

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS**  
ESCOLA POLITÉCNICA E DE ARTES / ENGENHARIA ELÉTRICA /  
ENGENHARIA DE CONTROLE E AUTOMAÇÃO  
Trabalho Final de Curso II

**Matheus Felipe da Silva Mariano**  
**Victor Pinheiro Borges**

REDES NEURAIIS APLICADAS NA CLASSIFICAÇÃO  
DE DISTÚRBIOS DA REDE ELÉTRICA

Trabalho Final de Curso II como parte dos requisitos para  
obtenção do título de bacharel em Engenharia de  
Controle e Automação e Engenharia Elétrica,  
apresentado à Pontifícia Universidade Católica de Goiás.

**BANCA EXAMINADORA:**

Prof. Dr. Marcos Antônio de Sousa – Orientador. POLI-PUC Goiás.  
Prof. Dr. Bruno Quirino de Oliveira – Examinador. POLI-PUC Goiás.  
Prof. Msc. Luís Fernando Pagotti – Examinador. POLI-PUC Goiás.

Goiânia, 12 de dezembro de 2023.

# Redes Neurais Aplicadas na Classificação de Distúrbios da Rede Elétrica

MATHEUS FELIPE DA SILVA MARIANO, VICTOR PINHEIRO BORGES, MARCOS ANTÔNIO SOUSA

*Abstract - Artificial neural networks (ANNs) multilayer perceptron are widely used in complex problems due to their ability to emulate learning and present lower errors in supporting decision making. Therefore, it is feasible to use this computational technique applied to the detection and classification of disturbances in class A consumers, given its ability to model complex electrical data. By being trained with voltage and current information, they can identify oscillations, harmonics, and imbalances, classifying them into specific categories. This automation significantly reduces the time required to identify and resolve electrical problems, ensuring the quality of the energy. This article presents a study with the application of artificial neural networks in the identification and classification of voltage disturbances in the electric power distribution network. The ANN is trained with real data. Test and validation scenarios are presented and discussed.*

**Keywords** – Neural Networks, power quality, disorders, classification, perceptron.

Resumo – Redes neurais artificiais (RNA) *perceptron* multicamadas são amplamente utilizadas em problemas complexos devido a sua capacidade de emular aprendizagem e apresentar menores erros no apoio à tomada de decisão. Com isso, é viável utilizar essa técnica computacional aplicada a detecção e classificação de distúrbios em consumidores do grupo A, diante da capacidade de modelar dados elétricos complexos. Ao serem treinadas com informações de tensão e corrente, elas conseguem identificar oscilações, harmônicas e desequilíbrios, classificando-os em categorias específicas. Essa automação reduz significativamente o tempo necessário para identificar e resolver problemas elétricos, garantindo a qualidade da energia. Esse artigo apresenta um estudo com aplicação de redes neurais artificiais na identificação e classificação de variações de tensão de longa duração na rede de distribuição de energia elétrica. A RNA é treinada com dados reais. Cenários de teste e validação são apresentados e discutidos.

**Palavras-chave** – redes neurais, qualidade de energia, distúrbios, classificação, *perceptron*;

## I. INTRODUÇÃO

A preocupação com a qualidade de energia elétrica (QEE) está ligada intrinsecamente com a evolução, complexidade e aprimoramento dos dispositivos. Isso se dá pela razão de que esses aparelhos estão aderindo modelos cada vez mais sensíveis a transitórios, como por exemplo a atuação de dispositivos de proteção e a vida útil de equipamentos [1]. Nesse sentido, há uma preocupação com a segurança, confiabilidade e alto padrão na qualidade do sinal, bem como a previsão e classificação de distúrbios que possam vir a comprometer as redes de energia, para que sejam minimizados seus efeitos econômicos.

É importante ressaltar que o emprego crescente de cargas eletrônicas e a falta de investimento em melhorias das redes de distribuição de energia estão entre as causas da perda

da QEE. Com a evolução da tecnologia, cargas não-lineares e/ou dispositivos com chaveamento eletrônico foram inseridos no sistema elétrico e, com isso, distorções, interrupções e variações na corrente e na tensão passaram a estar presentes na rede elétrica [2]. Muitas dessas perturbações na rede podem ser imperceptíveis a curto prazo ao usuário comum, no entanto, para o âmbito industrial, o dano pode ser visível quando equipamentos sensíveis a distúrbios têm seu funcionamento comprometido ou até interrompido [3].

A baixa qualidade de energia pode gerar problemas que vão desde a queima e inoperância de equipamentos até ao decaimento do fator de potência [4]. Nesse cenário, a automatização do processo de predição se torna necessária. Isso possibilitou o surgimento dos sistemas inteligentes artificiais para apoio à tomada de decisão. Dentre esses sistemas, vale destacar a rede neural artificial (RNA) que emula a forma de aprendizagem e a capacidade de resolver problemas tal qual o cérebro humano.

Entre as RNAs, a mais assertiva e precisa para predições com dados que podem ser fornecidos para treinamento é a *multilayer perceptron* (MLP). Essa ramificação de RNA é comumente utilizada em problemas de classificação e regressão. Ela é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, onde cada neurônio da rede está conectado a neurônios da camada seguinte. Com isso, as MLPs são capazes de aproximar funções não lineares complexas e possuem a capacidade de aprender a partir de dados não rotulados, através do processo de aprendizado não supervisionado [5].

Paralelamente, tem-se a transformada de *Wavelet* que é uma ferramenta matemática capaz de analisar sinais de diferentes frequências por meio de sua decomposição. Essa técnica é capaz de analisar até mesmo sinais não-estacionários, ou seja, sinais que possuem variações de amplitude e frequência ao longo do tempo. Assim, essa ferramenta permite apurar sinais usando convoluções de várias escalas, frequências e resoluções de tempo, o que contribui para aplicações que utilizem os componentes da onda para classificação de falha em sistemas [6].

Diante disso, esse trabalho tem como objetivo avaliar a viabilidade de se utilizar uma RNA MLP para classificar distúrbios presentes na rede elétrica, com destaque para: afundamento e elevação tensão. A ferramenta computacional utilizada para implementar a RNA MLP é o software *Python*. De acordo com as recomendações do PRODIST [7], as bases de dados a serem utilizadas devem conter cenários com registro de pelo menos 1.008 amostras válidas. Desses dados, 80% devem ser utilizados para o treinamento da RNA MLP e 20% para validação, de forma a permitir a conferência dos resultados e acurácia da aplicação.

## II. FUNDAMENTAÇÃO TEÓRICA

Os problemas que não possuem trivialidade em sua solução e, tampouco, métodos fáceis para sua análise exigem alternativas computacionais inteligentes que sejam capazes de processar rapidamente as informações de entrada, aprender com essas informações e oferecer saídas eficazes para o processo de tomada de decisão e, se possível, com alta imunidade a ruídos [8]. Partindo desse princípio, as redes neurais artificiais passaram a ser implementadas devido a sua adaptabilidade aos dados e sua velocidade e alto desempenho no processamento.

Com intuito de organizar e evidenciar a fundamentação, esta revisão bibliográfica está dividida em temas como distúrbios do sistema elétrico, com destaque para a qualidade da tensão elétrica. Também são apresentadas as principais técnicas de análise que podem ser utilizadas para avaliar a qualidade de energia, com destaque para a transformada de *Wavelet* e a Rede Neural Artificial.

### A. Distúrbios do Sistema Elétrico

No Brasil, opera por parte do governo, esforços para a regularização dos padrões de QEE nos âmbitos de consumo, distribuição e transmissão das concessionárias e manter o setor elétrico sempre em evolução. A Agência Nacional de Energia Elétrica (ANEEL) recorre ao PRODIST (Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional), o qual consta no módulo 8 os procedimentos relativos à QEE, considerando os aspectos como produto, serviço e atendimento ao consumidor [7].

A tensão em regime permanente deve ser avaliada por meio de leituras apropriadas e em pontos de conexão à Rede de Distribuição, nos pontos de conexão de distribuidoras e nos pontos de conexão entre as unidades consumidoras (UC), por meio dos indicadores estabelecidos no módulo 8.

Conforme o PRODIST, para a determinação de Índices Equivalentes por Consumidor, devem ser calculados o índice de duração relativa da transgressão para tensão precária equivalente ( $DRPE$ ) e o índice de duração relativa da transgressão para tensão crítica equivalente ( $DRCE$ ), de acordo com as equações (1) e (2):

$$DRPE = \sum \frac{DRPi}{NL} [\%] \quad (1)$$

$$DRCE = \sum \frac{DRCi}{NL} [\%] \quad (2)$$

onde:

$DRPi$ : duração relativa de transgressão de tensão precária individual da unidade consumidora (i);

$DRCi$ : duração relativa da transgressão de tensão crítica individual da unidade consumidora (i);

$DRPE$ : duração relativa de transgressão de tensão precária equivalente;

$DRCE$ : duração relativa de transgressão de tensão crítica equivalente;

$NL$ : total de unidades consumidoras objeto de medição.

Os limites dos indicadores de  $DRP$  e  $DRC$  são respectivamente, 3% e 0,5%.

A Tabela I lista os padrões de classificação quanto a qualidade do nível de tensão a ser oferecido pela

concessionária de energia ao consumidor do grupo A4, com tensão de 2,3kV a 25kV.

Tabela I – Tensão Nominal igual ou superior a 2,3 kV e inferior a 25kV

Tensão de Atendimento	Faixa de variação da Tensão de Leitura (TL) em relação a Tensão de Referência (TR)
Adequada	$0,93TR < TL \leq 1,05TR$ $205V < TL \leq 231V$
Precária	$0,90TR \leq TL < 0,93TR$ $198V < TL < 205V$
Crítica	$TL < 0,9TR$ ou $TL > 1,05TR$ $TL < 198V$ ou $TL > 231V$

Fonte: PRODIST, módulo 8, revisão 13, 2021 [7], adaptada.

Os eventos do sistema elétricos que estão intrinsecamente ligados a qualidade de energia são separados por classes como impulsivos, oscilatórios e interrupções. Assim, cabe citar os mais importantes distúrbios que pertencem a esses eventos: a sobretensão, interrupção, afundamento, elevação e harmônicos. A normatização das medidas desses eventos vem por meio da organização disponibilizada pela [9] IEEE (1995) que está disponível na Tabela II.

Tabela II. Classificação dos distúrbios.

Categoria	Duração/Frequência	Amplitude tensão(pu)
1. TRANSITÓRIOS	-	-
1.1. Impulsivos	-	-
Nano/Micro/Milisseg.	$<50 50-1 > 1ms$	-
1.2. Oscilatórios	-	-
Baixa Frequência	$3-50ms / <5KHz$	0-4 pu
Média Frequência	$20ms / 5-500KHz$	0-8 pu
Alta Frequência	$5ms / 0,5-5MHz$	0-9 pu
2. VT. Curta Duração	-	-
2.1. Instantânea	-	-
Afundamento de tensão	0,5-30 ciclos	0,1-0,9 pu
Elevação de tensão	0,5-30 ciclos	1,1-1,8 pu
2.2. Momentânea	-	-
Interrupção	0,5 ciclos - 3s	$<0,1$ pu
Afundamento de tensão	30 ciclos - 3s	0,1-0,9 pu
Elevação de tensão	30 ciclos - 3s	1,1-1,4 pu
2.3. Temporária	-	-
Interrupção	3s-1min	$<0,1$ pu
Afundamento de tensão	3s-1min	0,1-0,9 pu
Elevação de tensão	3s-1min	1,1-1,2 pu
3. VT. Longa Duração	-	-
3.1. Interrupção Sust.	$> 1$ min	0,0 pu
3.2. Subtensão Sust.	$> 1$ min	0,8-0,9 pu
3.3. Sobretensão Sust.	$> 1$ min	1,1-1,2 pu
4. Distorção / Onda	-	-
4.1. Harmônicos	reg. Perm.	0-20%
4.2. Notches	reg. Perm.	-
4.3. Ruído	reg. Perm.	0-1%

Fonte: IEEE/ Standards Board (1995) [9], adaptada.

A Tabela II se refere ao padrão IEEE, também mencionado como padrão americano, para os distúrbios de tensão. O sistema brasileiro conta com o Módulo 8 do PRODIST para padronizar as categorias dessas anomalias, e a ANEEL (órgão responsável por essas normativas) disponibiliza uma tabela que contempla os distúrbios de tensão de longa duração. A Tabela II, portanto, pode ser vista como um recurso adicional para a visualização dos procedimentos de classificação de distúrbios, conferindo embasamento a esse trabalho e, também, garantindo aderência às diretrizes estabelecidas pelo PRODIST.

Assim, entre os distúrbios que são recorrentes em redes de distribuição de energia podem ser destacados:


#### A.1. Variações de Tensão de Longa Duração

As variações de tensão de longa duração (VTLD) possuem duração 0,5 ciclo a 10 minutos, em média, sendo divididas em modificações instantâneas, momentâneas ou temporárias, dependendo de sua duração, como é possível observar na Tabela II. Essas variações são causadas, geralmente, por falta ou por energização de grandes cargas, pois necessitam de correntes altas para partida. Outra fonte de distúrbio pode ser gerada por falhas na conexão dos cabos, estes podem causar tanto o afundamento, quanto a elevação da tensão ou a interrupção total do sistema elétrico.

##### A.1.1. Afundamento de Tensão de Longa Duração

Acontece quando o valor eficaz da tensão é superior ou igual a 0,10 p.u (22V) e inferior a 0,90 p.u (198V), em relação a tensão nominal do sistema em um período de 0,5 ciclo e 10 minutos, em média, conforme a Tabela II. Ele pode ser dividido em externo e interno. O afundamento externo se dá por uma falta à montante com reflexos na tensão de suprimento de outras instalações, como por exemplo, um curto-circuito fase-terra no circuito de distribuição da concessionária em média tensão, que acarretará um afundamento na fase com defeito para a alimentação dos consumidores ligados a essa rede. O afundamento interno é gerado por partidas de motores, que consomem grande quantidade de energia reativa, não sendo suportadas pelas redes, devido à baixa potência de curto-circuito do sistema, conforme indicado na Figura I, onde os níveis de tensão média são discriminados em volts.

Figura I – Afundamento de tensão.



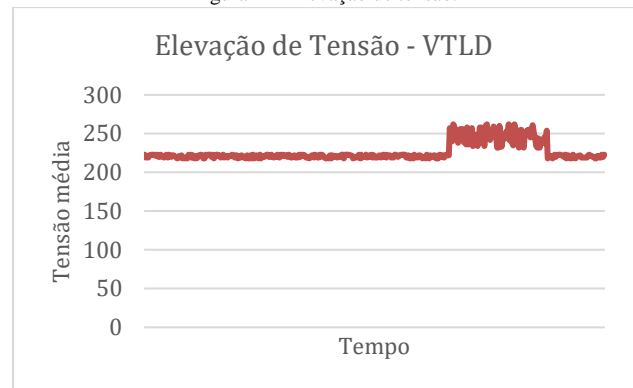
Fonte: Elaborado pelos autores.

##### A.1.2. Elevação de Tensão de Longa Duração

Ocorre quando o valor eficaz da tensão, aumenta entre 10% (242V) e 80% (396V) do valor da tensão na frequência

da rede, com duração de meio ciclo e 10 minutos, em média. Esse distúrbio está ligado à saída de grandes cargas ou a energização de bancos de capacitores conforme indicado na Figura II, onde os níveis de tensão média são discriminados em volts.

Figura II – Elevação de tensão.




Fonte: Elaborado pelos autores.

##### A.1.3. Interrupção

Sucedo quando a tensão de suprimento decresce para um valor menor que 10% (22V) da tensão por um período menor que 10 minutos, em média, podendo ocorrer por falta no sistema, falhas de equipamentos ou funcionamento defeituoso do sistema de controle, conforme indicado na Figura III, onde os níveis de tensão média são discriminados em volts.

Figura III – Interrupção.



Fonte: Elaborado pelos autores.

#### A.2. Distorções da Forma de Onda

Definida pelo conteúdo espectral, como um desvio, em regime permanente, da forma de onda. É puramente senoidal, na frequência da rede, que no Brasil é de 60 Hz.

##### A.2.1. Harmônicos

São componentes senoidais de uma tensão ou corrente alternada com frequência igual ou múltipla inteira da frequência fundamental, 60 Hz no Brasil, onde a ordem da harmônica é caracterizada pelo número de vezes que a frequência dela é múltipla da frequência utilizada no sistema.

Os harmônicos distorcem as formas de ondas, devido a cargas e equipamentos não lineares submetidos no sistema de energia. Geralmente são fenômenos de longa duração. Geralmente, quanto maior a sua ordem, menor sua intensidade. As harmônicas de ordem ímpar são mais intensas e muito mais frequentes. Podem reduzir a vida útil de

equipamentos e transformadores, aumentar a temperatura em máquinas rotativas e em condutores, e geram interferência eletromagnética em equipamentos de comunicação, entre outros.

Uma forma de reduzir a circulação de harmônicas é filtrá-las. Os filtros reduzem a amplitude de uma ou mais correntes harmônicas, em uma determinada parte do circuito.

Como qualquer outro distúrbio de QEE, o desequilíbrio de tensão em instalações elétricas é um problema extremamente relevante. Geralmente, os processos de identificação e mitigação desse problema necessitam de respostas rápidas e eficazes. Por essas razões, e por ser um distúrbio de QEE muito recorrente, que esse trabalho pretende propor uma plataforma de apoio a decisão para a identificação e classificação desses distúrbios utilizando técnicas de inteligência artificial. Mais precisamente, a técnica de aprendizado de máquina: redes neurais artificiais.

### B. Transformada de *Wavelet*

Uma das ferramentas matemáticas que se destacam pela análise das formas de onda que apresentam alterações nas suas características é a transformada de *Wavelet*. Essa transformada realiza a análise simultaneamente nos domínios da frequência e do tempo [2] [10] [11]. Isso se dá porque a forma de *Wavelet* que é usada para analisar não é apenas baseada em senos e cossenos, mas em demais funções, além de obter características de energia infinita e de curta duração.

Ademais, a vantagem também se encontra pela capacidade de estudar ondas não-lineares que apresentam distúrbios por chaveamento, ruídos e cargas relacionadas ao sinal em questão. Assim, ocorre a decomposição por escalas diferentes no sinal, a fim de capturar diversas frequências e resoluções que o represente.

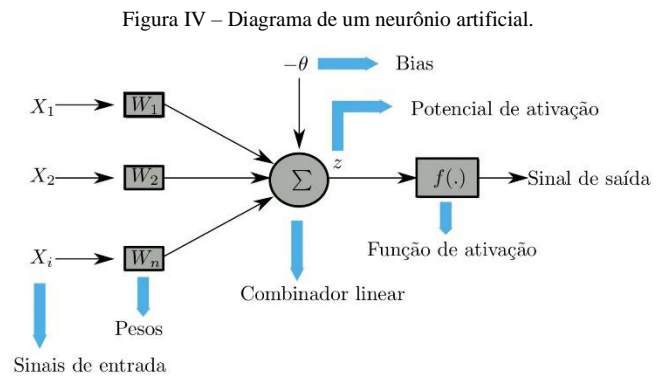
No entanto, apesar dessa modelagem matemática ser capaz de apontar os distúrbios no sistema elétrico, esse método não será utilizado, pois o presente trabalho recorre a técnicas computacionais que sejam capazes de adquirir aprendizado e adaptabilidade para diversos problemas relacionados a qualidade de energia.

### C. Redes neurais artificiais

As redes neurais artificiais (RNA) se baseiam no sistema nervoso humano para aquisição de aprendizado. Isso acontece porque dado um cenário, as variáveis de entrada formam conexões entre si para produzir uma resposta esperada [8].

É importante ressaltar que o motivo de utilizar esse tipo de inteligência artificial é devido a possibilidade de aplicar na solução de diferentes problemas. Dentre eles, cabe citar o reconhecimento de padrões, sistemas de previsões, análise de ondas, entre outros [8]. Elas são programadas para serem treinadas por meio de dados conhecidos e possui algoritmos de *backpropagation* (retorno de propagação), para atualizar os pesos sinápticos de acordo com o retorno dos erros.

De modo geral, o algoritmo pode ser explicado como um neurônio com  $n$  entradas que são multiplicadas por pesos sinápticos, as *bias*, e combinados a uma função de ativação para produzir a saída do neurônio, conforme a Figura IV [8].



Fonte: Silva et al (2016) [8], adaptada.

$X_n$ : sinal de entrada;

$n$ :  $n$ -ésima entrada sináptica;

$w_n$ : pesos sinápticos;

Como pode se observar na Figura IV, um sinal  $X_n$  é introduzido na sinapse “ $n$ ” interligada ao seu respectivo neurônio, multiplicados pelos pesos sinápticos  $w_n$  e após isso será combinado linearmente pelas sinapses dos neurônios com o limiar de ativação,  $-\theta$ . Esse limiar de ativação é um valor de referência, para que o resultado da multiplicação das entradas pelo peso seja comparado e ativem o neurônio para produzir saídas, caso essa comparação seja maior ou igual ao limiar.

A saída desse combinador linear é denominada como potencial de ativação,  $u_n$ , e é entendida pela equação (3).

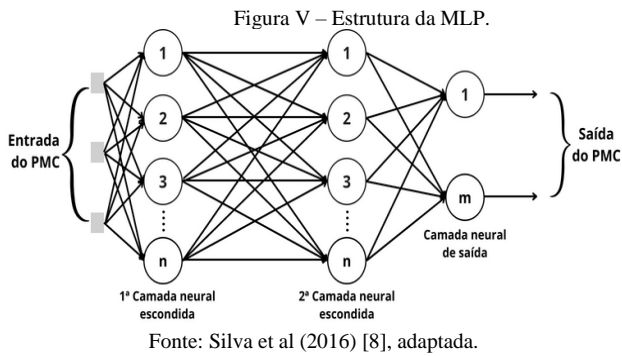
$$u_n = \sum_{i=1}^n w_{in} * x_n - \theta \quad (3)$$

É importante lembrar que a arquitetura das RNAs possui diferenças quanto ao fluxo de dados, sendo divididas entre RNAs *feedforward*, em que os dados possuem sempre o mesmo fluxo desde a entrada até a saída, e RNAs *recurrent*, que possuem realimentação de dados por meio da criação de *loops* internos [8].

Diante da complexidade dos dados não sequenciais e tendo em vista o objetivo de classificar os fenômenos elétricos, com destaque para os distúrbios de tensão, a topologia de RNA mais adequada é a *feedforward* (FF), utilizando a arquitetura *perceptron* multicamadas (MLP). Portanto, nesse trabalho serão utilizadas as redes *feedforward* MLP.

#### C1. *Perceptron* Multicamadas (MLP)

A MLP é um tipo de rede neural artificial *feedforward* que tem sido amplamente utilizado em diversas aplicações, como classificação, reconhecimento de padrões, previsão e controle de sistemas dinâmicos. As entradas iniciais são camadas ocultas que são reprogramadas e codificadas por sua função de ativação e pelo bias. Esse algoritmo é capaz de receber informações da sequência de camadas ocultas até a camada final, de acordo com a Figura V, elaborando padrão de resposta e aprendizagem. Com isso, o neurônio é capaz de criar o cenário ao qual será posteriormente inserido [8].



Uma das características mais marcantes de RNA é a capacidade de aprender por meio de suas análises. A retro propagação de erro é uma técnica fundamental para o treinamento supervisionado de redes neurais MLP, que tem sido amplamente utilizada em diversas áreas, com destaque para aplicações em problemas de reconhecimento de padrões, de previsão e de controle de sistemas dinâmicos. A retro propagação de erro é usada para ajustar os pesos da rede neural com o intuito de minimizar o erro entre a saída esperada (estimada pela MLP) e a saída real. A técnica é baseada no gradiente descendente, que é uma técnica de otimização para encontrar o mínimo de uma função, ou seja, esse cálculo é dado pela derivada parcial do erro quadrático de cada elemento em relação ao peso.

### III. MATERIAIS E MÉTODOS

Com o intuito de automatizar o processo, ou seja, reduzir a interferência humana, e não perder a qualidade, este estudo visa a utilização de técnicas de Inteligência Artificial, através da RNA. A aplicabilidade das RNAs é vasta e versátil. Por um lado, essa característica das RNAs permite uma alta adaptabilidade aos cenários de estudo. Porém, por outro lado, isso também exige um processo de customização bastante apurado. A quantidade de camadas, números de elementos por camada, a taxa de aprendizado e os critérios de treinamento, necessitam ser planejados e executados de forma individual para cada aplicação e resultado desejado. Conclui-se que, a elaboração da estrutura de uma RNA é fundamental no desdobramento de sua aplicação.

Esse trabalho consiste em identificar os possíveis distúrbios de rede, identificando-os em afundamento ou elevação de tensão a medida em que os dados são inseridos, tendo base nos treinamentos da IA. A partir da identificação do distúrbio, o usuário consegue entender a área em que ele deve atuar para corrigir.

Para a elaboração deste estudo e aplicações, será utilizado o software *Python*, pois permite por meio de suas funções trabalhar com Inteligência Artificial. Além disso, o software atende a proposta de implementação que é ser adaptável aos problemas, maior simplicidade de aplicação e maior acessibilidade ao público.

#### A. *Python*<sup>TM</sup>

*Python* é uma linguagem de programação que permite trabalhar rapidamente e integrar sistemas de forma mais eficaz. Dentre suas principais vantagens, deve-se destacar, a

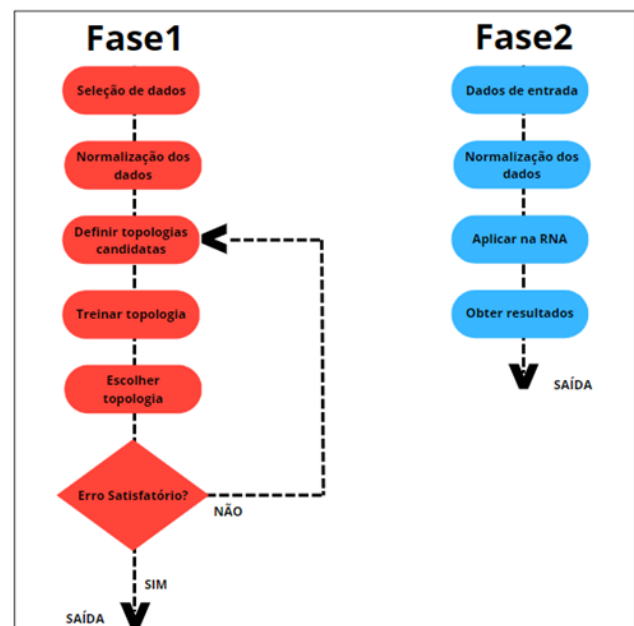
facilidade de aprender e por ser aberto ao público. O *Python* é desenvolvido sob uma licença de código aberto aprovada pela OSI (*Open Systems Interconnection* - Sistemas Abertos de Interconexão), tornando-o livremente utilizável e distribuível, mesmo para uso comercial. A licença *Python* é administrada pela *Python Software Foundation* [12].

Segundo SAS (*Statistical Analysis System* - Sistema de Análise Estatística), o aprendizado de máquina (*Machine Learning*), é um método de análise de dados que automatiza a construção de modelos analíticos. É um ramo da IA, baseado na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões com o mínimo de intervenção humana. Atualmente, a linguagem *Python* tem sido a mais utilizada no desenvolvimento de sistemas inteligentes com RNA, tanto em aplicações de estudos acadêmicos quanto de desenvolvimento de produtos comerciais.

#### B. Base de dados

A metodologia está dividida em duas fases. Sendo a fase 1 para treinamento da RNA e a fase 2 para validar os resultados. As etapas do processo podem ser conferidas no fluxograma indicado na Figura VI.

Figura VI – Fluxograma da metodologia.



Fonte: Silva (2016), adaptada.

#### Seleção dos dados

A base de dados utilizada foi coletada, com auxílio de equipamentos analisadores de energia, de onze consumidores grupo A4, sendo rede trifásica, totalizando 11.506 amostras. A coleta desses dados segue o Módulo 8 do PRODIST que recomenda que sejam feitas 1.008 leituras válidas, de cada consumidor, a cada intervalo de dez minutos, sem a ocorrência de interrupções de energia durante o processo de coleta [7].

Esses dados estão em formato de planilha e foram tratados, a fim de que essa planilha contenha as colunas do registro de tempo de coleta e dos valores médios de cada fase. Posteriormente, esses dados foram analisados e inserida a coluna de classificação de distúrbios. Essa análise é feita de acordo com os critérios da Tabela I.

Com isso, a RNA MLP é capaz de identificar os valores de tensão média como dados de entrada e a classificação de distúrbios presentes na tensão do sistema como saída desejada.

#### Normalização dos dados

A base de dados será inicializada e carregada na plataforma *Google Collab* utilizando a biblioteca *Pandas*, que permite trabalhar com arquivos de dados em diversos formatos, como "xlsx" ou "csv". Assim, seguirá para o processo de normalização dos dados, conforme a Fase 1 da Figura VI.

Primeiramente, dentre os 11.506 dados totais, sendo 1.008 dados válidos por consumidor exigidos pelo PRODIST, são necessários selecionar 80% para serem utilizados na fase 1. No primeiro momento, a seleção dos dados será feita de forma aleatória e automática, utilizando as entradas e as saídas que serão as classificações dos distúrbios. Como os valores numéricos dessa base são altos, será necessário utilizar a técnica de normalização para que os valores estejam em intervalos menores e sejam inseridos na função de ativação.

Para isso, foi utilizada a técnica de normalização 'standartscaler', em Python, que emprega o valor da diferença entre o valor e a média dos dados divididos pelo desvio padrão, conforme Equação 4.

$$X_{\text{padrão}} = \frac{X_{\text{valor}} - \text{Média}}{DP} \quad (4)$$

onde:

- $X_{\text{padrão}}$  – valor padronizado;
- $X_{\text{valor}}$  – valor de entrada;
- Média – média dos valores da tabela;
- DP – Desvio padrão.

Como saída desse processo, o domínio de saída assumirá um intervalo de valores de -1 a 1, para que seja possível implementá-los no modelo da função de ativação.

#### Treinamento Perceptron Multicamadas

O processo de treinamento é a parte que a IA aprende a responder aos dados fornecidos pelo usuário. A priori, neste processo a rede neural escolhe dados aleatórios do banco de dados, sendo que uma parcela desses dados será destinada ao treinamento, em que a RNA conhece os valores de entrada e saída. Nesse processo, a aplicação é treinada ajustando os pesos das *bias*, através da função de ativação da RNA.

Partindo desse princípio, a MLP foi configurada para escolher, aleatoriamente, 80% dos valores dentro da base de dados para treinamento, sendo os 20% restantes destinados para teste e avaliação da acurácia para otimização.

Após essa seleção, a rede neural analisará a base de dados. Para que ocorra o processo de aprendizado, a planilha deve conter as colunas que serão coletadas para informação de entrada da IA e coluna como saída conhecida condizente com a classificação dos distúrbios, conforme realizado na subseção Seleção de Dados.

Dentro da biblioteca *Scikit-learn*, é possível implementar a função de ativação ReLU (*Rectified Linear Activation*). Essa função foi selecionada devido a ampla utilização e alto desempenho em problemas de aprendizado profundo, pois introduz não linearidade nas redes neurais e permite que haja um gradiente eficiente para atualizar os

pesos sinápticos no processo de *backpropagation*. Com isso, é possível definir a função de ativação conforme equação (5):

$$f(x) = \max(0, x) \quad (5)$$

onde:

- $f(x)$  – valor de saída função ReLU;
- $\max(0, x)$  – indica que o valor de saída é o máximo entre 0 e  $x$ ;
- $x$  – soma ponderada das entradas da unidade pelos pesos correspondentes.

Em outras palavras, a função ReLU atua como um "interruptor" que ativa a unidade se a entrada ( $x$ ) for positiva ou zero, e desativa se a entrada for negativa.

Outro parâmetro de configuração da MLP é o algoritmo de otimização de aprendizado de máquina. Tendo por quesito de simplicidade, convergência rápida no aprendizado e capacidade de generalizar, foi implementado o algoritmo 'Adam'. O processo do Adam é feito por meio de otimização estocástica para ajuste das taxas de aprendizado e convergência mais rápida.

Para a avaliação do erro, se ele é aceitável ou não, são usados dois critérios. O primeiro é o RMSPE (*root mean square percentage error loss*), que em português significa a raiz quadrada média do erro percentual, calculada pela equação (6):

$$RMSPE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \left| \frac{r-p}{p} \right| \right)^2} \quad (6)$$

onde:

- $n$  – Número de amostras;
- $r$  – Valor Real;
- $p$  – Valor previsto.

O segundo critério utilizado na medida de desempenho da RNA é o MAPE (*mean absolute percentage error*), que em português é o erro percentual médio absoluto. O resultado apresenta a variação entre o valor final e o esperado, conforme indicado na equação (7):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{r-p}{r} \right| \quad (7)$$

onde:

- $n$  – Número de amostras;
- $r$  – Valor Real;
- $p$  – Valor previsto.

#### Topologia

O próximo passo envolve selecionar as topologias candidatas que partem do pressuposto da utilização do algoritmo de treinamento de RNA conhecido com *backpropagation*. Com isso, foram feitos treinamentos variando a quantidade de neurônios e a quantidade de épocas, a fim de verificar a acurácia e o tempo de resposta da RNA.

Inicialmente, foi adotado o método de Fletcher-Gloss, equação (8), para determinar a quantidade de neurônios necessários para implementar na camada oculta da RNA de maneira eficiente [6].

$$2 \times \sqrt{r} + r_2 \leq r_1 \leq 2 \times r + 1 \quad (8)$$

Onde:

- $r$  – é o número de entradas da rede;
- $r_1$  – é a quantidade de neurônios na camada oculta;

$r_2$  – é a quantidade de neurônios na camada de saída.

A base de dados dos cenários contemplados nesse estudo possui três variáveis de entrada, contemplando os valores de tensão média de cada fase (A, B e C) para cada instante de tempo, e uma variável de saída representando a classificação do distúrbio no circuito, no instante de tempo correspondente. De posse desse conhecimento, as topologias candidatas foram definidas pela equação (8) com os seguintes cálculos:

$$2 \times \sqrt{3} + 1 \leq r_1 \leq 2 \times 3 + 1$$

$$4,46 \leq r_1 \leq 7$$

Diante disso, o método determinou que a topologia da RNA tivesse de quatro a sete neurônios na camada oculta. De maneira empírica, a quantidade de épocas foi variada de uma até dez para cada topologia para verificar a acurácia e o tempo de resposta.

#### Teste e Validação da RNA

Ademais, os 20% restantes da base de dados foram utilizados como fonte de teste para supervisionar a porcentagem de erro. Com isso, utiliza-se por base a saída conhecida e a classificação, conforme Tabela 2 e, também, as diretrizes do Módulo 8 do PRODIST. Devido a uma inconsistência encontrada na base de dados de um dos consumidores, com destaque para os dados referentes a “afundamento de tensão”, esse consumidor foi retirado. Consequentemente, foi criada uma série de dados sintética com aproximadamente 600 valores aleatórios respeitando a variação padronizada pelo PRODIST.

## IV. RESULTADOS

Nessa seção são listados os resultados alcançados ao executar as etapas da metodologia proposta no fluxograma da Figura VI. Inicialmente, são descritos os resultados obtidos no processo de treinamento da RNA (Fase 1), com destaque para o ajuste dos hiper parâmetros de customização da aplicação proposta. Em seguida são listados os resultados de validação e teste, sendo avaliados os resultados da classificação de distúrbios de tensão realizados pela RNA customizada.

A Tabela III apresenta os resultados das simulações para identificar a topologia mais apropriada da RNA, para os cenários avaliados nesse trabalho. Observar que o número de neurônios na camada oculta procura respeitar o método de Fletcher-Gloss (equação (8)), enquanto o número de épocas foi estipulado de forma empírica.

A base de dados foi dividida em 80% para treinamento e 20% para validação. A acurácia indicada na Tabela III representa o nível de precisão na classificação realizada pela RNA nesse conjunto de 20% que não foi utilizado no processo de treinamento e calibração. A Figura VII apresenta essa base de dados de validação, que possui em torno de 2000 amostras, contemplando os valores de tensão (em volts) das três fases.

Conforme observado na Tabela III, os critérios de menor tempo e maior acurácia foram alcançados na topologia com 6 neurônios na camada oculta e com a execução de 5 épocas, com tempo de processamento de 6 segundos e com uma acurácia de 98%. Para que ficasse validado que o método de Fletcher-Gloss é adequado para a aplicação deste trabalho,

foram realizadas simulações com três neurônios e com oito neurônios na camada oculta. Essas simulações obtiveram acurácias menores em relação àquelas apresentadas na Tabela III.

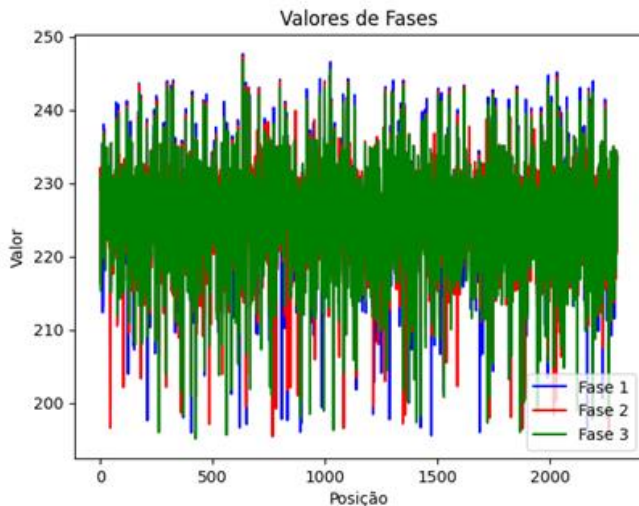
Tabela III – Desempenho das topologias candidatas.

Número de épocas	Número de neurônios	Acurácia (%)	Tempo (s)
1	4	97%	6
1	5	97%	8
1	6	98%	7
1	7	97%	6
2	4	97%	6
2	5	97%	8
2	6	98%	7
2	7	97%	7
3	4	97%	7
3	5	97%	9
3	6	98%	8
3	7	97%	8
4	4	97%	8
4	5	97%	10
4	6	98%	8
4	7	97%	7
5	4	97%	6
5	5	97%	7
5	6	98%	6
5	7	97%	7
6	4	97%	6
6	5	97%	7
6	6	98%	8
6	7	97%	10
7	4	97%	9
7	5	97%	7
7	6	98%	8
7	7	97%	7
8	4	97%	6
8	5	97%	7
8	6	98%	7
8	7	97%	7
9	4	97%	8
9	5	97%	9
9	6	98%	8
9	7	97%	7
10	4	97%	7
10	5	97%	8
10	6	98%	8
10	7	97%	8

Fonte: Elaborado pelos autores.



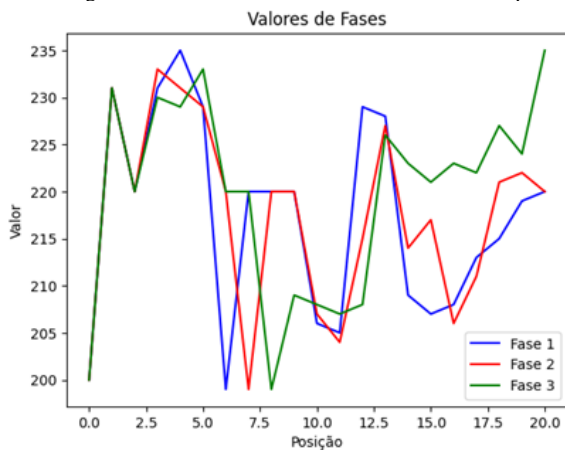
Figura VII: Dados utilizados na validação da IA.



Fonte: Elaborado pelos autores.

Na fase de teste (Fase 2, fluxograma Figura VI), foi gerada uma série sintética com 21 amostras contemplando cenários de normalidade, afundamento e elevação de tensão, conforme recomendações do PRODIST. O código foi adaptado para coletar essa nova base de dados, a partir de uma planilha eletrônica. A RNA treinada e validada na Fase 1 foi então utilizada para realizar a classificação dessa série sintética. A Figura VIII descreve o comportamento dos níveis de tensão (valores sintéticos) de cada uma das três fases. São 21 cenários de teste que foram submetidos ao processo de classificação da RNA customizada na Fase 1.

Figura VIII: Gráfico com valores de teste elaborado pela IA.



Fonte: Elaborado pelos autores.

Diante do gráfico apresentado na Figura VIII, as tensões médias de cada fase apresentam cenários de normalidade, afundamento e elevação, o que pode ser verificado na coluna de “resultado esperado” da Tabela IV.

Com a comparação realizada na Tabela IV, dentre as 21 amostras sintéticas é possível destacar que o resultado obtido pela RNA demonstrou três divergências com os resultados esperados. Isso se deve ao fato da base de dados utilizada na fase de treinamento (Fase 1, fluxograma Figura VI) não ter valores que favoreçam o aprendizado de máquina para situações de desequilíbrio de tensão entre as fases com grande diferença de valores para distúrbios de elevação.

Para o afundamento, a base de dados de treinamento condicionou o aprendizado desse distúrbio apenas quando alguma fase apresenta esse comportamento, inversamente a situação da elevação mencionada anteriormente.

Tabela IV: Desempenho da RNA desenvolvida.

V1	V2	V3	Resultado Esperado	Resultado Obtido RNA
200	200	200	Afundamento	Afundamento
231	231	231	Elevação	Elevação
220	220	220	Normal	Normal
231	233	230	Elevação	Elevação
235	231	229	Elevação	Elevação
229	229	233	Elevação	Normal
199	220	220	Afundamento	Afundamento
220	199	220	Afundamento	Afundamento
220	220	199	Afundamento	Afundamento
220	220	209	Normal	Normal
206	207	208	Normal	Normal
205	204	207	Normal	Afundamento
229	215	208	Normal	Normal
228	227	226	Normal	Normal
209	214	223	Normal	Normal
207	217	221	Normal	Normal
208	206	223	Normal	Normal
213	211	222	Normal	Normal
215	221	227	Normal	Normal
219	222	224	Normal	Normal
220	220	235	Elevação	Normal

Fonte: Elaborado pelos autores

No entanto, mesmo com essas divergências entre os resultados esperados e obtidos pela IA, a acurácia da fase de teste é de 90,48%. Assim, é possível verificar que o modelo empregado no aprendizado de máquina, bem como os dados selecionados para a Fase 1 e Fase 2 (fluxograma Figura VI) não apresentaram *overfitting*, ou seja, não sofreram sobre ajustes e se mostraram satisfatórios aos cenários reais do grupo A4. É importante ressaltar que a disparidade nas acurácias obtidas pode ser atribuída, em parte, à discrepância na quantidade de dados empregada nas fases de validação (2.000 amostras) e teste (21 amostras). Ademais, é relevante observar que os dados utilizados na Fase 2 não aderem estritamente aos padrões nos quais a RNA foi inicialmente treinada durante a Fase 1.

## V. CONCLUSÃO

Com base nos resultados e nas considerações apresentadas neste estudo, torna-se evidente que o desenvolvimento de uma ferramenta computacional voltada para a otimização da tomada de decisões em cenários de análise da qualidade de energia representa um avanço significativo. Através do que foi realizado neste trabalho,

constata-se que a Rede Neural Artificial (RNA) do tipo *Perceptron* Multicamadas (MLP) atingiu seus objetivos, conferindo viabilidade e confiabilidade à classificação de distúrbios, como afundamento e elevação de tensão, em conformidade com os padrões estabelecidos pelo PRODIST. Esta aplicação não apenas cumpre seu propósito inicial, mas também abre a possibilidade de lidar com outros distúrbios, como os harmônicos, proporcionando assim uma abordagem mais abrangente e aplicável.

A crescente presença de geradores de pequeno porte e sistemas distribuídos de geração e armazenamento de energia está abrindo novas possibilidades para a operação autônoma de segmentos do sistema elétrico, independentes da rede principal [6]. Contudo, para viabilizar essa autonomia, torna-se imperativo implementar um sistema robusto de monitoramento e controle da qualidade energética. Essa abordagem é fundamental tanto para os consumidores quanto para as concessionárias. Além disso, a aplicação de Redes Neurais Artificiais (RNA) em sistemas de monitoramento destaca-se como uma solução eficaz. Nesse contexto, a RNA pode detectar e sinalizar eventuais problemas na rede, acionando alarmes e interagindo com equipamentos programados para responder. Essa interação proporciona ao usuário informações precisas sobre os distúrbios que afetam sua distribuição de energia, capacitando-o a agir prontamente na correção desses problemas.

Este trabalho apresenta uma proposta abrangente para o monitoramento e classificação de distúrbios de tensão em redes elétricas de energia. O sistema de apoio à tomada de decisão desenvolvido adota a técnica de aprendizado de máquina com Redes Neurais Artificiais. Os processos de treinamento e validação do sistema são fundamentados em dados reais, coletados de acordo com as recomendações do PRODIST. Embora os resultados sejam preliminares, a acurácia alcançada permite vislumbrar cenários com alta aplicabilidade e customização do sistema proposto.

Atualmente, algumas funcionalidades adicionais podem ser incorporadas, tais como:

- Capacidade de avaliação de outros parâmetros de qualidade de energia, como a classificação de distúrbios devido à influência de harmônicos na rede;
- Inclusão de uma variedade de perfis de clientes;
- Integração com sistemas de coleta de dados em tempo real;
- Desenvolvimento de uma interface homem-máquina amigável para permitir a utilização do sistema por profissionais menos especializados.

A expectativa é que os sistemas autônomos operem de maneira estável e inteligente, atendendo aos requisitos de segurança e qualidade da energia elétrica. Esses avanços não apenas visam garantir a segurança, mas também otimizar a eficiência computacional nos processos de monitoramento e controle, especialmente em cenários de tempo real, beneficiando inclusive os consumidores de energia classificados como grupo A.

Nesse contexto, este estudo oferece uma contribuição significativa para a evolução dos sistemas de energia, promovendo decisões baseadas em maior quantidade de informações com eficácia na gestão da qualidade da energia elétrica.

## VIII. REFERÊNCIAS

- [1] R. M Fernandes. Uma nova técnica para detecção e classificação de transitórios em sistemas elétricos de potência. 2017.
- [2] A. A. S. A. Filho. Identificação de atributos e classificação de distúrbios da qualidade de energia elétrica baseada em métodos de análise de dados, processamento de sinal e rede neural. 2020
- [3] J.D.B. Delgado, et al. A Qualidade da Energia Elétrica na atualidade e o uso de novas tecnologias reparadoras. In: Seminário Brasileiro sobre Qualidade da energia Elétrica, 2. São Lourenço-MG. 1997.
- [4] I. F. P. Alcântara; B. H. G. Barbosa; D. D. Ferreira. Detecção de Distúrbios em Qualidade de Energia usando modelos NARX Neurais. Simpósio Brasileiro de Automação Inteligente (SBAI), 2019.
- [5] S. Haykin. Redes Neurais: Princípios e prática. Porto Alegre - RS:Bookman, 2019.
- [6] R. C. Marques. Detecção de desequilíbrio de tensão em microrredes utilizando redes neurais *perceptron*. 2022.
- [7] AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL: Procedimentos de Distribuição de Energia Elétrica - PRODIST. Módulo 8, Revisão 13 – Qualidade da Energia Elétrica. 2021. Disponível em: <[https://www2.aneel.gov.br/cedoc/aren2021956\\_2\\_7.pdf](https://www2.aneel.gov.br/cedoc/aren2021956_2_7.pdf)>. Acesso em: 19 junho 2023
- [8] I. N. Silva et al. Redes neurais artificiais para engenharia e ciências aplicadas: fundamentos teóricos e aspectos práticos. 2. ed. São Paulo: Artliber, 2016.
- [9] IEEE *Standards Board* (1995). *Ieee recommended practice for monitoring electric power quality*. IEEE Std 1159-1995, 1
- [10] M. Silva; M. Oleskovicz; D. V. Coury. Uma nova ferramenta baseada na transformada *wavelet* para localização digital de faltas. Sba: Controle & Automação Sociedade Brasileira de Automática, v. 16, p. 345-358, 2005.
- [11] O. D. Filho. Utilização da transformada *wavelet* para caracterização de distúrbios na qualidade da energia elétrica. Tese de Doutorado. Universidade de São Paulo. 2003
- [12] *Phyton Software Foundation*, <<https://www.python.org/>>. Acesso em: 16 maio 2023.



PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS  
GABINETE DO REITOR  
Av. Universitária, 1089 • Setor Universitário  
Cidade Postal 88 • CEP 74005-010  
Goiânia • Goiás • Brasil  
Fone: (62) 3649-1000  
www.pucgoias.edu.br • reitoria@pucgoias.edu.br

RESOLUÇÃO nº 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O(A) estudante Matheus Felipe da Silva Santos do Curso de Engenharia de Controle e Automação, matrícula 2019.1.0118.0035-5, telefone: (64) 99211-8898, e-mail 20191011800355@pucgo.edu.br, na qualidade de titular dos direitos autorais, em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor), autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho de Conclusão de Curso intitulado REDES NEURAIS APLICADAS NA CLASSIFICAÇÃO DE DISTÚRBIOS DA REDE ELÉTRICA, gratuitamente, sem ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF); Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros, específicos da área; para fins de leitura e/ou impressão pela internet, a título de divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 30 de agosto de 2023.

Assinatura do autor: Matheus Felipe da Silva Santos

Nome completo do autor: Matheus Felipe da Silva Santos

Assinatura do professor-orientador: Marcos A. de Sousa

Nome completo do professor-orientador: Marcos Antônio de Sousa



PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS  
GABINETE DO REITOR  
Av. Universitária, 1089 • Setor Universitário  
Cidade Postal 88 • CEP 74005-010  
Goiânia • Goiás • Brasil  
Fone: (62) 3649-1000  
www.pucgoias.edu.br • reitoria@pucgoias.edu.br

RESOLUÇÃO nº 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O(A) estudante Victor Pinheiro Borges do Curso de Engenharia Elétrica, matrícula 2019.1.0038.0025-2, telefone: (64) 992582541, e-mail 20191003800252@pucgo.edu.br, na qualidade de titular dos direitos autorais, em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor), autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho de Conclusão de Curso intitulado REDES NEURAIS APLICADAS NA CLASSIFICAÇÃO DE DISTÚRBIOS DA REDE ELÉTRICA, gratuitamente, sem ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF); Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros, específicos da área; para fins de leitura e/ou impressão pela internet, a título de divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 30 de agosto de 2023.

Assinatura do autor: Victor Pinheiro Borges

Nome completo do autor: Victor Pinheiro Borges

Assinatura do professor-orientador: Marcos A. de Sousa

Nome completo do professor-orientador: Marcos Antônio de Sousa