



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS QUIXADÁ
CURSO DE GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO

JOSÉ TIAGO TORRES DE LIMA

**SISTEMA DE IDENTIFICAÇÃO DE DISPOSITIVOS ELÉTRICOS BASEADO NA
CLASSIFICAÇÃO DE ASSINATURAS DE CORRENTE ALTERNADA COM
APRENDIZADO DE MÁQUINA**

QUIXADÁ

2026

JOSÉ TIAGO TORRES DE LIMA

SISTEMA DE IDENTIFICAÇÃO DE DISPOSITIVOS ELÉTRICOS BASEADO NA
CLASSIFICAÇÃO DE ASSINATURAS DE CORRENTE ALTERNADA COM
APRENDIZADO DE MÁQUINA

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação do Campus Quixadá da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia de Computação.

Orientador: Prof. Dr. André Ribeiro Braga.

QUIXADÁ

2026

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- L698s Lima, José Tiago Torres de.
Sistema de identificação de dispositivos elétricos baseado na classificação de corrente alternada com
aprendizado de máquina / José Tiago Torres de Lima. – 2026.
65 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Quixadá,
Curso de Engenharia de Computação, Quixadá, 2026.
Orientação: Prof. Dr. André Ribeiro Braga.
1. Aprendizado de máquina. 2. Monitoramento não intrusivo. 3. Instrumentação eletrônica. 4. Sistema
embarcado. 5. Eficiência energética. I. Título.

CDD 621.39

JOSÉ TIAGO TORRES DE LIMA

SISTEMA DE IDENTIFICAÇÃO DE DISPOSITIVOS ELÉTRICOS BASEADO NA
CLASSIFICAÇÃO DE ASSINATURAS DE CORRENTE ALTERNADA COM
APRENDIZADO DE MÁQUINA

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Engenharia de Com-
putação do Campus Quixadá da Universidade
Federal do Ceará, como requisito parcial à
obtenção do grau de bacharel em Engenharia de
Computação.

Aprovada em: 19/01/2026

BANCA EXAMINADORA

Prof. Dr. André Ribeiro Braga (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Luis Rodolfo Rebouças Coutinho
Universidade Federal do Ceará (UFC)

Prof. Dr. Cristiano Bacelar de Oliveira
Universidade Federal do Ceará (UFC)

Dedico este trabalho à minha mãe, que me amou antes que eu soubesse existir. E aos meus eus que, mesmo calados, sonharam por mim.

AGRADECIMENTOS

Gostaria de agradecer ao prof. Dr. André Ribeiro Braga e ao Eng. Me. Abdul-Hamid Matos Moreira pela oportunidade de orientação ao longo deste trabalho; aos docentes que compuseram a banca avaliadora e que contribuíram com sugestões fundamentais para a conclusão desta pesquisa.

À minha mãe, Marciana Torres, pelo apoio fundamental nos momentos de incerteza. Agradeço por estar ao meu lado em toda esta jornada e, principalmente, por me ensinar a persistir e a buscar sempre o melhor da vida.

Aos meus irmãos, Thais Torres e Yago Torres, por tanto carinho e por segurarem minha mão em momentos precisos. Ter o apoio de vocês foi fundamental para que eu enfrentasse os desafios desse percurso com muito mais tranquilidade.

A Sebastião Alves e à memória de meu pai, Itamar Lima, por serem calma necessária e as figuras paternas que, com amor e presença, sempre me apoiaram.

Aos amigos Nicole Pinheiro, Darlan Castro, Adriano Pinheiro, Beatriz Alencar e Mickaelly Nobre, pelo companheirismo inestimável e pelos ombros sempre amigos. Agradeço pelas longas conversas, pelos aprendizados compartilhados e pelo acolhimento constante — peça-chave para que eu conseguisse finalizar este ciclo acadêmico com equilíbrio e serenidade.

Às psicanalistas Simone Faustino e Aurineli Freire, pela inestimável escuta e por serem guias na cartografia do meu mundo interior, ajudando-me a navegar com coragem pelas complexidades da minha própria subjetividade.

À Universidade Federal do Ceará (UFC), pela infraestrutura e pelos recursos essenciais oferecidos ao longo do curso, possibilitando um ambiente de excelência propício ao meu desenvolvimento acadêmico e profissional.

*“O que me acontecia? Nunca saberei entender,
mas há de haver quem entenda. E é em mim que
tenho de criar esse alguém que entenderá.”*

(CLARICE LISPECTOR, 1964)

RESUMO

Diante do avanço das tecnologias aplicadas à gestão energética, cresce a demanda por soluções capazes de identificar com precisão o consumo individual de aparelhos em ambientes residenciais. No entanto, significativa parcela das pesquisas recentes fundamenta-se estritamente em conjuntos de dados sintéticos ou pré-existentes, abstraindo as complexidades inerentes à implementação física da etapa de aquisição. Este trabalho desenvolveu e validou um sistema completo de monitoramento não intrusivo, abrangendo desde a construção do *hardware* de instrumentação até a classificação por algoritmos de Aprendizado de Máquina. A arquitetura proposta integrou um microcontrolador, um sensor de corrente não invasivo e um conversor analógico-digital de alta resolução, assegurando a fidelidade na coleta das assinaturas de corrente. Os dados experimentais obtidos foram utilizados para treinar e comparar classificadores clássicos e redes neurais profundas, avaliando a robustez dos modelos frente a diferentes topologias de rede elétrica. Os resultados evidenciaram que a qualidade da instrumentação permite que modelos de menor custo computacional atinjam elevada precisão, validando a viabilidade de sistemas autônomos de monitoramento. Dessa forma, a abordagem apresenta uma solução verticalizada e escalável, contribuindo para reduzir a distância entre a modelagem teórica e a aplicação prática em eficiência energética.

Palavras-chave: aprendizado de máquina; monitoramento não intrusivo; instrumentação eletrônica; sistema embarcado; eficiência energética.

ABSTRACT

Given the advancement of technologies applied to energy management, there is a growing demand for solutions capable of accurately identifying the individual consumption of appliances in residential environments. However, a significant portion of recent research relies strictly on synthetic or pre-existing datasets, inherent complexities within the physical implementation during the acquisition phase. This work developed and validated a complete non-intrusive monitoring system, ranging from the construction of instrumentation hardware to classification via Machine Learning algorithms. The proposed architecture integrated a microcontroller, a non-invasive current sensor, and a high-resolution analog-to-digital converter, ensuring fidelity in the collection of current signatures. The experimental data obtained were used to train and compare classical classifiers and deep neural networks, evaluating the robustness of the models against different electrical grid topologies. The results evidenced that the quality of instrumentation allows models with lower computational cost to achieve high precision, validating the viability of autonomous monitoring systems. Thus, the approach presents a verticalized and scalable solution, contributing to bridging the gap between theoretical modeling and practical application in energy efficiency.

Keywords: machine learning; non-Intrusive monitoring; electronic instrumentation; embedded system; energy efficiency.

LISTA DE FIGURAS

| | |
|---|----|
| Figura 1 – Sinais de Corrente de Diferentes Aparelhos. | 16 |
| Figura 2 – Gráficos de Sinais | 17 |
| Figura 3 – Sinal Senoidal de 60 Hertz (Hz) no Domínio do Tempo e no Domínio da Frequência. | 18 |
| Figura 4 – <i>Aliasing</i> | 19 |
| Figura 5 – Exemplo de classificação do algoritmo kNN com $k = 7$ aplicado a dados sintéticos bidimensionais. | 23 |
| Figura 6 – Máquina de Vetor de Suporte. | 24 |
| Figura 7 – Arquitetura de Rede Neural Convolutiva Unidimensional (CNN-1D). | 25 |
| Figura 8 – Arquitetura de uma <i>Long Short-Term Memory</i> (LSTM) | 26 |
| Figura 9 – Estrutura conceitual da Matriz de Confusão | 27 |
| Figura 10 – Fluxograma da Metodologia | 30 |
| Figura 11 – Diagrama Esquemático do Sensor SCT-013-000. | 31 |
| Figura 12 – Esquemático do Módulo ADS1256. | 31 |
| Figura 13 – Esquemático de Pinagem do Microcontrolador ESP32-WROOM-32D. | 32 |
| Figura 14 – Arquitetura do Sistema de Aquisição | 33 |
| Figura 15 – Número de amostras por classe de dispositivo. | 41 |
| Figura 16 – Assinaturas de Corrente no Domínio do Tempo. | 42 |
| Figura 17 – Assinaturas de Corrente no Domínio da Frequência. | 44 |
| Figura 18 – Acurácia de teste dos modelos kNN, SVM, CNN e LSTM. | 47 |
| Figura 19 – Matriz de confusão para o modelo kNN. | 49 |
| Figura 20 – Matriz de confusão para o modelo SVM. | 50 |
| Figura 21 – Matriz de confusão para o modelo CNN. | 51 |
| Figura 22 – Matriz de confusão para o modelo LSTM. | 51 |
| Figura 23 – Formas de Onda de Corrente no Domínio do Tempo: Rede Residencial vs. Rede UFC | 54 |
| Figura 24 – Espectro de Frequência das Correntes: Rede Residencial vs. Rede UFC | 55 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 – Base de dados para métodos supervisionados | 21 |
| Tabela 2 – Dados para um método não supervisionado | 22 |
| Tabela 3 – Distribuição final das instâncias processadas por subconjunto. | 46 |
| Tabela 4 – Comparativo de consumo de recursos e eficiência temporal entre os modelos. | 52 |
| Tabela 5 – Resultados da inferência sob a rede elétrica da UFC (Campus Quixadá). . . | 56 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|------|--------------------------------------|
| AM | Aprendizado de Máquina |
| CNN | <i>Convolutional Neural Network</i> |
| FFT | <i>Fast Fourier Transform</i> |
| FN | Falso Negativo |
| FP | Falso Positivo |
| Hz | Hertz |
| IA | Inteligência Artificial |
| kNN | <i>K-Nearest Neighbors</i> |
| LSTM | <i>Long Short-Term Memory</i> |
| NILM | <i>Non-Intrusive Load Monitoring</i> |
| QEE | Qualidade de Energia Elétrica |
| SPI | <i>Serial Peripheral Interface</i> |
| SVM | <i>Support Vector Machine</i> |
| TVS | <i>Transient Voltage Suppressor</i> |
| VN | Verdadeiro Negativo |
| VP | Verdadeiro Positivo |

LISTA DE SÍMBOLOS

| | |
|----------|--|
| W | Potência ativa em Watts |
| s | Segundos |
| V | Tensão em Volts (V) |
| I | Corrente em Ampere (A) |
| \int | Símbolo de integral |
| e | Base do logaritmo natural, aproximadamente igual a 2.718 |
| j | Unidade imaginária, igual a $\sqrt{-1}$ |
| f | Frequência em Hertz (Hz) |
| t | Tempo em segundos (s) |
| ω | Frequência angular |
| σ | Função de Ativação Sigmoide |
| \tanh | Função Tangente Hiperbólica |
| Ω | Ohm |
| A | Ampere |
| mA | Miliampere |

SUMÁRIO

| | | |
|------------|---|-----------|
| 1 | INTRODUÇÃO | 13 |
| 1.1 | Objetivo Geral | 14 |
| 1.2 | Objetivos Específicos | 14 |
| 2 | FUNDAMENTAÇÃO TEÓRICA | 15 |
| 2.1 | Qualidade de Energia Elétrica | 15 |
| 2.2 | Análise de Sinais na Transformada de Fourier | 16 |
| 2.3 | Teorema da Amostragem | 18 |
| 2.4 | Processamento de Sinais em Sistemas Embarcados | 20 |
| 2.5 | Aprendizado de Máquina | 21 |
| 3 | TRABALHOS RELACIONADOS | 28 |
| 4 | PROCEDIMENTOS METODOLÓGICOS | 30 |
| 4.1 | Desenvolvimento do Sistema de Aquisição de Sinais | 30 |
| 4.2 | Coleta de Dados | 34 |
| 4.3 | Pré-processamento dos Dados | 35 |
| 4.4 | Treinamento dos Modelos de Classificação | 37 |
| 4.5 | Métricas de Validação e Procedimentos de Análise | 38 |
| 5 | RESULTADOS | 41 |
| 5.1 | Composição do Conjunto de Dados | 41 |
| 5.2 | Caracterização dos Sinais de Corrente | 42 |
| 5.3 | Estruturação dos Dados Pré-processados para Classificação | 46 |
| 5.4 | Análise do Desempenho Preditivo dos Modelos | 47 |
| 5.5 | Análise Diagnóstica via Matrizes de Confusão | 49 |
| 5.6 | Análise da Eficiência Computacional | 52 |
| 5.7 | Validação da Robustez dos Classificadores em Redes Distintas | 53 |
| 6 | CONCLUSÕES E TRABALHOS FUTUROS | 58 |
| | REFERÊNCIAS | 60 |
| | APÊNDICE A –CÓDIGOS FONTE E CONJUNTO DE DADOS | 63 |

1 INTRODUÇÃO

O sistema elétrico brasileiro iniciou sua estrutura no final do século XIX. As primeiras usinas e linhas de transmissão construídas tinham o propósito de alimentar cargas pontuais, porém, com o tempo, houve a disseminação do uso da eletricidade, tornando-se necessário transportar a energia elétrica até as residências (Barros *et al.*, 2014). Nesse contexto, a expansão elétrica, que no Brasil começou com estruturas voltadas para demandas locais, representou uma transformação profunda, não apenas no país, mas em escala global, visto que seus efeitos se ramificaram por diversas esferas sociais, especialmente no que diz respeito ao desenvolvimento tecnológico e informacional.

Nas últimas décadas, a tecnologia vem mudando a um ritmo cada vez mais intenso. A pressão para desenvolver novos produtos, melhorar o desempenho de sistemas existentes e criar novos mercados apenas acelera esse ritmo (Boylestad, 2012). Esse ritmo de mudanças, por sua vez, tem reflexo no setor elétrico, que precisa se adaptar constantemente às novas exigências de eficiência, visto que surge a necessidade de compreender com maior precisão o comportamento do consumo energético.

Paralelamente, segundo Haines *et al.* (2007), grandes desenvolvedores de tecnologia, prestadores de serviços e empresas de energia estão se mobilizando para expandir a inteligência além dos dispositivos específicos para o lar como um todo, e conectar essas casas inteligentes aos medidores, fios e tubulações das redes de serviços públicos. O surgimento das casas inteligentes pode garantir que as tecnologias inteligentes se tornem uma característica comum na vida das pessoas: nessa esfera de crescente integração entre tecnologia e infraestrutura residencial, torna-se fundamental compreender os métodos de monitoramento aplicados ao consumo energético das residências.

Segundo Liu (2020), o monitoramento de carga classifica-se fundamentalmente em duas abordagens: intrusiva e não intrusiva. A abordagem intrusiva consiste na medição direta e individualizada, exigindo acesso físico a cada carga ou ponto de consumo específico, o que garante alta precisão, mas impõe maior complexidade à infraestrutura da rede. Em contrapartida, o método não intrusivo, ou *Non-Intrusive Load Monitoring* (NILM), opera de forma centralizada, coletando sinais agregados na entrada principal do circuito. A partir desse ponto único de medição, o sistema identifica as assinaturas características de cada equipamento, consolidando-se como uma alternativa vantajosa pela facilidade de instalação e menor invasividade no ambiente monitorado.

O uso de técnicas de Aprendizado de Máquina (AM) tem se mostrado fundamental para aprimorar a precisão e a eficiência dos sistemas de monitoramento de carga, especialmente nos métodos não intrusivos. Algoritmos de AM e de Aprendizado Profundo são capazes de aprender e reconhecer padrões complexos nas assinaturas elétricas dos dispositivos, mesmo em situações com ruídos ou sobreposição de sinais. Com grandes volumes de dados coletados ao longo do tempo, esses modelos conseguem identificar, classificar e até prever o funcionamento dos aparelhos conectados à rede elétrica com elevado grau de confiabilidade.¹

Portanto, este trabalho busca identificar dispositivos elétricos em ambientes residenciais por meio de sinais de corrente. Para isso, aplicam-se técnicas de AM sobre dados obtidos por monitoramento não intrusivo (NILM), aproveitando a eficácia desses algoritmos na extração de características para a classificação dos equipamentos. Tal metodologia dispensa o uso de sensores intrusivos, alinhando-se às demandas de eficiência e sustentabilidade. Assim, a presente pesquisa contribui tanto para o avanço das soluções de NILM com AM, quanto para a construção de sistemas energéticos integrados às novas demandas de eficiência e sustentabilidade no setor elétrico.

1.1 Objetivo Geral

O objetivo geral deste trabalho consiste em desenvolver um sistema não intrusivo de identificação de dispositivos elétricos, fundamentado em algoritmos de Aprendizado de Máquina, a partir da classificação de suas assinaturas de corrente alternada.

1.2 Objetivos Específicos

1. Implementar um dispositivo embarcado capaz de realizar a aquisição e o processamento digital de sinais de corrente alternada;
2. Facilitar o processo de medição de corrente em dispositivos eletrônicos, por meio da disponibilização de dados;
3. Supervisionar a operação de dispositivos com foco na identificação de padrões de dispositivos na rede elétrica.

¹ Disponível em: <https://www.oracle.com/br/artificial-intelligence/machine-learning/what-is-deep-learning/>. Acesso em: 13 de maio de 2025.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os principais conceitos teóricos e estudos que embasam o desenvolvimento do presente trabalho. O intuito é contextualizar tecnicamente o problema e as soluções exploradas, oferecendo referências sobre os temas centrais.

2.1 Qualidade de Energia Elétrica

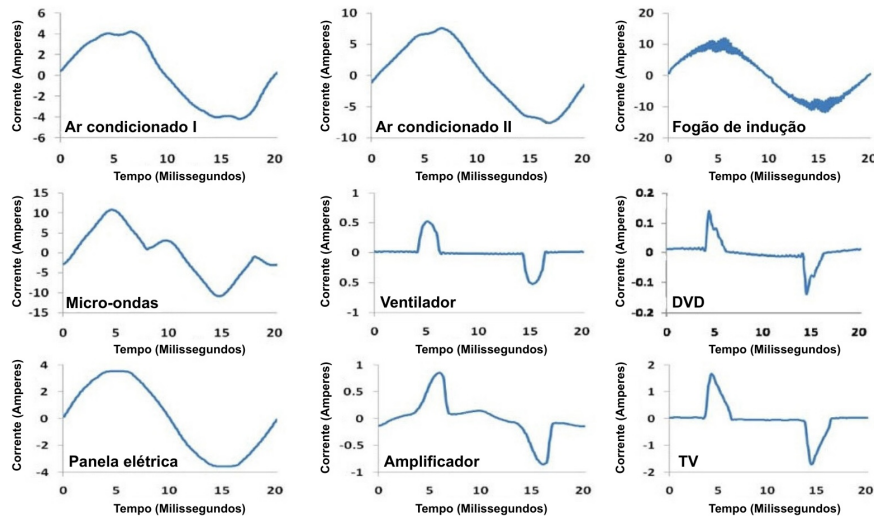
Conforme Meier (2024), a Qualidade de Energia Elétrica (QEE) abrange corrente, frequência e forma de onda. Do ponto de vista teórico, boa qualidade de energia pode ser entendida como a condição em que a tensão fornecida pela concessionária no ponto de entrada do serviço ao consumidor é estável e dentro dos limites especificados; a frequência da corrente alternada é constante e muito próxima de seu valor nominal; e a forma de onda, ou seja, o formato do gráfico da corrente alternada ao longo do tempo, se assemelha fortemente a uma onda senoidal. Na prática, entretanto, faz mais sentido definir qualidade de energia como a compatibilidade entre o que sai da tomada e o equipamento que é conectado a ela.

Em geral, os problemas relacionados com a QEE são identificados quando um equipamento alimentado pela rede elétrica deixa de funcionar como deveria. Assim, uma lâmpada que apresenta variações luminosas e equipamentos operando com sobreaquecimento podem ser indícios de problemas de QEE. Se tais problemas não forem devidamente tratados, pode haver prejuízos materiais (redução da vida útil de transformadores, motores, capacitores e equipamentos eletrônicos sensíveis), bem como ocorrer perturbações físicas em pessoas (incômodo visual devido ao efeito de cintilação, ou incômodo auditivo devido a vibrações mecânicas ou ressonâncias eletromagnéticas), levando ao comprometimento da capacidade produtiva tanto das máquinas como das pessoas (Deckmann; Pomilio, 2024).

De forma paralela, a assinatura de cargas emerge como uma ferramenta essencial para o diagnóstico e monitoramento da QEE. Segundo Bacurau (2014), a assinatura de cargas consiste em um conjunto de características elétricas únicas para cada aparelho, que podem ser medidas, e usadas para discriminação de cargas, como apresentado na Figura 1. Dentre essas características, destaca-se a corrente elétrica, que se apresenta como um dos principais mecanismos de identificação, uma vez que diferentes dispositivos consomem corrente de maneira distinta — variando em amplitude, forma de onda, harmônicas e comportamento dinâmico durante o acionamento.

Por meio da análise dessas assinaturas de corrente, é possível correlacionar anomalias

Figura 1 – Sinais de Corrente de Diferentes Aparelhos.



Fonte: Adaptado pelo autor baseado em (Liang *et al.*, 2009).

na forma de onda, variações de frequência ou distorções harmônicas com a atuação específica de cargas na instalação elétrica, promovendo uma abordagem mais proativa e precisa na gestão energética. Essa abordagem se conecta diretamente ao monitoramento NILM, que permite a vigilância detalhada de equipamentos individuais, identificando padrões de consumo e possíveis falhas sem a necessidade de intervenção direta no sistema, garantindo maior eficiência atrelada à prevenção de danos operacionais.


2.2 Análise de Sinais na Transformada de Fourier

O termo *senal* é geralmente aplicado a algo que transmite informação. Os sinais podem, por exemplo, transmitir informações sobre o estado ou o comportamento de um sistema físico. Em outra classe de exemplos, os sinais são sintetizados com o propósito de comunicar informações entre humanos ou entre humanos e máquinas (Oppenheim *et al.*, 2010).


Em paralelo, segundo Hsu (2011), um sinal $x(t)$ é classificado como *senal no tempo contínuo* se t for uma variável contínua. Caso contrário, se t for uma variável discreta, ou seja, se $x(t)$ estiver definido apenas em instantes específicos, então $x(t)$ é considerado um *senal no tempo discreto*. Nesse contexto, os sinais discretos costumam ser representados como uma *sequência de números*, denotada por $\{x_n\}$ ou $x[n]$, onde n é um número inteiro. Nesse cenário, a Figura 2 apresenta, respectivamente, um exemplo de sinal contínuo $x(t)$ e de sinal discreto $x[n]$.

Dado esse papel central dos sinais na representação e análise de sistemas físicos, os métodos de transformada fornecem uma abordagem matemática unificadora para o estudo de

Figura 2 – Gráficos de Sinais



(a) Sinal no tempo contínuo



(b) Sinal no tempo discreto

Fonte: Elaborado pelo autor baseado em (Hsu, 2011)

redes elétricas, bem como para analisar sistemas lineares e muitos outros dispositivos físicos, sejam elétricos ou não. Entre esses métodos, destaca-se a Transformada de Fourier, que desempenha um papel fundamental na decomposição de sinais em suas componentes de frequência (Bracewell, 2000).

Segundo (Diniz *et al.*, 2014) a Transformada de Fourier é uma operação matemática que permite representar uma função de tempo contínuo como uma soma contínua de funções senoidais de diferentes frequências. Formalmente, seja $f(t)$ uma função integrável no tempo contínuo; a Transformada de Fourier associa a essa função uma nova função $F(\omega)$, definida no domínio da frequência, por meio da expressão:

$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-i\omega t} dt \quad (2.1)$$

Nessa fórmula, ω representa a frequência angular (em rad/s), e i é a unidade imaginária. A função $F(\omega)$ obtida é, em geral, complexa, e descreve a contribuição de cada frequência ω para a formação do sinal original. Além disso, sob certas condições, a função original pode ser recuperada a partir de sua Transformada Inversa de Fourier:

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega) e^{i\omega t} d\omega \quad (2.2)$$


Essa capacidade de alternar entre os domínios do tempo e da frequência torna a transformada de Fourier uma ferramenta indispensável na análise de sinais e sistemas, permitindo a interpretação e o projeto de dispositivos físicos a partir de sua resposta espectral.

Consoante Oppenheim *et al.* (2010), em meados da década de 1960, um algoritmo, conhecido atualmente como transformada rápida de Fourier, ou do inglês *Fast Fourier Transform*

(FFT), foi apresentado. Esse algoritmo, que foi descoberto independentemente por Cooley e Tukey em 1965, também tem uma história considerável e pode, na verdade, ser encontrado nas anotações de Gauss. Nesse sentido, o que tornou sua descoberta moderna tão importante foi o fato de que a FFT mostrou-se perfeitamente adequada para uma eficiente implementação digital, o que reduziu em algumas ordens de grandeza o tempo necessário para calcular as transformadas. Esse avanço ampliou consideravelmente as possibilidades de análise espectral, tornando a FFT um elemento fundamental em diversos campos da engenharia e ciência.

Com o propósito de ilustrar esse algoritmo, na Figura 3 é apresentado um sinal composto por uma única onda senoidal de 60 Hz pura. Com isso, A FFT foi aplicada para observar a distribuição de energia do sinal no domínio da frequência, mostrando claramente a presença da componente de 60 Hz nesse cenário.

Figura 3 – Sinal Senoidal de 60 Hz no Domínio do Tempo e no Domínio da Frequência.



Fonte: Elaborado pelo autor.

A aplicação da FFT nesse contexto permite isolar a componente de 60 Hz do sinal. Dessa maneira, a transformada revela a presença clara e única dessa frequência, sem a interferência de outras componentes, o que é esperado em um sinal puramente senoidal. Destarte, observa-se, assim, que a FFT é eficaz para esse tipo de análise, sendo capaz de identificar e quantificar componentes espectrais com alta precisão.


2.3 Teorema da Amostragem

Segundo Oppenheim *et al.* (2010), sob certas condições, um sinal de tempo contínuo pode ser completamente representado por seus valores ou amostras uniformemente espaçadas no tempo. Essa propriedade vem de um resultado que é conhecido como o *Teorema da Amostragem*.

Conforme descrito em Haykin e Moher (2008), o processo de amostragem é geralmente, mas não exclusivamente, descrito no domínio do tempo. Desta forma, ele é uma operação básica ao processamento digital de sinais e comunicações digitais. Através da utilização do processo de amostragem, um sinal analógico é convertido em uma sequência correspondente de amostras que são geralmente uniformemente espaçadas no tempo. Claramente, para este procedimento ter utilidade prática, é necessário que se escolha a taxa de amostragem adequadamente, de tal forma que a sequência de amostras defina unicamente o sinal analógico original.

Paralelamente, pode-se sobrelevar, baseado em Nunes (2023), que ao capturar amostras de um sinal analógico, partes do sinal não são capturadas, havendo uma perda pequena da informação. Para definir quantas amostras devem ser capturadas do sinal original analógico para construção do sinal digital que o represente, é estabelecido o que se chama de taxa de amostragem. A conversão de um sinal analógico para digital envolve um processo de amostragem, cuja frequência é definida pela taxa de amostragem. Para garantir uma representação fiel do sinal original, é imperativo satisfazer o Teorema de Nyquist-Shannon, que postula que a taxa de amostragem (f_s) deve ser estritamente superior ao dobro da componente de frequência máxima (f_{max}) presente no sinal ($f_s > 2 \cdot f_{max}$). A violação deste critério, ou subamostragem, resulta em um fenômeno de distorção irreversível conhecido como *Aliasing*, apresentado na Figura 4.

Figura 4 – *Aliasing*.



Fonte: (Por *et al.*, 2019).

A Figura 4 demonstra de forma concisa o fenômeno do *aliasing* ao contrastar dois cenários de digitalização. No painel superior, uma taxa de amostragem elevada (pontos vermelhos) captura fielmente um sinal de baixa frequência (senoidal amarela), representando uma correta sobreamostragem. Em contrapartida, o painel inferior que uma taxa de amostragem inferior se torna insuficiente para um sinal de frequência muito mais alta, resultando em subamostragem.

Dessa forma, a consequência direta é que a reconstrução a partir desses pontos gera um sinal *alias* (senoidal azul) de baixa frequência, que é uma representação falsa do original.

2.4 Processamento de Sinais em Sistemas Embarcados

Um sensor é um dispositivo que detecta variações no ambiente e gera uma resposta, normalmente na forma de uma saída para outro sistema. Ele converte um fenômeno físico em uma tensão analógica mensurável (ou, em alguns casos, em um sinal digital), a qual pode ser apresentada de forma legível para o ser humano e transmitida para leitura ou processamento subsequente (Smith, 2025).

Segundo Matsunaga e Tsugawa (2005), os fenômenos do mundo real são, em sua maioria, analógicos. Em contrapartida, a tecnologia de processamento digital está cada vez mais presente no cotidiano da sociedade. Assim, são necessárias interfaces capazes de converter informações analógicas — oriundas do mundo físico — em dados digitais, os quais podem ser processados e, posteriormente, reconvertidos para a forma analógica.

Em paralelo, é válido salientar que os conversores analógico-digitais assumem um papel fundamental nessa cadeia de conversão: eles são responsáveis por transformar sinais contínuos provenientes do ambiente — como temperatura, pressão, corrente ou tensão — em representações digitais precisas, aptas a serem processadas por sistemas computacionais. Nesse sentido, a qualidade do conversor analógico-digital impacta diretamente a resolução, a fidelidade e o alcance dinâmico da aquisição, influenciando o desempenho global do sistema.

De forma complementar, a conversão digital-analógica, realizada ao final da cadeia, assegura que os resultados do processamento possam ser aplicados novamente ao domínio analógico de forma eficaz. Isso torna a conversão analógico-digital um elemento crucial na transição entre o mundo das quantidades físicas e o crescente poder de processamento digital de sinais (Pelgrom, 2017). Dessa forma, essa etapa de conversão é fundamental para viabilizar a atuação de dispositivos como microcontroladores, que dependem de dados digitais para executar suas funções de controle e tomada de decisão.

Conforme HASHEMI-POUR e LUTKEVICH (2024), um microcontrolador é um circuito integrado compacto, projetado para controlar operações específicas em um sistema embarcado. Em geral, esse dispositivo reúne, em um único chip, um processador, memória e periféricos de entrada e saída. Nesse contexto, Inc (2021) destaca que o microcontrolador gerencia as funções de um dispositivo ao interpretar os dados recebidos dos periféricos. Dessa forma,

esses dados são, então, armazenados e processados no próprio circuito integrado, permitindo que o microcontrolador execute as ações necessárias.

2.5 Aprendizado de Máquina

A crescente complexidade dos problemas a serem computacionalmente tratados, e a velocidade e volume de dados gerados por diferentes setores, motivou o desenvolvimento de ferramentas computacionais mais sofisticadas e autônomas, mais independentes da intervenção humana, para a aquisição de conhecimento. A maioria dessas ferramentas é baseada em AM, uma subárea da Inteligência Artificial (IA) que faz parte de várias das tecnologias atualmente utilizadas (Faceli *et al.*, 2021). Nesse sentido, segundo Richert e Coelho (2013), o objetivo da aprendizagem de máquina é ensinar máquinas (*softwares*) a realizar tarefas, fornecendo-lhes alguns exemplos (como fazer ou não fazer uma tarefa). Dessa forma, segundo Netto e Maciel (2021) pode-se identificar dois grandes grupos de algoritmos de AM quanto à intervenção de aprendizagem: os supervisionados e não supervisionados.

Na visão de SICSÚ *et al.* (2023), os algoritmos supervisionados são aplicados quando se tem uma base de dados em que a cada observação corresponde um conjunto de variáveis X_1, X_2, \dots, X_p , geralmente denominadas previsoras; e uma variável Y , denominada variável alvo, como apresentado na Tabela 1.

Tabela 1 – Base de dados para métodos supervisionados

| Previsoras | | | | Alvo |
|------------|-------|-----|-------|------|
| X_1 | X_2 | ... | X_p | Y |
| 1 | 5 | 6 | -4 | 8 |
| 2 | 3 | 8 | 6 | 7 |
| 3 | 2 | 11 | -5 | -4 |

Fonte: Adaptado pelo autor baseado em (SICSÚ *et al.*, 2023)

Nesse contexto, a variável Y funciona como um guia do algoritmo, visto que pode ser quantitativa ou qualitativa. A construção desses algoritmos fundamenta-se em detectar a relação entre as variáveis previsoras e a variável alvo. Uma vez identificada a relação, ela pode ser aplicada para prever ou classificar novos casos a partir das variáveis previsoras.

Conforme SICSÚ *et al.* (2023) nos algoritmos não supervisionados, não há uma variável alvo que sirva para direcionar os resultados. A função desses algoritmos é obter determinados padrões de comportamento entre as observações da amostra. Dessa forma, o algoritmo deve ser programado para aprender a identificar tais padrões, como apresentado na

Tabela 2.

Tabela 2 – Dados para um método não supervisionado

| X_1 | X_2 | ... | X_p |
|-------|-------|-----|--------|
| 2,3 | 3 | ... | 100,51 |
| 3,8 | 10 | ... | 89,32 |
| 11,5 | 8 | ... | 27,65 |

Fonte: Adaptado pelo autor baseado em (SICSÚ *et al.*, 2023)

A não existência de uma variável alvo Y torna os algoritmos mais complexos e as saídas mais difíceis de interpretar. Ao contrário dos métodos supervisionados, nos quais a comparação da previsão com o valor conhecido Y permite aferir a qualidade dos resultados de forma mais simples.


Nesse cenário, Tatsat *et al.* (2021) sobreleva que há duas variedades de algoritmos de aprendizado supervisionado: algoritmos de regressão e de classificação. Os métodos de aprendizado supervisionado baseados na regressão tentam prever saídas com base nas variáveis de entrada. Já os métodos de aprendizado supervisionado com base na classificação identificam a categoria à qual um conjunto de dados pertence. Nesse sentido, os algoritmos de classificação são baseados em probabilidade, ou seja, a saída é a categoria para a qual o algoritmo encontra a probabilidade mais alta de que o conjunto de dados pertence a ela: os algoritmos de regressão, em contraste, estimam a saída de problemas que possuem um número infinito de soluções (conjunto contínuo de possíveis saídas). Dessa forma, exemplos de algoritmos utilizados para classificação são *K-Nearest Neighbors* (kNN), *Support Vector Machine* (SVM), LSTM e *Convolutional Neural Network* (CNN).

O algoritmo kNN, segundo Müller e Guido (2016), é, provavelmente, o algoritmo de aprendizado de máquina mais simples em termos de implementação, pois sua construção se resume ao armazenamento do conjunto de dados de treinamento. Para realizar uma previsão de um novo ponto de dados, o algoritmo busca os pontos mais próximos dentro do conjunto de treinamento — os chamados “vizinhos mais próximos”.

Para fins de demonstração prática e visual do funcionamento do algoritmo kNN, apresenta-se na Figura 5 uma simulação baseada em dados sintéticos bidimensionais gerados artificialmente. Esses dados foram criados utilizando a função `make_classification` da biblioteca `scikit-learn` em Python. Nesse sentido, foram geradas 100 amostras, cada uma com dois atributos informativos (`n_features=2`, `n_informative=2`), o que permite sua representação em um espaço bidimensional. Por conseguinte, a configuração `n_redundant=0` assegura que

não há atributos desnecessários, e `n_clusters_per_class=1` garante que cada uma das duas classes (linearmente separáveis) se agrupe em um único *cluster*, facilitando a visualização. Nesse contexto, um `random_state=42` foi definido para garantir que a geração desses dados seja reproduzível, ou seja, sempre resultará no mesmo conjunto de pontos se o código for executado novamente. Assim, o objetivo é ilustrar o processo de classificação realizado pelo algoritmo ao receber como entrada um novo ponto de dados ainda não rotulado.

Figura 5 – Exemplo de classificação do algoritmo kNN com $k = 7$ aplicado a dados sintéticos bidimensionais.



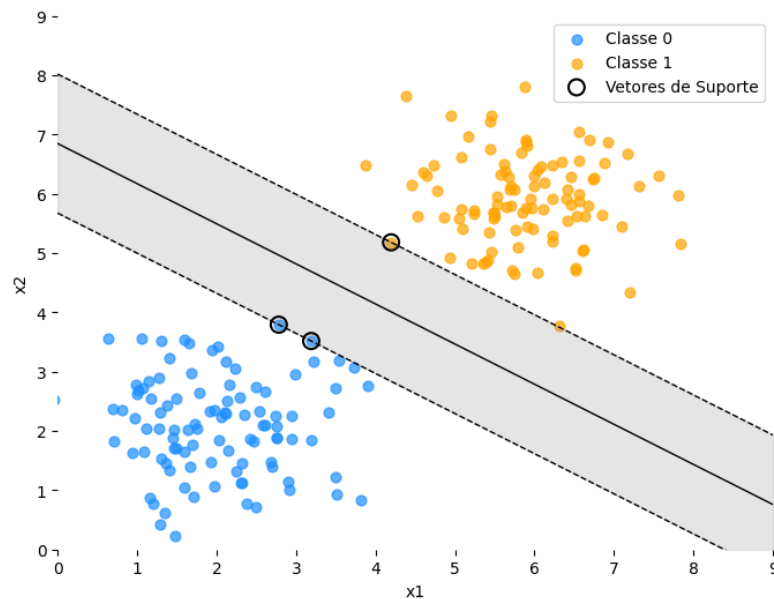
Fonte: Elaborada pelo autor.

Nesta simulação, o algoritmo é configurado empiricamente com o parâmetro $k = 7$, o que significa que a decisão de classe será tomada com base nos sete vizinhos mais próximos ao ponto em questão, segundo a métrica de distância Euclidiana. Dessa forma, pode-se observar que um novo ponto é inserido no espaço de características e, posteriormente, o algoritmo calcula a distância entre esse ponto e todas as amostras presentes no conjunto de treinamento. Em seguida, seleciona os sete exemplos mais próximos e determina, por maioria simples, a classe a ser atribuída ao ponto consultado.

Por outro lado, conforme Tatsat *et al.* (2021), o objetivo do algoritmo SVM é maximizar a margem (a área em cinza no centro da Figura 6), que é definida como a distância entre o hiperplano separador (ou fronteira de decisão) e as amostras de treinamento que estão mais próximas desse hiperplano, os denominados vetores de suporte. A margem é calculada como a distância perpendicular entre a linha até apenas os pontos mais próximos, como apresentado na Figura 6. Sendo assim, o SVM calcula uma fronteira com margem máxima que leva a uma divisão homogênea de todos os pontos de dados.

Nesse contexto, os dados estão desordenados e não podem ser separados perfeita-

Figura 6 – Máquina de Vetor de Suporte.



Fonte: Adaptado pelo autor baseado em (Tatsat *et al.*, 2021).

mente com um hiperplano. A limitação de maximizar a margem da linha que separa as classes deve ser relaxada. Uma mudança permite que alguns pontos de dados de treinamento violem a linha separatória. Por conseguinte, um conjunto adicional de coeficientes é introduzido, o que dá à margem flexibilização em cada dimensão. Em seguida, um parâmetro de calibração é introduzido, chamado simplesmente de C , que define a magnitude da flexibilização permitida em todas as dimensões. Dessa forma, quanto maior for o valor de C , mais violações do hiperplano serão permitidas.


Uma ramificação específica do AM, conhecida como Aprendizado Profundo, surgiu como uma estrutura excepcionalmente poderosa e de propósito geral para aprender a partir de dados. O Aprendizado Profundo é baseado em modelos computacionais chamados Redes Neurais, que foram originalmente inspirados por mecanismos de aprendizagem e processamento de informações no cérebro humano (Bishop; Bishop, 2024).

Nesse sentido, uma abordagem amplamente consolidada no âmbito do aprendizado profundo para o tratamento de dados temporais fundamenta-se no emprego de Redes Neurais Convolucionais (CNN). Conforme exposto por Gulli e Pal (2018), essa arquitetura utiliza camadas de convolução que aplicam filtros sobre os dados de entrada com o intuito de extrair, de forma automatizada, características em múltiplos níveis de abstração. No contexto unidimensional, tais filtros operam ao longo do eixo temporal para identificar padrões locais recorrentes — como tendências de curto prazo ou variações abruptas —, o que justifica a eficácia das camadas

Conv1D na análise e classificação de séries temporais (JAIN, 2024).

Conforme Sanchez-Reolid *et al.* (2022) a Figura 7 detalha essa estrutura, organizada em três estágios fundamentais: entrada, camadas ocultas e saída.

Figura 7 – Arquitetura de Rede Neural Convolutacional Unidimensional (CNN-1D).



Fonte: Adaptado pelo autor baseado em (Sanchez-Reolid *et al.*, 2022).

Inicialmente, no estágio (a), a camada de entrada recebe o segmento da série temporal previamente processado. Em (b), as camadas convolucionais aplicam filtros sucessivos para transformar o sinal original em mapas de características, nos quais os atributos discriminativos tornam-se progressivamente mais evidentes para a etapa de decisão. Na sequência, a camada *flatten* (c) realiza a vetorização desses mapas, permitindo sua integração com a camada densa e o mecanismo de *dropout* (d). Esse conjunto é responsável pela combinação global das informações extraídas e, simultaneamente, pela mitigação do sobreajuste por meio da regularização dos pesos. Finalmente, no estágio (e), a camada de saída normaliza as ativações finais em escores de probabilidade, frequentemente via função *softmax*, o que conclui a rotulação do segmento analisado. Dessa forma, a arquitetura CNN destaca-se pela capacidade de aprender hierarquias de representação complexas diretamente dos dados brutos, otimizando a identificação de padrões em sinais temporais.


Adicionalmente, segundo Olah (2015), as LSTMs são um tipo especial de Rede Neural Recorrente, capazes de aprender dependências de longo prazo. Elas foram introduzidas por Hochreiter e Schmidhuber (1997) e foram refinadas e popularizadas por muitos pesquisadores em trabalhos posteriores. Dessa maneira, elas funcionam extremamente bem em uma grande variedade de problemas e, atualmente, são amplamente utilizadas.

Conforme descrito em ALMEIDA (2023), as LSTMs introduzem unidades de me-

mória que podem aprender e reter informações por longos períodos, tornando-as ideais para capturar dependências temporais complexas. Nesse sentido, consoante Leandro (2021), as LSTM possuem três portas principais: a porta de entrada, a porta de esquecimento e a porta de saída.

A Figura 8 apresenta a arquitetura interna de células de LSTM, representadas em blocos. Nesse sentido, Leandro (2021) cita que a rede opera passo a passo, onde t representa o tempo atual; assim, ela recebe a entrada do momento presente (x_t) e a saída ou "memória" do passo anterior (h_{t-1}). O objetivo é calcular a nova saída, h_t , que captura o contexto atualizado. Para fazer isso, a célula utiliza um sofisticado sistema de "portões"(gates) que regulam o fluxo de informação através de sua memória principal, o "estado da célula"(a linha horizontal no topo). Nesse cenário, esses portões são geralmente compostos por uma função de ativação sigmoide (σ), que gera um valor entre 0 e 1, descrevendo o nível de ativação do portão, onde 0 significa que está completamente fechado (bloqueando dados) e 1 que está completamente aberto (permitindo a passagem de dados).

Figura 8 – Arquitetura de uma LSTM



Fonte: (Leandro, 2021).

Enquanto a sigmoide decide o quanto de informação passa, a função tangente hiperbólica (\tanh) é usada para escalar e preparar os valores da informação, colocando-os num intervalo de -1 a 1. O processo funciona da seguinte forma: primeiro, o "portão de esquecimento"(com sigmoide) decide o que apagar da memória antiga; em seguida, o "portão de entrada"(usando sigmoide e \tanh) determina quais novas informações são relevantes e as adiciona à memória; por fim, o "portão de saída"(com sigmoide) filtra essa memória atualizada para produzir o resultado final, h_t . Destarte, é essa capacidade de seletivamente esquecer, reter e emitir informações que permite às LSTMs capturar dependências de longo prazo, tornando-as extremamente eficazes para tarefas complexas como identificação de séries temporais.

Para avaliar a eficácia de arquiteturas de classificação, é fundamental o emprego de

métricas que quantifiquem a capacidade de acerto e generalização do sistema. Nesse contexto, a acurácia destaca-se por mensurar a proporção global de predições corretas do modelo em relação ao total de amostras (SOUZA, 2022), sendo calculada conforme a Equação 2.3:

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.3)$$

Na expressão apresentada, as variáveis do numerador representam as classificações assertivas, onde Verdadeiro Positivo (VP) denota a correta identificação de instâncias da classe positiva e Verdadeiro Negativo (VN) corresponde às instâncias negativas corretamente rejeitadas pelo sistema. O denominador, por sua vez, abrange o universo total de predições, somando aos acertos os erros de generalização: o termo Falso Positivo (FP), que indica instâncias negativas erroneamente categorizadas como positivas, e o Falso Negativo (FN), que representa a omissão do modelo ao classificar uma instância positiva como negativa.

Para consolidar a visualização dessas relações entre as classes reais e as classes preditas, utiliza-se a estrutura conhecida como matriz de confusão. Segundo Gulli e Pal (2018), essa estrutura confronta as classes previstas pelo modelo com as classes reais, permitindo a decomposição do desempenho conforme ilustrado na Figura 9.

Figura 9 – Estrutura conceitual da Matriz de Confusão



Fonte: Elaborado pelo autor com base em (Gulli; Pal, 2018).

Dessa forma, a interpretação da acurácia em par com a matriz de confusão não apenas quantifica o sucesso global, mas qualifica o desempenho do classificador, evidenciando quais tipos específicos de erro penalizam a generalização do sistema.

3 TRABALHOS RELACIONADOS

O trabalho de Xavier Neto (2024) tem como foco principal a criação de uma interface de monitoramento em tempo real do consumo energético, utilizando sensores de corrente do tipo não invasivo baseados em efeito Hall e transformadores de corrente. O sistema é composto por um módulo de aquisição de dados, por meio do qual o usuário pode visualizar informações como corrente, potência e consumo acumulado. Além disso, o autor adota conceitos de modularização e acessibilidade da interface para permitir escalabilidade e usabilidade do sistema em diferentes ambientes.

Ainda que o trabalho de Xavier Neto (2024) apresente contribuições relevantes no contexto da automação residencial e da gestão do consumo energético, seu foco reside na visualização e no controle do uso de energia, sem avançar para a identificação de padrões específicos de funcionamento dos dispositivos monitorados. Além disso, a ausência de um conversor analógico-digital externo de alta resolução compromete a precisão dos dados adquiridos, limitando a capacidade de análise mais detalhada dos sinais. Dessa forma, o presente trabalho distingue-se por adotar uma abordagem de maior precisão de dados e centrada na caracterização dos sinais de corrente alternada como forma de extrair assinaturas únicas de dispositivos eletrônicos.

O trabalho de Amurim (2024) propõe uma abordagem de identificação de dispositivos elétricos com base na análise de seus perfis de consumo, utilizando técnicas de aprendizado de máquina aplicadas a dados de corrente alternada. Uma das principais contribuições metodológicas está na adoção de um sistema de aquisição baseado em osciloscópio digital, que permite a coleta de sinais com elevada resolução temporal e ampla faixa dinâmica, garantindo extrema fidelidade na representação das formas de onda. Nesse sentido, essa escolha técnica assegura maior riqueza de informações para as etapas de pré-processamento e extração de características, favorecendo o desempenho dos modelos classificadores. O autor também emprega representações de corrente alternada no domínio do tempo e da frequência, o que amplia o espectro de informações disponíveis para a caracterização dos dispositivos monitorados.

Apesar da robustez na aquisição e no processamento dos dados, o sistema proposto por Amurim (2024) possui limitações em termos de aplicabilidade prática em ambientes embarcados, dada a dependência de instrumentos laboratoriais como o osciloscópio. Nesse viés, o presente trabalho diferencia-se ao propor uma solução viável para diversos contextos de uso, baseada em um dispositivo embarcado versátil. Ainda que com uma taxa de amostragem menor, comparada à de instrumentos dedicados, o sistema embarcado desenvolvido busca equili-

brar precisão e viabilidade de implementação, efetivando a coleta de dados em tempo real e a identificação de dispositivos com base em assinaturas de corrente obtidas diretamente da rede elétrica.

O trabalho de Martins (2024) tem como objetivo principal o desenvolvimento de uma solução para o monitoramento do consumo energético em ambientes residenciais, com ênfase na geração de relatórios detalhados sobre o uso de aparelhos eletrônicos. A proposta envolve a utilização de sensores de corrente não invasivos baseados no efeito Hall, integrados a um sistema microcontrolado responsável por realizar medições periódicas e armazenar os dados localmente. O sistema possibilita ao usuário visualizar parâmetros como corrente, tensão e potência, além de manter um histórico das leituras para análises posteriores.

Embora apresente uma abordagem prática e funcional no contexto da gestão energética residencial, o trabalho de Martins (2024) concentra-se na coleta e visualização de dados agregados, sem avançar para a identificação individualizada dos dispositivos monitorados. Ademais, não há a adoção de conversores analógico-digitais externos de alta resolução, o que pode comprometer a precisão na captura dos sinais elétricos. Em contraste, o presente trabalho propõe uma arquitetura voltada à caracterização refinada dos sinais de corrente alternada, utilizando o ADS1256 como conversor de alta precisão e aplicando algoritmos de AM para possibilitar a identificação automatizada dos dispositivos a partir de suas assinaturas elétricas individuais.

Quadro 1 – Comparativo entre os trabalhos analisados

| Trabalho | Microcontrolador | Sensor de Corrente | Conversor ADC | Reconhece Dispositivos |
|--------------------------|-------------------------|---------------------------|----------------------|-------------------------------|
| (Xavier Neto, 2024) | ESP8266 | SCT-013-000 | Interno do ESP | Não |
| (Amurim, 2024) | Não aplicável | SCT-013-000 | Osciloscópio digital | Sim |
| (Martins, 2024) | ESP8266 | SCT-013-010 | Interno do ESP | Não |
| Trabalho Proposto | ESP32-WROOM-32D | SCT-013-000 | ADS1256 | Sim |

Fonte: Elaborado pelo autor

4 PROCEDIMENTOS METODOLÓGICOS

Este capítulo descreve os procedimentos metodológicos adotados para a implementação do sistema de monitoramento de dispositivos elétricos a partir de sinais de corrente. A Figura 10 apresenta as etapas desde a coleta dos sinais até a classificação por meio de modelos de AM. A metodologia foi estruturada com o objetivo de garantir a reprodutibilidade dos experimentos e a validação dos resultados.

Figura 10 – Fluxograma da Metodologia




Fonte: Elaborado pelo Autor.

4.1 Desenvolvimento do Sistema de Aquisição de Sinais

O desenvolvimento do sistema de aquisição de dados deste trabalho consistiu no projeto e implementação de uma infraestrutura de instrumentação voltada à captura e ao processamento de assinaturas elétricas. Nesse sentido, para viabilizar a caracterização precisa do consumo de diferentes dispositivos, foi construída uma arquitetura que integra o sensoriamento não invasivo, o condicionamento analógico de sinais e a digitalização de alta resolução, servindo como base técnica para a posterior análise de padrões de carga.

O sensor SCT-013-000, apresentado na Figura 11, foi escolhido por se tratar de um transformador de corrente não invasivo, o que permite medições sem a necessidade de interromper o circuito elétrico analisado. Seu núcleo do tipo *split-core* facilita a instalação em condutores energizados, sendo ideal para aplicações em ambientes já operacionais. Internamente, esse modelo possui uma razão de transformação de 1:2000, o que significa que para cada 1 A no primário (condutor monitorado), é gerado 0,5 mA no secundário, além de incorporar um dispositivo supressor de surtos do tipo *Transient Voltage Suppressor (TVS)* conectado em paralelo ao enrolamento secundário, o qual permanece em alta impedância durante a operação normal, protegendo o sensor e os circuitos associados contra sobretensões transitórias.

Figura 11 – Diagrama Esquemático do Sensor SCT-013-000.

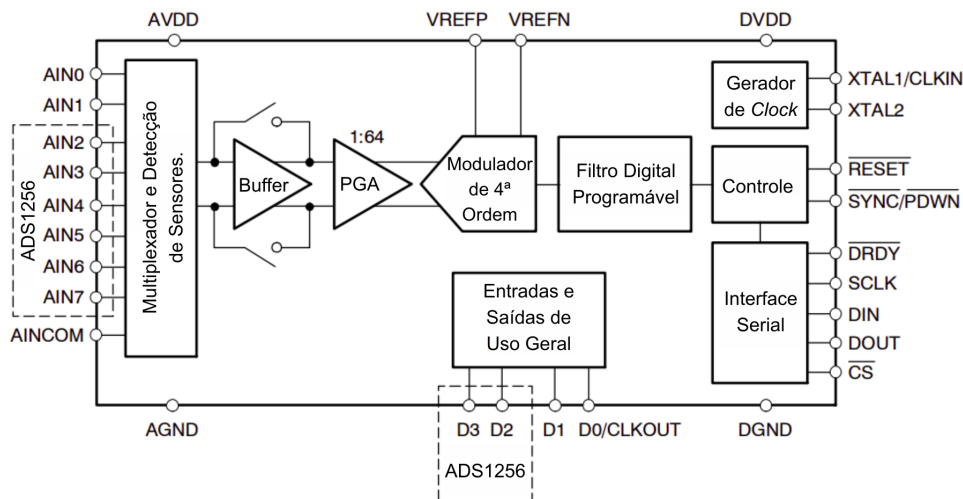


Fonte: (BEIJING YAOHUACHANG ELECTRONIC CO., LTD, 2026)

Para converter corrente em um sinal de tensão utilizável por circuitos eletrônicos, foi conectado externamente um resistor de carga de $33\ \Omega$, resultando em um sinal de até $1,65\ \text{V}$ de pico. A escolha do valor do resistor levou em consideração a faixa linear do sensor e a necessidade de manter a amplitude do sinal abaixo do limite de alimentação dos circuitos seguintes, evitando saturações.

Além disso, o conversor analógico-digital ADS1256, apresentado na Figura 12, foi adotado no projeto devido à sua alta resolução de 24 bits e capacidade de leitura diferencial, essenciais para aplicações que exigem alta precisão em sinais analógicos de pequena amplitude.

Figura 12 – Esquemático do Módulo ADS1256.



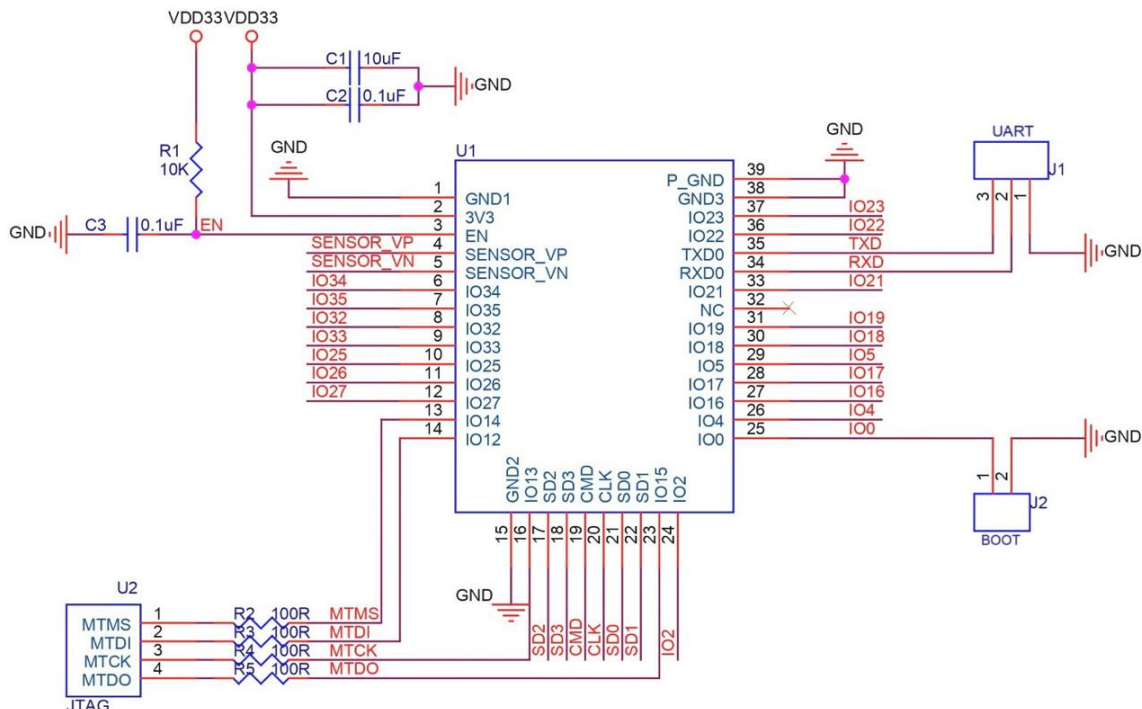
Fonte: Adaptado pelo autor baseado em (TEXAS INSTRUMENTS, 2013).

Embora o circuito suporte alimentação de até $5\ \text{V}$, optou-se por alimentá-lo com $3,3\ \text{V}$, o que garante compatibilidade direta com os níveis lógicos do ESP32 e reduz o consumo energético geral do sistema. Para garantir alta estabilidade e precisão na conversão, utiliza-se a referência de tensão interna de $2,5\ \text{V}$ do próprio ADS1256. Essa escolha, combinada ao ganho de $2\times$, otimiza a resolução do conversor para a faixa de tensão gerada pelo circuito de

condicionamento. As entradas diferenciais AIN0 e AIN1 foram conectadas diretamente ao sinal condicionado pelo circuito de *offset*, e o ganho interno foi configurado como $2\times$, aumentando a resolução efetiva na faixa de interesse. A arquitetura Delta-Sigma do ADS1256 incorpora um filtro digital programável, responsável por limitar a largura de banda efetiva do sinal na saída do conversor. Esse estágio de filtragem interna contribui para a conformação do ruído de quantização para frequências mais altas, resultando em uma relação sinal-ruído significativamente superior àquela proporcionada por conversores de Aproximações Sucessivas, tipicamente limitados a resoluções de 10 ou 12 bits e desprovidos de mecanismos intrínsecos de modelagem de ruído.

O microcontrolador ESP32 WROOM-32D, cujo esquemático de conexões é apresentado na Figura 13, atua como a unidade central de processamento do sistema, executando o controle lógico da aquisição de sinais e a interface de comunicação com o conversor ADS1256. O processador de núcleo duplo de 32 bits, operando a 240 MHz, suporta a interface SPI de alta velocidade configurada em modo mestre. Esta topologia coordena a temporização e a transferência de dados digitais com latência mínima, condição necessária para viabilizar a sustentação de elevadas taxas de amostragem sem comprometer a integridade dos dados adquiridos.

Figura 13 – Esquemático de Pinagem do Microcontrolador ESP32-WROOM-32D.



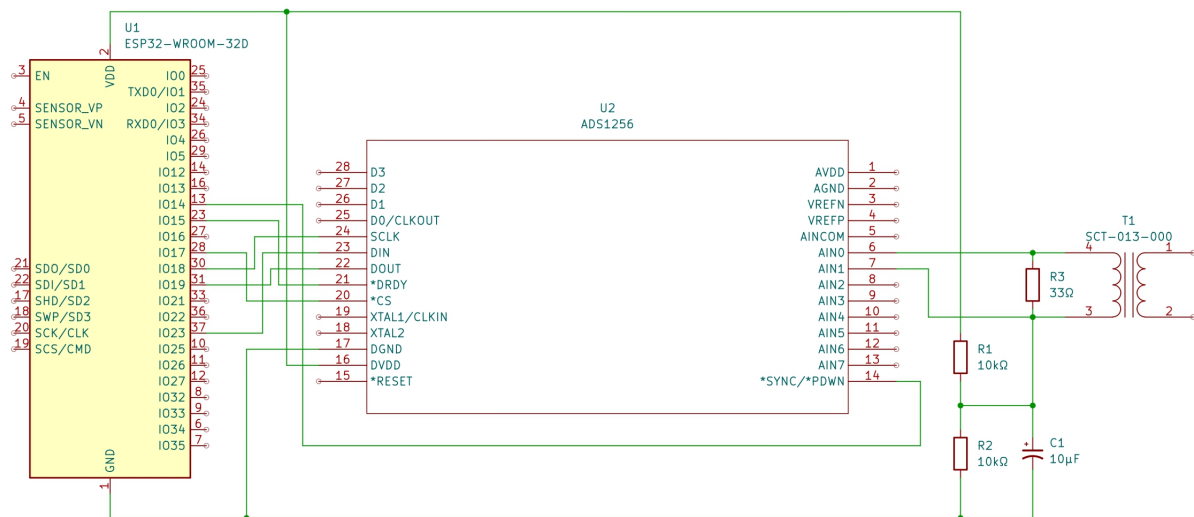
Fonte: Adaptado pelo autor baseado em (ESPRESSIF SYSTEMS, 2026)

Para garantir a integridade e o fluxo contínuo dos dados amostrados, a interface *Serial Peripheral Interface* (SPI) foi configurada com parâmetros de temporização otimizados, maximizando a vazão dos pacotes de 24 bits provenientes do conversor analógico-digital. A

sincronização da leitura é realizada por meio do sinal de interrupção externa *Data Ready* (DRDY), o qual aciona o microcontrolador imediatamente após a conclusão de cada ciclo de conversão do ADS1256, eliminando a sobrecarga de processamento associada a técnicas de *polling* e assegurando o determinismo temporal da amostragem.

O circuito de aquisição de sinais desenvolvido neste trabalho é ilustrado na Figura 14, onde se observa a integração física entre os estágios de sensoriamento, condicionamento analógico, conversão digital e processamento. A arquitetura foi concebida de forma modular, permitindo a validação individual de cada subsistema antes da integração final.

Figura 14 – Arquitetura do Sistema de Aquisição



Fonte: Elaborado pelo Autor.

O fluxo de dados inicia-se na captura da corrente pelo sensor não invasivo, cujo sinal é adequado aos níveis de tensão do conversor ADS1256 pelo circuito de condicionamento. Após a digitalização, as amostras são transferidas ao microcontrolador ESP32 através do barramento SPI de alta velocidade. Uma vez centralizados na unidade de processamento, os blocos de dados são transmitidos sequencialmente ao computador via interface UART para armazenamento definitivo e análise. A escolha desta interface de comunicação serial foi fundamentada na necessidade de minimizar a sobrecarga de processamento (*overhead*) do microcontrolador frente à alta taxa de amostragem exigida, evitando o custo computacional de protocolos de rede complexos e garantindo a integridade da coleta sem perda de amostras.

Para facilitar a reprodutibilidade e auxiliar na montagem do protótipo físico, os Quadros 2, 3 e 4 detalham as conexões elétricas estabelecidas entre os blocos do sistema.

Quadro 2 – Conexões entre sensor SCT-013-000 e circuito de condicionamento

| Componente | Ponto de conexão | Elemento associado |
|---------------------------|------------------|----------------------------------|
| SCT-013-000 | Saída | Em paralelo com R3 |
| R3 | Terminal 4 | Entrada AIN0 do ADS1256 |
| R3 | Terminal 3 | Divisor de tensão (R1/R2) e AIN1 |
| Divisor R1/R2 (10kΩ cada) | Ponto médio | Terminal 3 R3 |
| Capacitor C1 (10μF) | Paralelo | Entre divisor e R3 |

Fonte: Elaborado pelo autor com base na arquitetura do projeto.

Quadro 3 – Conexões de sinal entre circuito de condicionamento e ADS1256

| Sinal do Circuito | Polaridade | Pino ADS1256 |
|-------------------------------------|--------------|---------------|
| Sinal AC + <i>Offset</i> (Saída R3) | Positivo (+) | AIN0 (Pino 6) |
| Referência de <i>Offset</i> | Negativo (-) | AIN1 (Pino 7) |

Fonte: Elaborado pelo autor com base na arquitetura do projeto.

Quadro 4 – Conexões de interface SPI entre ADS1256 e ESP32

| Pino ADS1256 | Função | Pino ESP32 (GPIO) |
|-----------------|---------------------|-------------------|
| DOUT (Pino 22) | Dados do ADC (MISO) | GPIO 19 |
| DIN (Pino 23) | Comandos (MOSI) | GPIO 23 |
| SCLK (Pino 24) | Clock SPI | GPIO 18 |
| CS (Pino 20) | Chip Select | GPIO 5 |
| DRDY (Pino 21) | Data Ready | GPIO 16 |
| RESET (Pino 15) | Reset do ADC | GPIO 27 |
| SYNC (Pino 13) | Sincronização | GPIO 26 |

Fonte: Elaborado pelo autor com base na arquitetura do projeto.

4.2 Coleta de Dados

A rotina de *firmware* implementada no microcontrolador inicia-se pela configuração dos parâmetros operacionais do conversor analógico-digital. O Código-fonte 1 ilustra a inicialização do dispositivo, onde são definidos a taxa de amostragem de 7500 SPS, o ganho do amplificador programável e o canal de entrada diferencial dedicado ao sensor de corrente.

Código-fonte 1 – Configuração de inicialização do ADS1256 no ESP32

```

1 // Definicão de parametros do conversor ADS1256 (7500 SPS e Ganho 2x)
2 ads.begin(ADS1256_DRATE_7500SPS, ADS1256_GAIN_2, false);
3 ads.setChannel(0, 1); // Entrada diferencial para o sensor SCT-013
4 ads.waitDRDY(); // Sincronizacao com o sinal Data Ready

```

Após a etapa de configuração, o processo de aquisição é estruturado em janelas temporais contínuas de 1 segundo. A organização do fluxo de dados utiliza um empacotamento simplificado com marcadores de controle (*Start* e *End*), que delimitam cada vetor de amostras

transmitido. Esses marcadores são essenciais para garantir a sincronização e o processamento automatizado pelo *software* receptor, assegurando a integridade do armazenamento de cada bloco capturado.

Para a caracterização das assinaturas elétricas, definiu-se uma estratégia de coleta baseada na captura de 60 blocos sequenciais por ensaio, totalizando 450.000 pontos por equipamento. Com a taxa de amostragem fixada em $f_s = 7500$ Hz, cada janela temporal de 1 segundo engloba exatamente 7500 amostras, correspondendo a 60 ciclos da rede. Essa configuração estabelece uma frequência de Nyquist de 3750 Hz, o que viabiliza a análise espectral não apenas da fundamental (60 Hz), mas principalmente dos componentes harmônicos de ordem elevada — essenciais para a distinção de cargas não lineares. Dessa forma, a largura de banda obtida permite a reconstrução fiel de componentes até a 62ª ordem, cobrindo com ampla margem os harmônicos tipicamente utilizados em algoritmos de identificação de cargas.

4.3 Pré-processamento dos Dados

O ambiente computacional utilizado para esta seção e para todas as etapas subsequentes foi o *Google Colab*, operando sobre uma infraestrutura baseada no processador *Intel Xeon CPU @ 2.20GHz*. Nesse sentido, os sinais brutos provenientes da etapa de aquisição foram submetidos a um fluxo de tratamento digital para garantir a extração de padrões representativos e a compatibilidade com as diferentes arquiteturas de AM utilizadas neste trabalho. Assim, este processo compreende a segmentação temporal, a extração de atributos no domínio da frequência e a organização dos dados em estruturas tensoriais específicas para cada classificador.

Nesse cenário, os sinais de corrente foram segmentados em janelas de dimensão fixa, permitindo que o sistema avalie o comportamento da carga em intervalos discretos, em vez de processar uma série temporal longa onde múltiplos estados de operação estariam sobrepostos. Dessa forma, cada janela foi projetada para abranger exatamente um período da rede elétrica (60 Hz), resultando em 125 amostras por ciclo. Ademais, para aumentar a densidade do conjunto de dados e permitir que os modelos capturassem transições dinâmicas no sinal, aplicou-se um janelamento deslizante com sobreposição (*overlap*) de 80%, o que equivale a um deslocamento de 25 amostras entre janelas sucessivas.

Outrossim, é válido ressaltar o detalhamento da extração de características para os modelos de aprendizado clássico (kNN e SVM). A partir de cada janela segmentada, gerou-se um vetor híbrido composto por atributos no domínio do tempo e no domínio da frequência via

(FFT), compreendendo as amplitudes da frequência fundamental e de seus harmônicos até a 15ª ordem, conforme apresentado no Código-fonte 2.

Código-fonte 2 – Extração de Características

```

1 # Janelamento e FFT para extracao espectral
2 win_hann = win * np.hanning(len(win))
3 fft_vals = np.fft.rfft(win_hann)
4 mag = np.abs(fft_vals) / (len(win) / 2.0)
5
6 # Calculo dos 15 harmonicos
7 harm_mag = detect_harmonics(mag, n_harmonics=15)
8 thd = np.sqrt(np.sum(harm_mag[1:]**2)) / (harm_mag[0] + 1e-12)
9
10 # Formacao do vetor de atributos (Tempo + Frequencia)
11 features = np.hstack([time_features(win), harm_mag, thd])

```

De forma paralela, para garantir que variáveis com diferentes ordens de magnitude não influenciassem desproporcionalmente o cálculo das métricas de distância ou a definição do hiperplano separador, aplicou-se a padronização global via `StandardScaler`. Esse método reescala os dados para média zero e variância unitária, sendo que o ajuste (*fit*) do escalonador foi realizado rigorosamente apenas sobre o conjunto de treinamento, evitando que informações estatísticas do conjunto de teste influenciassem o aprendizado dos classificadores.

Por outro lado, para a implementação das redes neurais convolucionais, a estrutura de dados foi desenhada para permitir que a rede realizasse a extração autônoma de padrões morfológicos diretamente das janelas extraídas dos sinais brutos. Em vez de vetores de características, preservaram-se as janelas originais de 125 amostras correspondentes a cada ciclo de corrente. Nesse formato, aplicou-se a normalização *z-score* individual (amostra por amostra), o que remove componentes de *offset* contínuo e torna a representação invariante à escala absoluta da corrente. Essa estratégia foca o aprendizado da rede na assinatura da forma de onda, facilitando a identificação de dispositivos que apresentam distorções harmônicas características, independentemente da magnitude da potência consumida no momento da aquisição.

Ademais, para as redes recorrentes do tipo LSTM, os dados foram organizados em sequências temporais compostas por múltiplos ciclos consecutivos. Diferente das abordagens

anteriores, que analisam janelas isoladas, nesta configuração cada entrada do modelo consiste em uma sequência de cinco janelas ($L_{seq} = 5$), representando cinco períodos seguidos da rede elétrica (aproximadamente 83,3 milissegundos). Essa organização é fundamental para que a arquitetura recorrente possa capturar dependências temporais de curto prazo e dinâmicas cíclicas que ocorrem entre períodos sucessivos. Assim, o modelo torna-se capaz de aprender não apenas a morfologia do ciclo individual, mas também a estabilidade e o comportamento sequencial da corrente em regime permanente, agregando uma camada de contexto temporal essencial para a distinção de cargas com perfis de consumo similares.

Por fim, o conjunto de dados processado foi então particionado cronologicamente nas proporções de 70% para treinamento, 15% para validação e 15% para teste. Com isso, a separação dos blocos ocorreu antes da aplicação da sobreposição de janelas, evitando que segmentos correlacionados fossem distribuídos entre conjuntos distintos, o que mitigou riscos de superestimação de desempenho por vazamento de dados.

4.4 Treinamento dos Modelos de Classificação

Com os dados devidamente pré-processados, iniciou-se a fase de treinamento dos quatro modelos propostos: kNN, SVM, CNN e LSTM. O treinamento seguiu a lógica de aprendizado supervisionado, utilizando a partição de treinamento para o ajuste dos parâmetros internos e a partição de validação para a sintonização de hiperparâmetros e monitoramento da capacidade de generalização. O Quadro 5 consolida as configurações finais adotadas para cada arquitetura.

Quadro 5 – Modelos de classificação e hiperparâmetros de treinamento.

| Modelo | Tipo de entrada | Hiperparâmetros de Configuração |
|--------|---------------------------------------|---|
| kNN | Vetores tempo+frequência | $k = 5$; métrica Euclidiana; pesos <i>distance</i> . |
| SVM | Vetores tempo+frequência | Núcleo RBF; $C = 10,0$; $\gamma = \text{scale}$. |
| CNN | Janelas $[N, T, 1]$ | 2 camadas Conv1D (32 e 64 filtros, kernel 5, ReLU, <i>same</i>); MaxPooling (2); Densa (128); Dropout (0,5); Adam (10^{-3}); <i>Early stopping</i> (paciência 10). |
| LSTM | Sequências $[N_{seq}, L_{seq}, T]$ | Camada LSTM (64 un.); Dropout (0,5); Densa (64); Adam (10^{-3}); <i>Early stopping</i> (paciência 10). |

Fonte: Elaborado pelo autor.

Para os modelos tradicionais, a configuração priorizou a robustez estatística frente

aos vetores de atributos. No classificador kNN, definiu-se $k = 5$ vizinhos com métrica de distância Euclidiana. A adoção da ponderação baseada no inverso da distância (*distance*) foi fundamental para mitigar a influência de possíveis ruídos (*outliers*) nas fronteiras de decisão do espaço de características. No SVM, utilizou-se o núcleo de Função de Base Radial (RBF) para lidar com a não-linearidade intrínseca das classes. O parâmetro de regularização foi fixado em $C = 10,0$ para penalizar erros de classificação no treino sem comprometer excessivamente a margem de separação, enquanto o parâmetro γ seguiu a estratégia `scale`, ajustando-se automaticamente à variância dos dados de entrada.

No âmbito das redes neurais profundas, as arquiteturas foram projetadas para extrair de forma autônoma padrões de tempo e frequência diretamente das janelas temporais. A CNN foi estruturada com duas camadas de convolução sequenciais (32 e 64 filtros), ambas com núcleos de tamanho 5, preenchimento *same* e ativação ReLU para introduzir não-linearidade e capturar características morfológicas locais. Além disso, camadas de *max-pooling* com fator 2 foram aplicadas para reduzir a dimensionalidade espacial, seguidas por uma camada densa de 128 neurônios. Já a rede LSTM utilizou uma camada recorrente com 64 unidades para processar as sequências de cinco ciclos ($L_{seq} = 5$), seguida de uma camada densa de 64 neurônios, focando na captura das dependências temporais de curto prazo e na estabilidade cíclica do sinal de corrente.

Para garantir a convergência e a generalização dos modelos neurais, utilizou-se o otimizador Adam com taxa de aprendizado inicial de 10^{-3} e a função de perda *categorical crossentropy*. Como estratégia de regularização, adotou-se o mecanismo de *dropout* com taxa de 0,5 para reduzir a co-adaptação de neurônios. Adicionalmente, implementou-se a técnica de *early stopping* com paciência de 10 épocas, monitorando a perda no conjunto de validação para interromper o treinamento prematuramente e restaurar os melhores pesos obtidos, prevenindo assim sobreajuste.

4.5 Métricas de Validação e Procedimentos de Análise

A estratégia de validação das arquiteturas propostas fundamentou-se em uma abordagem multidimensional, compreendendo a verificação da eficácia preditiva, a análise de robustez experimental e a avaliação de eficiência computacional. Para a quantificação do desempenho preditivo, adotou-se a Acurácia Global como métrica primária, calculada sobre o conjunto de teste. A opção por esta métrica fundamenta-se no rigoroso balanceamento das classes no conjunto de dados, cenário no qual a taxa de acerto global converge para valores equivalentes às

médias harmônicas de precisão e sensibilidade, permitindo uma avaliação fidedigna da capacidade de generalização do modelo sem a necessidade de ponderações adicionais para compensar desequilíbrios amostrais.

Além da métrica escalar, empregou-se a Matriz de Confusão como instrumento de diagnóstico qualitativo do erro. Diferentemente da acurácia, que sintetiza o desempenho em um valor único, a matriz de confusão permite a discriminação dos erros de classificação entre pares de categorias específicas. Esta análise é crucial para investigar a correlação entre a similaridade física das cargas e a sobreposição de suas representações no espaço de características, evidenciando as limitações de separabilidade de cada algoritmo proposto.

Paralelamente, no que tange à viabilidade técnica, a avaliação de eficiência computacional foi conduzida através do monitoramento de três parâmetros críticos para a implementação em *hardware*: a ocupação de armazenamento, inferida pelo tamanho do modelo serializado; a latência de inferência do conjunto de teste, definida pelo tempo de processamento unitário de uma janela ou sequência; e a demanda computacional, mensurada pela taxa de ocupação da unidade central de processamento (CPU). A análise conjunta destes indicadores visa estabelecer a relação de compromisso entre a complexidade arquitetural dos modelos e sua aptidão para operação em tempo real, fornecendo subsídios para a seleção da solução mais adequada a microcontroladores com recursos limitados.

De forma complementar, visando validar a imunidade do sistema frente a variações nos parâmetros de qualidade de energia — como distorções harmônicas —, estabeleceu-se um protocolo experimental de inferência cruzada. Neste procedimento, os modelos treinados foram submetidos a sinais de cargas representativas (linear e não linear) adquiridos em uma infraestrutura elétrica distinta do conjunto de dados original (rede da UFC – Campus Quixadá), permitindo avaliar a estabilidade das fronteiras de decisão e a confiança da classificação diante de alterações na impedância da fonte de alimentação.

Para quantificar a certeza desta generalização, definiu-se a métrica de Confiança de Predição, cujo cálculo é adaptado à natureza da saída de cada modelo. Uma vez que a classificação final do dispositivo é determinada pela classe majoritária entre as janelas processadas, a confiança é extraída de duas formas: para modelos de Aprendizado Profundo (CNN e LSTM), ela corresponde à média aritmética das probabilidades (*Softmax*) atribuídas à classe vencedora em todas as janelas do sinal; para modelos clássicos sem estimativa probabilística direta (kNN e SVM), a métrica reflete a consistência da decisão, calculada pela frequência relativa de votos da

classe majoritária sobre o total de janelas analisadas, conforme ilustrado no Código-fonte 3.

Código-fonte 3 – Cálculo da Confiança via Softmax Médio e Votação

```
1 # 1. Determinar classe majoritaria (Moda)
2 contagem = Counter(preds)
3 idx_majoritario, frequencia = contagem.most_common(1)[0]
4
5 # 2. Calcular a Certeza (Confianca)
6 if nome_modelo in ['CNN', 'LSTM']:
7     # Media da probabilidade maxima de cada janela
8     prob_media = np.mean(np.max(probs_dl[nome_modelo], axis=1)) * 100
9     certeza_str = f"{prob_media:.2f}% (softmax)"
10 else:
11     # Consistencia: % de janelas que votaram na classe majoritaria
12     consistencia = (frequencia / len(preds)) * 100
13     certeza_str = f"{consistencia:.2f}% (votacao)"
```

Em síntese, o arcabouço metodológico aqui delineado integra as métricas de precisão estatística com a análise de eficiência computacional e a variabilidade do ambiente elétrico real. Essa abordagem holística assegura não apenas a eficácia preditiva dos modelos, mas também certifica que as soluções propostas operem com um custo de processamento racional e otimizado, mantendo a estabilidade da classificação mesmo quando expostas a redes elétricas com características distintas das observadas no treinamento.


5 RESULTADOS

Nesta seção são apresentados e discutidos os principais resultados obtidos com o sistema proposto, abrangendo desde a análise das formas de onda de corrente medidas até o desempenho dos modelos de classificação na identificação dos dispositivos elétricos.

5.1 Composição do Conjunto de Dados

O conjunto de dados empregado neste trabalho é constituído por oito classes de dispositivos elétricos típicos de ambientes residenciais: *Celular*, *Escova*, *Geladeira*, *Lâmpada incandescente*, *Lâmpada LED*, *Notebook*, *Roteador* e *Secador de Cabelo*. A distribuição do número de amostras por classe é apresentada na Figura 15, na qual se observa que todas as categorias consideradas são contempladas com o mesmo volume de dados, o que evidencia a preocupação em construir um conjunto de dados estatisticamente equilibrado.

Figura 15 – Número de amostras por classe de dispositivo.




Fonte: Elaborado pelo autor.

Dessa forma, em termos quantitativos, o conjunto de dados bruto reúne 450.000 amostras por classe e, considerando as oito classes, perfaz exatamente 3,6 milhões de amostras no total. Com isso, a disponibilidade dessa vasta quantidade de dados brutos permite capturar com maior fidelidade as variações intrínsecas de cada carga, compondo a base sólida utilizada nas etapas subsequentes de modelagem do sistema.

5.2 Caracterização dos Sinais de Corrente

Nesta etapa são analisadas as assinaturas de corrente medidas pelo sistema de aquisição, com o intuito de evidenciar a qualidade dos sinais obtidos e a diversidade de comportamentos presentes no conjunto de dados. Para fins de clareza visual e detalhamento do perfil das ondas, cada subgráfico da Figura 16 exibe um recorte temporal contendo, exatamente, dois ciclos fundamentais do sinal original de cada classe.

Figura 16 – Assinaturas de Corrente no Domínio do Tempo.



Fonte: Elaborado pelo autor.

A inspeção visual da Figura 16 revela distinções morfológicas claras, intrinsecamente ligadas à topologia elétrica de cada carga monitorada. Essas variações manifestam-se fundamentalmente na continuidade da condução e na simetria dos semiciclos, refletindo a natureza dos estágios de entrada de cada equipamento. Tais características permitem não apenas a diferenciação imediata entre categorias de cargas, mas também a inferência preliminar sobre o grau de não linearidade do dispositivo em resposta à tensão da rede elétrica.

Em tal cenário, é indubitável que a Lâmpada Incandescente estabelece o referencial de linearidade do sistema. O dispositivo exibe uma forma de onda senoidal pura, comportamento característico de cargas resistivas, nas quais a corrente preserva a morfologia da tensão de alimentação sem introduzir defasagens ou distorções harmônicas significativas.

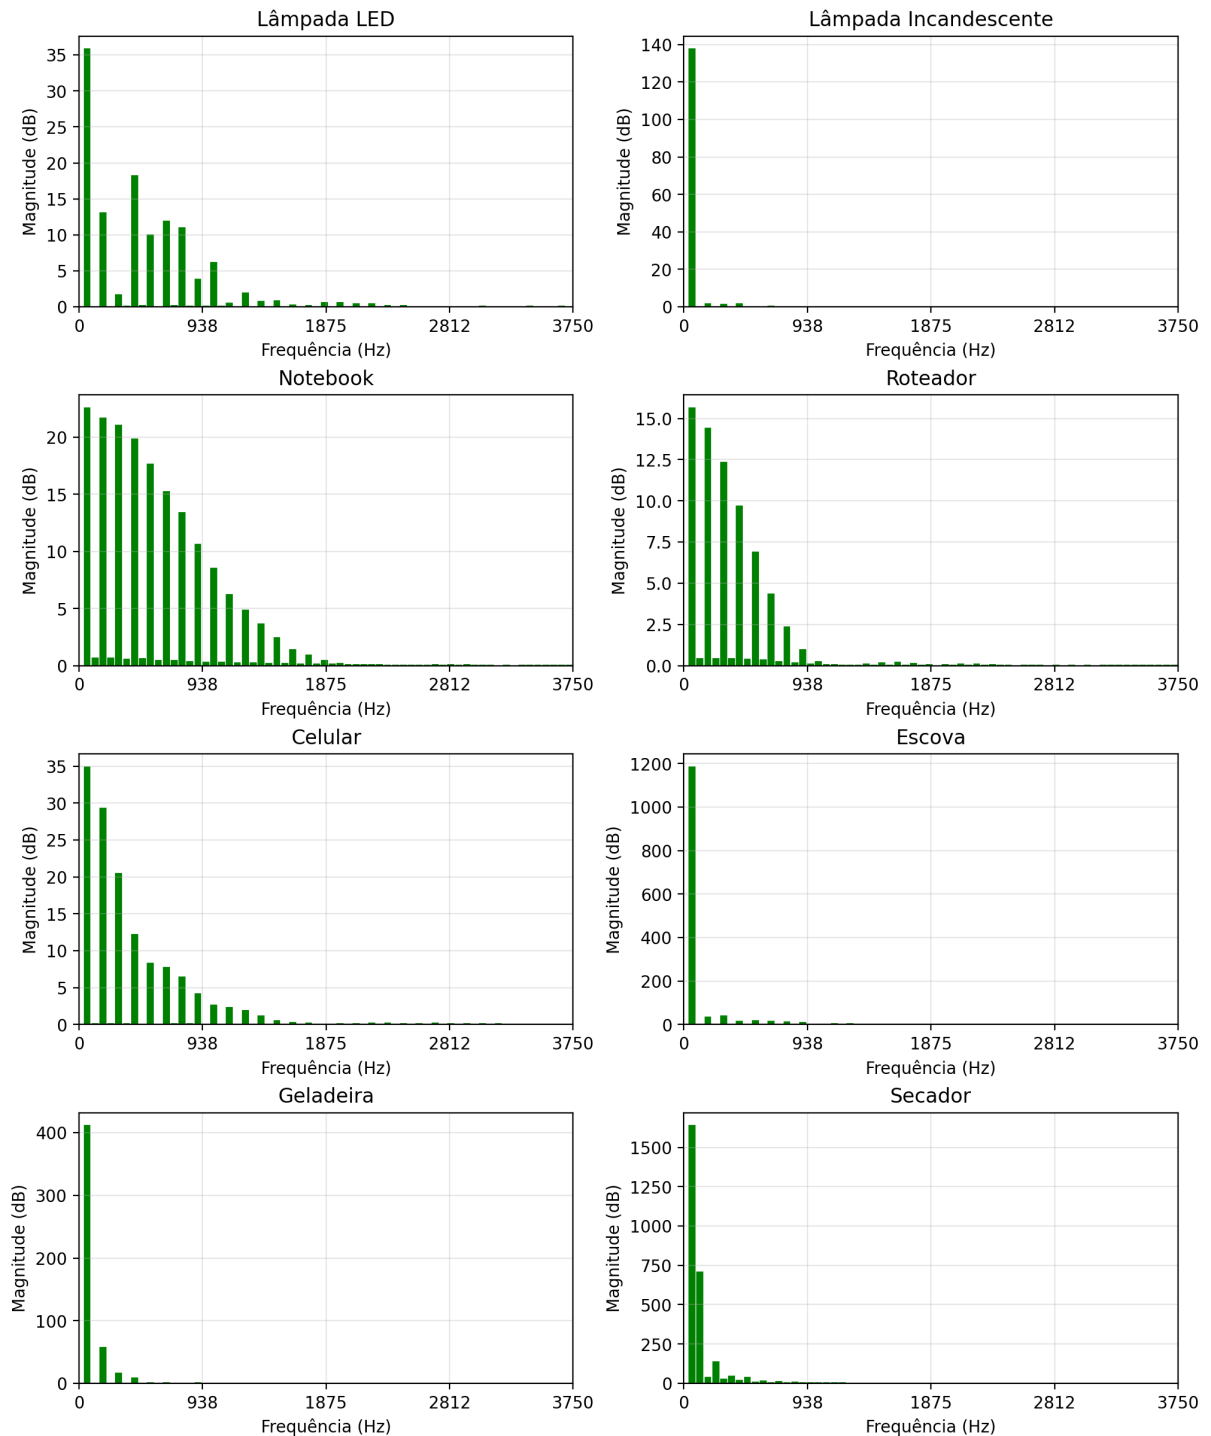
Em contrapartida, observa-se um comportamento não linear acentuado nos dispositivos eletrônicos de baixa potência, tais como o *Notebook*, o *Roteador*, o *Celular* e a *Lâmpada LED*. Estes equipamentos operam com fontes chaveadas em regime de condução descontínua. A análise gráfica revela um consumo de corrente concentrado em pulsos abruptos de curta duração e elevado fator de crista. Tal fenômeno decorre do estágio de retificação e filtragem capacitiva dessas fontes, que drenam corrente da rede elétrica apenas quando a tensão instantânea de entrada supera a tensão armazenada nos capacitores do barramento DC, gerando picos coincidentes com as cristas da senóide da tensão.

Simultaneamente, cargas de maior potência e de natureza eletromecânica apresentam assinaturas singulares. A *Geladeira*, *Escova Elétrica* e o *Secador de Cabelo*, embora mantenham um envelope próximo ao senoidal contínuo, exibem deformações específicas: o secador e a escova apresentam alta amplitude com distorções sutis, enquanto a *Geladeira* demonstra características de motores de indução, com assimetrias que sugerem a presença de harmônicas de baixa ordem. Essa diversidade de assinaturas temporais — oscilando entre a linearidade resistiva, a indução motora e a não linearidade pulsada — valida a eficácia do sistema de aquisição, confirmando que este possui sensibilidade e largura de banda suficientes para a captura de dados com alta fidelidade.

Além disso, embora a análise no domínio do tempo revele a morfologia macroscópica da corrente, ela possui limitações intrínsecas na quantificação precisa das não-linearidades. Visualmente, é complexo distinguir a contribuição individual de cada ordem harmônica, uma vez que elas se apresentam superpostas na forma de onda resultante. Para superar essa barreira e evidenciar a estrutura espectral oculta nos sinais, aplicou-se a (FFT). Essa mudança de domínio

permite decompor o sinal em suas frequências constitutivas, transformando as distorções visuais observadas anteriormente em padrões discretos e quantificáveis de magnitude. As assinaturas espectrais resultantes, que funcionam como um perfil harmônico detalhado da topologia interna de cada carga, são apresentadas na Figura 17.

Figura 17 – Assinaturas de Corrente no Domínio da Frequência.



Fonte: Elaborado pelo autor.

Preliminarmente, destaca-se, em consonância com a taxa de amostragem definida

de 7500 Hz, que os espectros apresentados estendem-se até o limite de Nyquist de 3750 Hz. Observa-se que essa largura de banda abrange a totalidade do espectro relevante das cargas, permitindo a visualização de componentes até a ordem aproximada de 62 harmônicas, o que garante a integridade da informação e evita perdas significativas por *aliasing*.

Sob essa ótica, a análise dos perfis espectrais confirma que a natureza da carga determina diretamente a distribuição de energia entre a componente fundamental (60 Hz) e seus múltiplos inteiros. No caso da *Lâmpada Incandescente*, o gráfico corrobora a análise temporal de linearidade: a energia do sinal concentra-se quase exclusivamente na frequência fundamental, com magnitudes harmônicas desprezíveis, caracterizando uma carga com Distorção Harmônica Total próxima de zero.

Em contraste, os dispositivos eletrônicos de baixa potência (*Notebook, Roteador, Celular e Lâmpada LED*) exibem um espectro rico em harmônicas ímpares. Este comportamento constitui a assinatura espectral característica de retificadores de onda completa alimentando cargas capacitivas. É fundamental notar, contudo, que a taxa de decaimento da amplitude dessas harmônicas varia significativamente entre os dispositivos. O *Notebook*, por exemplo, apresenta um decaimento espectral mais lento, preservando componentes de magnitude relevante que se estendem até frequências superiores a 900 Hz. Já o *Roteador* exibe uma atenuação abrupta, com sua energia concentrada predominantemente nas harmônicas de baixa ordem. Tal fenômeno reflete a maior potência e a complexidade dos estágios de regulação da fonte do computador portátil.

No que tange às cargas de maior potência, como a *Geladeira, Escova e o Secador de Cabelo*, observa-se a predominância massiva da componente fundamental. Embora existam harmônicas de baixa ordem visíveis, sua magnitude relativa em comparação ao pico fundamental é significativamente inferior àquela observada nos dispositivos eletrônicos, indicando uma operação mais próxima da linearidade, porém com deformações pontuais oriundas de saturação magnética ou características eletromecânicas.

Portanto, a análise conjunta dos domínios do tempo e da frequência demonstra que cada classe de dispositivo possui uma identidade elétrica multidimensional. Enquanto o domínio do tempo revela a morfologia do consumo, o domínio da frequência detalha a composição espectral dessa energia. Essa complementaridade enriquece o vetor de características fornecido aos algoritmos de aprendizado de máquina, potencializando a capacidade do modelo de distinguir cargas que, embora possam apresentar potências ativas similares, divergem em suas topologias

internas e conteúdo harmônico.

5.3 Estruturação dos Dados Pré-processados para Classificação

A consolidação da base de dados pré-processada, obtida através da segmentação dos sinais em janelas deslizantes com 80% de sobreposição, resultou em um universo de 143 904 amostras válidas, distribuídas de forma balanceada entre as oito classes de dispositivos monitorados. Nesse sentido, visando garantir a robustez estatística dos experimentos, o particionamento cronológico destinou a maior parcela das instâncias ao treinamento dos modelos (aproximadamente 100 mil instâncias), reservando volumes idênticos e independentes para as etapas de validação e teste, assegurando assim a integridade da avaliação de generalização.

No que tange à representação desses sinais tratados, adotou-se uma abordagem dual para atender às especificidades de cada arquitetura. Os classificadores estatísticos (kNN e SVM) operaram sobre um espaço de atributos de baixa dimensionalidade, utilizando vetores de características que sintetizam descritores estatísticos e componentes espectrais previamente normalizados. De forma divergente, as arquiteturas de Aprendizado Profundo foram alimentadas com a estrutura temporal do sinal processado: a CNN utilizou vetores densos de 125 pontos (representando um ciclo completo da rede), enquanto a LSTM manipulou matrizes sequenciais de 5×125 , capturando as dinâmicas temporais e harmônicas entre ciclos sucessivos.

Ressalta-se que a organização sequencial exigida pela arquitetura recorrente (LSTM) implicou um ajuste marginal no volume total de instâncias, decorrente do agrupamento de janelas. A Tabela 3 detalha a distribuição quantitativa definitiva utilizada em cada etapa do fluxo de classificação.

Tabela 3 – Distribuição final das instâncias processadas por subconjunto.

| Subconjunto | Proporção | Janelas Individuais (kNN/SVM/CNN) | Sequências (LSTM) |
|--------------------|------------------|--|------------------------------|
| Treinamento | 70% | 100 768 | 100 736 |
| Validação | 15% | 21 568 | 21 536 |
| Teste | 15% | 21 568 | 21 536 |
| Total | 100% | 143 904 | 143 808 |

Fonte: Elaborado pelo autor.

Essa estruturação final estabelece condições experimentais rigorosas, onde a normalização dos dados (via *StandardScaler* e *z-score*) elimina vieses de magnitude e permite que a comparação de desempenho, apresentada a seguir, reflita exclusivamente a capacidade de

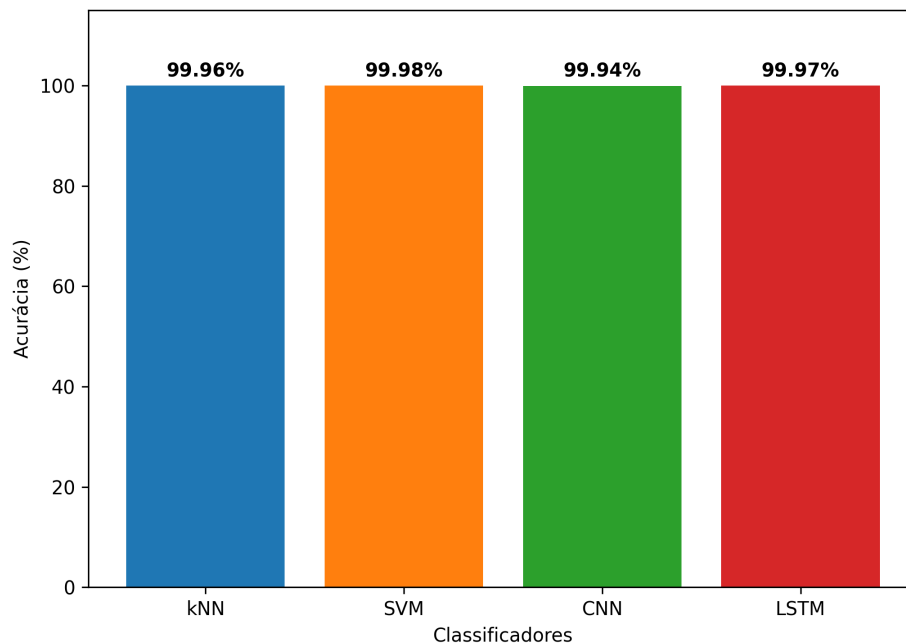
aprendizado de cada algoritmo.

5.4 Análise do Desempenho Preditivo dos Modelos

Após a definição das arquiteturas, a estruturação dos dados de entrada e a sintonização dos hiperparâmetros, procedeu-se à avaliação quantitativa do desempenho dos classificadores na tarefa de identificação das cargas elétricas. Nesta etapa, adotou-se a acurácia global sobre o conjunto de teste como métrica primária de avaliação. A escolha fundamenta-se no rigoroso balanceamento entre as oito classes de dispositivos, o que permite que essa métrica reflita fielmente a taxa de acerto do sistema sem as distorções estatísticas comuns em cenários de classes desbalanceadas.

A Figura 18 sintetiza o desempenho comparativo das arquiteturas avaliadas. Observa-se que todos os modelos atingiram índices de acerto excepcionalmente elevados, situados no intervalo entre 99,94% e 99,98%. Tais patamares indicam que, sob as condições experimentais estabelecidas, as assinaturas elétricas de corrente possuem alta discriminabilidade, permitindo que as fronteiras de decisão sejam estabelecidas com precisão quase absoluta, tanto por abordagens de Aprendizado Profundo quanto por modelos clássicos baseados em engenharia de atributos.

Figura 18 – Acurácia de teste dos modelos kNN, SVM, CNN e LSTM.



Fonte: Elaborado pelo autor.

Conforme os dados experimentais, o classificador SVM atingiu o teto de desempenho

deste estudo, registrando 99,98% de acurácia, seguido imediatamente pela rede recorrente LSTM (99,97%) e pelo classificador kNN (99,96%). A rede CNN unidimensional apresentou o menor índice relativo entre as arquiteturas, com 99,94%, embora tal diferença seja estatisticamente marginal. A uniformidade desses resultados, todos situados acima de 99,9%, evidencia a robustez do fluxo de pré-processamento adotado.

É imperativo destacar que esses índices de acerto, embora numericamente elevados, não devem ser interpretados como indício de sobreajuste. A garantia da generalização sustenta-se, primeiramente, no rigoroso particionamento dos dados, que respeitou a cronologia da aquisição e impediu que amostras temporais adjacentes — e, portanto, altamente correlacionadas — fossem distribuídas entre os conjuntos de treinamento e teste. Somado a isso, o próprio volume estatístico do conjunto de teste, superior a 21 mil amostras, assegura a cobertura representativa da variabilidade operacional das cargas.

Adicionalmente, a consistência dos resultados observada entre modelos de naturezas opostas — desde a simplicidade geométrica do kNN até a complexidade recorrente da LSTM — sugere que o alto desempenho é mérito da separabilidade intrínseca das classes no espaço de características, e não de uma memorização espúria por parte de uma arquitetura específica. Com isso, deve-se considerar a influência da natureza do problema, delimitada neste estudo à classificação de cargas em operação isolada. Essa condição elimina a complexidade estocástica inerente à superposição de múltiplos sinais simultâneos, reduzindo drasticamente a ambiguidade das fronteiras de decisão e facilitando a convergência dos algoritmos para taxas de acerto superiores.

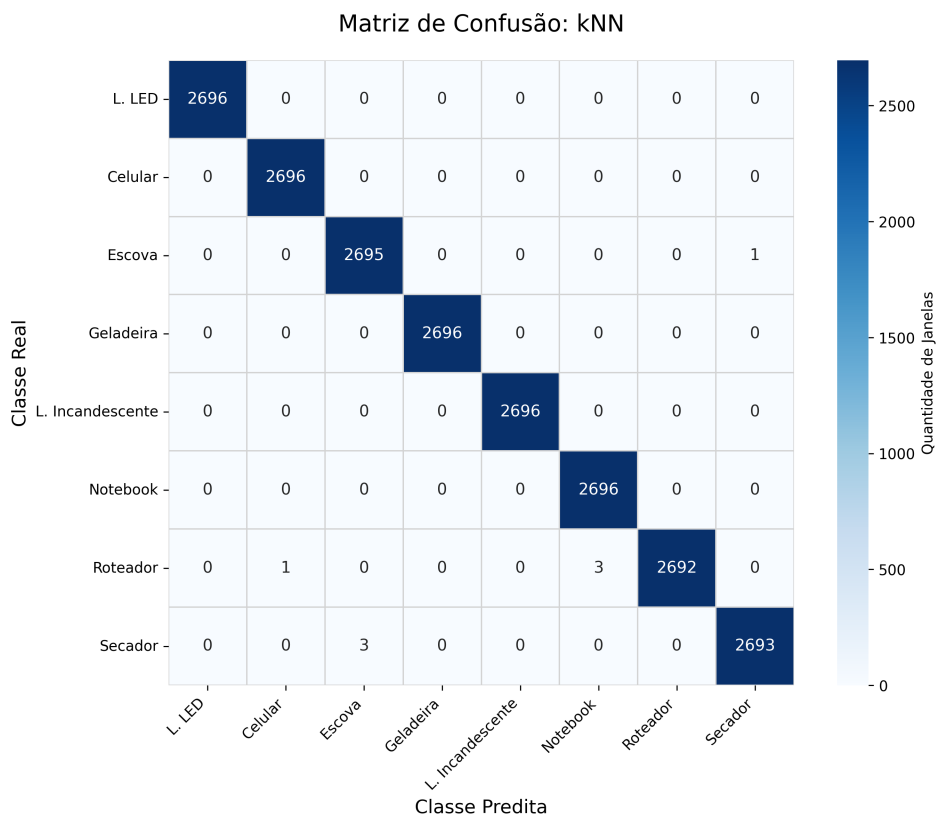
Portanto, a equivalência de desempenho entre os modelos clássicos e as redes neurais traz uma conclusão relevante para a aplicação prática: a inclusão explícita de atributos espectrais (FFT) no vetor de entrada do SVM e kNN mostrou-se tão eficaz quanto a capacidade de extração autônoma de características das redes profundas. Tal resultado corrobora diretamente a qualidade do projeto de instrumentação, evidenciando que um sistema de aquisição de baixo ruído, aliado a um pré-processamento rigoroso dos dados, simplifica significativamente a tarefa de classificação. Isso implica que, para este domínio de problema, a excelência na etapa de condicionamento e tratamento do sinal reduz a necessidade de modelos de alta complexidade para atingir precisão elevada.

5.5 Análise Diagnóstica via Matrizes de Confusão

Para aprofundar a compreensão sobre o comportamento dos classificadores e investigar o grau de similaridade entre as classes preditas, procedeu-se à análise detalhada das matrizes de confusão. A avaliação inicia-se pelos modelos baseados em aprendizado de máquina convencional (kNN e SVM), que operam sobre vetores de características temporais e harmônicas extraídas. O desempenho destes algoritmos é ilustrado, respectivamente, nas Figuras 19 e 20.


Ressalta-se que, para a elaboração destes e dos demais gráficos diagnósticos, a nomenclatura dos dispositivos foi padronizada visando a otimização da legibilidade. Utilizaram-se as abreviações "L. LED" para o dispositivo de iluminação eletrônica e "L. Incandescente" para a carga resistiva de referência, evitando a sobreposição de caracteres nos eixos e assegurando a identificação imediata tanto da diagonal principal quanto dos erros residuais.

Figura 19 – Matriz de confusão para o modelo kNN.



Fonte: Elaborado pelo autor.

Figura 20 – Matriz de confusão para o modelo SVM.

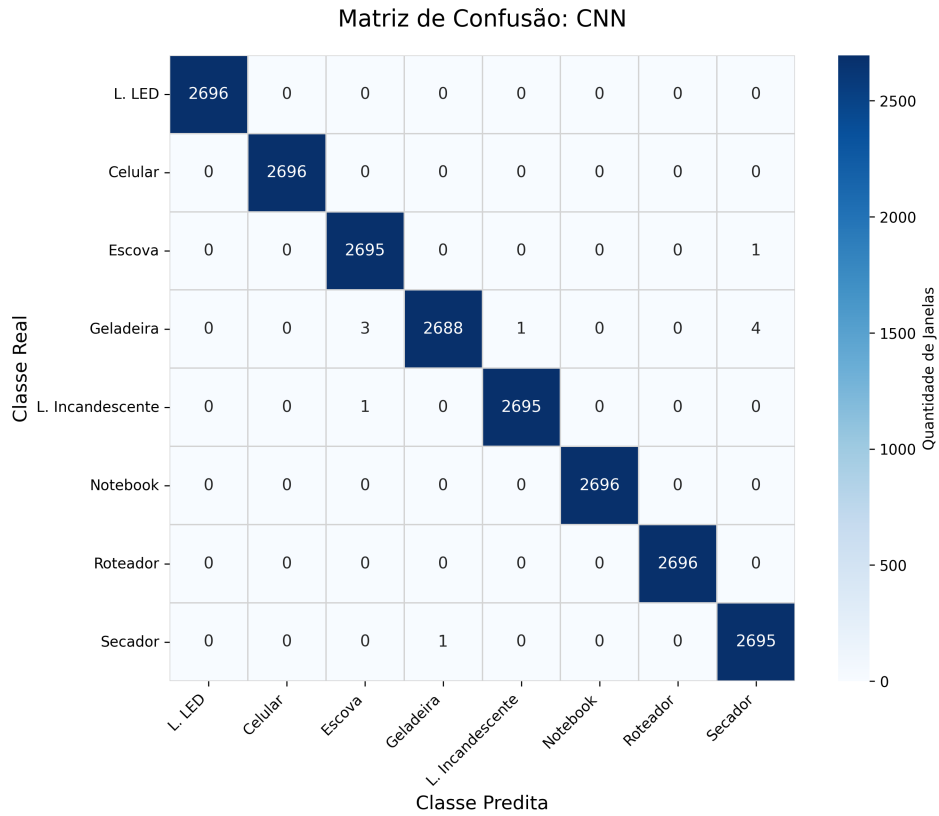


Fonte: Elaborado pelo autor.

A análise aprofundada das matrizes permite qualificar a natureza dos erros residuais observados. No caso do kNN, as dispersões, embora marginais, concentraram-se em dois eixos: a confusão entre cargas motorizadas (3 janelas de *Secador* atribuídas à classe *Escova*) e a sobreposição entre fontes chaveadas (3 janelas de *Roteador* classificadas como *Notebook*). Eletricamente, tais resíduos são justificados pela extrema proximidade dos vetores de características gerados por topologias análogas — motores universais e retificadores em ponte, respectivamente — que desafiam a discriminação puramente baseada em distância Euclidiana.


Em contrapartida, o classificador SVM demonstrou uma estabilidade superior na definição das fronteiras de decisão. O modelo suprimiu integralmente as ambiguidades entre cargas eletromecânicas, restringindo seus erros residuais a ocorrências pontuais na distinção de dispositivos eletrônicos de baixa potência (*Roteador* confundido marginalmente com *Celular* e *Notebook*). Por outro lado, as arquiteturas de Aprendizado Profundo operam sob o paradigma do aprendizado de características, processando ciclos de corrente normalizados de forma autônoma. A Figura 21 exibe a matriz de confusão para a rede neural convolucional, seguida pela Figura 22, que detalha o desempenho da rede de memória de longo prazo.

Figura 21 – Matriz de confusão para o modelo CNN.



Fonte: Elaborado pelo autor.

Figura 22 – Matriz de confusão para o modelo LSTM.



Fonte: Elaborado pelo autor.

A arquitetura CNN apresentou um desempenho robusto na classe *Geladeira*, exibindo dispersões marginais onde 4 instâncias foram classificadas como *Secador* e 3 como *Escova*. Tais ocorrências sugerem uma sensibilidade dos filtros convolucionais a transientes instantâneos. Em contrapartida, a rede LSTM alterou o perfil desses resíduos: embora tenha registrado um leve incremento na confusão com a *Escova* (4 ocorrências), a arquitetura foi capaz de eliminar integralmente a falsa atribuição ao *Secador*.

Portanto, a inspeção detalhada das matrizes de confusão confirma a robustez do desempenho preditivo global, visto que a análise das divergências revela apenas sutilezas no comportamento dos modelos. Diante desses resultados sólidos, a definição da arquitetura ideal expande-se para além da métrica de acerto, incorporando requisitos críticos de eficiência computacional. Esse alinhamento, a ser detalhado a seguir, garante que o modelo selecionado preserve a performance de classificação ao ser transposto para cenários de aplicação real, respeitando as restrições de recursos inerentes ao *hardware*.

5.6 Análise da Eficiência Computacional

A viabilidade técnica de um sistema de monitoramento não intrusivo transcende a métrica de acurácia, sendo intrinsecamente condicionada pela eficiência no gerenciamento de recursos computacionais. A transposição de modelos teóricos para ambientes de produção exige que o alto desempenho preditivo seja sustentável sob restrições de *hardware*. Diante disso, avaliou-se o desempenho dos classificadores sob quatro dimensões críticas: ocupação de memória não volátil, demanda de processamento (carga de CPU), tempo total de execução sobre o conjunto de teste e latência unitária de inferência. A Tabela 4 apresenta o comparativo quantitativo entre as arquiteturas, destacando o custo operacional associado a cada modelo.

Tabela 4 – Comparativo de consumo de recursos e eficiência temporal entre os modelos.

| Modelo | Armazenamento (MB) | Carga de CPU (%) | Tempo Total de Teste (s) | Latência por Instância (ms) |
|---------------|-------------------------------|-----------------------------|-------------------------------------|--|
| kNN | 19,99 | 61,16 | 35,906 | 1,6648 |
| SVM | 0,20 | 99,97 | 1,090 | 0,0506 |
| CNN | 3,08 | 97,86 | 2,647 | 0,1227 |
| LSTM | 0,64 | 123,38 | 1,289 | 0,0598 |

Nota: O “Tempo Total” refere-se ao processamento integral do conjunto de teste (21.568 janelas para kNN/SVM/CNN e 21.536 sequências para LSTM). A “Latência por Instância” refere-se ao tempo de inferência de uma única instância. Valores de CPU acima de 100% indicam paralelização em múltiplos núcleos lógicos.

Fonte: Elaborado pelo autor (2025).

Os resultados foram obtidos em ambiente controlado de computação em nuvem, utilizando a plataforma *Google Colab*. Ressalta-se que a aceleração por GPU foi deliberadamente desativada, restringindo a execução à *Intel Xeon CPU @ 2.20GHz*, a fim de proporcionar uma comparação mais justa e representativa de cenários onde aceleradores de *hardware* dedicados podem não estar disponíveis.

A análise dos dados evidencia que o classificador SVM oferece a maior eficiência para cenários com limitações de memória e processamento. Com um tamanho de arquivo de apenas 0,20 MB e uma latência unitária de 0,0506 ms, o modelo mostrou-se aproximadamente 32 vezes mais célere que o kNN (1,6648 ms), mantendo a mesma faixa de precisão. Essa disparidade deriva diretamente da estrutura matemática dos algoritmos: enquanto o SVM reduz a inferência a um cálculo algébrico de posicionamento em relação a um hiperplano, o kNN exige o armazenamento integral do corpus de treinamento (resultando em 19,99 MB de ocupação) e realiza uma custosa busca por similaridade a cada nova classificação, o que compromete sua escalabilidade em aplicações reais.

No espectro das redes neurais, a arquitetura LSTM apresentou uma otimização de armazenamento superior à CNN unidimensional, ocupando 0,64 MB contra 3,08 MB da rede convolucional. Essa compactidade deve-se à eficiência das células de memória em parametrizar o problema sem a necessidade de múltiplos mapas de características densos. Além disso, neste cenário puramente baseado em CPU, a LSTM destacou-se pela eficiência temporal (0,0598 ms), superando a CNN (0,1227 ms), o que sugere uma implementação altamente otimizada das operações recorrentes na biblioteca de execução.


Por fim, a análise de processamento revela que o SVM e as redes neurais maximizaram o uso da CPU (cargas $\approx 100\%$ ou mais) para reduzir a latência via paralelização. Já o kNN, com menor ocupação (61,16%) e resposta lenta, evidenciou que seu desempenho é limitado pela latência de memória e não pelo cálculo. Tais dados confirmam que a eficiência computacional varia drasticamente conforme a arquitetura, independentemente da precisão alcançada.

5.7 Validação da Robustez dos Classificadores em Redes Distintas

Com o objetivo de corroborar a aplicabilidade prática do sistema proposto, expandiu-se a análise para além do conjunto de teste padrão, submetendo os modelos a um cenário de inferência cruzada. O experimento utilizou dados adquiridos na rede elétrica da Universidade Federal do Ceará (Campus Quixadá), ambiente que impõe desafios adicionais de generalização

devido às suas características distintas de impedância e distorção harmônica em comparação à residência de treinamento. Para avaliar o impacto dessas variações, selecionaram-se três cargas representativas: o *Celular*, a *Lâmpada Incandescente* e o *Notebook*. A Figura 23 ilustra as formas de onda de corrente capturadas nos dois ambientes, evidenciando que, apesar da preservação da morfologia geral, ocorrem desvios de amplitude e deformações nos picos decorrentes da interação com a impedância da nova rede.

Figura 23 – Formas de Onda de Corrente no Domínio do Tempo: Rede Residencial vs. Rede UFC

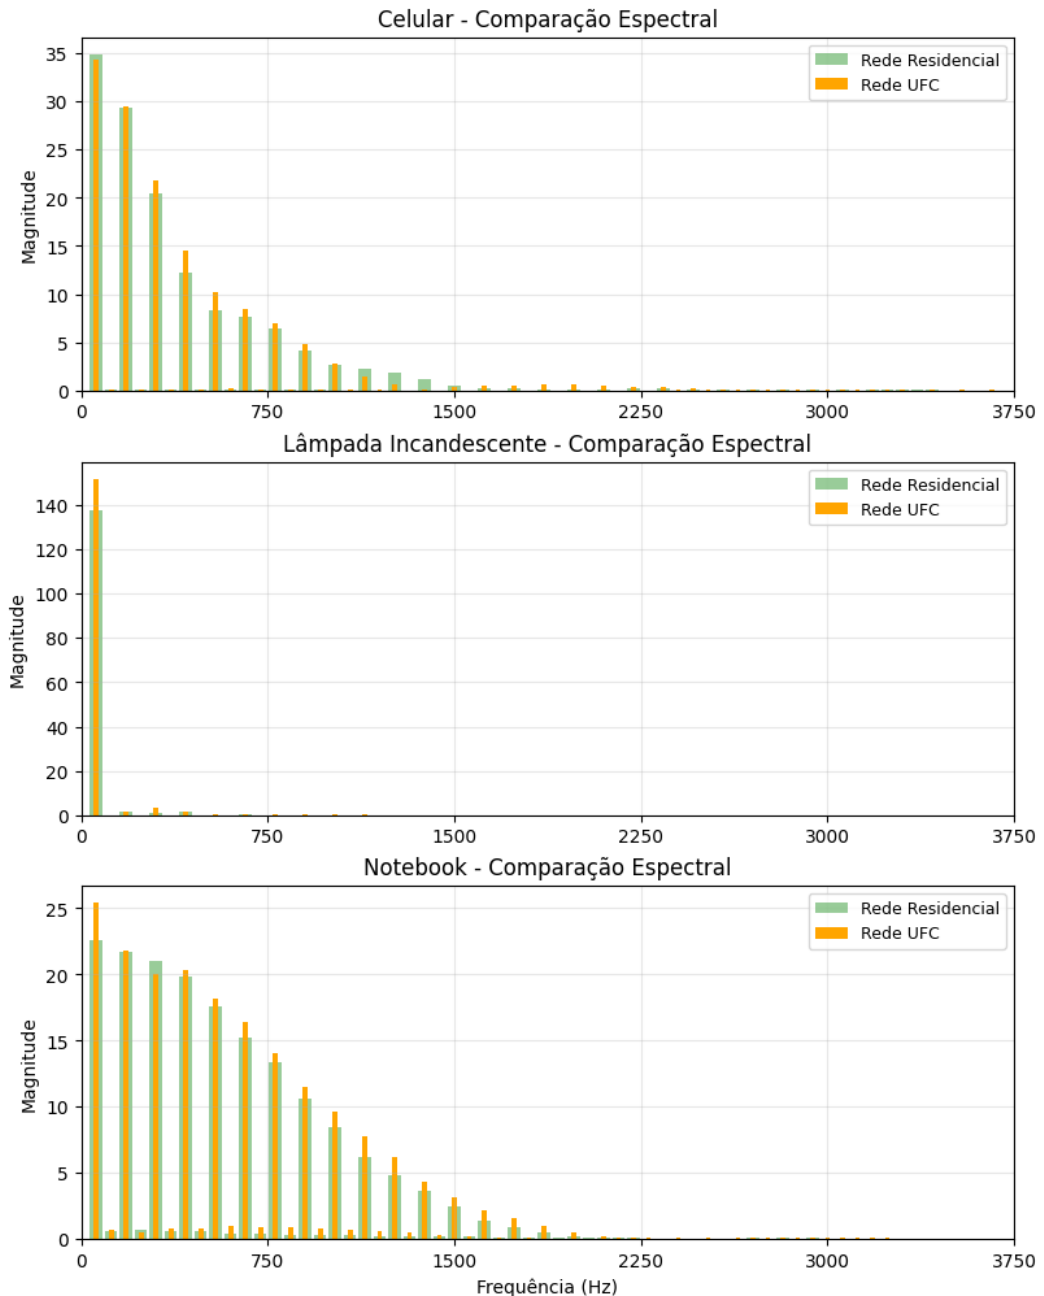


Fonte: Elaborado pelo autor.

De forma paralela, a Figura 24 detalha essas alterações no domínio da frequência,

onde se notam flutuações nas magnitudes das harmônicas, especialmente no dispositivo de baixa potência. Tais discrepâncias espectrais constituem um ruído de domínio que testa a resiliência das fronteiras de decisão aprendidas pelos modelos.

Figura 24 – Espectro de Frequência das Correntes: Rede Residencial vs. Rede UFC



Fonte: Elaborado pelo autor.

A Tabela 5 compila a classe majoritária predita e os níveis de confiança associados a cada arquitetura frente a essas perturbações.

Tabela 5 – Resultados da inferência sob a rede elétrica da UFC (Campus Quixadá).

| Dispositivo | Modelo | Predição Final | Confiança (%) |
|-----------------------|---------------|-----------------------|----------------------|
| Lâmpada Incandescente | kNN | Lâmpada Incandescente | 100,00 |
| | SVM | Lâmpada Incandescente | 100,00 |
| | CNN | Lâmpada Incandescente | 99,95 |
| | LSTM | Lâmpada Incandescente | 99,96 |
| Celular | kNN | Celular | 60,14 |
| | SVM | Celular | 100,00 |
| | CNN | Celular | 97,99 |
| | LSTM | Celular | 94,33 |
| Notebook | kNN | Notebook | 100,00 |
| | SVM | Notebook | 100,00 |
| | CNN | Notebook | 100,00 |
| | LSTM | Notebook | 100,00 |

Fonte: Elaborado pelo autor.

A análise dos resultados evidencia uma elevada consistência no desempenho dos classificadores para a identificação da *Lâmpada Incandescente* e do *Notebook*. Observou-se que ambos os dispositivos foram categorizados com índices de probabilidade de pertinência (*confidence scores*) próximos à unidade por todas as arquiteturas avaliadas. Tal comportamento sugere que as assinaturas espectrais destes equipamentos possuem alta invariância frente às flutuações da rede. Tanto a predominância da componente fundamental na carga resistiva quanto o padrão harmônico bem definido da fonte chaveada preservaram suas características distintivas, demonstrando baixa sensibilidade às variações de tensão inerentes à rede institucional.

Em contrapartida, a classificação do carregador de *Celular* evidencia disparidades na capacidade de generalização entre os algoritmos. Embora o acerto de predição tenha sido mantido, o classificador kNN apresentou um decaimento significativo na métrica de confiança, registrando valor médio de 60,14%. Este resultado indica que as perturbações na rede elétrica institucional induziram deslocamentos na distribuição das amostras no espaço de características, reduzindo a margem de separabilidade em relação às classes adjacentes em aproximadamente 40% das janelas processadas. Diferentemente, o SVM e as redes neurais (CNN e LSTM) sustentaram níveis de confiança superiores a 94%, corroborando a superioridade de fronteiras de decisão não lineares e da extração hierárquica de atributos frente à sensibilidade a ruídos observada em métodos baseados em distância euclidiana.

Logo, os dados confirmam a robustez da metodologia proposta. O sistema demonstrou não apenas alta precisão no domínio de origem, mas também a plasticidade necessária para

operar sob as distorções harmônicas de uma rede elétrica distinta. A capacidade do SVM e dos modelos de aprendizado profundo em preservar a confiabilidade na identificação de cargas complexas, mesmo aquelas com assinaturas voláteis, como fontes chaveadas, valida a estabilidade das fronteiras de decisão aprendidas, indicando que as características extraídas são de fato representativas do fenômeno físico e não meros artefatos do ambiente de treinamento.

6 CONCLUSÕES E TRABALHOS FUTUROS

A presente investigação validou a eficácia de uma arquitetura de monitoramento não intrusivo, demonstrando que a robustez na identificação de dispositivos elétricos é consequência direta da integração sinérgica entre uma instrumentação de alta fidelidade e algoritmos de AM. Nesse sentido, uma contribuição fundamental deste trabalho reside na demonstração de que o desenvolvimento de um sistema de aquisição de dados de alta resolução, apto a preservar a integridade das componentes harmônicas e a dinâmica transiente da corrente, reduz substancialmente a complexidade demandada nas etapas subsequentes de processamento.

Ao prover aos classificadores um espaço de características com elevada separabilidade, a plataforma de *hardware* desenvolvida permitiu que tanto arquiteturas clássicas quanto redes neurais profundas convergissem para métricas de acurácia superiores, evidenciando que a qualidade do sinal de entrada é um fator determinante para o êxito no reconhecimento de padrões, equiparável em importância à própria topologia do modelo preditivo.

A equivalência de desempenho verificada entre o classificador SVM e os modelos de Aprendizado Profundo sugere um horizonte promissor para a autonomia operacional do sistema. Embora o consumo de recursos de *hardware* ainda apresente margem para otimização, a alta eficiência computacional observada nos testes, especialmente a baixa latência do SVM e a compactação da LSTM, já fundamenta a viabilidade técnica de migrar a inteligência do modelo diretamente para o dispositivo de borda. Tal evolução, partindo do protótipo experimental para uma solução integrada em placa de circuito impresso dedicada, eliminaria a dependência de servidores externos, assegurando uma operação autônoma com latência mínima, requisito essencial para aplicações de monitoramento contínuo em tempo real.

A equivalência de desempenho verificada entre o classificador SVM e os modelos de Aprendizado Profundo sugere um horizonte promissor para a autonomia operacional do sistema. Embora a demanda por recursos de *hardware* ainda careça de refinamentos para plataformas de baixíssima potência, os resultados atuais já comprovam a eficácia da solução: a latência mínima obtida pelo SVM e a eficiência estrutural da LSTM demonstram que o processamento local é tecnicamente exequível.

Nesse contexto, recomenda-se que investigações futuras priorizem a validação de estratégias para a identificação de cargas concorrentes e a otimização dos algoritmos para execução em microcontroladores de baixo consumo energético. Tal esforço visa ratificar a metodologia proposta como uma solução escalável e robusta para a gestão eficiente de energia em

ambientes residenciais e industriais, expandindo a análise para cenários de operação simultânea.

Para atingir esses objetivos de otimização, sugere-se a exploração de técnicas de compressão de modelos, como a quantização de pesos e a poda (*pruning*) de redes neurais. Essa abordagem alinha-se ao paradigma emergente de *TinyML*, viabilizando a implementação completa, desde a aquisição até a inferência, em dispositivos de baixo custo. Adicionalmente, propõe-se investigar a aplicação de Aprendizado Federado, permitindo que dispositivos distribuídos atualizem seus modelos de forma colaborativa sem o compartilhamento de dados brutos, preservando a privacidade do usuário.

Por fim, no que tange ao aprimoramento funcional, futuras iterações podem integrar algoritmos de detecção de eventos em tempo real, capazes de acionar a classificação apenas quando transições significativas de potência forem observadas, economizando recursos computacionais. Complementarmente, o desenvolvimento de uma interface de visualização analítica para o usuário final fecharia o ciclo da solução, transformando os dados técnicos de classificação em *insights* acionáveis.

REFERÊNCIAS

- ALMEIDA, V. **Compreendendo Redes Neurais Recorrentes (RNNs) e LSTM**. 2023. Disponível em: <https://blog.grancursosonline.com.br/compreendendo-redes-neurais-recorrentes-rnns-e-lstm/>. Acesso em: 26 set. 2023.
- AMURIM, A. D. T. **Identificação de dispositivos elétricos em ambientes domésticos**. 96 p. Dissertação (Dissertação (Mestrado em Computação)) – Universidade Federal do Ceará, Campus de Quixadá, Quixadá, 2024. Disponível em: <http://repositorio.ufc.br/handle/riufc/78953>. Acesso em: 6 jul. 2025.
- BACURAU, R. M. **Medidor de energia inteligente para discriminação de consumo por aparelho através de assinatura de cargas**. Dissertação (Dissertação (Mestrado em Engenharia Elétrica)) – Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação, Campinas, SP, 2014. Programa de Pós-Graduação em Engenharia Elétrica.
- BARROS, B. F. d.; BORELLI, R.; GEDRA, R. L. **Geração, Transmissão, Distribuição e Consumo de Energia Elétrica**. 1. ed. São Paulo: Érica, 2014.
- BEIJING YAOHUADECHANG ELECTRONIC CO., LTD. **SCT013 Series Split Core Current Transformer**. [S. l.], 2026. Disponível em: <http://en.yhdc.com/product/SCT013-401.html>. Acesso em: 15 jan. 2026.
- BISHOP, C. M.; BISHOP, H. **Deep Learning: Foundations and concepts**. Cham: Springer Nature Switzerland AG, 2024. ISBN 978-3-031-45467-7.
- BOYLESTAD, R. L. **Introdução à Análise de Circuitos**. 12. ed. São Paulo: Pearson Prentice Hall, 2012. Revisão técnica de Benedito Donizete Bonatto. ISBN 9788564574205.
- BRACEWELL, R. N. **The Fourier transform and its applications**. 3. ed. New York: McGraw-Hill, 2000. (McGraw-Hill series in electrical and computer engineering). ISBN 9780071160438.
- DECKMANN, S. M.; POMILIO, J. A. **Qualidade da Energia Elétrica: Conceituação e processamento digital**. São Paulo: Blucher, 2024. (Coleção Projeto SBA). ISBN 978-85-212-2155-5.
- DINIZ, P. S. R.; SILVA, E. A. B. da; NETTO, S. L. **Processamento Digital de Sinais: Projeto e análise de sistemas**. 2. ed. Porto Alegre, Brasil: Bookman Editora, 2014. Versão brasileira do livro originalmente publicado pela Cambridge University Press. ISBN 978-85-8260-124-2.
- ESPRESSIF SYSTEMS. **ESP32-WROOM-32D and ESP32-WROOM-32U Datasheet**. [S. l.], 2026. V2.6. Disponível em: https://documentation.espressif.com/esp32-wroom-32d_esp32-wroom-32u_datasheet_en.pdf. Acesso em: 15 jan. 2026.
- FACELI, K.; LORENA, A. C.; GAMA, J.; ALMEIDA, T. A. d.; CARVALHO, A. C. P. d. L. F. d. **Inteligência Artificial: Uma abordagem de aprendizado de máquina**. 2. ed. Rio de Janeiro: LTC, 2021. ISBN 9788521637349.
- GULLI, A.; PAL, S. **Hands-On Convolutional Neural Networks with TensorFlow**. 1. ed. Birmingham, UK: Packt Publishing, 2018. ISBN 9781789130331.

HAINES, V.; MITCHELL, V.; COOPER, C.; MAGUIRE, M. Probing user values in the home environment within a technology driven smart home project. **Personal and Ubiquitous Computing**, Springer, v. 11, n. 5, p. 349–359, 2007.

HASHEMI-POUR, C.; LUTKEVICH, B. **Microcontroller**. 2024. Disponível em: <https://www.techtarget.com/iotagenda/definition/microcontroller>. Acesso em: 04 jul. 2025.

HAYKIN, S.; MOHER, M. **Introdução aos sistemas de comunicação**. 2. ed. Porto Alegre: Bookman, 2008. Recurso eletrônico. Tradução de Gustavo Guimarães Parma. Revisão técnica de Antonio Pertence Júnior. ISBN 978-85-7780-329-3.

HSU, H. P. **Signals and Systems**. 2. ed. New York: McGraw-Hill, 2011. (Schaum's Outline Series). ISBN 978-0-07-163473-1.

INC, L. T. **What is a microcontroller**. 2021. Disponível em: <https://www.loomia.com/blog/what-is-a-microcontroller>. Acesso em: 04 jul. 2025.

JAIN, A. **Understanding the 1D Convolutional Layer in Deep Learning**. 2024. Disponível em: <https://medium.com/@abhishekjainindore24/understanding-the-1d-convolutional-layer-in-deep-learning-7a4cb994c981>. Acesso em: 22 dez. 2025.

LEANDRO, J. C. **Aplicação de Redes Neurais LSTM para Previsão de Séries Temporais Financeiras**. Dissertação (Trabalho de Conclusão de Curso) – Universidade Federal da Grande Dourados, Dourados, MS, 2021. Acesso em: 28 jul. 2025.

LIANG, J.; NG, S. K.; KENDALL, G.; CHENG, J. W. Load signature study—part i: Basic concept, structure, and methodology. **IEEE Transactions on Power Delivery**, IEEE, v. 25, n. 2, p. 551–560, 2009.

LIU, H. **Non-intrusive Load Monitoring: Theory, technologies and applications**. 1. ed. Singapore: Springer, 2020. 277 p. ISBN 9789811518591.

MARTINS, B. A. B. **Sistema de monitoramento detalhado de consumo de eletricidade para gestão de energia em edificações**. 60 p. – Universidade Estadual de Campinas, Campinas, 2024. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade Estadual de Campinas, Campinas, SP. Disponível em: <https://hdl.handle.net/20.500.12733/24904>. Acesso em: 6 jul. 2025.

MATSUNAGA, A. M.; TSUGAWA, M. O. **Conversor Digital/Analógico**. 2005. Apostila da disciplina PCS 2498 - Laboratório de Processadores II. Disponível em: https://www2.pcs.usp.br/~labdig/pdf/files_2009/2498-convDA-2005.pdf. Acesso em: 5 jul. 2025.

MEIER, A. von. **Electric Power Systems: A conceptual introduction**. 2. ed. Hoboken, NJ: John Wiley & Sons, 2024. Published in cooperation with the IEEE.

MÜLLER, A. C.; GUIDO, S. **Introduction to Machine Learning with Python**. 1. ed. Sebastopol, CA: O'Reilly Media, 2016. ISBN 9781449369415.

NETTO, A.; MACIEL, F. **Python para Data Science e Machine Learning Descomplicado**. Rio de Janeiro: Editora Alta Books, 2021. ISBN 9786555203172.

NUNES, T. **Amostragem, teorema de Nyquist e aliasing**: Ferramentas importantes durante processamento de sinal neural por eeg. 2023. Disponível em: <https://neuroeducamente.com/amostragem-teorema-de-nyquist-e-aliasing/>. Acesso em: 3 jul. 2025.

OLAH, C. **Understanding LSTM Networks**. 2015. Disponível em: <https://colah.github.io/about.html>. Acesso em: 1 jul. 2025.

OPPENHEIM, A. V.; WILLSKY, A. S.; NAWAB, S. H. **Sinais e sistemas**. 2. ed. São Paulo: Pearson Prentice Hall, 2010. Tradução: Daniel Vieira. Revisão técnica: Marcio Eisencraft, Maria D. Miranda. Título original: *Signals and Systems*.

PELGROM, M. **Analog-to-Digital Conversion**. 3. ed. Cham: Springer International Publishing, 2017. ISBN 978-3-319-44970-8.

POR, E.; KOOTEN, M. v.; SARKOVIC, V. **Nyquist–Shannon sampling theorem**. 2019. Universiteit Leiden. Disponível em: https://home.strw.leidenuniv.nl/~por/AOT2019/docs/AOT_2019_Ex13_NyquistTheorem.pdf. Acesso em: 04 jul. 2025.

RICHERT, W.; COELHO, L. P. **Building Machine Learning Systems with Python**. Birmingham, UK: Packt Publishing, 2013. ISBN 9781782161400.

SANCHEZ-REOLID, R.; ROSA, F. Lopez de la; LOPEZ, M. T.; FERNANDEZ-CABALLERO, A. One-dimensional convolutional neural networks for low/high arousal classification from electrodermal activity. **Biomedical Signal Processing and Control**, v. 71, p. 103203, 2022.

SICSÚ, A. L.; SAMARTINI, A.; BARTH, N. L. **Técnicas de Machine Learning**. São Paulo: Editora Blucher, 2023. ISBN 9786555063974.

SMITH, G. M. **What is a sensor**. 2025. Blog Dewesoft. Disponível em: <https://dewesoft.com/blog/what-is-a-sensor>. Acesso em: 6 jul. 2025.

SOUZA, I. **Conheça as métricas mais importantes para avaliar classificadores em Machine Learning**. 2022. Disponível em: <https://medium.com/@igor1245souza/conhe%C3%A7a-as-m%C3%A9tricas-mais-importantes-para-avaliar-classificadores-em-machine-learning-bd270602f317>. Acesso em: 05 jan. 2026.

TATSAT, H.; PURI, S.; LOOKABAUGH, B. **Blueprints de aprendizado de máquina e ciência de dados para finanças**: desenvolvendo desde estratégias de trades até robôs advisors com python. 1. ed. Rio de Janeiro: Alta Books, 2021. ISBN 9788550821726.

TEXAS INSTRUMENTS. **ADS1255/ADS1256 Very Low Noise, 24-Bit Analog-to-Digital Converter Datasheet**. [S. l.], 2013. Rev. K. SBAS288K. Disponível em: <https://www.ti.com/lit/ds/symlink/ads1256.pdf>. Acesso em: 15 jan. 2026.

XAVIER NETO, W. **Monitoramento do consumo de energia elétrica em aparelhos de ar-condicionado em sistemas residenciais**: Climatização sustentável. 2024. Trabalho de Conclusão de Curso (Graduação em Engenharia de Computação) – Universidade Federal do Ceará, Campus de Sobral, Sobral. Disponível em: <http://repositorio.ufc.br/handle/riufc/78453>. Acesso em: 6 jul. 2025.

APÊNDICE A – CÓDIGOS FONTE E CONJUNTO DE DADOS

Todo o material suplementar deste trabalho, incluindo os códigos-fonte e as bases de dados geradas, pode ser consultado integralmente no seguinte endereço eletrônico:

<https://github.com/tiagotorresofc/Dados-TCC>