XIII Congresso Brasileiro de Inteligência Computacional**. 2013.

WANG, Sun-Chong. Artificial neural network. In: **Interdisciplinary computing in java programming**. Springer, Boston, MA, 2003. p. 81-100.





**RELATÓRIO FINAL DE CURSO Nº 20/2025 - CEENP (11.51.21)**

**(Nº do Protocolo: NÃO PROTOCOLADO)**

**(Assinado digitalmente em 10/04/2025 15:16)**

MARCIO WLADIMIR SANTANA  
PROFESSOR ENS BASICO TECN TECNOLOGICO  
CTETTNP (11.50.36)  
Matricula: ###520#9

Visualize o documento original em <https://sig.cefetmg.br/documentos/> informando seu número: 20, ano: 2025, tipo:  
**RELATÓRIO FINAL DE CURSO**, data de emissão: 10/04/2025 e o código de verificação: 0757094282