



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA  
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA

EVERALDO FERREIRA DE LUCENA NETO

**ANÁLISE DAS ASSINATURAS ELÉTRICAS PARA SEGREGAÇÃO DE CARGAS COM  
REDES NEURAS VISANDO O CONSUMO INDIVIDUALIZADO DE ENERGIA**

Recife  
2024

EVERALDO FERREIRA DE LUCENA NETO

**ANÁLISE DAS ASSINATURAS ELÉTRICAS PARA SEGREGAÇÃO DE CARGAS  
COM REDES NEURAS VISANDO O CONSUMO INDIVIDUALIZADO DE  
ENERGIA**

Trabalho de Conclusão de Curso apresentado ao Departamento de Engenharia Elétrica da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Orientador(a): Prof. Dr. Jeydson Lopes da Silva

Recife  
2024

Ficha de identificação da obra elaborada pelo autor,  
através do programa de geração automática do SIB/UFPE

Lucena Neto, Everaldo Ferreira de.

Análise das assinaturas elétricas para segregação de cargas com redes neurais visando o consumo individualizado de energia / Everaldo Ferreira de Lucena Neto. - Recife, 2024.

71 p.

Orientador(a): Jeydson Lopes da Silva

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Engenharia Elétrica - Bacharelado, 2024.

1. Rede Neural Artificial. 2. Harmônicos de Corrente. 3. Identificação de Cargas. 4. Modelagem em Python. 5. Monitoramento Energético. I. Silva, Jeydson Lopes da. (Orientação). II. Título.

620 CDD (22.ed.)

EVERALDO FERREIRA DE LUCENA NETO

**ANÁLISE DAS ASSINATURAS ELÉTRICAS PARA SEGREGAÇÃO DE CARGAS  
COM REDES NEURAIIS VISANDO O CONSUMO INDIVIDUALIZADO DE  
ENERGIA**

Trabalho de Conclusão de Curso apresentado ao Departamento de Engenharia Elétrica da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Engenheiro Eletricista.

Aprovado em: 21/03/2024.

**BANCA EXAMINADORA**

---

Prof. Dr. Jeydson Lopes da Silva (Orientador)  
Universidade Federal de Pernambuco

---

Prof. Dr. Douglas Contente Pimentel Barbosa (Examinador Interno)  
Universidade Federal de Pernambuco

---

Prof. M.Sc Calebe Hermann de Oliveira Lima (Examinador Interno)  
Universidade Federal de Pernambuco

Este trabalho é dedicado com imenso carinho e gratidão aos meus pais e irmã, pilares fundamentais da minha vida. Graças ao apoio deles, tudo que vivenciei e conquistei se tornou possível.

## **AGRADECIMENTOS**

Gostaria de expressar meus sinceros agradecimentos, primeiramente a Deus que de todos os desafios e momentos difíceis vividos, foi e é o alicerce fundamental que segura e norteia minha vida. Grato a minha família que sempre me apoiou e aconselhou em todos os momentos, Em especial, gostaria de agradecer às peças-chaves desse meu caminho: minha mãe Vania, meu pai Everaldo e minha irmã Camila.

Ao meu orientador Dr. Jeydson Lopes, pela disponibilidade e confiança em ter aceitado me guiar nesse trabalho com um tema não comum e bem desafiador. Grato pelo projeto extensão empresa júnior da Watt Consultoria e demais colegas que trabalharam comigo durante, foi onde tive meus primeiros passos conhecendo o mercado de trabalho e evolução profissional e pessoal. Agradeço a oportunidade de participar do projeto do TRF5 e a equipe de campo, mesmo com todas as dificuldades envolvidas, os aprendizados foram muito maiores. Em destaque para Marcos, onde além de todo conhecimento técnico visto durante todo o projeto, possui um dom incrível de querer ensinar para todos em sua volta, com um carisma incomparável.

A XP Energy, onde tive meu primeiro contato com o universo da programação em análise de dados em larga escala e aprofundamento no mercado como profissional de engenharia. Foram das conversas e ideias disruptivas que surgiu o tema deste trabalho. Roube o Futuro.

Para finalizar, um agradecimento especial ao bonde Insolide, cuja amizade e companheirismo tornaram a jornada da graduação muito mais leve e divertida. As risadas, as conversas e as 'fofocas' compartilhadas foram momentos preciosos que aliviaram as tensões nos momentos difíceis.

De coração, muito obrigado!

"A mente que se abre a uma nova ideia jamais  
voltará ao seu tamanho original"  
(Albert Einstein)

## RESUMO

Este trabalho propõe o desenvolvimento de uma Rede Neural Artificial (RNA) capaz de reconhecer e segregar o consumo energético utilizando as assinaturas elétricas dos harmônicos de corrente. O objetivo principal é impulsionar a implementação prática de uma gestão de energia eficiente e inteligente em ambientes diversos, como residenciais, comerciais e industriais. A metodologia envolveu a modelagem detalhada da RNA em Python, com foco na análise precisa de dados como tensão, corrente, Distorção Harmônica Total (THD) e componentes harmônicas individuais, bem como os ângulos de fase dos equipamentos utilizados nos experimentos. Um aspecto crucial foi a implementação de uma superposição calculada dos harmônicos de corrente, comparada com medições reais em equipamentos funcionando em paralelo, visando uma melhor viabilidade do uso da técnica proposta ao eliminar a necessidade de medir todas as combinações possíveis de equipamentos em operação simultânea. O projeto finalizou com a modelagem de um algoritmo capaz de simular medições em tempo real, identificando as cargas e calculando o consumo acumulado de energia em kWh. Este estudo representa um avanço significativo na otimização do consumo de energia, contribuindo para avanços em soluções de eficiência energética inteligente.

**Palavras-chave:** Rede Neural Artificial; Harmônicos de Corrente; Identificação de Cargas; Modelagem em Python; Monitoramento Energético.

## ABSTRACT

This work proposes the development of an Artificial Neural Network (ANN) capable of recognizing and segregating energy consumption using the electrical signatures of current harmonics. The main objective is to boost the practical implementation of efficient and intelligent energy management in various environments, such as residential, commercial, and industrial. The methodology involved detailed modeling of the ANN in Python, focusing on precise data analysis such as voltage, current, Total Harmonic Distortion (THD), and individual harmonic components, as well as the phase angles of the equipment used in the experiments. A crucial aspect was the implementation of a calculated superposition of current harmonics, compared with real measurements in equipment operating in parallel, aiming for better viability of the proposed technique by eliminating the need to measure all possible combinations of equipment in simultaneous operation. The project concluded with the modeling of an algorithm capable of simulating real-time measurements, identifying the loads and calculating the accumulated energy consumption in kWh. This study represents a significant advancement in optimizing energy consumption, contributing to advancements in intelligent energy efficiency solutions.

**Keywords:** Artificial Neural Network; Current Harmonics; Load Identification; Python Modeling; Energy Monitoring.

## LISTA DE ILUSTRAÇÕES

Figura 1– Aumento do Consumo de energia primeiro semestre de 2023 comparado a 2022. ....	14
Figura 2 – Distribuição do consumo de energia pelo Anuário Estatístico de 2022. ....	15
Figura 3 – Diagrama do novo paradigma da programação .....	20
Figura 4 – Representação dos dois tipos mais utilizados aprendizado supervisionada. ....	20
Figura 5 – Representação do aprendizado não supervisionada .....	22
Figura 6 – Representação do aprendizado por reforço. ....	23
Figura 7 – Diagrama de blocos do processo de funcionamento de uma RNA. ....	24
Figura 8 – Representação do neurônio artificial modelado por McCulloch e Pitts comparado a neurônio biológico. ....	25
Figura 9 – Representação detalhada do neurônio artificial .....	25
Figura 10 – Representação da função de ativação degrau. ....	26
Figura 11 – Representação da função de ativação sinal. ....	27
Figura 12 – Representação da função de ativação sigmoide. ....	27
Figura 13 – Representação da função de ativação tangente hiperbólica. ....	28
Figura 14 – Representação da função de ativação ReLU. ....	28
Figura 15 – Representação da função de ativação softmax. ....	29
Figura 16 – Arquitetura de uma rede neural do tipo MLP. ....	30
Figura 17 – Representação das etapas do algoritmo backpropagation. ....	31
Figura 18 – Exemplo de distorção e suas decomposições harmônicas. ....	36
Figura 19 – Distorção harmônica de tensão. ....	38
Figura 20 – Análise do processamento do sinal das harmônicas impares. ....	40
Figura 21 – Espectro harmônica das componentes impares 1, 3 e 5 da imagem anterior. ....	40
Figura 22 – Diagrama ilustrativos do experimento. ....	42
Figura 23 – Analisador de energia Fluke 435 series II. ....	43
Figura 24 – Software da Fluke. ....	44
Figura 25 – Tela da assistente de exportação dos dados. ....	45
Figura 26 – Arquivo no formato TXT. ....	46
Figura 27 – Arquivo no formato CSV separado por vírgula. ....	46

Figura 28 – Harmônicos de corrente do ruído, em percentual pelo tempo.....	51
Figura 29 – Harmônicos de corrente do ruído com seu espectro em percentual .....	51
Figura 30 – Função em Python para tratamento complexo dos dados de harmônicos. .....	53
Figura 31 – Decomposição dos sinais harmônicos de corrente em parte real e imaginária.....	53
Figura 32 – Estrutura das camadas e neurônios da rede neural.....	56
Figura 33 – Implementação das funções otimizadora e perda.....	56
Figura 34 – Ilustração da saída do reconhecimento a RNA.....	57
Figura 35 – Trecho responsável pelo cálculo do consumo energético.....	57
Figura 36 – Código da função groupby.....	59
Figura 37 – Representação das bases de dados separadas.....	60
Figura 38 – Progresso de treinamento do modelo da RNA.....	63

## LISTA DE TABELAS

Tabela 1 – Exemplos de cargas lineares .....	37
Tabela 2 – Exemplos de cargas não lineares.....	37
Tabela 3 – Cargas residenciais utilizadas no experimento. ....	47
Tabela 4 – Lista de medições e seus equipamentos.....	49
Tabela 5 – Sistema de classificação de tags dos equipamentos ligados. ....	52
Tabela 6 – Representação do dataframe com o valor do consumo calculado pelo algoritmo.....	58
Tabela 7 – Representação atualizado do dataframe.....	59
Tabela 8 – Representação do acumulado do consumo agrupado. ....	59
Tabela 9 – Resultado da identificação discreta da RNA. ....	64
Tabela 10 – Resultados do reconhecimento e consumo energético acumulado.....	65

## LISTA DE ABREVIATURAS E SIGLAS

CCEE	Câmara de Comercialização de Energia Elétrica
CSV	Comma Separated Values
EPE	Empresa de Pesquisa Energética
IA	Inteligência Artificial
ILM	Intrusive Load Monitoring
kWh	Quilowatt-hora
MLP	Multilayer Perceptron
NILM	Nonintrusive Load Monitoring
PU	Per Unit
RNA	Redes Neurais Artificiais
TC	Transformador de Corrente
THD	Total Harmonic Distortion
TUG	Tomada de Uso Geral
TWh	Terawatt-hora
TXT	Text File

## LISTA DE SÍMBOLOS

$E_{QM}$	Erros Quadráticos Médios
$I_1$	Componente harmônica fundamental de corrente
$I_h$	Demais componentes harmônicas de corrente
$V_1$	Componente harmônica fundamental de tensão
$V_h$	Demais componentes harmônicas de tensão
$I$	Corrente
$R$	Resistência
$V$	Tensão
$E$	Erro Quadráticos
$T$	Período
$W_0$	Bias
$W_i$	Pesos da rede neural
$X_i$	Entradas de dados da rede neural
$a$	Função ativação
$\omega$	Frequência Angular

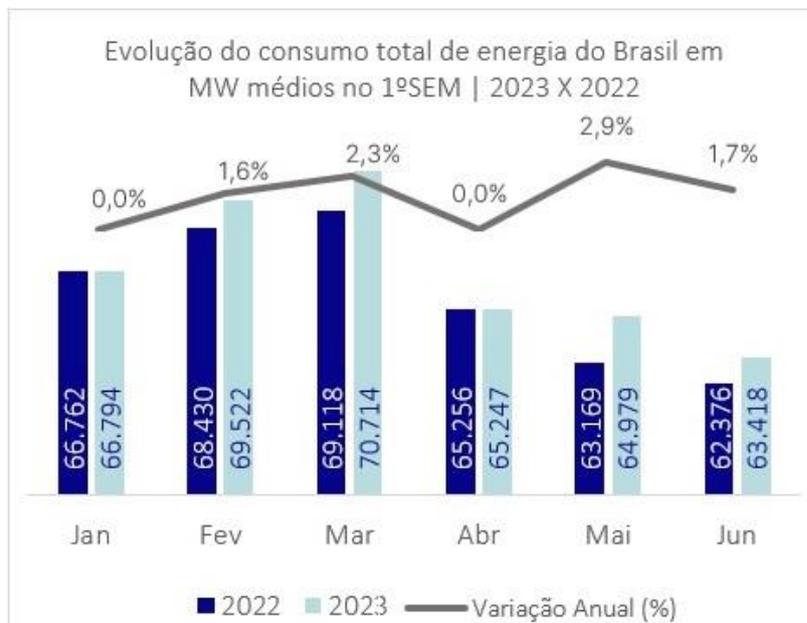
## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>14</b>
1.1.1	Objetivos.....	17
1.1.2	Geral.....	17
1.1.3	Específicos .....	17
1.2	ORGANIZAÇÃO DO TRABALHO.....	17
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>19</b>
2.1	APRENDIZADO DE MÁQUINA E SUAS CATEGORIAS.....	19
2.1.1	Aprendizagem Supervisionada:.....	20
2.1.2	Aprendizagem Não Supervisionada: .....	21
2.1.3	Aprendizado por Reforço:.....	22
2.2	REDES NEURAIS ARTIFICIAS.....	23
2.2.1	Arquitetura da Rede Neural .....	29
2.2.1.1	<i>Treinamento e Funções perdas</i> .....	30
2.3	INTRODUÇÃO À QUALIDADE DE ENERGIA .....	34
2.4	DISTORÇÕES HARMÔNICAS.....	35
2.4.1	Teorema de Fourier .....	38
<b>3</b>	<b>BANCADA DE MEDIÇÃO.....</b>	<b>42</b>
3.1	ANALISADOR DE ENERGIA E SOFTWARE DE EXTRAÇÃO DOS DADOS 43	
3.2	CARGAS UTILIZADOS NO EXPERIMENTO .....	46
<b>4</b>	<b>ELABORAÇÃO METODOLÓGICA .....</b>	<b>48</b>
4.1	MEDIÇÕES .....	48
4.2	PRÉ-PROCESSAMENTO DOS DADOS.....	50
4.3	MODELAGEM DA RNA EM PYTHON.....	54
4.4	ALGORITMO DO CÁLCULO DO CONSUMO DE ENERGIA.....	57
4.5	AVALIAÇÃO DA PERFORMANCE .....	60
<b>5</b>	<b>RESULTADOS .....</b>	<b>62</b>
5.1	TAXA DAS PERDAS E ACURÁCIA AO LONGO DO TREINAMENTO DA RNA 62	
5.2	ACURÁCIA DO RECONHECIMENTO DISCRETO .....	63
5.3	ACURÁCIA DO RECONHECIMENTO CONTÍNUO E O CONSUMO ENERGÉTICO ACUMULADO.....	65
<b>6</b>	<b>CONCLUSÕES E PROPOSTAS DE CONTINUIDADE .....</b>	<b>67</b>
6.1	TRABALHOS FUTUROS.....	68
	<b>REFERÊNCIAS.....</b>	<b>69</b>

## 1 INTRODUÇÃO

Nos últimos anos, tem-se observado um aumento significativo no consumo de energia elétrica no Brasil. No primeiro semestre de 2023, o país registrou um crescimento de 1,4% em comparação com o mesmo período de 2022, chegando a registrar crescimentos acima de 2% nos meses de março e maio, onde atingiu um pico de 2,9%, como ilustrado na Figura 1. Esse aumento é atribuído principalmente ao crescimento nos setores de comércio, serviços e indústria de mineração [1].

Figura 1– Aumento do Consumo de energia primeiro semestre de 2023 comparado a 2022.



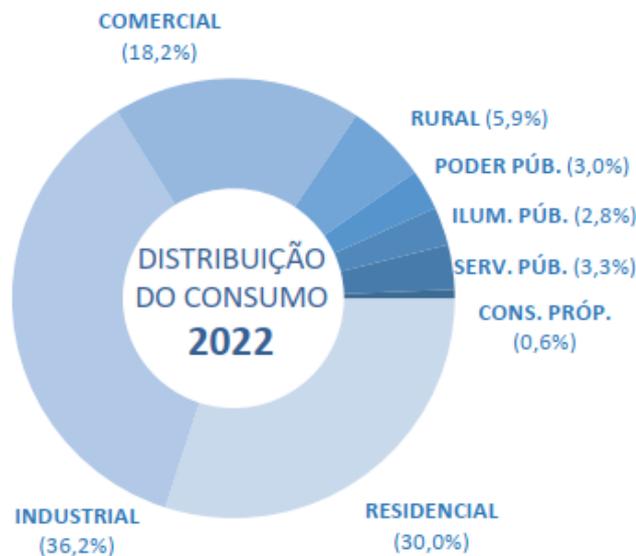
Fonte: CCEE (2023)

Diante do crescimento contínuo, a necessidade de mitigar os níveis de desperdício energético torna-se cada vez mais premente. Foi constatado que estas perdas podem alcançar até 43 terawatt-hora (TWh) anualmente, o que equivale ao consumo de aproximadamente 20 milhões de residências no Brasil [2], resultando em bilhões em prejuízos para a sociedade.

Como resposta a este desafio, as entidades governamentais implementaram programas de incentivo e aprimoramento da eficiência energética. Destaca-se o Programa de Conservação de Energia Elétrica (PROCEL), estabelecido pela Portaria

Interministerial nº 1.877 de 1985. O programa tem atuado significativamente nas três principais categorias de consumo do país: industrial (36,2%), residencial (30%) e comercial (18,2%), conforme ilustrado na Figura 2, baseada nos dados do Anuário Estatístico de Energia Elétrica de 2023 da Empresa de Pesquisa Energética (EPE) [3].

Figura 2 – Distribuição do consumo de energia pelo Anuário Estatístico de 2022.



Fonte: EPE (2023)

Com a implementação e incentivo a setores específicos, focando na substituição de maquinários e equipamentos obsoletos, o programa tem demonstrado resultados consistentes e robustos ano após ano. Os dados consolidados de 2022 apontam uma economia de cerca de R\$ 4,144 bilhões, representando 4,35% do consumo total de eletricidade no Brasil [4]. Este marco foi alcançado, em parte, através da implementação de sistemas de medição e controle de cargas, permitindo a identificação precisa de equipamentos que necessitam substituição ou manutenção. Tais sistemas de gerenciamento e monitoramento fornecem informações cruciais para detectar padrões de consumo de energia e possíveis desvios. Por exemplo, o monitoramento do uso de energia elétrica em equipamentos residenciais pode levar a uma economia de 5% a 20% [5]. Este princípio pode ser facilmente adaptado para indústrias de manufatura, que possuem diversos processos e linhas de produção, ou para comércios de produção de alimentos, que utilizam variados maquinários.

Embora pareça uma tecnologia recente, a ideia original de monitoramento de cargas data da década de 90, proposta por Hart. Inicialmente, uma barreira para a adoção mais ampla desses sistemas era a falta de robustez tecnológica. Hart observou em 1992 que os primeiros medidores de energia elétrica eram complexos em instalação e manutenção, pois eram instalados em série com os maquinários, conhecidos como Intrusive Load Monitoring (ILM) [6]. Eles tinham limitações físicas em seu hardware e eram instalados individualmente em cada equipamento, elevando o custo de implementação.

Hart propôs uma nova abordagem, usando Transformadores de Corrente (TCs) para medir indiretamente a corrente circulante, simplificando a robustez do hardware e permitindo instalações mais versáteis e fáceis de manter. Essa técnica, conhecida como Non-intrusive Load Monitoring (NILM), permitiu aglutinar vários equipamentos em um único medidor, reduzindo significativamente os custos de implementação.

Contudo, essa técnica trouxe um novo desafio: como determinar o consumo individual de cada carga a partir de um único ponto de medição. A solução surgiu com a indústria 4.0, através de sistemas de conexão em nuvem, Internet das Coisas e inteligência artificial, proporcionando análises mais profundas e dinâmicas do uso da energia elétrica. Com o avanço dessas tecnologias, surgiram os “Smart Meters” ou Medidores Inteligentes, capazes de realizar análises e avaliações das cargas em tempo real, utilizando assinaturas elétricas dos equipamentos e redes neurais para reconhecimento e ação automáticos, elevando a eficiência energética a um novo patamar [7].

Neste contexto, este trabalho visa desenvolver um algoritmo, usando Redes Neurais em Python, que possa identificar quais cargas estão em operação e fazer a segregação do consumo de energia em kWh a partir de um único ponto de medição. A abordagem utilizada se baseia no uso de harmônicos de corrente em regime permanente para treinamento e reconhecimento futuro, abrangendo tanto cargas lineares quanto não-lineares, conforme metodologias propostas em estudos anteriores [8] [9] [10] [11].

### **1.1.1 Objetivos**

#### **1.1.2 Geral**

O objetivo é desenvolver uma Rede Neural capaz de identificar e classificar o consumo individualizado de energia elétrica, utilizando as assinaturas elétricas dos harmônicos de corrente.

#### **1.1.3 Específicos**

- Calcular a superposição dos harmônicos de corrente em alguns equipamentos e comparar os resultados com medições reais para validar o modelo de superposição;
- Modelar a estrutura da Rede Neural em Python para o problema proposto e verificar a sua acurácia no reconhecimento das cargas individuais e em paralelo;
- Modelar um algoritmo que simule medições em tempo real dos dados medidos, passando pelo reconhecimento e fazendo o cálculo do consumo da energia em kWh acumulada;

## **1.2 Organização do Trabalho**

O trabalho está organizado no formato de 6 capítulos. O Capítulo 1 contempla uma introdução com a contextualização da importância que o tema da eficiência energética reflete no país, bem como as problemáticas que dificultaram a uma aplicação anteriormente e a sua relevância ampliação na área de estudo da Engenharia Elétrica.

O capítulo 2 é onde toda a fundamentação teórica que guia o trabalho será tratada. Tendo foco uma revisão bibliográfica que englobe o problema de estudo relativos aos harmônicos, bem como as principais características referentes dentro da

qualidade de energia. Também serão descritos os aspectos na construção das redes neurais e peculiaridades.

No capítulo 3, será abordada a bancada de testes que foi montada para obtenção dos dados de estudo. Como as cargas que foram utilizadas, qual o instrumento utilizado para fazer tais medições e apresentação do software responsável pela exportação dos dados com certo tratamento.

No capítulo 4, realiza um detalhamento do passo a passo para o desenvolvimento do problema. São descritos os algoritmos elaborados para calcular uma superposição das cargas, construção da Rede Neural, comparação dos dados de treinamento e testes de acurácia e o acumulativo do consumo final, com ênfase nos métodos utilizados e parâmetros empregados.

No capítulo 5, serão apresentados os resultados obtidos da implementação e testes realizados, finalizando com o capítulo 6, onde concentra-se nas conclusões finais do trabalho em cima dos resultados e possíveis propostas de trabalhos futuros, para aprimoramentos e mais testes a serem elaborados.

## 2 FUNDAMENTAÇÃO TEÓRICA

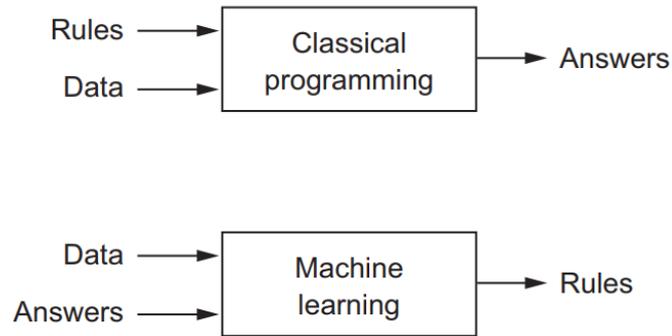
Este capítulo cobre as principais fundamentações teóricas que serão os alicerces de todos o trabalho proposto. Será dividido em três macro partes: em 2.1 abordará sobre fundamentos do Aprendizado de Máquina e suas categorias, em 2.2 sobre a estrutura e o funcionamento das Redes Neurais Artificiais e em 2.3 os aspectos e entendimento das distorções Harmônicas.

### 2.1 Aprendizado de Máquina e suas categorias

Desde o advento dos computadores. que por volta da década de 1940. começaram a ganhar fama pelas possibilidades de ferramentas, usos e praticidade que poderiam trazer para indústria e sociedade em geral, também se iniciou o pensamento se os computadores poderiam ser feitos para "pensar", onde seria o nascimento da expressão inteligência artificial (IA), tendo várias ramificações de discussões e origens de trabalhos e artigos nessa área, com a seguinte pergunta "para onde isso tudo poderia levar a humanidade?".

Em 1950, em seu importante artigo [12], Turing indaga-se sobre se os computadores de propósito geral possuem a capacidade de autodesenvolvimento e inovação. Essencialmente, questiona-se se é possível para um computador ultrapassar a execução de tarefas predeterminadas e, em vez disso, aprender autonomamente como realizar funções específicas, surgindo a expressão de aprendizado de máquina. Essa indagação desafia a noção tradicional de programação, onde os programadores definem regras de processamento de dados, propondo a ideia de que um computador poderia descobrir essas regras por meio da análise de dados, ilustrado na Figura 3.

Figura 3 – Diagrama do novo paradigma da programação



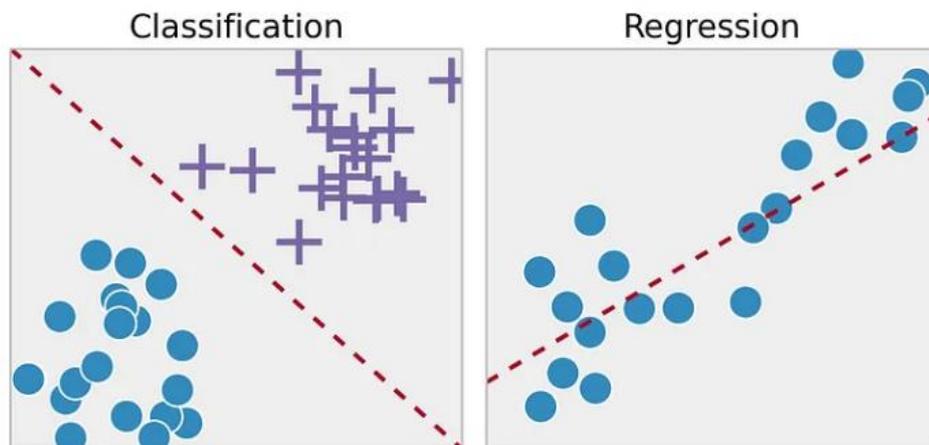
Fonte: Extraído de [13].

De acordo com François Chollet [13], renomado especialista em aprendizado de máquina e criador da biblioteca Keras, existem três categorias principais de aprendizado de máquina, serão detalhados a seguir:

### 2.1.1 *Aprendizagem Supervisionada:*

A aprendizagem supervisionada representa um dos métodos predominantes no campo do aprendizado de máquina. Sua essência reside na habilidade de aprender a associação entre dados de entrada e saídas correspondentes. Na Figura 4 mostra um exemplo ilustrativo dos dois tipos mais utilizados.

Figura 4 – Representação dos dois tipos mais utilizados aprendizado supervisionada.



Fonte: Extraído de [14].

Onde a classificação e regressão constituem a maior parte da aprendizagem supervisionada. A classificação envolve categorizar dados em classes pré-definidas, enquanto a regressão trata de prever valores contínuos.

Com isso, além dos mostrados anteriormente, as categorias principais dentro da aprendizagem supervisionada também incluem:

**Geração de Sequências:** Como, por exemplo, gerar uma legenda para uma imagem. Esta tarefa pode ser reformulada em uma série de problemas de classificação.

**Previsão de Árvores Sintáticas:** Envolve prever a decomposição de uma frase em uma árvore sintática.

**Detecção de Objetos:** Consiste em identificar e localizar objetos em imagens, podendo ser abordada como um problema de classificação ou como uma combinação de classificação e regressão.

**Segmentação de Imagens:** O objetivo é desenhar máscaras em nível de pixel em objetos específicos em uma imagem.

O presente trabalho se enquadra na categoria de aprendizado supervisionado, considerando que, para o aprendizado, foram utilizados casos de medições com rótulos indicativos do equipamento responsável pelas assinaturas elétricas obtidas.

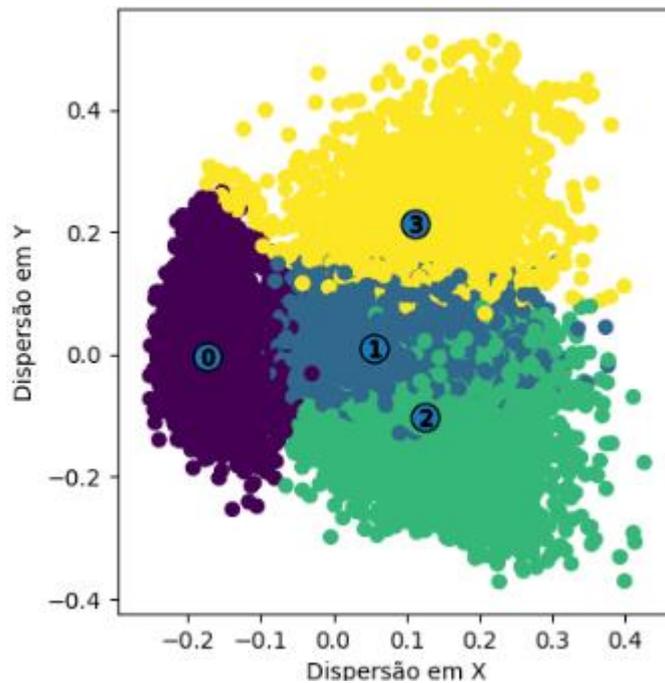
### **2.1.2 Aprendizagem Não Supervisionada:**

A aprendizagem não supervisionada busca explorar conjuntos de dados a fim de descobrir padrões subjacentes sem orientações pré-definidas. Com isso, segue uma ilustração de clusterização para este tipo de aprendizado na Figura 5.

Um exemplo seria aplicar para a segmentação de cliente. Utilizando-se padrões de compra foram analisados com base em frequência, valor gasto e variedade de produtos adquiridos. Os resultados poderiam indicar a formação de três segmentos principais: clientes com compras frequentes e de baixo valor, clientes com compras esporádicas e de alto valor, e clientes com padrões de compra diversificados. Todos feitos sem uma validação com resultados esperados, mas só pela separação analisada na base de dados.

A aprendizagem não supervisionada pode ser comparada ao processo de organizar uma biblioteca sem um sistema pré-existente, agrupando livros por temas semelhantes ou condensando informações complexas em resumos simplificados.

Figura 5 – Representação do aprendizado não supervisionada



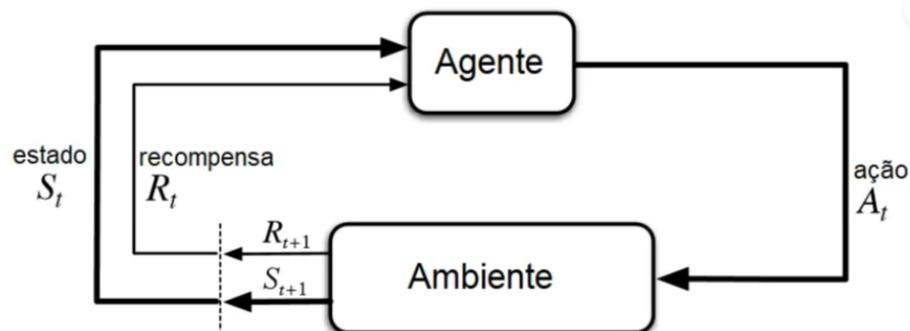
Fonte: Extraído de [15].

### **2.1.3 Aprendizado por Reforço:**

Este método ganhou notoriedade com os avanços do Google DeepMind em jogos Atari e no jogo de Go. No aprendizado por reforço, um agente aprende a tomar decisões para maximizar recompensas com base nas informações do ambiente. Segue um diagrama do aprendizado em Figura 6. Um exemplo seria uma rede neural treinada para jogar videogames, visando a maximização da pontuação.

Embora seu foco atual seja mais voltado para pesquisa e aplicado principalmente em contextos lúdicos, antecipa-se uma expansão do aprendizado por reforço para aplicações práticas, incluindo veículos autônomos, robótica e gestão de recursos.

Figura 6 – Representação do aprendizado por reforço.



Fonte: Extraído de [16].

## 2.2 Redes Neurais Artificiais

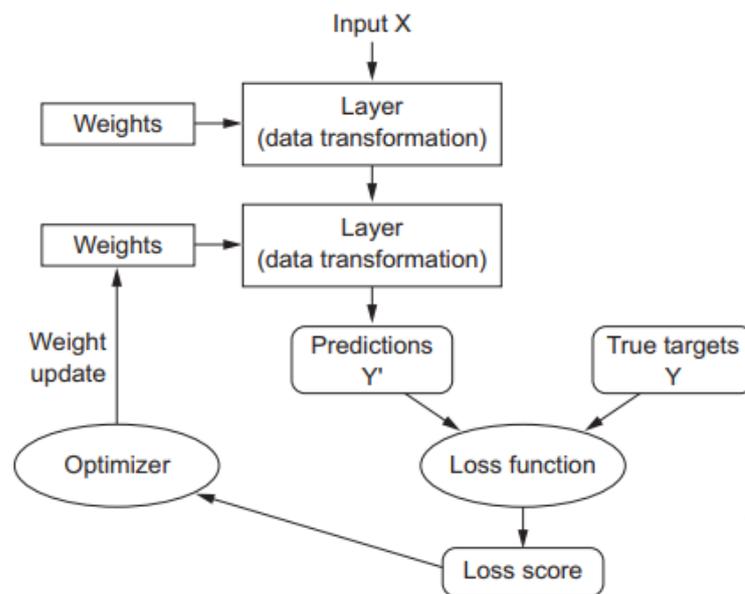
Este estudo foi concebido para empregar aprendizado de máquina supervisionado, utilizando Redes Neurais Artificiais. Constituem um subconjunto da área de aprendizado de máquina e representam o fundamento dos algoritmos empregados em aprendizado profundo. Estruturalmente, as RNAs são formadas por múltiplas camadas de nós ou neurônios, que incluem uma camada de entrada, uma ou várias camadas intermediárias, comumente chamadas como camadas ocultas, e uma camada de saída, como foi proposto por [17].

De acordo com [18], a formulação da Redes Neurais Artificiais (RNAs) são modelos matemáticos inspirados na rede neural biológica. Assim como suas contrapartes biológicas, elas são formadas por neurônios e suas conexões. Um sinal é transmitido e transformado através da rede, que se aprimora por meio de um processo de aprendizado. Sendo assim, o conhecimento acontece por meio da passagem e comparação dos dados várias vezes durante o aprendizado e são armazenados nas conexões entre cada neurônio existente na estrutura que foi elaborada.

Uma forma de visualizar como um diagrama de blocos a estrutura de uma RNA se encontra abaixo na Figura 7. Onde pode-se verificar que é composta pela camada de entrada de dados  $X$ , onde serão inseridos os dados para realização tanto do treinamento como de reconhecimento. Posteriormente, as camadas de análise e processamento são interconectadas em forma de rede, sendo seus resultados seguidas pelas funções de perdas, a qual define o sinal de feedback usado para

verificar quão bem foi o aprendizado. Caso esteja distante do resultado esperado, passa pelo o otimizador que determina como o aprendizado será reajustado, retornando os pesos de correção a cada iteração, a fim de serem usados para refinamento a cada laço do processo até chegar em um valor alvo estatístico ideal.

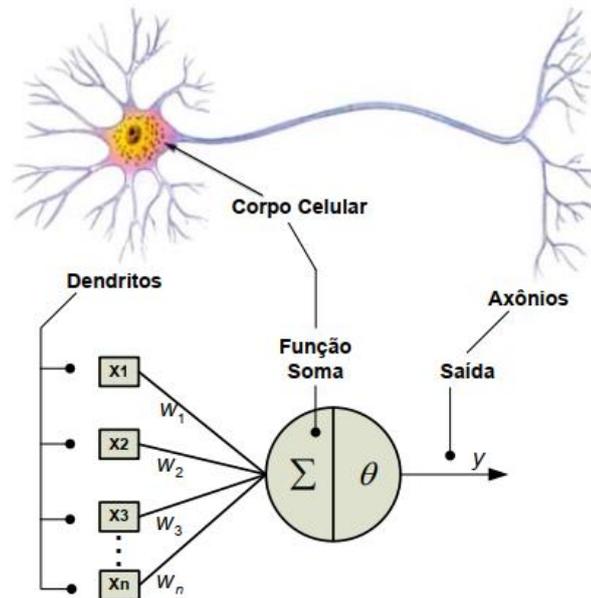
Figura 7 – Diagrama de blocos do processo de funcionamento de uma RNA.



Fonte: Extraído de [13].

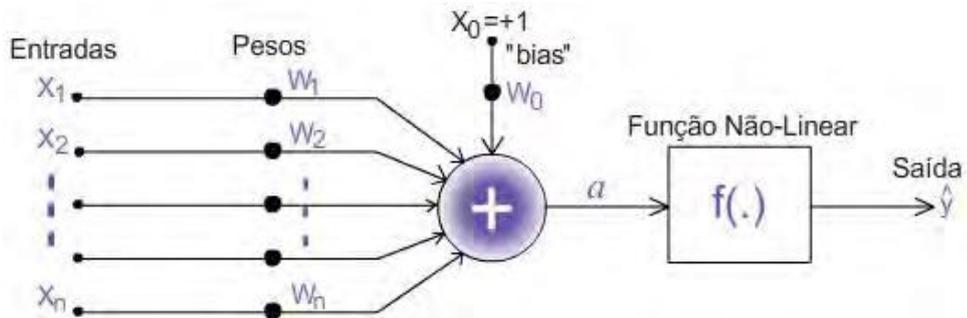
Mesmo as RNAs sendo tópicos de vários estudos recentes, as mesmas são discutidas há muito tempo, contudo não se tinham capacidade computacional para poder fazer seus estudos e observações na época quando começaram as primeiras discussões. A primeira formulação da estrutura das RNAs é datada de 1943 [19], quando o psiquiatra Warren McCulloch em parceria com o matemático Walter Pitts, desenvolveram o modelo que funcionaria como a lógica de um neurônio do cérebro humano, visto nas Figura 8 e Figura 9 a seguir.

Figura 8 – Representação do neurônio artificial modelado por McCulloch e Pitts comparado a neurônio biológico.



Fonte: Extraído de [20].

Figura 9 – Representação detalhada do neurônio artificial



Fonte: Extraído de [21].

Conforme Mantovani descreve em [21], os modelos de RNAs contam com um conjunto de entradas, designadas por  $X_i$ , que variam de -1 a +1. Essas entradas são multiplicadas por pesos correspondentes, representados por  $W_i$ , e a soma desses produtos, adicionada ao sinal de "bias", um ajuste que tem uma entrada fixa de +1 e um peso variável  $W_0$ , compõe a função de soma, que é fundamental para a função de ativação a de acordo com a equação (2.1) a seguir.

$$a = \sum_i^n W_i * X_i + W_0 \quad (2.1)$$

Após a função de ativação, que também é conhecida como função não-linear, processar as somas de cada entrada e passando por todas as repetições de treinamento, irá produzir um sinal de saída  $y$  resultante da operação do neurônio, como mostra a equação (2.2).

$$y(i) = f(a) = f\left(\sum_i^n W_i * X_i + W_0\right) \quad (2.2)$$

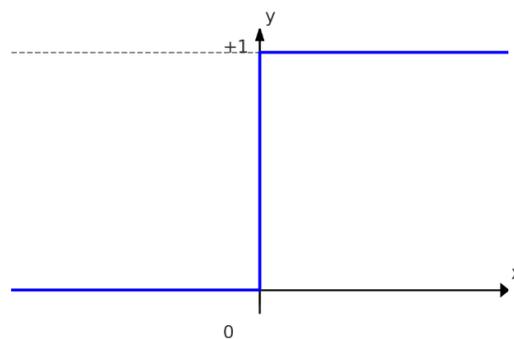
Tais funções, são responsáveis pelo controle das análises e hipóteses na saída do neurônio e tem como características pela diferenciação da matemática clássica. Pois, sem as mesmas, as RNAs só poderiam realizar operações lineares e não conseguiriam lidar com problemas mais complexos que envolvem a não linearidade dos dados. O que seria essencial para aprender e ajustar seus parâmetros durante o treinamento, sendo necessário a verificação de qual tipo vai melhor se adequar com a base de dados a ser utilizada.

As funções mais utilizadas têm seus cálculos e representação gráfica a seguir:

#### 1. Degrau:

$$y(x) = \begin{cases} y = 1, & \text{se } x \geq 0 \\ y = 0, & \text{se } x < 0 \end{cases} \quad (2.3)$$

Figura 10 – Representação da função de ativação degrau.

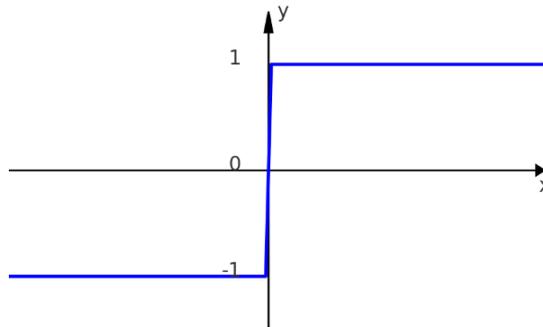


Fonte: Autor.

## 2. Sinal:

$$y(x) = \begin{cases} y = 1, & \text{se } x > 0 \\ y = 0, & \text{se } x = 0 \\ y = -1, & \text{se } x < 0 \end{cases} \quad (2.4)$$

Figura 11 – Representação da função de ativação sinal.

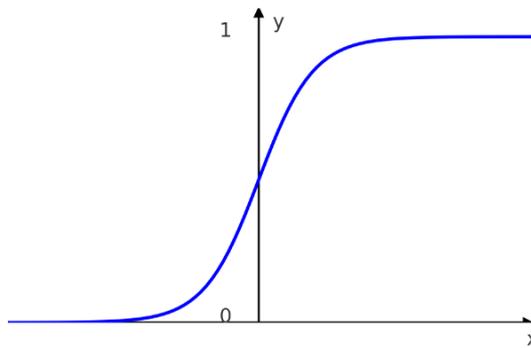


Fonte: Autor.

## 3. Sigmoide:

$$y(x) = \frac{1}{(1 + e^{-x})} \quad (2.5)$$

Figura 12 – Representação da função de ativação sigmoide.

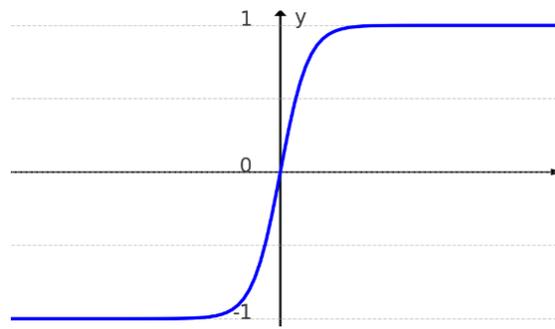


Fonte: Autor.

## 4. Tangente Hiperbólica (TanH):

$$y(x) = \frac{2}{(1 + e^{-2x})} - 1 \quad (2.6)$$

Figura 13 – Representação da função de ativação tangente hiperbólica.

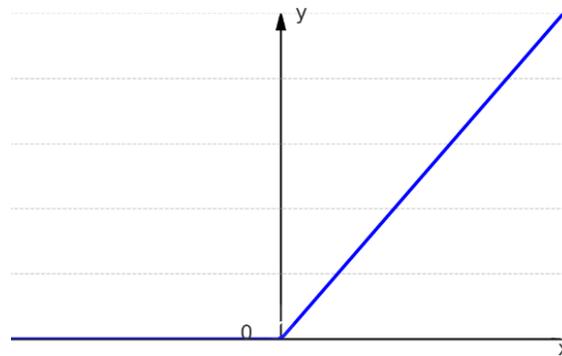


Fonte: Autor.

## 5. ReLU:

$$y(x) = \begin{cases} 0, & \text{se } x < 0 \\ x, & \text{se } x \geq 0 \end{cases} \quad (2.7)$$

Figura 14 – Representação da função de ativação ReLU.

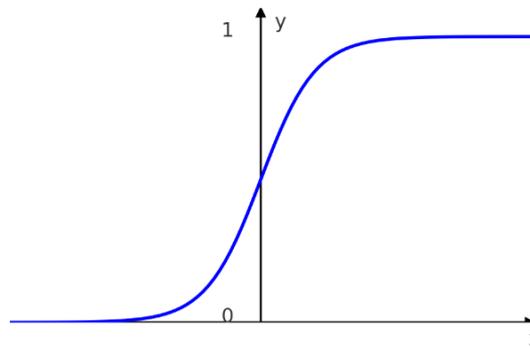


Fonte: Autor.

## 6. Softmax:

$$y(x) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (2.8)$$

Figura 15 – Representação da função de ativação softmax.



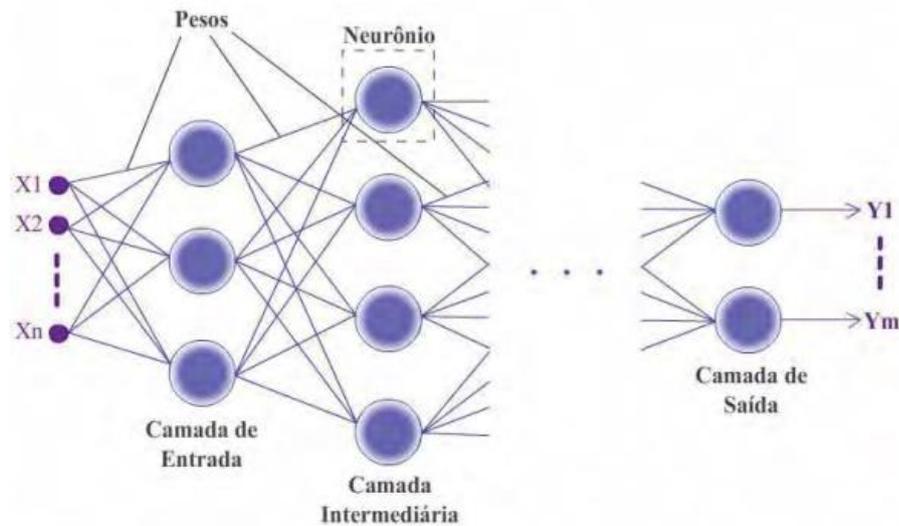
Fonte: Autor.

### **2.2.1 Arquitetura da Rede Neural**

Em sua construção de camadas mais simples da Rede Neural constituída com uma única camada, apenas um neurônio na camada de saída. Nessa concepção é limitada e possui como maior foco a realização de classificações binárias, também conhecida como perceptron, já representado na Figura 9. Este algoritmo foi desenvolvido pela primeira vez por Rosenblatt em [22], em um procedimento de aprendizado onde exemplifica esse processo através da função  $y = W * X + B$ . Neste modelo, uma saída unidimensional é gerada a partir de múltiplas entradas, configurando-se uma combinação linear, ponderada pelos respectivos pesos. A seguir será explanados alguns tipos de arquiteturas mais conhecidas.

Logo, para poder fazer um uso das RNAs em outros problemas, que não envolvem apenas casos de binários de classificação ou reconhecimento, é necessário o uso de mais de um perceptron, ou seja, uma arquitetura em múltiplas camadas [18]. Conhecida formalmente por Multilayer Perceptron (MLP), Figura 16, consiste em uma camada de entrada, várias camadas ocultas ou intermediárias para processamento e uma camada de saída para previsões, frequentemente aplicados a problemas de aprendizagem supervisionados. Esta topologia consegue aproximar quaisquer funções contínuas complexas.

Figura 16 – Arquitetura de uma rede neural do tipo MLP.



Fonte: Retirada de [21].

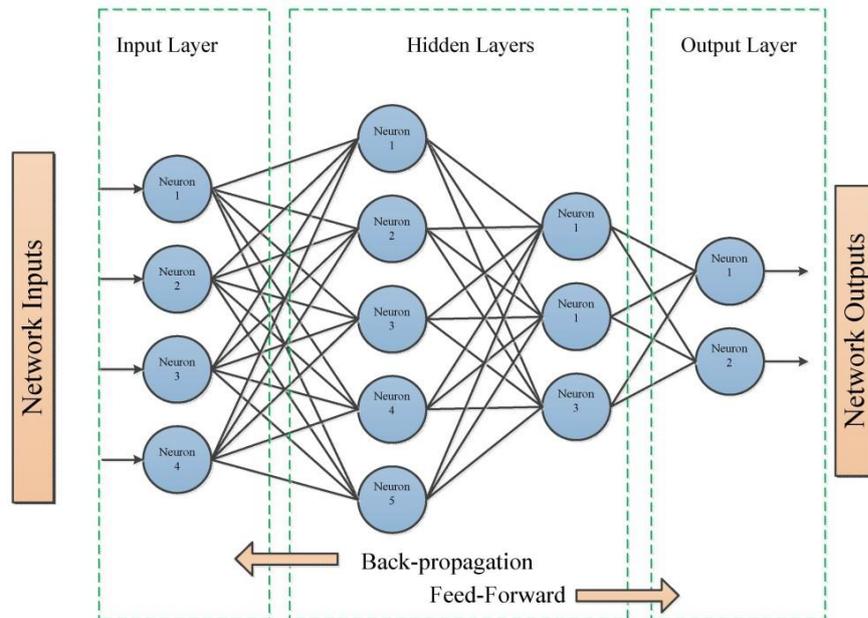
Como bem descrito por Mantovani em [21], selecionar a topologia correta para uma rede neural é desafiador e depende muito da experiência do desenvolvedor. Não há regras para estabelecer a arquitetura, apenas sugestões, como a quantidade de neurônios na camada oculta não ser menor que nas camadas de entrada e saída. Frequentemente, a definição se dá pelo método de tentativa e erro verificando qual melhor se adapta para o problema proposto ou apoiando-se em estudos anteriores.

Prosseguindo com a discussão, abordaremos como a rede neural realiza o aprendizado, um processo conhecido como treinamento. O qual é conduzido por meio de cálculos matemáticos e se caracteriza pelo ajuste dos pesos da rede em um procedimento iterativo, que será melhor detalha a seguir.

### 2.2.1.1 Treinamento e Funções perdas

Para o detalhamento do processo de treinamento de uma rede neural, será explicitado o funcionamento do algoritmo de *backpropagation*, proposto por Werbos em [23], o qual consistem em duas macros etapas: a propagação para frente chamada de *forward*, e posteriormente, consiste na propagação reversa chamada de *backward*, ilustrados a seguir Figura 17 .

Figura 17 – Representação das etapas do algoritmo backpropagation.



Fonte: Autor desconhecido.

1. **Propagação para Frente (Forward Propagation):** A entrada passa pela rede neural camada a camada, produzindo uma saída. Cada camada processa os sinais de entrada com os pesos e funções de ativação atuais, resultando numa saída que é encaminhada para a próxima camada. Após a determinação das saídas na rede neural, utiliza-se as funções de perdas que vão calcular o nível de divergência entre as saídas, será melhor detalhado mais a frente, por hora utilizando um problema do tipo regressão por exemplo, calculam-se os erros quadráticos (2.9) e os erros quadráticos médios (2.10). Essa etapa é crucial para avaliar o desempenho da rede, comparando as saídas calculadas com as saídas desejadas.

$$E = \frac{1}{2} \sum_{j=1}^n (d_j - y_j)^2 \quad (2.9)$$

$$E_{QM} = \frac{1}{p} \sum_{k=1}^p E \quad (2.10)$$

Onde:

$n$  = A quantidade de atributos apresentados a rede neural;

$j$  = Quantidade de neurônios da camada atual;

$i$  = Quantidade de neurônios anterior a atual;

$dj$  = representa a saída desejada;

$yj$  = A resposta calculada;

$p$  = Quantidade de padrões que serão dados como entrada para o treinamento.

2. **Propagação Reversa (Backward Propagation):** Esses erros são então retropropagados, começando da última camada até a primeira. Durante o processo, calculam-se os gradientes dos erros em relação aos pesos, utilizando a regra da cadeia (2.11). Esses gradientes são empregados para ajustar os pesos com o objetivo de minimizar os erros (2.12). Esta etapa é realizada por meio de algoritmos de otimização, como os gradientes locais.

$$\frac{\partial E}{\partial W} = \frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial I_j} \cdot \frac{\partial I_j}{\partial W} \quad (2.11)$$

$$W^+ = W - n \cdot \frac{\partial E}{\partial W} \quad (2.12)$$

Onde:

$n$  = A quantidade de atributos apresentados à rede neural;

$j$  = Quantidade de neurônios da camada atual;

$i$  = Quantidade de neurônios anterior a atual;

$W$  = Representa os pesos entre as camadas;

$yj$  = Representa a entrada da camada atual

$Ij$  = Representa a entrada da camada a atual.

O algoritmo vai sendo processado de forma recursiva reiniciando o processo até atingir o número máximo de iterações determinados ou erro nulo ou dentro de um limite tolerável seja obtido.

Um dos passos importantes para definição de quão bem vai se adaptar a rede neural ao problema em questão, como já comentado anterior na explicação do

*backpropagation*, são as formas de calcular o nível de divergência entre a saída calculada para a saída desejada. De acordo com [24], A escolha de uma função de perda inadequada pode afetar significativamente a eficácia de algoritmos de aprendizado de máquina.

Visto que as funções minimizam as perdas durante o treinamento, tendo duas como as mais comumente utilizadas, as de Regressão e Classificação.

Na Regressão é um processo para estimar a relação entre uma variável dependente e uma ou mais variáveis independentes. A forma mais comum é a regressão linear, que busca a linha ou combinação linear mais adequada aos dados. Sendo duas as mais utilizadas, a Erro Quadrático Médio (*Mean Squared Error*), onde calcula a média dos quadrados das diferenças entre os valores previstos pelo modelo. E a função Erro Absoluto Médio (*Mean Absolute Error*), a qual mede a média dos valores absolutos das diferenças entre as previsões feitas pelo modelo e os valores reais. Sendo mais eficaz para quantificar o erro de um modelo, que possuam muitos *outliers* em comparação com o erro quadrático médio, pois não eleva as diferenças ao quadrado.

Já na classificação ocorre previsão de caegorias discretas, sendo elas subdivididas em: Classificação binária onde envolve duas classes com objetivo é categorizar os dados em uma de duas categorias distintas. Classificação de etiqueta única, multiclases em que cada amostra pertence a uma entre várias classes, mas apenas uma classe é a correta para cada amostra. Classificação de múltiplas etiquetas, multiclases a amostra pode ser classificada em mais de uma classe dentre várias disponíveis.

Entre as mais utilizadas de cada uma, na binária tem a *Cross-Entropy loss*, a qual o valor de saída é único tipicamente restrito a -1 e 1 ou 0 e 1. Para as não binárias, têm duas mais usadas. A Entropia Cruzada Categórica (*Categorical Cross-Entropy*) quando os rótulos de classe estão no formato *one-hot* (uma matriz com zeros e um), como por exemplo a matriz a seguir representando uma classe [0, 1, 0, 0, 0].

E a Entropia Cruzada Categórica Esparsa (*Sparse Categorical Cross-Entropy*) quando os rótulos são números inteiros (um único valor representando a classe). Esta função de perda calcula a probabilidade de qual classe seja a mais correta na previsão de acordo com a entrada, sendo mais eficiente para lidar com um grande número de

classes. Ou seja, retorna uma matriz da possibilidade de ser cada classe, onde cada posição da matriz representa uma classe e sua probabilidade.

### **2.3 Introdução à Qualidade de Energia**

Antes de abordar os indicadores que serão utilizados para a identificação das cargas elétricas proposto por este trabalho. Faz-se necessário fazer uma breve explanação do tema de qualidade de energia.

A qualidade da energia elétrica pode ser definida de várias maneiras, mas geralmente se refere a como os desvios na tensão e na corrente que afetam o funcionamento dos equipamentos. Basicamente, se a energia não mantém uma forma de onda senoidal e estável, pode causar problemas ou até mesmo falhas nos equipamentos. Boa qualidade de energia significa que há poucos desvios e os equipamentos funcionam bem, enquanto má qualidade indica desvios significativos que podem prejudicar ou danificar os equipamentos. Além disso, diferentes equipamentos têm diferentes níveis de tolerância a esses desvios. A confiabilidade geral do sistema pode ser comprometida se essas variações não estiverem dentro dos padrões regulamentados, como bem explicados por [25].

No Brasil, a norma que regulamenta as características e os indicadores da qualidade de energia verificada no dia a dia, é a Prodist Módulo 8 [26]. Na mesma, pode-se verificar as duas principais seções, a de Qualidade do Produto e Qualidade do Serviço.

Na primeira, discute tópicos como padrões de tensão normais, eficiência energética (fator de potência), distorções na forma de onda da tensão e da corrente (distorções harmônicas), diferenças de tensão em sistemas trifásicos (desequilíbrio de tensão), variações na magnitude da tensão (flutuação de tensão), mudanças na frequência da tensão ou corrente (variação de frequência), e breves mudanças na tensão (variação de tensão de curta duração). Também abrange os equipamentos e métodos para medir esses fenômenos, como lidar com reclamações sobre a qualidade da energia, e estudos específicos para conectar-se aos sistemas de distribuição.

Já na segunda, define grupos de consumidores para análise da qualidade do serviço, como tratar reclamações dos consumidores, métricas para responder a

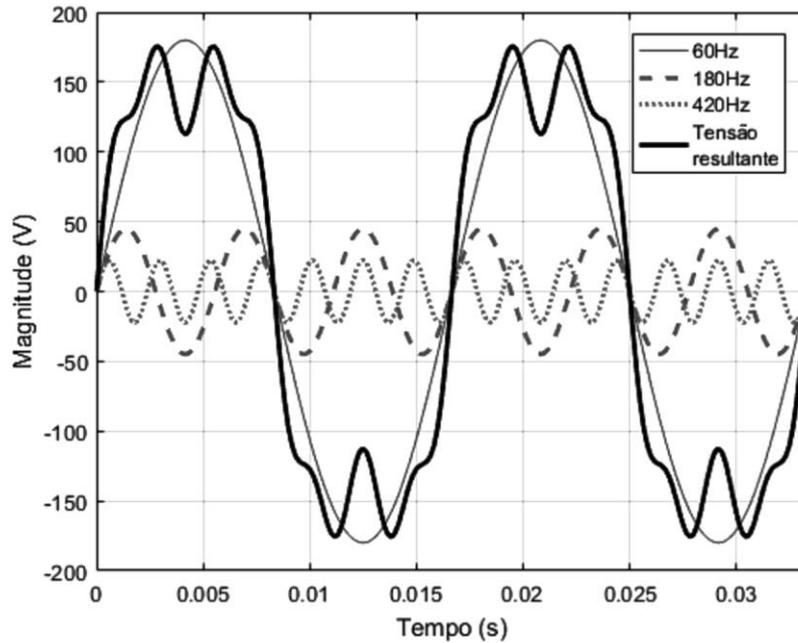
emergências, avaliar a continuidade e confiabilidade do fornecimento de energia, e a continuidade do serviço entre diferentes entidades do setor elétrico. Inclui também os limites para a continuidade do serviço e eventos que podem afetá-la.

Após esse compilado introdutório do tema de qualidade de energia, será escolhido como ênfase a seguir as distorções harmônicas, visto que é o tema de estudo do trabalho.

## **2.4 Distorções Harmônicas**

No estudo da engenharia elétrica, em ênfase nos sistemas de potência, um dos fenômenos mais desafiadores são as distorções harmônicas. Por definição, os harmônicos são distorções nos sinais de corrente e tensão com frequências diferentes e múltiplas da fundamental, [27], como exemplificada na Figura 18. No mundo basicamente existem 2 padrões para a frequência dos sinais senoides, 50Hz e 60 Hz, para o trabalho em questão, o padrão de alimentação é em 60 Hz. Contudo, faz necessário ressaltar para não associar aos transitórios, visto que os mesmos possuem como características a curta duração, geralmente relacionado a atuação, acionamento ou algo outro evento não permanente. Para o tema a ser estudado, será tratado das distorções em regime permanente, ou seja, da característica natural construtiva desses equipamentos, que podem ser diferenciados de acordo com as suas aplicações.

Figura 18 – Exemplo de distorção e suas decomposições harmônicas.



Fonte: Extraído de [28].

O entendimento da distorção harmônica vem tornando-se cada vez mais necessário e importante, pois com o avanço tecnológico no campo da eletrônica de potência, pode-se ver uma crescente quantidade de cargas não-lineares empregadas em sistemas industriais complexos até equipamentos domésticos comuns.

As cargas lineares são aquelas onde a tensão e a corrente seguem uma relação direta e previsível, como exemplificado na Lei de Ohm em (2.13). Essa lei diz que a corrente em um circuito com resistência constante é diretamente proporcional à tensão aplicada. Em termos simples, se aumentar a tensão, a corrente também aumenta na mesma proporção, [28].

$$I = \frac{V}{R} \quad (2.13)$$

Onde:

$I$  = Corrente;

$V$  = Tensão;

$R$  = Resistência.

São exemplos de cargas lineares apresentados na tabela a seguir:

Tabela 1 – Exemplos de cargas lineares

ELEMENTOS RESISTIVOS	ELEMENTOS INDUTIVOS	ELEMENTOS CAPACITIVOS
Iluminação Incandescente	Motores de Indução	Bancos de Capacitores para Correção do Fator de Potência
Aquecedores Elétricos	Reatores Limitadores de Corrente	Cabos Subterrâneos e Isolados
	Geradores de Indução	Capacitores em Filtros Harmônicos
	Reatores de Amortecimento	
	Reatores de Sintonia em Filtros Harmônicos	

Fonte: Adaptado de [28].

As cargas não-lineares, por sua natureza, distorcem a forma de onda da corrente elétrica, mesmo que alimentadas por fontes de tensão perfeitamente senoidais. Isso acontece por vários motivos, como o uso de chaves eletrônicas que conduzem a corrente da carga apenas por uma fração do período da frequência de energia, a qual a corrente não segue a forma de onda sinusoidal da tensão da fonte, não obedecendo a Lei de Ohm, são exemplos:

Tabela 2 – Exemplos de cargas não lineares

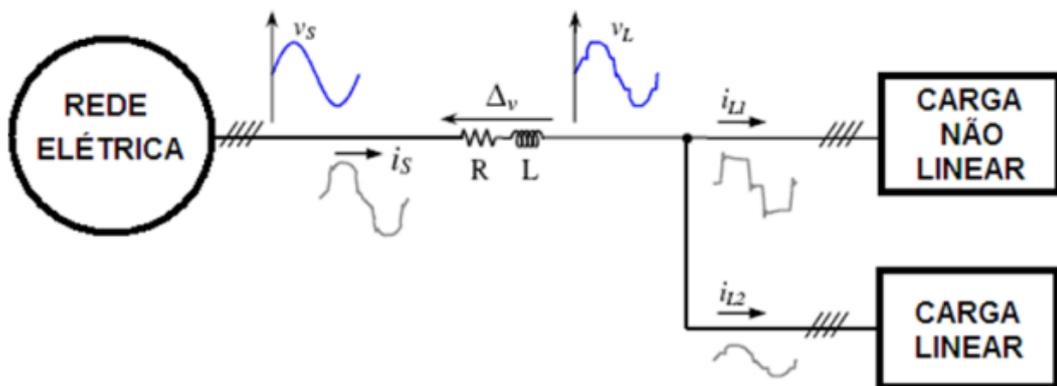
CARGAS NÃO LINEARES
Inversores de frequência
Controladores de motores DC
Guindastes
Siderúrgicas
Fontes de alimentação
UPS (Sistemas de Alimentação Ininterrupta)
Carregadores de bateria
Iluminação fluorescente
Iluminação LED

Fornos a arco
Máquinas de solda

Fonte: Adaptado de [28].

Estes equipamentos podem gerar distúrbios e impactar o funcionamento adequado da rede, embora ofereçam inúmeras vantagens, como eficiência energética e controle aprimorado. A distorção origina-se da corrente, a qual quando flui pelas impedâncias do sistema em série com o equipamento, provocam tanto uma queda de tensão, como uma reflexão de distorção harmônica nas tensões, de menor amplitude [29]. Como pode-se verificar o diagrama abaixo.

Figura 19 – Distorção harmônica de tensão.



Fonte: Autor desconhecido.

#### 2.4.1 Teorema de Fourier

Uma forma de quantificar matematicamente e analisar o nível das distorções harmônicas em um sistema ou equipamento, visto que seu entendimento é de vários sinais em ondas em forma de senoide, é por meio da série de Fourier. Como abordado em [30], o teorema estabelece que qualquer função periódica contínua no tempo pode ser representada como uma soma de senos e cossenos, ou, de forma mais geral, como uma série de Fourier. Essa representação é fundamental para a análise de

sinais em diversos campos como engenharia elétrica, representada em (2.14) e suas expressões complementares (2.15), (2.16) e (2.17).

$$f(t) = C_0 + \sum_{n=1}^{\infty} (a_n \cos(n\omega t) + b_n \sin(n\omega t)) \quad (2.14)$$

$$C_0 = \frac{1}{T} \int_0^T f(t) dt \quad (2.15)$$

$$a_n = \frac{2}{T} \int_0^T f(t) \cos(n\omega t) dt \quad (2.16)$$

$$b_n = \frac{2}{T} \int_0^T f(t) \sin(n\omega t) dt \quad (2.17)$$

Onde:

$T$  = É o período, que é o inverso da frequência;

$n$  = Representa a  $n$ -ésima componente harmônica;

$\omega$  = A frequência angular,  $2\pi/T$ .

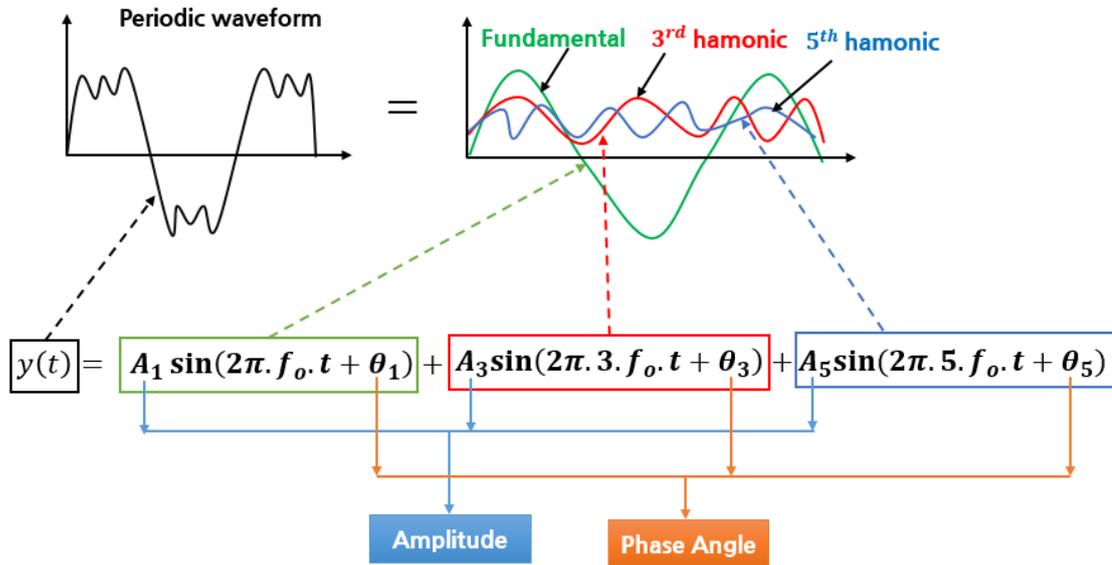
Um aspecto crucial deste estudo está relacionado ao uso do ângulo de fase  $\theta_n$  das componentes harmônicas. Muitas vezes, negligenciado em análises do impacto dos harmônicos de tensão e corrente, pois usam-se apenas as magnitudes das distorções. No entanto, para uma representação fidedigna das componentes harmônicas, faz-se necessário considerar tanto os ângulos de fase da tensão com as magnitudes. Esta abordagem permite verificar a interação entre as cargas, com seus espectros decompostos, e possibilitando identificar quais componentes se cancelarão ou se somarão [31] e [32].

Outro fator importante para as análises das distorções harmônicas está relacionado com sinais trigonométricos decompostos visto da série Fourier, com relação às harmônicas de ordem pares e ímpares. Como bem pontuado em [33], em termos comparativos, as harmônicas de ordem par têm um impacto relativamente menor na forma das ondas de tensão e corrente. Isso ocorre porque suas magnitudes são significativamente menores em comparação com as harmônicas de ordem ímpar. Logo podem ser desconsideradas nos estudos do impacto ou das caracterizações das componentes harmônicas no sistema em proposto.

Na Figura 20 a seguir é apresentado uma ilustração de como é processado os sinais senoidais, em frequências diferentes em relação ao teorema de Fourier,

utilizando as amplitudes e os ângulos de fase das componentes ímpares 1, 3 e 5. Lembrando que a componente 1 é a fundamental em 60Hz.

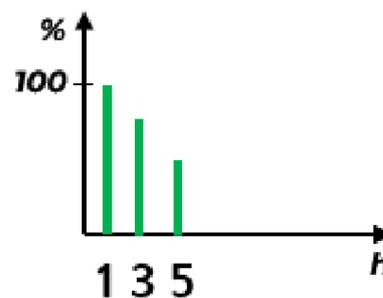
Figura 20 – Análise do processamento do sinal das harmônicas ímpares.



Fonte: Retirada de [33].

Já na Figura 21, seria o gráfico processado da representação no espectro harmônico dos sinais apresentados anteriormente com relação só as suas magnitudes em percentual da distorção e suas ordens. Ressaltando que a primeira ordem é o sinal em si e, as posteriores ordens, são a distorção em percentual em relação a fundamental.

Figura 21 – Espectro harmônica das componentes ímpares 1, 3 e 5 da imagem anterior.



Fonte: Adaptado de [33].

Além das componentes harmônicas individuais, um outro indicador importante é a Distorção Harmônica Total (THD, sigla em inglês para "Total Harmonic Distortion"). Como descrita em [28], este índice é fundamental para a análise mais macro da qualidade da energia, pois leva em consideração a contribuição total de cada componente harmônico individual presente no sinal, representando a real distorção causada pela carga. A definição de THD é aplicada tanto para sinais de tensão quanto para sinais de corrente, sendo descrita respectivamente da seguinte maneira:

$$\text{THD}_V = \frac{\sqrt{\sum_{h=2}^{\infty} V_h^2}}{V_1} \quad (2.18)$$

$$\text{THD}_I = \frac{\sqrt{\sum_{h=2}^{\infty} I_h^2}}{I_1} \quad (2.19)$$

Onde:

$h$  = índices das componentes harmônicas, ex.: 2,3,4,5...;

$V_1$  = É a componente harmônica fundamental de tensão;

$I_1$  = É a componente harmônica fundamental de corrente;

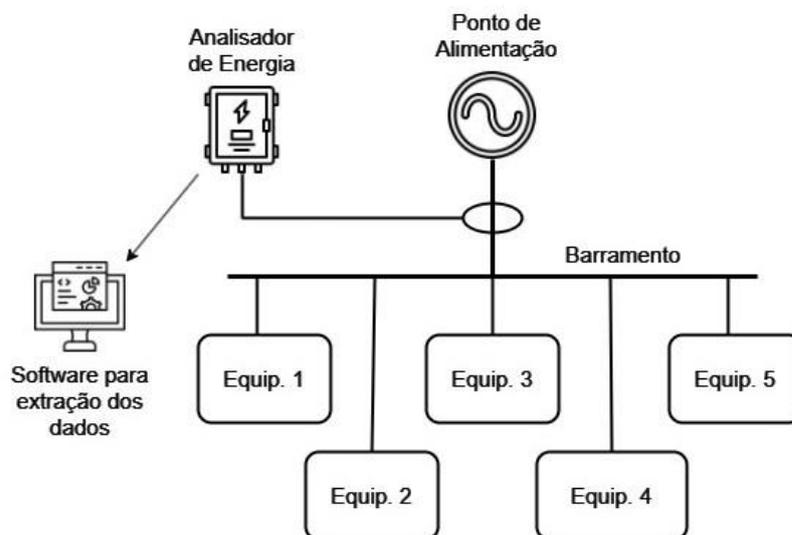
$V_h$  = As demais componentes harmônicas de tensão;

$I_h$  = As demais componentes harmônicas de corrente;

### 3 BANCADA DE MEDIÇÃO

Para organizar a montagem da bancada de medição, utilizou-se uma Tomada de Uso Geral (TUG) comum, disponível no próprio laboratório. Esse arranjo visa simular as condições típicas de alimentação elétrica que seriam encontradas em locais diversos, evitando o uso de filtros ou fontes de tensão controladas. Conectado a essa tomada, e estendendo-se até uma prancha de conexões destinada à alocação das cargas, foram posicionados os sensores de corrente do analisador Fluke 435 Series II. Este ponto de medição central, localizado antes de todas as cargas, foi escolhido para imitar a configuração encontrada em quadros elétricos industriais, comerciais e residenciais. Tal montagem está representada na Figura 22 a seguir.

Figura 22 – Diagrama ilustrativos do experimento.



Fonte: Autor

Após a montagem da bancada, a etapa subsequente envolve a aquisição de dados. Esta fase inclui a extração de harmônicas de corrente, realizada através do software integrado ao analisador de energia. Posteriormente, as análises serão conduzidas empregando Redes Neurais, abrangendo tanto a fase de treinamento quanto a de reconhecimento. É importante destacar que o Capítulo 4 deste trabalho dedicará especial atenção ao aprofundamento das metodologias, parâmetros e

características específicas da Rede Neural adotada, alinhando-se ao problema proposto pela pesquisa.

### 3.1 Analisador de energia e software de extração dos dados

O instrumento de medição utilizado no experimento foi o analisador de energia Fluke 435 series II, representado na Figura 23 a seguir. Para especificações detalhadas do instrumento, segue em [34].

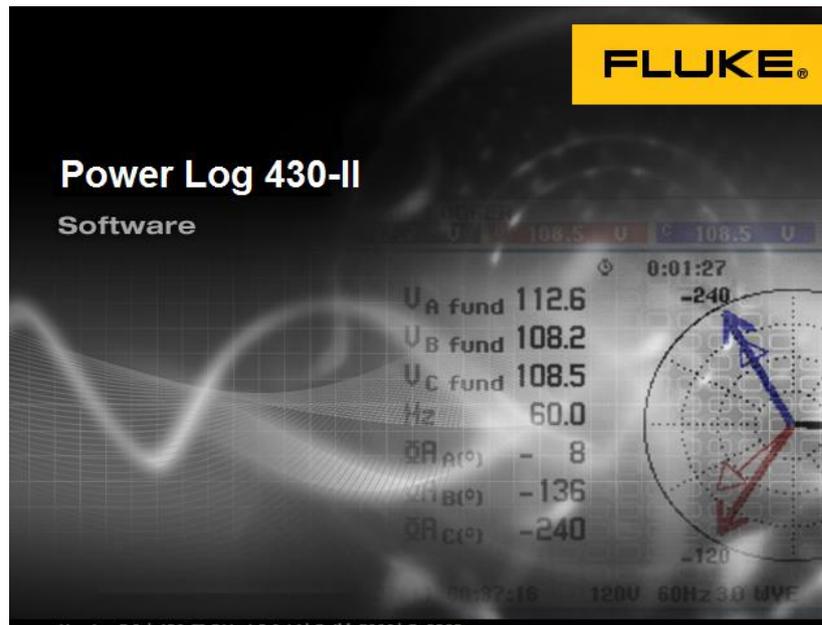
Figura 23 – Analisador de energia Fluke 435 series II.



Fonte: Autor.

Para a visualização e extração dos dados de tensão, corrente e as harmônicas de correntes, foi necessário retirar o cartão de memória do equipamento, fazendo a leitura no computador utilizando o próprio software da Fluke, o Power Log 430-II, Figura 24.

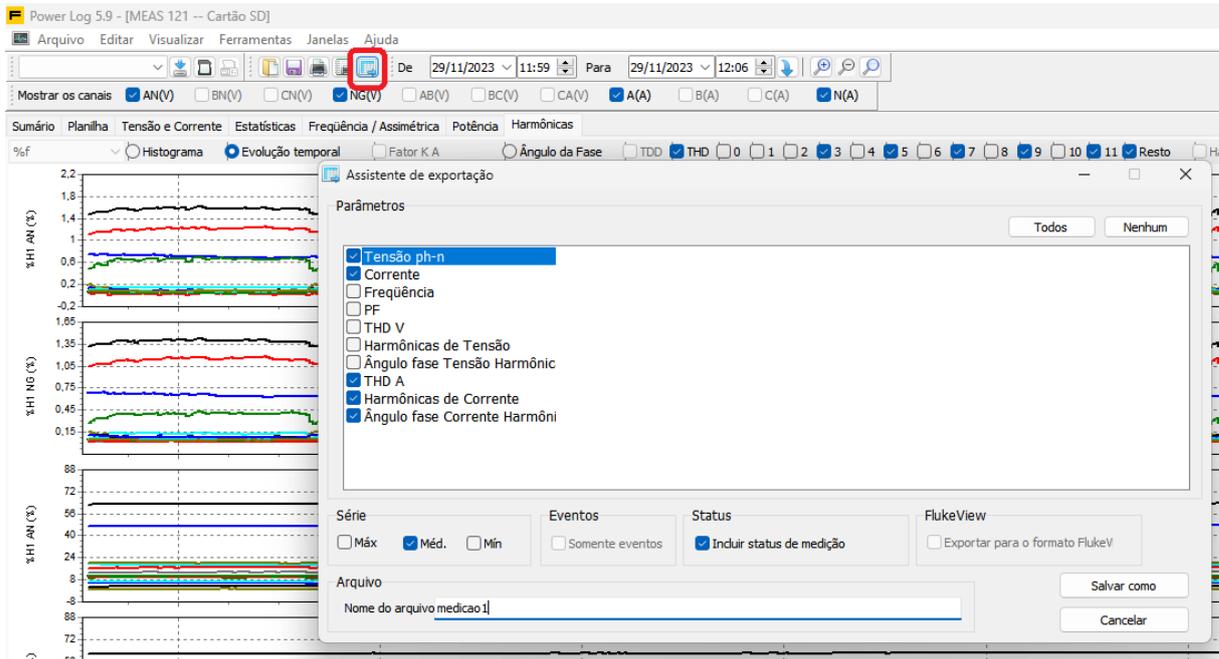
Figura 24 – Software da Fluke.



Fonte: Autor.

No software utilizado para as análises, diversas funcionalidades estão disponíveis. Contudo, dada a necessidade específica deste estudo, será dada ênfase à aba 'Harmônicas'. Esta seção permite a análise tanto de histogramas quanto do comportamento das componentes harmônicas de tensão e corrente durante o período completo da medição. No entanto, para atender aos objetivos desta pesquisa, é imprescindível extrair de forma numérica os dados relativos às componentes harmônicas de corrente, tensão e ângulo de fase das correntes. Estes dados, coletados em cada medição, são cruciais para as etapas de treinamento e reconhecimento da Rede Neural. Logo, por meio da assistente de exportação, Figura 25, escolhe-se o tipo, local de destino que será processado um arquivo de texto (TXT).

Figura 25 – Tela da assistente de exportação dos dados.



Fonte: Autor.

Após a extração dos dados no formato de arquivo TXT, identificou-se a necessidade de ajustá-los para uma utilização mais eficiente no algoritmo. Os dados nesse formato apresentaram uma organização complexa para a realização de leituras e análises, conforme ilustrado na Figura 26. Para facilitar esse processo, procedeu-se com a conversão do tipo de arquivo, transformando-o de TXT para Comma-separated values (CSV). Essa conversão foi realizada utilizando um conversor genérico disponível na internet. No formato CSV, a organização dos dados é realizada por meio de vírgulas, segmentando cada valor de data, hora, tensão, corrente e harmônicos de corrente, o que torna a consulta via algoritmo substancialmente mais prática, como demonstrado na Figura 27.

Figura 26 – Arquivo no formato TXT.

```

nica15 AN - Ângulo da Fase de Corrente Harmônica15 NG - Ângulo da Fase de Corrente
armônica17 AN - Ângulo da Fase de Corrente Harmônica17 NG - Ângulo da Fase de Corrente
te Harmônica19 AN - Ângulo da Fase de Corrente Harmônica19 NG - Ângulo da Fase de C
rrente Harmônica21 AN - Ângulo da Fase de Corrente Harmônica21 NG - Ângulo da Fase
e Corrente Harmônica23 AN - Ângulo da Fase de Corrente Harmônica23 NG - Ângulo da F
se de Corrente Harmônica25 AN - Ângulo da Fase de Corrente Harmônica25 NG

29/11/2023 11:59:33 .156 0,069 0,070 62,570 61,750 100,000 100,000 46,750
46,160 16,130 15,840 9,190 9,010 19,110 18,880 20,480 20,200 12,580
12,420 2,780 2,740 5,550 5,510 10,010 9,890 10,990 10,850 6,700
6,610 ,610 ,590 23,800 -156,280 -5,320 -185,400 -20,860 -200,86
184,840 4,500 182,520 2,300 177,380 -2,820 179,120 -1,120 148,100 -31,680
14,000 -166,400 ,020 -180,260 -,840 -181,120 -11,820 -191,920
-101,720 -280,160

29/11/2023 11:59:34 .156 0,069 0,070 62,570 61,770 100,000 100,000 46,790
46,210 16,140 15,850 9,140 8,980 19,080 18,860 20,490 20,220 12,600
12,450 2,770 2,720 5,560 5,520 9,970 9,860 10,930 10,790 6,730
6,630 ,590 ,570 23,820 -156,260 -5,320 -185,380 -20,880 -200,92
184,860 4,440 182,500 2,300 177,440 -2,760 179,200 -1,060 148,380 -31,500
14,000 -166,460 ,200 -180,120 -,760 -181,120 -11,660 -191,780
-95,580 -273,080

29/11/2023 11:59:35 .156 0,069 0,070 62,620 61,810 100,000 100,000 46,800
46,210 16,220 15,930 9,250 9,080 19,090 18,870 20,390 20,120 12,630
12,480 2,830 2,790 5,540 5,500 10,080 9,960 10,950 10,810 6,680
6,590 ,700 ,680 23,840 -156,240 -5,320 -185,400 -20,960 -200,98
184,500 4,080 182,520 2,300 177,500 -2,700 178,860 -1,440 149,240 -30,520
13,720 -166,640 ,040 -180,460 -,600 -180,940 -11,720 -191,780
-95,660 -273,660
    
```

Fonte: Autor.

Figura 27 – Arquivo no formato CSV separado por vírgula.

	A	B	C	D	E	F	G	H	I	J
1	Data,Hora	Corrente.A.Méd.,	Corrente.N.Méd.,	THD.A.A.Méd.,	THD.A.N.Méd.,	Harmônicas.de.	Corrente1.			
2	29/11/2023,11:59:33.	156,0.069,0.070,	62.570,61.750,	100.000,100.000,	46.750,46.160,	16.130,15.840,	9.190,9.010,	19.110,18.880,	20.480,20.200,	12.580
3	29/11/2023,11:59:34.	156,0.069,0.070,	62.570,61.770,	100.000,100.000,	46.790,46.210,	16.140,15.850,	9.140,8.980,	19.080,18.860,	20.490,20.220,	12.600
4	29/11/2023,11:59:35.	156,0.069,0.070,	62.620,61.810,	100.000,100.000,	46.800,46.210,	16.220,15.930,	9.250,9.080,	19.090,18.870,	20.390,20.120,	12.630
5	29/11/2023,11:59:36.	156,0.069,0.070,	62.620,61.810,	100.000,100.000,	46.820,46.230,	16.330,16.050,	9.380,9.010,	19.110,18.880,	20.480,20.200,	12.580
6	29/11/2023,11:59:37.	156,0.069,0.070,	62.600,61.800,	100.000,100.000,	46.780,46.200,	16.300,16.010,	9.420,9.050,	19.010,9.890,	10.990,10.850,	6.700
7	29/11/2023,11:59:38.	156,0.069,0.070,	62.600,61.800,	100.000,100.000,	46.800,46.220,	16.330,16.050,	9.360,9.010,	19.110,18.880,	20.480,20.200,	12.580
8	29/11/2023,11:59:39.	156,0.069,0.070,	62.610,61.790,	100.000,100.000,	46.830,46.240,	16.330,16.040,	9.380,9.010,	19.010,9.890,	10.990,10.850,	6.700
9	29/11/2023,11:59:40.	156,0.069,0.070,	62.640,61.830,	100.000,100.000,	46.820,46.240,	16.420,16.130,	9.620,9.010,	19.110,18.880,	20.480,20.200,	12.580
10	29/11/2023,11:59:41.	156,0.069,0.070,	62.650,61.840,	100.000,100.000,	46.810,46.230,	16.490,16.210,	9.690,9.010,	19.010,9.890,	10.990,10.850,	6.700
11	29/11/2023,11:59:42.	156,0.069,0.070,	62.700,61.890,	100.000,100.000,	46.890,46.300,	16.610,16.310,	9.650,9.010,	19.010,9.890,	10.990,10.850,	6.700
12	29/11/2023,11:59:43.	156,0.069,0.070,	62.700,61.880,	100.000,100.000,	46.890,46.300,	16.600,16.300,	9.620,9.010,	19.010,9.890,	10.990,10.850,	6.700
13	29/11/2023,11:59:44.	156,0.069,0.070,	62.640,61.840,	100.000,100.000,	46.860,46.280,	16.570,16.280,	9.620,9.010,	19.010,9.890,	10.990,10.850,	6.700
14	29/11/2023,11:59:45.	156,0.069,0.070,	62.630,61.810,	100.000,100.000,	46.860,46.260,	16.470,16.170,	9.690,9.010,	19.010,9.890,	10.990,10.850,	6.700
15	29/11/2023,11:59:46.	156,0.069,0.070,	62.670,61.860,	100.000,100.000,	46.870,46.270,	16.480,16.200,	9.700,9.010,	19.010,9.890,	10.990,10.850,	6.700
16	29/11/2023,11:59:47.	156,0.069,0.070,	62.680,61.870,	100.000,100.000,	46.880,46.280,	16.550,16.250,	9.680,9.010,	19.010,9.890,	10.990,10.850,	6.700

Fonte: Autor.

### 3.2 Cargas utilizados no experimento

Para a obtenção das medições das assinaturas elétricas necessárias para este estudo, optou-se pelo uso de equipamentos residenciais. Esta escolha baseou-se na maior facilidade de manuseio desses equipamentos no ambiente do laboratório e na ampla diversidade de tipos disponíveis, abrangendo categorias como eletrônicos,

resistivos e rotativos. Na Tabela 3 abaixo, segue um demonstrativo de quais foram usados e suas características.

Tabela 3 – Cargas residenciais utilizadas no experimento.

EQUIPAMENTOS	POTÊNCIA (W)	TENSÃO (V)	FREQUÊNCIA (Hz)	TIPO
Cafeteira	550	220	60	Monofásico
Batedeira	600	220	60	Monofásico
Liquidificador	700	220	60	Monofásico
Ventilador	55	220	60	Monofásico
Grill	1370	220	60	Monofásico
Lâmpada LED	15	220	60	Monofásico

Fonte: Autor.

## 4 ELABORAÇÃO METODOLÓGICA

Neste capítulo, será tratado as etapas e processos da metodologia empregada no desenvolvimento de uma Rede Neural destinada à identificação e segregação do consumo individualizado de energia elétrica, utilizando as assinaturas elétricas dos harmônicos de corrente.

Para tal fim, essa seção será dividida em cinco partes, afim de escrever detalhadamente as etapas desenvolvidas para o estudo em questão. São elas, na 4.1 descreve como foi realizada a captura das medições, em 4.2 é elaborado como foi o pré-processamento dos dados para prepara-los como entradas das etapas de treinamentos e testes de avaliação do modelo criado, a própria estrutura da Rede Neural, 4.4 depois do reconhecimento, o algoritmo que vai fazer o cálculo acumulado do consumo energético gasto em kWh e, por fim, 4.5 com avaliação e acurácia do modelo.

Com as etapas da metodologia aplicada, os resultados observados serão apresentados e discutidos no capítulo 5.

### 4.1 Medições

A etapa experimental foi conduzida utilizando uma fonte de alimentação padrão, conectada a uma TUG (tomada de uso comum) de 220V eficaz e frequência de 60Hz, típica de ambientes residenciais, comerciais e industriais. As cargas utilizadas, já explanadas na seção 3.2, foram sendo alimentadas de forma individual ou por combinações de 2 em 2, medidas pelo Fluke 435 series II também já relatado anteriormente.

As medições ocorreram em tempos de 15min totais em intervalos de cada 1s, menor escala possível do analisador, para capturar o mais próximo do tempo real possível. Um ponto importante a ser mencionado, é que as medições ocorreram visando o regime permanente das cargas e não foram consideradas as mudanças de estado, pois a *IEEE std. 519-2022* [35] caracteriza esta forma como o verdadeiro perfil harmônico de uma carga a ser avaliada.

Ainda em relação as extrações das medições, foram configuradas de variáveis a serem obtidas pelo o instrumento:

- Tensão eficaz monofásica;
- Corrente eficaz total e fundamental;
- Harmônicas de corrente de ordens 1<sup>a</sup> a 25<sup>a</sup> e o TDH (distorção total);
- Ângulos de fase de ordens 1<sup>a</sup> a 25<sup>a</sup>.

Ressaltando que o Fluke para calcular essas variáveis das componentes harmônicas e armazena-las de forma já processadas, foi utilizando o Teorema de Fourier, já explanado anteriormente.

Cada medição foi realizada em intervalos de um segundo, ao longo de um período total de dez minutos. A Tabela 4 detalha especificamente as medições realizadas e os equipamentos envolvidos. Os equipamentos separados por “&”, indicam que estavam ligados em paralelo.

Tabela 4 – Lista de medições e seus equipamentos.

GRUPO DE MEDIÇÃO	EQUIPAMENTOS
01	Vent.vel_Baixa; Vent.vel_Alta; Ruído
02	Grill; Ruído
03	Vent.vel_Baixa; Vent.vel_Alta; Vent.vel_Baixa&Grill; Ruído
04	Liquid.vel_Baixa; Liquid.vel_Alta; Ruído
05	Liquid.vel_Baixa; Liquid.vel_Alta; Liquid.vel_Baixa&Grill; Liquid.vel_Alta&Grill; Ruído
06	Bat; Bat&Grill; Ruído
07	LED; Ruído
08	Liquid.vel_Baixa&LED; Liquid.vel_Alta&LED; LED; Ruído
09	Liquid.vel_Baixa; Cafet; Liquid.vel_Baixa&Cafet; Ruído

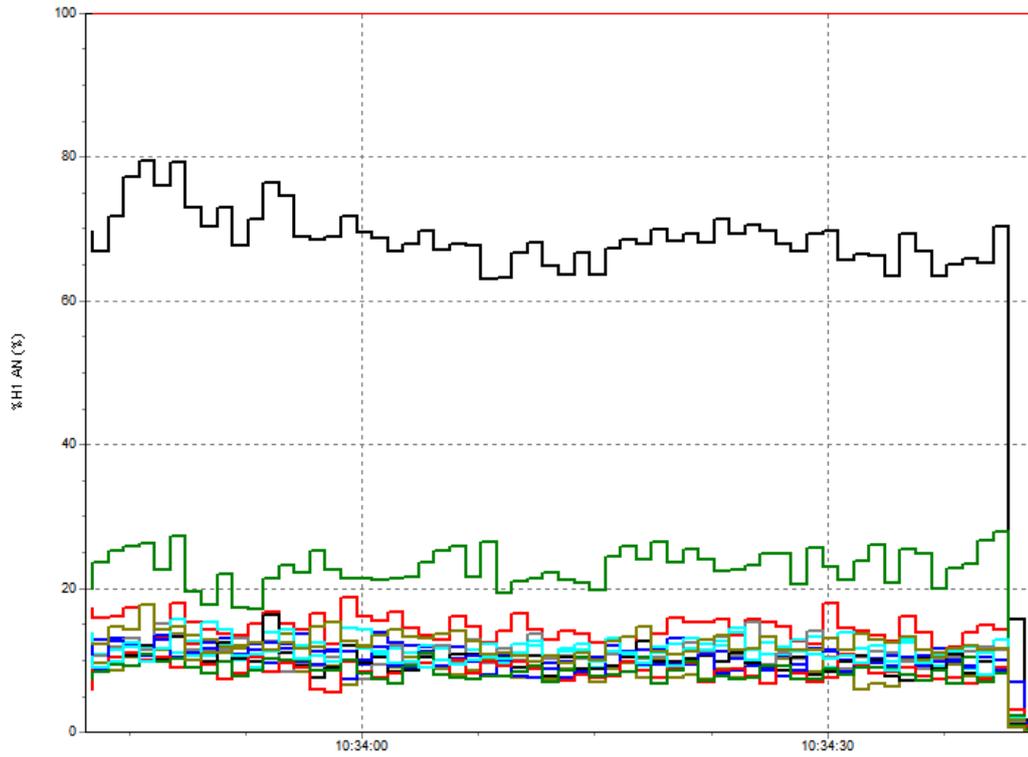
## 4.2 Pré-processamento dos dados

Mesmo os dados já sendo armazenados com as componentes harmônicas calculadas, é necessário fazer alguns ajustes para melhor utilização das medições realizadas do Fluke. Como apresentado na seção 3.1, os dados extraídos do software do próprio analisador são em formato TXT e com uma formatação não trivial para ser já diretamente trabalhada. Com isso, foi necessário adaptar os arquivos de medição ao formato CSV, adotando vírgulas para a separação das variáveis e pontos para a delimitação das unidades decimais.

Uma observação relevante incidiu sobre o comportamento dos equipamentos rotativos, como ventiladores e liquidificadores. Verificou-se que as distorções harmônicas apresentavam variações significativas em função da velocidade de operação desses aparelhos. Conseqüentemente, as medições envolvendo tais equipamentos foram categorizadas de acordo com a velocidade, baixa e alta, facilitando assim o processo de treinamento mais eficaz da Rede Neural Artificial para reconhecimento de padrões em diferentes níveis de velocidade. Tanto nas medições individuais, como as em paralelo com outros equipamentos.

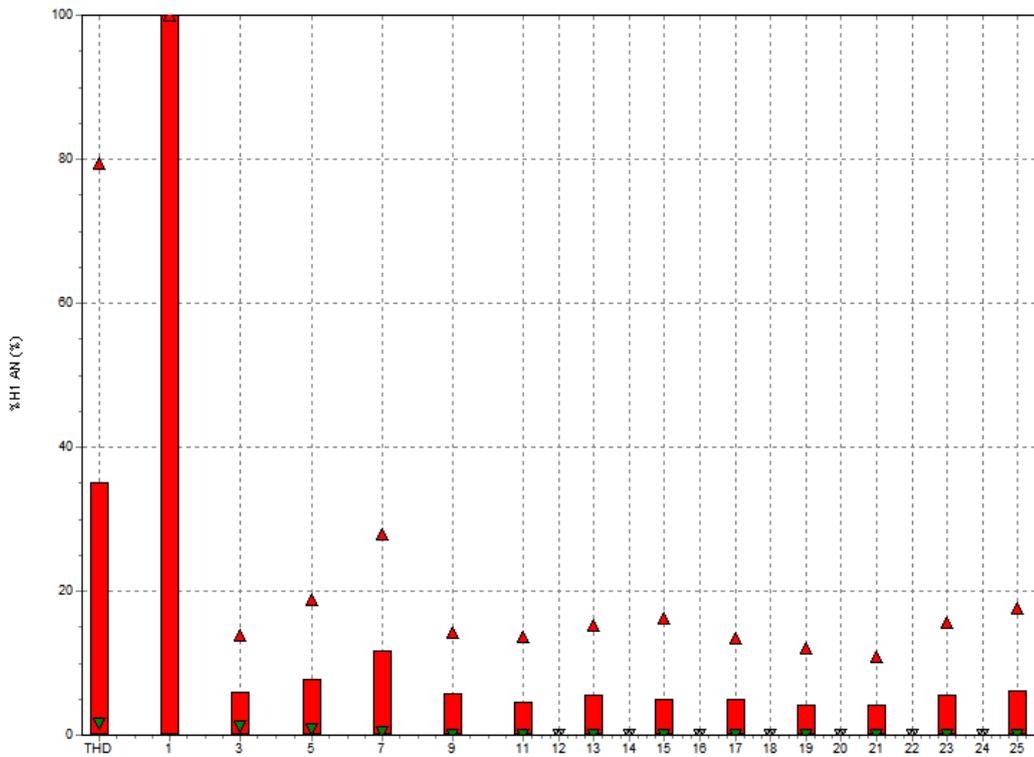
Para implementar o aprendizado supervisionado necessário neste estudo, foi desenvolvido um sistema de classificação que identifica qual equipamento ou combinação de equipamentos corresponde a cada conjunto de medições. A classificação por numérica tags é detalhada a seguir na Tabela 5, demonstrando como cada equipamento ou combinação de equipamentos é representado e reconhecido pelo modelo. A escolha de cada foi feita de modo esporádico. Uma ressalva é o Ruído, representada tag 5, indica que nenhum equipamento estava ligado no momento, só tendo o ruído harmônico do sistema, a seguir está demonstrando o comportamento desse ruído observado pelos harmônicos de corrente com, em percentual no domínio do tempo Figura 28 e o seu espectro em percentual Figura 29.

Figura 28 – Harmônicos de corrente do ruído, em percentual pelo tempo



Fonte: Autor.

Figura 29 – Harmônicos de corrente do ruído com seu espectro em percentual



Fonte: Autor.

Tabela 5 – Sistema de classificação de tags dos equipamentos ligados.

Tag	Equipamentos
0	Batedeira
1	Grill
2	Liquid.vel_Baixa
3	LED
4	Vent.vel_Alta
5	Ruído
6	Cafeteira
7	Liquid.vel_Alta
8	Batedeira&Grill
9	Vent.vel_Baixa&Grill
10	Cafeteira&Liquid.vel_Alta
11	Liquid.vel_Baixa&Grill
12	Liquid.vel_Alta&Grill
13	Liquid.vel_Baixa&LED
14	Liquid.vel_Alta&LED
15	Vent.vel_Baixa

No experimento, apenas os harmônicos de ordem ímpares foram escolhidos, como já explicado em 2.4. Mesmo configurando para extrair as componentes THD, 1<sup>a</sup> a 25<sup>a</sup>, apenas foram utilizados para o treinamento e reconhecimento o THD e as ordens de 3<sup>a</sup> a 15<sup>a</sup>, pois o analisador mede os harmônicos em por unidade (PU) em relação a corrente fundamental. Logo, a 1<sup>a</sup> é sempre representada por 1, ou seja, em percentual 100%, não sendo eficaz para diferenciação do experimento. Um aspecto crucial do uso de componentes em PU é que isso ajuda a mitigar o risco de uma Rede Neural Artificial (RNA) desenvolver uma tendência a identificar padrões harmônicos apenas pela amplitude em Amperes, e não pelo comportamento em si. Por exemplo, uma lâmpada LED de 5W pode exibir um perfil harmônico em PU idêntico ao de uma lâmpada de 15W. No entanto, devido à diferença nas magnitudes das correntes, uma RNA treinada com dados da lâmpada de 5W pode falhar ao tentar reconhecer a lâmpada de 15W. Utilizar a escala PU permite uma comparação mais direta do comportamento harmônico, independente da magnitude da corrente.

Com esse ponto abordado, foi seguido o método empregado em [11], onde a amplitude e a fase dos harmônicos foram convertidas para uma representação complexa, também explanada na seção 2.4.1. Neste formato, cada harmônico possui uma parte real e uma parte imaginária. Em Python foi criada uma função chamada “criar\_complexo”, na qual vai receber lista com a amplitude e o ângulo de fase para poder desmembrar com uma saída real e imaginária na variável z, Figura 30, basicamente, a função transforma uma representação de número complexo de forma polar (módulo e ângulo) para sua forma retangular (parte real e imaginária).

Essa abordagem permite uma análise mais eficiente e precisa dos harmônicos, facilitando o processamento e a interpretação dos dados em estudos relacionados à análise de sinais elétricos. Com essa abordagem as componentes harmônicas vão ser processadas de acordo com a Figura 31 abaixo.

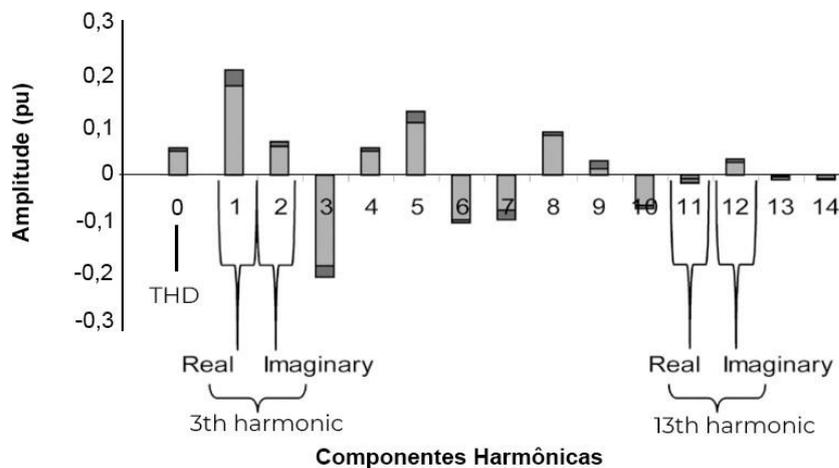
Figura 30 – Função em Python para tratamento complexo dos dados de harmônicos.

```
def criar_complexo(row):
    modulo_ih = row[modulo]
    angulo_graus_ih = row[angulo]
    angulo_radianos = math.radians(angulo_graus_ih)
    z = cmath.rect(modulo_ih, angulo_radianos)

    return z.real, z.imag
```

Fonte: Autor.

Figura 31 – Decomposição dos sinais harmônicos de corrente em parte real e imaginária.



Fonte: Adaptado de [11].

Para finalizar a preparação dos dados e treinar a RNA e tendo visto a decomposição complexa das componentes harmônicas anteriormente. De acordo com proposição em [11], já que dois equipamentos estão sendo alimentados pela mesma fonte, estão em paralelo e funcionam de forma independente um do outro, a corrente total consumida pelos os dois é uma combinação que deve corresponder a somas das correntes. Com esse princípio, foi elaborado conjuntos de dados de treinamento com a soma vetorial das componentes harmônicas dos equipamentos individualmente. Com esse método é possível reconhecer as combinações dos equipamentos a partir só das medições individuais, sem precisar medir cada caso o que tornaria inviável aplicar essa tecnologia para uma quantidade razoável de dispositivos.

Com esse propósito, a corrente fundamental foi propagada multiplicando-se cada componente em PU, tanto a real quanto imaginário, obtendo assim os valores das distorções em amperes. Isso permitiu a soma direta de cada componente de cada dispositivo. Em seguida, os valores foram convertidos para PU novamente, por meio da divisão da soma das correntes fundamentais dos equipamentos somados, resultando em um padrão equivalente aos outros harmônicos provenientes do dispositivo de medição Fluke. Com isso, os dados individuais e da combinação de 2 em 2 dos dispositivos, estão prontos para treinarem a RNA modelada a seguir.

### **4.3 Modelagem da RNA em Python**

Para criar a estrutura da RNA do trabalho proposto será utilizado a biblioteca *TensorFlow* com a versão mais recente 2.0. O mesmo é uma biblioteca em código aberto desenvolvida pela *Google Brain Team*, que possui como grande foco desenvolver modelos de inteligência artificial. O TensorFlow 2.0 simplifica o desenvolvimento de modelos de inteligência artificial ao oferecer comandos pré-configurados que facilitam a criação de modelos de aprendizado de máquina. Isso elimina a necessidade de construir modelos do zero. O destaque desta versão é a integração avançada com o Keras, que é uma biblioteca especializada para redes neurais, tornando o processo ainda mais acessível e eficiente [36].

Da sua modelagem, foram divididos os dados do banco de treinamento em 80% para o treinamento e 20% para validação da estrutura *Backpropagation*, pelo aprendizado supervisionado, ou seja, terá os dados de entrada para a RNA, chamados de X e os dados de identificação dos equipamentos e suas combinações, chamadas de Y. A escolha da proporcionalidade de cada etapa foi realizada de forma empírica escolhendo 4 partes para treinamento e 1 para validação, ou seja, 80% e 20%.

Para a modelagem da RNA, será considerada simples sendo a quantidade de dados de entrada, como já foi observado no tópico anterior, serão 15 itens, THD e a componente harmônica 3<sup>a</sup> a 15<sup>a</sup> decomposta em parte real e imaginária. De camadas, terá a camada de entrada com 15 termos, uma camada oculta, visto que os dados possuem a complexidade de não serem lineares, com 26 neurônios e a camada de saída com 16 neurônios. A escolha da quantidade de neurônios da camada oculta é algo mais empírico, onde por meio de testes consegue-se chegar a uma quantidade mais ideal para o seu problema. Contudo, segundo Jeff Heaton em [37], existem 3 bons métodos de escolher essa quantidade, ditas a seguir:

- Número de neurônios ocultos deve estar entre o tamanho da camada de entrada e o tamanho da camada de saída;
- Número de neurônios ocultos deve ser 2/3 do tamanho da camada de entrada, mais o tamanho da camada de saída;
- Número de neurônios ocultos deve ser menos que o dobro do tamanho da camada de entrada;

Para a RNA em questão, foi adotada a segunda opção, visto que foi o método que trouxe uma quantidade neurônios maior que a entrada e saída, mas não pesa significamente a rede em si. Para as funções de ativação, foi escolhida a combinação *ReLU* na camada oculta e *Softmax* na de saída, foram os que melhor se adaptaram para o problema de multiclases, na Figura 32 a seguir, está o código da estrutura da RNA em Python.

Figura 32 – Estrutura das camadas e neurônios da rede neural.

```

# Estruturas das camdas e neurônios

model = tf.keras.Sequential()
model.add(tf.keras.layers.InputLayer(input_shape=(15, )))
model.add(tf.keras.layers.Dense(26, activation='relu'))
model.add(tf.keras.layers.Dense(16, activation='softmax'))

```

Fonte: Autor.

Em relação a função perda e a função de otimizar o *Backpropagation*, foram escolhidas respectivamente o *sparse categorical crossentropy explicada na seção 2.2.1.1* e a função *Adam*, responsável pela estrutura do cálculo do gradiente na atualização dos pesos da RNA, detalhada em [38]. Com as funções e a modelagem da RNA escolhida, foram colocados para treinar as variáveis X e Y em uma quantidade de épocas de 1000 vezes. Outro ponto foi determinar a escolha do *batch size*, que é alocação de amostras para atualizar o gradiente, ou seja, ao invés de treinar o banco todo de uma vez, ele vai dividir em pacotes menores para treinar o modelo, escolheu-se 72 resultando em 31 divisões.

Ressaltando novamente, a construção do modelo é fundamentalmente baseada em empirismo, visto que não há uma fórmula específica para calcular com acurácia o valor ideal para cada variável mencionada. A escolha dos parâmetros, como o número de épocas, o tamanho do *batch size*, e a estrutura da rede neural, depende em grande parte da experimentação e ajuste conforme os resultados observados. Trecho do código pode ser visto a seguir em Figura 33.

Figura 33 – Implementação das funções otimizadora e perda.

```

model.compile(optimizer=tf.keras.optimizers.Adam(learning_rate=0.001),
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])

epochs_Adam = model.fit(X_train,Y_train, epochs=1000, batch_size= 72)

```

Fonte: Autor.

Em conclusão, a saída do modelo consiste em uma matriz que descreve a probabilidade de cada reconhecimento pertencer a uma classe específica, conforme ilustrado na Figura 34 a seguir. A classe com o maior valor de probabilidade é considerada a mais provável e, conseqüentemente, escolhida como o resultado final.

Figura 34 – Ilustração da saída do reconhecimento a RNA.

```
array([3.80963678e-024, 2.87927413e-243, 1.00782681e-007, 1.56707822e-040,
       6.29994505e-180, 2.21881702e-010, 4.35723392e-165, 4.02056230e-013,
       1.20255951e-031, 2.09161740e-143, 1.13595957e-037, 9.68646262e-008,
       3.08764897e-081, 9.99999355e-001, 4.47316564e-007, 5.80452412e-093])
```

Fonte: Autor.

#### 4.4 Algoritmo do cálculo do consumo de energia

Após o treinamento da Rede Neural, será o processo para determinação do consumo energético em kWh. Para tal finalidade, além dos 15 termos dos dados de entrada da RNA para reconhecimento, este novo conjunto de dados inclui informações adicionais, como tensão eficaz, corrente eficaz, data e horário das ocorrências das medições. Com essas informações foi possível elaborar um novo trecho de código, utilizando a biblioteca *Pandas*, responsável por organizar os dados e calcular o consumo energético em kWh, o qual pode ser visto a seguir em Figura 35.

Figura 35 – Trecho responsável pelo cálculo do consumo energético.

```
## Calcular a diferença em horas
df2['Delta_t [h]'] = pd.to_datetime(df2['Horario']).astype(str).diff().dt.total_seconds().fillna(1) /
3600
df2

## Energia Instantanea [kWh]
df2['Vrms'] = df['Vrms.ph-n.AN.Méd.'].
df2['Irms'] = df['Corrente.A.Méd.'].

def retorna_energia_instantanea(delta_t, Vrms, Irms):
    return (delta_t * Vrms * Irms) / 1000

df2['kWh'] = df2.apply(lambda x: retorna_energia_instantanea(x['Delta_t [h]'], x['Vrms'], x['Irms']), axis=1)
```

Fonte: Autor.

Df2 é um *dataframe* é uma estrutura de dados que organiza os dados em uma tabela bidimensional, o mesmo vai ter uma coluna *Delta\_t [h]* que vai receber o os valores da diferença em horas de cada intervalo de medição. Na função “*retorna\_energia\_instantanea*”, a mesma vai receber os valores de *Delta\_t [h]*, tensão em volts, corrente em ampere. Com isso, ela será responsável pelo cálculo do consumo em kWh igual a equação (4.1) a seguir.

$$E_{kWh} = \frac{\text{potência}(W) \times \text{tempo}(h)}{1000} \quad (4.1)$$

Já na Tabela 6, é uma amostra do *dataframe* Df2 criado para receber os valores calculados do consumo energético.

Tabela 6 – Representação do dataframe com o valor do consumo calculado pelo algoritmo.

	Horario	Delta_t [h]	Vrms	Irms	kWh
0	11:51:13.393000	0.000278	213.32	5.930	0.000351
1	11:51:14.393000	0.000278	213.32	5.926	0.000351
2	11:51:15.393000	0.000278	213.25	5.921	0.000351
3	11:51:16.393000	0.000278	213.29	5.920	0.000351
4	11:51:17.393000	0.000278	213.03	5.910	0.000350
...	...	...	...	...	...
62	11:54:19.393000	0.000278	213.48	5.883	0.000349
63	11:54:20.393000	0.000278	213.94	5.894	0.000350
64	11:54:21.393000	0.000278	213.95	5.894	0.000350
65	11:54:22.393000	0.000278	213.51	5.881	0.000349
66	11:54:23.393000	0.000278	213.38	5.877	0.000348

Fonte: Autor.

Quando a RNA processa as medições, ela identifica qual equipamento ou combinação de equipamentos está ativa com base na maior probabilidade. Essa identificação é adicionada ao *dataframe* original em uma nova coluna chamada Rec. Com isso, o *dataframe* atualizado retornará uma estrutura a seguir.

Tabela 7 – Representação atualizado do dataframe.

	Horario	Delta_t [h]	Vrms	Irms	kWh	Rec
0	11:51:13.393000	2.778e-04	213.32	5.930	3.514e-04	0
1	11:51:14.393000	2.778e-04	213.32	5.926	3.511e-04	0
2	11:51:15.393000	2.778e-04	213.25	5.921	3.507e-04	0
3	11:51:16.393000	2.778e-04	213.29	5.920	3.507e-04	0
4	11:51:17.393000	2.778e-04	213.03	5.910	3.497e-04	8
5	11:51:18.393000	2.778e-04	213.00	5.907	3.495e-04	8
6	11:51:19.393000	2.778e-04	213.19	5.910	3.500e-04	8
7	11:51:20.393000	2.778e-04	213.63	5.919	3.512e-04	8
8	11:51:21.393000	2.778e-04	213.35	5.910	3.502e-04	8
9	11:51:22.393000	2.778e-04	213.20	5.903	3.496e-04	8
10	11:51:23.393000	2.778e-04	213.33	5.904	3.499e-04	8
11	11:51:24.393000	2.778e-04	213.20	5.898	3.493e-04	8
12	11:51:25.393000	2.778e-04	213.14	5.895	3.490e-04	8
..	..	..	..	..	..	-

Fonte: Autor.

Finalizando a análise e tendo o retorno do consumo de energia em kWh acumulado por meio da utilização da função groupby, Figura 36 . Portando a mesma vai somar todos os valores do banco de medições passados e irá agrupar de acordo com as classes reconhecidas pela RNA, ilustrada no exemplo em Tabela 8.

Figura 36 – Código da função groupby.

```
soma_kwh = df2.groupby('Rec').agg({'kWh': sum})
```

Fonte: Autor.

Tabela 8 – Representação do acumulado do consumo agrupado.

kWh	
Rec	
0	0.001404
8	0.077391

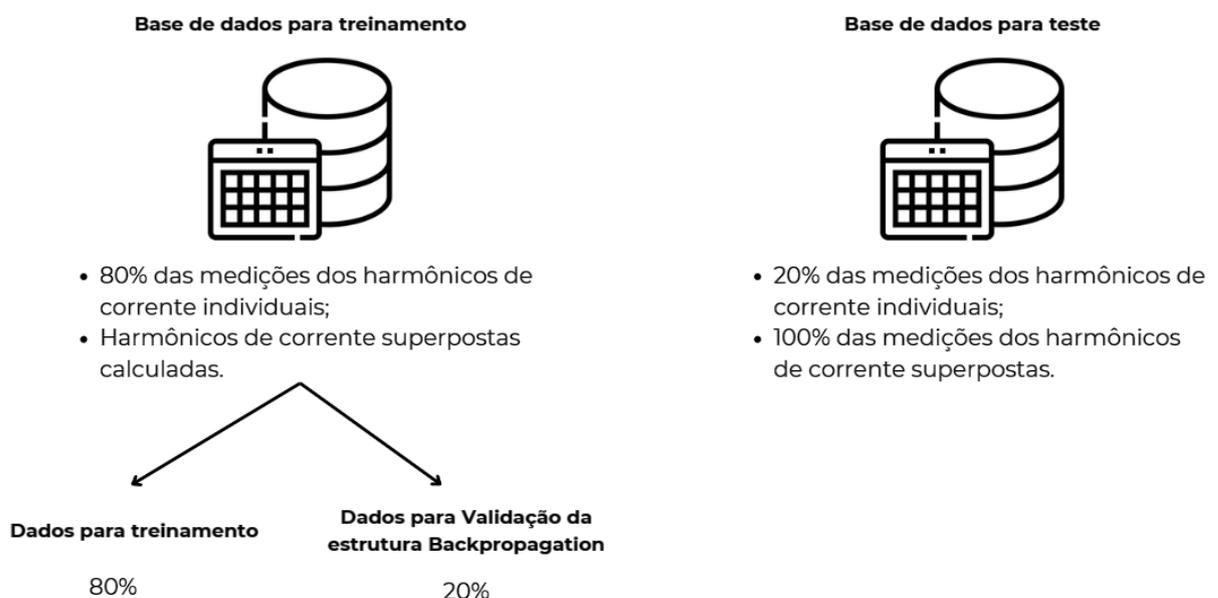
Fonte: Autor.

## 4.5 Avaliação da performance

Nesse tópico será abordado como foi realizada os testes da modelagem escolhida. Basicamente vai ser sobre comparar os resultados retornados da RNA com os dados reais das medições obtidas diretamente do analisador. Logo, vai ser em duas etapas, a primeira é se a RNA consegue reconhecer a quantidade de vezes que tais equipamentos foram ligados e a segunda é por meio da comparação do consumo energético, em kWh, calculado em relação ao medido.

Antes de detalhar as etapas de validação montadas, vale a ressalva de como foi realizada as divisões das medições feitas. As medições foram divididas em duas bases de dados, uma que ia compor o banco de treinamento da RNA, com 80% das medições individuais de cada equipamento e com os harmônicos de corrente superpostos calculados das combinações. E a outra parte, com 20% das individuais e as medições reais das combinações, formaram o banco de reconhecimento. Foi realizado dessa forma para evitar algum tipo de vicio ou que a mesma medição usada para treinamento se repetisse no momento dos testes finais. Lembrando que o banco de treinamento possui outra divisão interna, que foi falada no tópico 4.3, para o cálculo de ida e volta do *Backpropagation*. Processo ilustrado abaixo em Figura 37.

Figura 37 – Representação das bases de dados separadas.



Fonte: Autor.

Na primeira forma de validação, utilizou-se as medições do banco de reconhecimento e com a função *shuffle*, embaralhou todas as medições para evitar algum tipo de vício de reconhecimento com as medições contínuas. Com isso, colocando a RNA para processar os dados, foi comparado a quantidade de medições reconhecidas por ela com a realidade de cada medição. Finalizando com a porcentagem de reconhecimento para cada classificação e a total do banco de reconhecimento.

A segunda forma de validação, foi colocar as medições do banco de reconhecimento para a rede neural processar como se fosse medições reais de forma contínua, agrupar os valores reconhecidos e ter o valor calculado do consumo energético, explicado no tópico anterior. Com esses valores, foi comparado com o que de fato foi medido no analisador Fluke, logo tem-se a porcentagem de comparação do consumo para cada classificação e total.

## 5 RESULTADOS

Neste capítulo, serão apresentados os resultados obtidos da análise comparativa entre os dados gerados pela rede neural e as medições reais. Esta comparação foi realizada utilizando somente os dados separados para o banco de reconhecimento.

Com isso será dividido em três partes, a primeira é com base no banco de treinamento, onde a RNA dividiu os dados em 80/20 para treinar e validar. A partir disso, pode-se verificar a taxa das perdas decrescendo e a acurácia aumentando a cada época.

Na segunda parte, será apresentado os resultados da identificação de cada classe de forma discreta, tanto dos equipamentos individualizados como dos que estavam em paralelismo. Logo, será possível verificar a acurácia do reconhecimento discreto e da superposição dos harmônicos de corrente calculados no banco de treinamento.

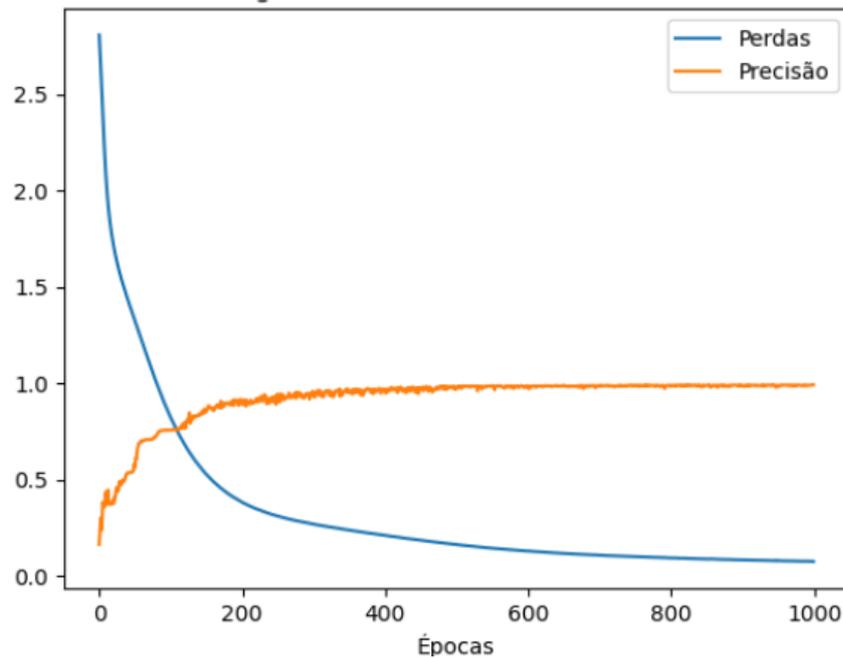
Na terceira parte do estudo, será realizado a análise através do acúmulo do consumo energético, expresso em kWh, comparando os resultados obtidos pelo reconhecimento da RNA, junto do algoritmo que retorna o consumo dos equipamentos calculados, com os valores reais obtidos a partir das medições do analisador de energia.

### 5.1 Taxa das perdas e acurácia ao longo do treinamento da RNA

Ao analisar o gráfico, Figura 38 que representa as curvas das taxas de perda e acurácia obtidas durante o treinamento da RNA com a função de perda *sparse\_categorical\_crossentropy*, observa-se que valores de perda próximos a 0 são indicativos de um bom aprendizado. No entanto, é crucial que esses valores não atinjam exatamente 0, pois isso poderia indicar um fenômeno de *overfitting*, onde o modelo se ajusta excessivamente aos dados de treinamento, comprometendo sua capacidade de generalizar para novos dados. Neste contexto, a perda final alcançada foi de 0,0854, sugerindo um ajuste adequado sem incidência de *overfitting*.

Quanto à acurácia calculada pela RNA, um valor mais próximo de 1 indica uma alta taxa de acertos do modelo nos dados que foi capaz de testar. Para esta métrica, o valor final observado foi de 0,9885, demonstrando uma elevada acurácia do modelo em sua tarefa de classificação com os dados de validação separados no banco de treinamento.

Figura 38 – Progresso de treinamento do modelo da RNA.



Fonte: Autor.

## 5.2 Acurácia do reconhecimento discreto

Após a apresentação dos resultados relacionados ao processo de aprendizado do modelo, serão expostos os resultados advindos do reconhecimento realizado no conjunto de testes. É importante destacar que os dados foram aleatorizados conforme descrito na seção 4.5, e submetidos individualmente para avaliação pela RNA.

Logo, avaliando apenas a reconhecimento da quantidade de medições reais, individuais e paralelos, está detalhado na Tabela 9 a seguir. Onde cada número representa a tag de identificação da lista de equipamentos da Tabela 5 e suas porcentagens do acerto.

Tabela 9 – Resultado da identificação discreta da RNA.

TAG	EQUIPAMENTOS	ACURÁCIA (%)
0	Batedeira	100,00%
1	Grill	96,97%
2	Liquid.vel_Baixa	100,00%
3	LED	87,50%
4	Vent.vel_Alta	100,00%
5	Ruído	100,00%
6	Cafeteira	100,00%
7	Liquid.vel_Alta	95,83%
8	Batedeira&Grill	100,00%
9	Vent.vel_Baixa&Grill	86,27%
10	Cafeteira&Liquid.vel_Alta	99,26%
11	Liquid.vel_Baixa&Grill	86,52%
12	Liquid.vel_Alta&Grill	89,17%
13	Liquid.vel_Baixa&LED	99,07%
14	Liquid.vel_Alta&LED	96,31%
15	Vent.vel_Baixa	100,00%

Analisando os dados da tabela anterior, verifica-se que o modelo proposto demonstrou uma excelente acurácia na identificação da maioria das cargas utilizadas no experimento, incluindo aquelas que representam a superposição teórica em relação às reais. Avaliando o aspecto global do reconhecimento, verificou-se uma percentagem de 94,12% de acertos da RNA, configurando-se um ótimo resultado.

Entre as combinações que apresentaram menores percentagens de acurácia, destacam-se a do ventilador em baixa velocidade com o Grill, liquidificador em baixa velocidade junto ao Grill, e a lâmpada de LED, alcançando 86,27%, 86,52% e 87,50% de acerto, respectivamente. Esses valores podem ser considerados aceitáveis dentro do contexto do experimento.

### 5.3 Acurácia do reconhecimento contínuo e o consumo energético acumulado

Concluindo o capítulo de resultados, serão apresentados os valores de acurácia obtidos agora com as medições contínuas. Estas replicam o comportamento real de um medidor ou analisador. Cabe ressaltar que os resultados apresentados são posteriores ao pré-tratamento, do desmembramento das componentes harmônicas abordadas na seção 4.2.

Com isso segue, na Tabela 10, a apresentação dos resultados referentes à acurácia do reconhecimento das medições, acompanhados do algoritmo responsável pelo cálculo e do acumulado do consumo energético em kWh. Portanto, as precisões a seguir referem-se aos valores do consumo individualizados das classes reconhecidas pelo modelo da RNA e retornados pelo algoritmo, comparados com os dados de consumo medidos diretamente no analisador.

Tabela 10 – Resultados do reconhecimento e consumo energético acumulado.

GRUPO DE MEDIÇÃO	EQUIPAMENTOS	CONSUMO MEDIDO (kWh)	CONSUMO ALGORITMO (kWh)	ACURÁCIA (%)
01	Vent.vel_Baixa	7,3700E-04	7,7122E-04	95,56%
	Vent.vel_Alta	1,6763E-03	1,6520E-03	98,55%
	Ruído	-	-	99,39%
02	Grill	7,3362E-02	6,6047E-02	90,03%
	Ruído	-	-	85,80%
03	Vent.vel_Baixa	1,0352E-03	9,8400E-04	95,05%
	Vent.vel_Alta	4,6602E-04	4,4000E-04	94,42%
	Vent.baixa&Grill	1,1443E-01	1,1144E-01	97,38%
	Grill	2,2035E-02	2,4353E-02	90,48%
	Ruído	-	-	100,00%
04	Liquid.vel_Baixa	9,1505E-03	9,5930E-03	99,69%
	Liquid.vel_Alta	9,8553E-03	9,7750E-03	99,19%
	Ruído	-	-	97,56%
05	Liquid.vel_Baixa	5,1787E-03	5,1660E-03	99,75%
	Liquid.vel_Alta	3,2335E-03	3,2750E-03	98,72%

	Liquid.vel_Baixa&Grill	6,4517E-02	5,9781E-02	92,66%
	Liquid.vel_Alta&Grill	9,7027E-02	8,6163E-02	88,80%
	Ruído	-	-	86,52%
06	Batedeira	7,2101E-03	6,3260E-03	87,80%
	Batedeira&Grill	1,1656E-01	1,0567E-01	90,66%
	Ruído			100,00%
07	LED	1,7360E-03	1,7363E-03	99,98%
	Ruído	-	-	99,99%
08	Liquid.vel_Alta&LED	8,9243E-03	9,0440E-03	98,66%
	Liquid.vel_Baixa&LED	8,0159E-03	7,6320E-03	95,21%
	LED	1,2159E-05	1,2000E-05	98,70%
	Ruído	-	-	100,00%
09	Liquid.vel_Baixa	2,3824E-03	2,5520E-03	92,88%
	Cafeteira	2,6488E-02	2,6488E-02	100,00%
	Liquid.vel_Baixa&Cafeteira	2,7360E-02	2,3620E-02	86,33%
	Ruído	-	-	100,00%

Após análise dos resultados, observa-se que a acurácia das medições contínuas seguiu uma proporção similar à das avaliações discretas. A maioria dos valores de acurácia ultrapassou os 90%, um indicativo de excelência. O valor mais baixo registrado foi de 85,80%, atribuído ao ruído no grupo de medição 02. Quanto à acurácia global, alcançou-se 95,31%, um desempenho ligeiramente superior ao observado nas medições discretas.

Um aspecto importante a destacar diz respeito aos resultados relacionados ao ruído. Este foi definido para os momentos em que nenhuma carga estava ligada, resultando em um consumo energético nulo. Entretanto, observou-se que, em alguns momentos, o algoritmo indicou valores de consumo para esses períodos de ruído, o que foi considerado um erro de reconhecimento, mas mesmo assim os valores são tão pequenos que foram desconsiderados. Entretanto, foi levado em conta a quantidade de vezes que o ruído foi detectado comparado à quando realmente aconteceu pelas medições. Por outro lado, quando houve 100% de assertividade, isso significou que o ruído foi corretamente identificado pelo algoritmo e que nesses casos, reportou corretamente.

## 6 CONCLUSÕES E PROPOSTAS DE CONTINUIDADE

Neste trabalho, apresenta-se uma proposta inovadora que explora a aplicação da tecnologia de redes neurais profundas no reconhecimento de cargas elétricas. Esta abordagem é realizada por meio da análise das assinaturas harmônicas das correntes, visando quantificar o consumo energético em kWh para cada configuração treinada. O objetivo central deste estudo é fomentar a aplicabilidade da eficiência energética inteligente em ambientes residenciais, comerciais e industriais.

Esta metodologia dispensa a necessidade de investimentos adicionais em sensores de corrente ou medidores descentralizados para o monitoramento energético individualizado dos equipamentos. Destaca-se, portanto, o potencial significativo desta proposta para a gestão otimizada do consumo de energia, contribuindo para uma melhor performance na eficiência energética. Para a realização deste estudo, foi essencial a análise detalhada dos harmônicos de corrente. Verificou-se que a superposição destes harmônicos, considerando tanto a amplitude quanto o ângulo de fase, proporciona uma simulação altamente precisa da superposição real observada nos experimentos. Este aspecto é fundamental para aplicabilidade da metodologia em vários equipamentos, não precisando de medições nas várias possibilidades de combinação possíveis.

Importante ressaltar que o estudo se concentrou em cargas residenciais e dispositivos monofásicos. As medições foram realizadas em ensaios controlados em laboratório, utilizando um instrumento de medição altamente confiável e certificado: o analisador e grandezas elétricas Fluke 435 series II. Este equipamento permitiu a coleta de dados precisos, incluindo a tensão e corrente, a Distorção Harmônica Total (THD) de corrente, além dos componentes harmônicos do 3º ao 15º, desmembrados em suas partes reais e imaginárias.

Após modelar e treinar a RNA, os resultados foram comparados com os dados reais, tanto individuais quanto a superposição calculada com a real. Esta comparação confirmou que a RNA foi eficaz em reconhecer as cargas elétricas corretamente, assim como o algoritmo para realizar o consumo acumulado individualizado reconhecido entre as classes da RNA. Assim, os objetivos do estudo foram alcançados com sucesso, demonstrando a utilidade das redes neurais profundas para monitorar e gerenciar o consumo de energia de forma inteligente.

Embora os resultados obtidos sejam promissores, é importante ressaltar algumas limitações e desafios encontrados durante o estudo. Uma das dificuldades enfrentadas foi a disponibilidade limitada do laboratório e do instrumento de medição. Além disso, houve restrições quanto aos equipamentos disponíveis para coleta de dados e à variedade de marcas e modelos de fabricantes.

Dessa forma, seria imprudente afirmar que os resultados obtidos com um único tipo de equipamento podem ser aplicados para estabelecer um perfil harmônico abrangente para todas as variações desse mesmo equipamento disponíveis no mercado. É importante reconhecer que o perfil harmônico de um equipamento é influenciado não apenas pela sua natureza e funcionalidade, mas também pela qualidade construtiva imposta por cada fabricante. Isso significa que pode haver variações nos padrões harmônicos entre produtos semelhantes de diferentes marcas. Expandir a base de dados para incluir mais tipos de equipamentos e fabricantes melhoraria a acurácia do modelo de rede neural. Isso tornaria os resultados mais aplicáveis a uma variedade maior de situações, garantindo que o modelo seja eficaz em condições mais variadas.

## 6.1 Trabalhos Futuros

A seguir, será abordada sugestões de propostas futuras para contínuo desenvolvimento do que foi elaborado neste trabalho:

- Expandir a modelagem para contemplar cargas bifásicas e trifásicas;
- Testar com uma base de dados maior, inclusive com mais cargas em paralelo testando a superposição calculada x real;
- Verificar se há alguma limitação ou até que ponto vai um reconhecimento aceitável com várias cargas ligadas em paralelo;
- Reconhecimento de falhas elétricas por meio dos harmônicos de corrente;
- Aplicar o modelo embarcado em algum medidor com a tecnologia da Internet das Coisas (IoT) e verificar a acurácia com medições em tempo real.

## REFERÊNCIAS

1. CCEE. Consumo de energia no Brasil cresceu 1,4% no primeiro semestre de 2023, aponta CCEE. **CCEE**, 2023. Disponível em: <<https://www.ccee.org.br/pt/web/guest/-/consumo-de-energia-no-brasil-cresceu-1-4-no-primeiro-semester-de-2023-aponta-ccee>>. Acesso em: 17 Fevereiro 2024.
2. FEDERAÇÃO DAS INDÚSTRIAS DO ESTADO DE SANTA CATARINA - FIESC. Desperdício elétrico no Brasil equivale ao consumo de 20 milhões de residências. **FIESC**, 2022. Disponível em: <<https://fiesc.com.br/pt-br/imprensa/desperdicio-eletrico-no-brasil-equivale-ao-consumo-de-20-milhoes-de-residencias>>. Acesso em: 17 Fevereiro 2024.
3. EMPRESA DE PESQUISA ENERGÉTICA - EPE. Anuário Estatístico de Energia Elétrica. **EPE**, 2023. Disponível em: <<https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-160/topico-168/anuario-factsheet.pdf>>. Acesso em: 17 Fevereiro 2024.
4. PROCEL. Resultado procel 2023. **Procel Info**, 2023. Disponível em: <[http://www.procelinfo.com.br/resultadosprocel2023/Procel\\_rel\\_2023\\_web.pdf](http://www.procelinfo.com.br/resultadosprocel2023/Procel_rel_2023_web.pdf)>. Acesso em: 17 Fevereiro 2024.
5. ZHUANG, M.; SHAHIDEHPOUR, M.; LI, Z. **An overview of non-intrusive load monitoring**: Approaches, business applications, and challenges. international conference on power system technology (POWERCON). [S.l.]: IEEE. 2018. p. 4291-4299.
6. HART, G. W. Nonintrusive appliance load monitoring. **Proceedings of the IEEE**, v. 80, n. 12, p. 1870-1891, 1992.
7. SAP INSIGHTS. Medição inteligente: ajudando os clientes a reduzir o consumo. **SAP Insights**. Disponível em: <<https://www.sap.com/brazil/insights/smart-metering-helping-customers-reduce-consumption.html>>. Acesso em: 17 Fevereiro 2024.
8. BARBOSA, E. et al. APLICAÇÃO DE REDES NEURAIAS ARTIFICIAIS PARA O RECONHECIMENTO DE ASSINATURAS HARMÔNICAS DE EQUIPAMENTOS ELETROMÉDICOS. **Revista de Sistemas e Computação-RSC**, v. 7, n. 1, 2017.
9. BERNARDES, W. M.; SILVA, S. F. D. P.; FERNANDES, R. A. S. **Reconhecimento de cargas não lineares hospitalares por meio de redes neurais artificiais**. IV Simpósio Brasileiro de Sistemas Elétricos. Goiânia: [s.n.]. 2012.
- 10 MAZZINI, A. P.; BERNARDES, W. M.; DE VASCONCELOS, F. M. **Application of artificial neural networks for discrimination of nonlinear loads**. IEEE PES Conference on Innovative Smart Grid Technologies (ISGT Latin America). [S.l.]: [s.n.]. 2013. p. 1-7.
- 11 SRINIVASAN, D.; NG, W. S.; LIEW, A. C. Neural-network-based signature recognition for harmonic source identification. **IEEE transactions on power delivery**, v. 21, n. 1, p. 398-405, 2005.
- 12 TURING, A. M. Computing Machinery and Intelligence. **Mind**, v. 59, n. 236, p. 433–460, 1950.
- 13 CHOLLET, F. **Deep learning with Python**. [S.l.]: Simon and Schuster, 2021.

- 14 BARROS, P. Aprendizagem de Máquina: Supervisionada ou Não Supervisionada? . **Medium**, 2016. Disponível em: <<https://medium.com/opensanca/aprendizagem-de-maquina-supervisionada-ou-n%C3%A3o-supervisionada-7d01f78cd80a>>. Acesso em: 22 Fevereiro 2024.
- 15 GOMES, L. M. Clusterização de texto de reclamação não supervisionada usando K-means com python. **LAMFO**, 2019. Disponível em: <[https://lamfo-unb.github.io/2019/09/02/cluster\\_texto/](https://lamfo-unb.github.io/2019/09/02/cluster_texto/)>. Acesso em: 01 Abril 2024.
- 16 NEVES, E. C. Aprendizado por Reforço #1— Introdução. **Medium**, 2020. Disponível em: <<https://medium.com/turing-talks/aprendizado-por-refor%C3%A7o-1-introdu%C3%A7%C3%A3o-7382ebb641ab>>. Acesso em: 22 Fevereiro 2024.
- 17 GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.I.]: The Mit Press, 2016.
- 18 HAYKIN, S. **Neural networks - A comprehensive Foudation**. [S.I.]: Prentice Hall, 1999.
- 19 MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, p. 115-133, 1943.
- 20 FERNANDES, R. A. S. **Identificação de fontes de correntes harmônicas por redes neurais artificiais**. Tese (Doutorado) - Universidade de São Paulo, USP. São Paulo. 2009.
- 21 MANTOVANI, W. A. **Utilização de redes neurais recorrentes na caracterização de cargas não lineares em sistemas elétricos**. Dissertação (Mestrado) - Faculdade de Engenharia , UNESP. [S.I.]. 2011.
- 22 ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386, 1958.
- 23 WERBOS, P. J. **Beyond regression: new tools for prediction and analysis in the behavioral**. Thesis (PhD) – Harvard University. Cambridge. 1974.
- 24 WANG, Q. E. A. A comprehensive survey of loss functions in machine learning. **Annals of Data Science**, p. 1-26, 2020.
- 25 ROCHA, J. E. **QUALIDADE DA ENERGIA ELÉTRICA**. [S.I.]: [s.n.], 2016.
- 26 AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, ANEEL. **Procedimentos de Distribuição. no Sistema Elétrico Nacional (PRODIST): Módulo 8-Qualidade da Energia Elétrica**. [S.I.]. 2010.
- 27 ARRILLAGA, J.; WATSON, N. R.; CHEN, S. **Power system quality assessment**. [S.I.]: John Wiley & Sons, 2000.
- 28 FRANCISCO, C. D. L. R. **Harmonics and power systems**. [S.I.]: CRC press, 2006.
- 29 SANTOSO, S. M. F. M. R. C. D. A. H. W. B. **Electrical Power Systems Quality**. 3. ed. [S.I.]: McGraw-Hill Education, 2012.
- 30 OPPENHEIM, A. V.; WILLISKY, A. S.; NAWAB, S. H. **Sinais e sistemas**. 2. ed. São Paulo: Pearson Education do Brasil, 2010.

- 31 XAVIER, G.; JR, J. R. M. Agregação Temporal dos Ângulos de Fase das Componentes Harmônicas – Parte I: Desenvolvimento da Metodologia. **Anais da XIV Conferência Brasileira sobre Qualidade da Energia Elétrica**, Campinas, 2021. Disponível em: <<https://proceedings.science/cbqee-2021/trabalhos/agregacao-temporal-dos-angulos-de-fase-das-componentes-harmonic-as-parte-i-desenv?lang=pt-br>>. Acesso em: 17 Fevereiro 2024.
- 32 OLIVEIRA, T. T. D. **Estudo da distorção harmônica em redes de distribuição de baixa tensão com sistemas fotovoltaicos e veículos elétricos**. Dissertação (Mestrado) - Universidade Federal do Rio Grande do Sul, UFRS. Rio Grande do Sul. 2019.
- 33 KANG, H. E. A. Household appliance classification using lower odd-numbered harmonics and the bagging decision tree. **IEEE Access**, v. 8, p. 55937-55952, 2020.
- 34 FLUKE CORPORATION. Fluke 434-II/435-II/437-II - Analisadores de Qualidade de Potência e Energia Trifásicos. **FLUKE**, January 2012. Disponível em: <[https://dam-assets.fluke.com/s3fs-public/F430-II\\_umpor0100.pdf](https://dam-assets.fluke.com/s3fs-public/F430-II_umpor0100.pdf)>. Acesso em: 17 Fevereiro 2024.
- 35 IEEE. 519-2022 - IEEE Standard for Harmonic Control in Electric Power Systems. **IEEE Xplore**, p. 1-31, 2022. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9848440&isnumber=9848439>>. Acesso em: 17 Fevereiro 2024.
- 36 DATABRICKS. TensorFlow. **databricks**. Disponível em: <<https://www.databricks.com/br/glossary/tensorflow-guide>>. Acesso em: 02 Abril 2024.
- 37 HEATON, J. **Introduction to neural networks with Java**. [S.l.]: Heaton Research, 2008.
- 38 KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. **arXiv preprint arXiv**, 2014.
- 39 PULZ, L. T. C. **Uso de pseudomedidas em estimador de estados para cálculo de distorção harmônica em sistemas elétricos**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, UFRGS. Porto Alegre. 2017.