



UNIVERSIDADE FEDERAL DO CEARA
CAMPUS SOBRAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
COMPUTAÇÃO
MESTRADO ACADÊMICO EM ENGENHARIA ELÉTRICA E COMPUTAÇÃO

JORGE PEDRO

DESENVOLVIMENTO DE UM SISTEMA DE GERENCIAMENTO DE ENERGIA EM
EDIFÍCIOS PREDIAIS BASEADO EM *EDGE COMPUTING* E *MACHINE LEARNING*

SOBRAL

2026

JORGE PEDRO

DESENVOLVIMENTO DE UM SISTEMA DE GERENCIAMENTO DE ENERGIA EM
EDIFÍCIOS PREDIAIS BASEADO EM *EDGE COMPUTING* E *MACHINE LEARNING*

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia Elétrica e de Computação do Programa de Pós-Graduação em Engenharia Elétrica e de Computação da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica e Computação. Área de Concentração: Engenharia da Computação

Orientador: Prof. Dr. Wendley Souza da Silva

SOBRAL

2026

JORGE PEDRO

DESENVOLVIMENTO DE UM SISTEMA DE GERENCIAMENTO DE ENERGIA EM
EDIFÍCIOS PREDIAIS BASEADO EM *EDGE COMPUTING* E *MACHINE LEARNING*

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia Elétrica e de Computação do Programa de Pós-Graduação em Engenharia Elétrica e de Computação da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Elétrica e Computação. Área de Concentração: Engenharia da Computação

Aprovada em:

BANCA EXAMINADORA

Prof. Dr. Wendley Souza da Silva (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Ialis Cavalcante De Paula Junior
Universidade Federal do Ceará (UFC)

Prof. Dr. Jermana Lopes De Moraes
Universidade Federal do Ceará (UFC)

AGRADECIMENTOS

A realização desta dissertação não teria sido possível sem o apoio e a colaboração de diversas pessoas e instituições, às quais expresso minha mais sincera gratidão.

À **Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP)**, pelo financiamento concedido, que tornou viável a execução desta pesquisa e contribuiu de forma decisiva para o avanço do conhecimento na área de energia e engenharia.

Ao meu orientador, **Prof. Wendley Silva**, pela dedicação, paciência e rigor científico com que conduziu a orientação deste trabalho. Suas contribuições foram fundamentais para o amadurecimento das ideias aqui apresentadas e para o meu crescimento como pesquisador.

À **direção da faculdade**, pela liderança comprometida e pelo ambiente institucional que favoreceu o desenvolvimento desta pesquisa. Ao **coordenador do curso**, pelo acompanhamento atento e pelo suporte prestado ao longo do programa. Ao **pessoal técnico**, pela disponibilidade, eficiência e, em especial, pela abertura na comunicação, que facilitou a resolução de todas as questões administrativas com cordialidade e prontidão.

Ao colega **Geraldo Martins**, pelo apoio constante, pela troca de conhecimentos e pela parceria ao longo desta jornada. A sua colaboração foi um alicerce importante nos momentos de maior dificuldade.

Aos **colegas da Universidade Licungo**, pelo apoio financeiro, pelo suporte nas diversas etapas deste percurso e pelos valiosos conselhos que, em momentos decisivos, iluminaram o caminho e fortaleceram a minha determinação em seguir em frente.

À minha **família**, pelo amor incondicional, pela compreensão nas ausências e pelo incentivo que nunca faltou. Cada conquista minha é, antes de tudo, uma conquista nossa.

Aos **amigos**, que estiveram presentes com palavras de encorajamento e gestos de solidariedade, tornando este percurso mais leve e significativo.

A todos que, de forma direta ou indireta, contribuíram para a concretização deste trabalho, o meu profundo agradecimento.

LISTA DE FIGURAS

Figura 1 - Princípio da arquitetura passivo.....	16
Figura 2- Arquitetura de IoT.....	19
Figura 3- Arquitetura do sistema proposto.....	29
Figura 4- Circuito de central processamento.....	32
Figura 5 - Circuito de fonte de tensão da central.....	34
Figura 6 - Esquema do Módulo de 5 canais.....	35
Figura 7 - Circuito condicionador de sinal de corrente.....	36
Figura 8- Circuito condicionado de sinal (tensão).....	37
Figura 9- Esquema do circuito da fonte de tensão.....	38
Figura 10- Esquema do Módulo de 1 canal.....	40
Figura 11 Imagem 3D das PCI (Módulo de 6 canais, central de comando, Módulo de 1 canal) ..	40
Figura 12 - Tela Menu.....	49
Figura 13- Tela de informações gerais.....	50
Figura 14 - Parâmetros Elétricos Gerais.....	50
Figura 15 - Detalhes por canal.....	51
Figura 16- Configuração do sistema.....	51
Figura 17- Análise de Anomalias.....	52
Figura 18 - Protótipo instalado na residência para coleta de dados.....	53
Figura 19- Central do sistema (interface com o usuário e processamento de dados).....	59
Figura 20 - Módulo de um canal (frente e verso).....	59
Figura 21- Módulo de 6 canais (frente e verso).....	60
Figura 22 - Linearidade da tensão(A). Erro medio(B).....	61
Figura 23 - Linearidade e erro médio: (A) Curvas de linearidade; (B) Erro médio por canal.....	64
Figura 24 -Taxa de sucesso na transmissão de dados em função do intervalo entre envios.....	68
Figura 25- Latência de comunicação: (A) Box plot comparativo; (B) Histograma.....	70
Figura 26- Métricas comparativas.....	73

LISTA DE TABELAS

Tabela 1- Características do multímetro Hikari HM-2030	42
Tabela 2- Valores obtidos para validação de linearidade dos sensores de tensão.....	61
Tabela 3 - Indicadores de desempenho dos sensores de tensão	62
Tabela 4- Dados de validação dos sensores de corrente	63
Tabela 5- Indicadores de desempenho dos sensores de corrente	65
Tabela 6 - Indicadores de desempenho do sistema de medição.....	66
Tabela 7 -Taxa de sucesso na transmissão de dados em função do intervalo entre envios	67
Tabela 8- Latência de comunicação em diferentes intervalos de transmissão.....	69
Tabela 9 - Síntese do desempenho da comunicação ESP-NOW	71
Tabela 10 – Tabela comparativa de desempenho.....	72
Tabela 11 - Desempenho do hardware.....	74

LISTA DE ABREVIATURAS E SIGLAS

3D	tridimensional
CC	corrente continua
RTC	Real-Time Clock (Relógio em Tempo Real)
IEA	International Energy Agency (Agência Internacional de Energia)
IoT	Internet of Things
MIT	Massachusetts Institute of Technology
NPN	negative-positivo-negativo
PCI	placa de circuito impresso
PTH	Plated Through-Hole (Furo Passante Revestido)
SMD	Surface-Mount Device (Dispositivo de Montagem em Superfície)
NVS	Non-Volatile Storage (armazenamento não volátil)

Resumo

Este trabalho apresenta o desenvolvimento e a validação experimental de um sistema de gerenciamento e otimização de energia em edificações, baseado em Edge Computing e técnicas de Machine Learning, utilizando o microcontrolador ESP32-S3. O aumento da demanda por energia elétrica, aliado à necessidade de soluções sustentáveis, impulsiona o uso de tecnologias inteligentes capazes de monitorar e controlar o consumo energético em tempo real. Nesse contexto, a proposta integra conceitos de Internet das Coisas, computação em borda e inteligência artificial, permitindo o processamento local dos dados, com redução da latência e do consumo de largura de banda. A metodologia adotada foi a Design Science Research (DSR), contemplando revisão bibliográfica, desenvolvimento do protótipo de hardware e software e realização de testes laboratoriais. A arquitetura do sistema é composta por uma unidade central e módulos distribuídos de medição e controle, interligados por comunicação sem fio baseada no protocolo ESP-NOW, eliminando a dependência de infraestrutura externa. O sistema utiliza sensores de corrente e tensão baseados no circuito integrado ATM90E36, associados a circuitos de condicionamento de sinal. Os resultados experimentais demonstram elevada precisão nas medições, com coeficiente de determinação superior a 0,9998 e erros médios inferiores a $\pm 0,30\%$. A comunicação apresentou taxa de sucesso de 99,5% e latência média de 5,8 ms, mesmo em ambiente com obstáculos. O modelo Random Forest Regressor, treinado com dados coletados ao longo de 30 dias, apresentou erro absoluto médio de 70,71 W, sendo implementado diretamente no firmware do ESP32-S3, com tempo de inferência de 15 ms. Conclui-se que o sistema proposto constitui uma solução de baixo custo, eficiente e escalável para o gerenciamento energético em edificações, demonstrando a viabilidade da aplicação de técnicas de aprendizado de máquina em sistemas embarcados para suporte à eficiência energética.

Palavras-chave: Internet das Coisas; Edge Computing; Eficiência Energética; ESP32; Machine Learning.

Abstract

This work presents the development and experimental validation of an energy management and optimization system for buildings, based on Edge Computing and Machine Learning techniques, using the ESP32-S3 microcontroller. The increasing demand for electrical energy, combined with the need for sustainable solutions, has driven the adoption of intelligent technologies capable of monitoring and controlling energy consumption in real time. In this context, the proposed solution integrates concepts from the Internet of Things, edge computing, and artificial intelligence, enabling local data processing while reducing latency and bandwidth consumption.

The adopted methodology follows the Design Science Research (DSR) approach, encompassing literature review, hardware and software prototyping, and laboratory testing. The system architecture consists of a central unit and distributed measurement and control modules, interconnected through a wireless communication protocol based on ESP-NOW, eliminating the need for external infrastructure. The system employs current and voltage sensors based on the ATM90E36 integrated circuit, combined with signal conditioning circuits.

Experimental results demonstrate high measurement accuracy, with a coefficient of determination above 0.9998 and mean errors below $\pm 0.30\%$. The communication achieved a success rate of 99.5% and an average latency of 5.8 ms, even in environments with physical obstacles. The Random Forest Regressor model, trained on data collected over a 30-day period, achieved a mean absolute error of 70.71 W. The model was successfully deployed directly on the ESP32-S3 firmware, with an inference time of 15 ms, without requiring external connectivity.

The results indicate that the proposed system is a low-cost, efficient, and scalable solution for energy management in buildings, demonstrating the feasibility of applying machine learning techniques in embedded systems to support energy efficiency applications.

Keywords: Internet of Things; Edge Computing; Energy Efficiency; ESP32; Machine Learning.

Sumário

LISTA DE TABELAS	6
INTRODUÇÃO	12
1.1 Pergunta da pesquisa:	13
1.2 Objetivos.....	13
1.2.1 <i>Objetivo Geral</i>	13
1.2.2 <i>Objetivos Específicos</i>	13
2 FUNDAMENTAÇÃO TEÓRICA	14
2.1 Eficiência Energética.....	14
2.1.1 <i>Estratégias passivas de eficiência energética.</i>	15
2.1.2 <i>Benefícios e Impactos da eficiência energética.</i>	17
2.2 Internet das Coisas (IoT).....	18
2.3 <i>Edge Computing</i>	21
2.3.1 <i>Implementação de Machine Learning (ML) em Edge Computing</i>	21
3 TRABALHOS RELACIONADOS	24
3.1 Internet das coisas baseada em eficiência energética em edifícios Prediais	24
3.2 Inteligência artificial aplicada em eficiência energética.	25
3.3 Síntese e Contribuições para o Projeto	26
4 METODOLOGIA.....	27
4.1 Revisão Bibliográfico.....	27
4.1.1 <i>Resultados da revisão bibliográfica</i>	28
4.2 Desenvolvimento do Protótipo.....	28
4.2.1 <i>Requisitos</i>	28
4.2.2 <i>Arquitetura do Sistema</i>	29
4.2.3 <i>Desenvolvimento de Hardware</i>	30
4.2.4 <i>Projeção das Placas de Circuito Impresso (PCI)</i>	40
4.3 Testes e calibração do Módulo de medição	42
4.3.1 Ambiente e Configuração dos Testes.....	42
4.3.2 Equipamentos Utilizados.....	42
4.3.3 Calibração do Módulo de medição.....	43
4.4 Validação da Comunicação entre Módulos.....	45
4.4.1 Avaliação da Integridade de Transmissão	46
4.4.2 Caracterização da Latência de Comunicação	46

4.5	Desenvolvimento de <i>firmware</i>	46
4.5.1	<i>Firmware do Módulo medição</i>	47
4.5.2	<i>Firmware da Central de Processamento</i>	48
4.5.3	<i>Interface com o Usuário</i>	49
4.5.4	<i>Comunicação com o Display</i>	52
4.6	Treinamento de ML	52
4.6.1	<i>Caracterização do Dataset</i>	53
4.6.2	<i>Preparação e Pré-processamento</i>	53
4.6.3	<i>Engenharia de Features</i>	54
4.6.4	<i>Estratégia de Divisão e Validação dos Dados</i>	54
4.6.5	<i>Modelos de Machine Learning Implementados</i>	55
4.6.6	<i>Métricas de Avaliação</i>	55
4.6.7	<i>Integração do Modelo com o Firmware do Protótipo</i>	57
5	RESULTADOS E DISCUSSÃO	59
5.1	Validação da Precisão dos Sensores	60
5.1.1	<i>Sensores de Tensão</i>	60
5.1.2	<i>Sensores de Corrente</i>	63
5.1.3	<i>Adequação do Sistema de Medição aos Objetivos</i>	66
5.2	Validação da Comunicação entre Módulos.....	66
5.2.1	<i>Integridade da Transmissão de Dados</i>	67
5.2.2	<i>Latência e Sincronização</i>	68
5.2.3	<i>Adequação aos Requisitos do Sistema</i>	71
5.3	Validação do Desempenho do Modelo de ML	72
5.3.1	<i>Desempenho dos modelos no microcontrolador</i>	73
6	CONCLUSÃO	75
6.1	Trabalhos futuros.....	76
6.2	Contribuições.....	77
7	BIBLIOGRAFIA.....	78

INTRODUÇÃO

O aumento exponencial da demanda por energia Elétrica, especialmente em centros urbanos, tem colocado em xeque a sustentabilidade e a eficiência dos sistemas de abastecimento energético. Sônego et al. (2016) Afirma que desde a Revolução Industrial, a dependência da sociedade moderna da eletricidade para suprir atividades industriais, comerciais e domésticas intensificou-se, resultando em um consumo crescente que desafia as capacidades das infraestruturas tradicionais. Esse cenário é agravado pela necessidade de reduzir os impactos ambientais associados à geração de energia, alinhando-se às metas globais de sustentabilidade, como as estabelecidas pelo Acordo de Paris (FCCC, 2015). Assim, a busca por estratégias que promovam o uso eficiente da energia tornou-se uma prioridade tanto para mitigar os efeitos das mudanças climáticas quanto para equilibrar a relação entre geração e consumo.

A modernização das infraestruturas energéticas por meio de tecnologias inovadoras é essencial para enfrentar esses desafios. Nos últimos anos, avanços na Internet das Coisas (IoT) e na inteligência artificial (IA) têm possibilitado o desenvolvimento de sistemas inteligentes de monitoramento e controle do consumo energético em tempo real. Alfonso et al. (2024) defende que tais sistemas permitem a coleta e análise de dados detalhados, oferecendo soluções como o ajuste dinâmico de cargas e a previsão de padrões de uso, o que pode reduzir significativamente o desperdício energético.

Nesse contexto, a eficiência energética destaca-se como uma estratégia, aplicável à geração, distribuição e uso final da eletricidade. Conforme Motta (2012), citado por Santos et al. (2015), melhorias nos sistemas consumidores — como a substituição de equipamentos ineficientes ou a implementação de controles automatizados — podem otimizar o desempenho energético sem prejuízo às operações.

A integração de computação na borda (*Edge Computing*) com microcontroladores de baixo custo, como o ESP32-S3, e algoritmos de *ML* amplia ainda mais essas possibilidades, reduzindo latência e consumo de banda ao processar dados localmente (Li et al., 2022). Apesar dessas inovações, persistem lacunas no desenvolvimento de soluções acessíveis e escaláveis que combinem alta precisão e adaptação a ambientes reais.

Diante desse panorama, esta pesquisa propõe o desenvolvimento de um sistema de gerenciamento e otimização de energia prediais baseado em Edge Computing, utilizando ML e o microcontrolador ESP32-S3. O objetivo é projetar uma solução que monitore e permita ajuste do consumo energético em tempo real, adaptando-se às limitações computacionais do hardware embarcado.

A relevância deste trabalho reside na sua contribuição para a eficiência energética predial, oferecendo uma abordagem prática e de baixo custo que pode ser replicada em diversos contextos urbanos. Além disso, busca-se preencher lacunas identificadas na literatura, como a validação experimental de sistemas embarcados, fornecendo dados que possam orientar futuras inovações na área.

1.1 Pergunta da pesquisa:

Como o sistema baseado em Edge Computing, utilizando ML no microcontrolador ESP32-S3, pode gerenciar e otimizar o consumo de energia em edifícios prediais?

1.2 Objetivos

1.2.1 Objetivo Geral

Desenvolver um Sistema de Gerenciamento e Otimização de Energia Predial Baseado em *Edge Computing* utilizando *ML* e ESP32-S3".

1.2.2 Objetivos Específicos

- Projetar e construir um sistema de monitoramento de consumo de energia composto por uma central baseada no microcontrolador ESP32-S3 e placas de sensores e atuadores distribuídos;
- Implementar modelo de *ML* otimizado para *Edge Computing*, no microcontrolador ESP32-S3;
- Realizar testes em laboratório para validar a precisão dos sensores, comunicação entre os módulos e o desempenho do modelo de *ML*;

2 FUNDAMENTAÇÃO TEÓRICA

A fundamentação teórica deste trabalho tem como objetivo consolidar os conceitos essenciais para o desenvolvimento de um sistema de gerenciamento e otimização de energia em edifícios prediais, utilizando *Edge Computing*, ML e o microcontrolador ESP32-S3. Este capítulo aborda os principais conceitos que sustentam a pesquisa, incluindo eficiência energética, *Edge Computing*, inteligência artificial e protocolos de comunicação, com foco em sua aplicação prática no sistema desenvolvido. A partir de uma revisão da literatura, combinada com especificações técnicas dos componentes utilizados, esta seção estabelece as bases conceituais e tecnológicas possíveis para compreender os desafios e as soluções propostas, contribuindo para a validação do sistema e para o avanço da sustentabilidade energética.

2.1 Eficiência Energética

Segundo SOUZA et al. (2019) “eficiência energética é definida como o consumo de menos energia no processo de garantia do mesmo serviço energético. A utilização racional pode ser alcançada em qualquer fase do processo energético entre a transformação da energia primária e o consumo de energia final”. Em outras palavras, eficiência energética consiste na capacidade de realizar as mesmas atividades com menor uso de recursos energéticos, o que implica ganhos operacionais e toda a cadeia energética. Matematicamente, pode ser expressa como a razão entre a energia útil (ou aproveitada) e a energia total fornecida:

$$\eta = \frac{\text{Energia útil}}{\text{Energia fornecida}} \times 100\% \quad (1)$$

Onde η é a eficiência energética, expressa em percentual. Um valor próximo de 100% indica alta eficiência, enquanto valores menores refletem perdas significativas. De acordo com SOUSA et al. (2019) A eficiência energética pode ser alcançada em qualquer fase do processo energético desde a geração, transformação e o consumo final de energia.

No contexto de edifícios prediais, a eficiência energética é definida como sendo a capacidade de utilizar a energia de forma racional, garantindo o conforto e a funcionalidade dos espaços com o menor consumo possível (Nascimento & Oliveira, 2025). A eficiência energética em edifícios pode ser alcançada por meio de diversas estratégias, que abrangem desde o projeto arquitetônicos até a implementação de sistemas de gerenciamento energético. Essas estratégias são


comumente classificadas em dois grandes grupos: estratégias passivas e estratégias ativas, conforme descrito a seguir.

2.1.1 Estratégias passivas de eficiência energética.

As estratégias passivas de eficiência energética em edifícios prediais aproveitam o projeto arquitetônicos, a orientação do edifício em relação ao entorno dos recursos naturais disponíveis para proporcionar ambientes internos confortáveis, reduzindo significativamente a demanda energética (IFECHUKWU GIL-OZOUDEH et al. 2022) As estratégias de otimização energética em edifícios prediais podem ser organizadas em quatro pilares: projeto arquitetônico e materiais, modernização de equipamentos, sistemas de gerenciamento inteligente e integração de fontes renováveis.

Segundo IFECHUKWU GIL-OZOUDEH et al. (2022) “A orientação do local é fundamental no projeto passivo, pois otimiza a exposição do edifício ao sol, vento e outros fatores ambientais, permitindo aquecimento, resfriamento e iluminação naturais”. Técnicas de design passivo, como a orientação solar adequada e o uso de sombreamento, também são fundamentais. Por exemplo, um edifício orientado para aproveitar a luz solar matinal pode reduzir o consumo de iluminação em até 20%(IEA, 2022) A figura 1 representa um exemplo de uma residência com um projeto passivo.

Figura 1 - Princípio da arquitetura passivo



Fonte:(ROSAS, 2022)

Estratégias ativas de eficiência energética

As estratégias ativas para eficiência energética diferentemente da estratégia passiva esta requer a utilização de sistemas e equipamentos que permitem o controle do consumo de energia. Segundo NASCIMENTO e OLIVEIRA, (2025, apud Teixeira, Guimarães e Delgado, 2022), "as tecnologias ativas e sistemas eficientes representam um conjunto de soluções que operam dinamicamente para otimizar o consumo energético em edificações, integrando-se a estratégias passivas e projetos bioclimáticos".

Nesse contexto, as estratégias ativas de eficiência energética referem-se à utilização de sistemas automatizados que monitoram, controlam e adaptam o uso de energia de forma inteligente. Isso inclui, por exemplo, sensores de presença que ativam ou desligam iluminação, sistemas refrigeração ou aquecimento com controle inteligente de temperatura e ventilação, painéis solares com rastreamento solar automático, bem como dispositivos de gestão de energia baseados em

inteligência artificial. Estas soluções atuam continuamente em resposta às condições ambientais e ao comportamento dos utilizadores, promovendo um ambiente mais sustentável e com menor desperdício energético.

A estratégia de eficiência energética ativa muitas vezes não atua de forma isolada as duas estratégias se complementam. NASCIMENTO e OLIVEIRA, (2025) enfatizam que as tecnologias ativas representam um elemento complementar às estratégias passivas, permitindo que edifícios operem como sistemas adaptativos e inteligentes.

2.1.2 Benefícios e Impactos da eficiência energética.

De acordo com Agência Internacional de Energia IEA (2022) A eficiência energética é uma estratégia fundamental para enfrentar os desafios contemporâneos relacionados ao consumo de energia, sustentabilidade ambiental e desenvolvimento econômico. Sua adoção proporciona ganhos significativos em múltiplas dimensões:

- **Benefícios Econômicos:** A redução do consumo energético resulta diretamente na diminuição dos custos operacionais. Segundo a Agência Internacional de Energia (IEA, 2022) investimentos em eficiência energética podem levar a economias significativas, especialmente em setores como o de edificações comerciais. Além disso, a adoção de tecnologias eficientes contribui para a estabilidade econômica ao mitigar os impactos de flutuações nos preços de energia.
- **Impactos Ambientais Positivos:** A menor dependência de fontes fósseis reduz substancialmente as emissões de gases de efeito estufa, favorecendo o cumprimento de metas globais de neutralidade de carbono até 2050 (IEA, 2022). A eficiência energética também contribui para a preservação de recursos naturais e para a mitigação dos efeitos das mudanças climáticas.
- **Avanços Sociais e Comportamentais:** A introdução de sistemas inteligentes permite a integração de interfaces visuais e notificações em tempo real, promovendo a conscientização dos usuários sobre seus hábitos de consumo. A abordagem sobre eficiência energética induz mudanças comportamentais sustentáveis e maior engajamento da população com práticas responsáveis (KORNEEVA et al., 2024).
- **Melhoria da Qualidade de Vida** A eficiência energética possibilita ambientes mais confortáveis, seguros e saudáveis, por meio de melhor controle de temperatura, iluminação

e ventilação. Isso impacta directamente no bem-estar dos ocupantes, tanto em ambientes residenciais quanto corporativos (GUZUEVA et al., 2024).

2.2 Internet das Coisas (IoT)

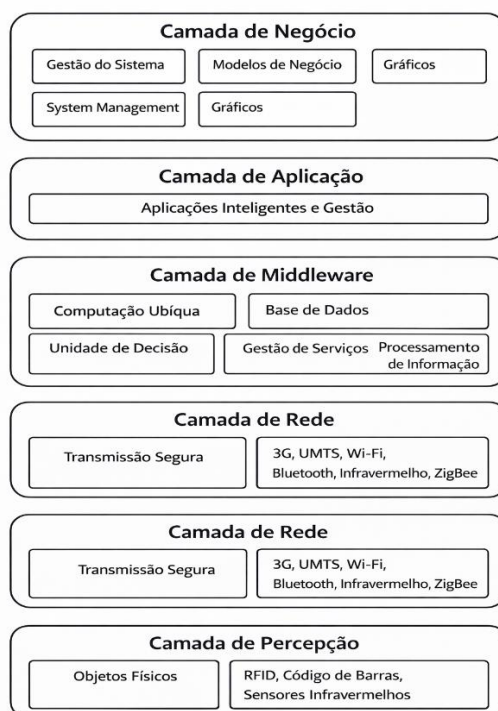
Com o avanço das tecnologias de comunicação, a Internet das Coisas (IoT, do inglês *Internet of Things*) tem experimentado uma evolução significativa no campo da tecnologia da informação, promovendo a interconexão de dispositivos físicos à Internet. Essa interligação permite a colecta, a troca e a análise de dados em tempo real, possibilitando o desenvolvimento de aplicações inteligentes em áreas como saúde, indústria, transporte, agricultura e automação residencial.

Embora a popularização da IoT tenha ocorrido nas últimas décadas, suas origens remontam à década de 1990, quando surgiram os primeiros dispositivos conectados à Internet. Entre os exemplos pioneiros destacam-se a torradeira controlada via Internet, desenvolvida por John Romkey em 1990, e o monitoramento remoto de uma máquina de venda automática na Universidade Carnegie Mellon, considerado um dos primeiros sistemas de IoT documentados (MPHALE et al. 2024)

Somente em 1999, o termo *Internet das Coisas* foi criado por Kevin Ashton, então pesquisador do Instituto de Tecnologia de Massachusetts (MIT), ao propor a integração entre objetos físicos e sistemas computacionais por meio da tecnologia RFID. (Dvali & Belonin, 2020) Ashton utilizou a expressão ao descrever a aplicação de tecnologia de identificação por radiofrequência (RFID) para integrar objetos físicos a sistemas computacionais, destacando a possibilidade de capturar dados automaticamente sem intervenção humana.

A Internet das Coisas (IoT) é definida como sendo como uma infraestrutura de rede global composta por numerosos dispositivos conectados que dependem de tecnologias sensoriais, de comunicação, de rede e de processamento de informação (Xu,Hi e Li 2014). Dada sua complexidade e diversidade, para compreender a organização funcional da IoT, são adoptadas modelos de arquitetura em camadas, o qual descreve a hierarquia e os papéis desempenhados por diferentes componentes do sistema a figura 2. A abordagem mais utilizada é a arquitetura de três camadas. No entanto, arquiteturas mais complexas podem incluir até cinco camadas ou mais. A seguir, apresentam-se as principais camadas da arquitetura:

Figura 2- Arquitetura de IoT



Fote: adaptado de MEHTA et al, 2018

Camada de percepção: também conhecida como **camada física**, esta camada é composta por sensores, atuadores, etiquetas RFID, câmeras, dispositivos vestíveis e outros elementos capazes de capturar informações do mundo real sua principal função é a coleta de dados do ambiente físico. Esta camada reúne dados importantes dos dispositivos de detecção sobre um objeto e os transforma em um sinal digital e envia para camada de rede (Rahaman, 2022).

Camada de rede: A camada de rede é responsável pela transmissão dos dados capturados na camada de percepção, atuando como um meio intermediário entre os dispositivos sensores e as camadas superiores de processamento ou aplicação. Essa camada assegura a entrega eficiente e confiável dos dados à camada de *middleware*, onde ocorre o tratamento e análise das informações (MEHTA et al, 2018). Nesse contexto, a camada de rede envolve duas componentes centrais que são **as tecnologias de comunicação e os protocolos de comunicação**.

- **As tecnologias de comunicação** referem-se aos meios físicos que viabilizam a troca de informações entre dispositivos em ambientes de Internet das Coisas (IoT), podendo operar por conexões com ou sem fio em longo e curto alcance. Entre as tecnologias sem fio mais comuns

estão o Bluetooth, RFD, ZigBee, Wi-Fi, 3G, UMTS, 5G e, mais recentemente, o Wi-Fi 6, cada uma oferecendo diferentes vantagens em termos de alcance, largura de banda, consumo energético e escalabilidade. A escolha da tecnologia apropriada depende diretamente dos requisitos do sistema, como cobertura, taxa de transmissão, custo e topologia da rede (Kumar et al., 2020; Mahmud et al., 2021).

- **protocolos de comunicação** são conjuntos de regras e formatos que determinam como os dados são organizados, transmitidos e interpretados entre dispositivos e a plataformas de gerenciamento. Eles garantem que os dispositivos interajam de maneira eficiente, segura e escalável, mesmo em ambientes heterogêneos e distribuído protocolos mais adotados são MQTT, CoAP, HTTP e AMQP.

Camada de *Middleware*: Essa camada atua como um elo intermediário entre a camada de rede e a camada de aplicação, sendo responsável por gerenciar, processar e armazenar os dados provenientes dos dispositivos conectados. Essa camada recebe as informações da camada Network, processa esses dados toma uma decisão com base na informação recebidas (Mai & Spohn, 2023). Seu principal objetivo é oferecer uma plataforma comum que permita a interoperabilidade entre diferentes dispositivos e protocolos, abstraindo a complexidade do sistema.

Camada de Aplicação: A camada de aplicação é a mais próxima dos usuários e tem como principal função apresentar as informações de forma clara e acessível, seja para os próprios usuários ou para sistemas superiores de tomada de decisão. Nessa camada, encontram-se as interfaces de usuário, painéis de visualização (*dashboards*), serviços web e aplicativos móveis que possibilitam a interação com os dados provenientes das camadas inferiores. Além disso, ela é responsável por gerenciar os aplicativos de forma abrangente, com base nas informações processadas na camada de *middlewar* (MEHTA et al., 2018).

Camada de Negócios (*Business Layer*): é responsável pela gestão global do sistema de Internet das Coisas (IoT), no que se refere aos aplicativos, serviços e objetivos organizacionais. Sua principal função é interpretar os dados processados pela camada anterior (*middleware*), transformando-os em informações estratégicas por meio da elaboração de modelos de negócios, gráficos, fluxogramas e outros recursos analíticos. Com base na análise desses dados, essa camada é capaz de prever comportamentos futuros, propor ações corretivas ou de melhoria, além de auxiliar na tomada de decisões de alto nível dentro do contexto da aplicação (MEHTA et al, 2018).

2.3 *Edge Computing.*

Com o crescimento do número de dispositivos conectados à rede de Internet das Coisas (IoT), também se intensifica a produção de grandes volumes de dados em tempo real. Esses dados, muitas vezes, requerem respostas imediatas e seguras, o que desafia os modelos tradicionais baseados exclusivamente na computação em nuvem. Segundo HUA et al. (2023) o desenvolvimento da *Edge Computing* a computação em nuvem começou a expor cada vez mais problemas dados gerados por dispositivos terminais globais incluindo baixa taxa de transferência, alta latência, gargalos de largura de banda, privacidade de dados, vulnerabilidades.

Diante deste cenário surge a *Edge Computing* surge como uma alternativa, ao permitir que o processamento e a análise dos dados sejam realizados próximos à origem, ou seja, nos próprios dispositivos ou em *gateways* locais. HUA et al. (2023) define *Edge Computing* como sendo um paradigma que desloca operações de processamento, armazenamento e análise de dados que tradicionalmente seriam realizadas na nuvem para a extremidade da rede, próxima aos dispositivos finais ou fontes de dados.

Enquanto a computação na nuvem consiste em uma estrutura centralizada que fornece recursos de computação sob demanda, como servidores, redes, armazenamento, onde os dados devem ser transmitidos aos *data centers* para processamento e análise adicionais para serem utilizáveis (Jouini et al., 2024b) a *Edge Computing* torna esse processo mais simplificado processando os dados próximo da fonte.

A *Edge Computing* oferece diversas vantagens significativas, especialmente em ambientes que demandam processamento em tempo real e alta disponibilidade. Ao permitir que o processamento de dados ocorra próximo à fonte de geração, essa abordagem reduz a latência, proporcionando respostas mais rápidas, diminui a dependência da largura de banda da rede, melhora da segurança e privacidade dos dados.

2.3.1 *Implementação de Machine Learning (ML) em Edge Computing*

A fusão entre Machine Learning (ML) e *Edge Computing*, conhecida como **Edge AI** ou **TinyML**, visa levar a inteligência diretamente aos dispositivos terminais. Em vez de transmitir dados para servidores distantes na nuvem, os dispositivos realizam inferências localmente. Essa abordagem é fundamental em aplicações que requerem tomadas de decisão rápidas, como automação predial, detecção de falhas em tempo real e otimização de consumo energético.

Segundo JOUINI et al, (2024) A integração de recursos de ML na computação de borda pode reduzir a dimensionalidade dos dados. O pré-processamento seria executado na borda para extrair informações importantes transmitidas à nuvem para análise avançada, diminuindo os requisitos de largura de banda e a carga de trabalho nos sistemas em nuvem.

2.3.1.1 *Técnicas e Procedimentos de Implementação de ML na Edge Computing*

KHOUAS et al, (2024) afirma que atualmente, a maioria das ferramentas de ML voltadas para *Edge Computing* concentra-se predominantemente na fase de inferência, deixando de oferecer suporte completo ao treinamento local. Essa limitação evidencia uma lacuna significativa na infraestrutura disponível para a implementação completa de modelos diretamente nos dispositivos de borda.

Diante dessas limitações, a implementação eficaz de algoritmos de ML na *Edge Computing* exige a consideração de diversos fatores fundamentais, como a escolha adequada do hardware, a utilização de *frameworks* otimizados, técnicas de compressão de modelos e a seleção criteriosa de algoritmos de aprendizado. Esses elementos influenciam diretamente a eficácia e a eficiência das aplicações de inteligência artificial em ambientes com recursos computacionais restritos (JOUINI et al, 2024). Para que o ML seja implementado de forma eficiente na borda, é necessário seguir um conjunto de procedimentos técnicos que envolvem desde o pré-processamento de dados até a inferência embarcada.

A implementação eficiente de ML na borda depende de um conjunto de técnicas fundamentais:

- **Escolha do hardware adequado:** Um dos desafios atuais da integração de inteligência em dispositivos na borda são os recursos limitados do hardware e sua capacidade de lidar com inferência ou treinamento de aprendizado de máquina no dispositivo (JOUINI et al., 2024). É por esta razão que diversas empresas têm trabalhado arduamente para desenvolver uma seleção de hardware ideal, considerando fatores como precisão, consumo de energia, taxa de transferência e custo.
- **Seleção de modelos de ML compactos:** Segundo KHOUAS et al. (2024), a seleção de modelos de ML compactos para ambientes de borda envolve técnicas de compressão como

quantização, destilação de conhecimento e poda, essenciais para viabilizar o treinamento e inferência em dispositivos com recursos limitados.

- **Utilização de *frameworks* otimizados:** KHOUAS et al, (2024) descrevem que a utilização de *frameworks* otimizados, envolve seleccionar a ferramenta adequada compatível com o hardware do dispositivo, adaptar o modelo às operações suportadas, aplicar técnicas de otimização e aproveitar aceleradores de hardware disponíveis para realizar o treinamento de forma eficiente em ambientes com recursos limitados. Ferramentas como TensorFlow Lite, ONNX Runtime e EdgeX Foundry são projetadas para esse propósito.

3 TRABALHOS RELACIONADOS

Esta seção analisa o estado da arte em eficiência energética predial, com foco na integração de Internet das Coisas (IoT) e inteligência artificial (IA), para fundamentar o desenvolvimento de um sistema de gerenciamento e otimização de energia baseado em *Edge Computing* com o microcontrolador ESP32-S3. A pesquisa foi conduzida em bases de dados acadêmicos como IEEE Xplore, ResearchGate e Google Scholar, utilizando termos de busca como "IoT", "eficiência energética", "automação residencial" e "inteligência artificial aplicada à eficiência energética".

Foram considerados artigos publicados entre 2015 e 2024, priorizando estudos experimentais com relevância técnica para o uso de IoT e IA em sistemas embarcados e impacto prático na redução do consumo energético. Os critérios de inclusão abrangeram publicações revisadas por pares, em inglês ou português, que abordassem soluções aplicáveis a edifícios prediais. Os estudos foram organizados em duas subseções temáticas: IoT aplicada à eficiência energética e IA para previsão e controle de consumo de energia.

3.1 Internet das coisas baseada em eficiência energética em edifícios Prediais

O crescimento populacional e a urbanização intensificam a demanda por energia elétrica, levantando preocupações sobre a sustentabilidade do setor energético a curto e longo prazo (SÔNEGO et al. 2016). Nesse contexto, a eficiência energética emerge como uma estratégia essencial, aplicável à geração, distribuição e uso final, conforme destacado por Motta 2012, apud, (Santos, et al., 2015) que aponta a possibilidade de reduzir o consumo sem comprometer o desempenho por meio de melhorias nos sistemas consumidores. A IoT desempenha um papel crucial ao viabilizar dispositivos inteligentes para monitoramento e controle energético.

SERRANO, (2020) desenvolveu uma tomada IoT para monitoramento de consumo, demonstrando sua utilidade em contextos de geração distribuída e cargas não lineares. O estudo experimental fornece dados valiosos sobre o comportamento de eletrodomésticos, mas carece de integração com controles automatizados. (Joha et al., 2023) avançaram ao propor um sistema de medição e controle baseado em ESP32 e sensores PZEM-004T, utilizando a plataforma Blynk para monitoramento em tempo real de tensão, corrente e potência. Embora eficaz na automação, o trabalho não quantifica a redução energética, limitando sua aplicabilidade prática. Por outro lado, Ali et al. (2024) combinaram IoT com previsão via algoritmos de Machine Learning (LSTM) e

estatísticos (ARIMA, Prophet), destacando o LSTM como o mais preciso para estimar consumo futuro. A inclusão de uma aplicação Android para visualização e alertas amplia o controle do usuário, mas a dependência de conectividade na nuvem pode ser uma desvantagem em cenários de infraestrutura limitada.

(Carreiro et al., 2022) exploraram uma abordagem inovadora com IoT e Gêmeos Digitais, criando representações virtuais de dispositivos para análise detalhada do uso de energia. Os resultados indicaram uma economia de até 25% em horários de pico, evidenciando o impacto da conscientização dos usuários. Contudo, a complexidade da implementação pode restringir sua adoção em larga escala. Similarmente, (El-Khozondar et al., 2024) propuseram um sistema de baixo custo com ESP32, Blynk e notificações via WhatsApp, focado em regiões com escassez elétrica, como a Faixa de Gaza. O sistema monitora com precisão e reduz desperdícios, mas sua simplicidade limita funcionalidades preditivas.

3.2 Inteligência artificial aplicada em eficiência energética.

A ML tem se consolidado como uma ferramenta poderosa para previsão e otimização energética. Alfonso et al. (2024) desenvolveram uma plataforma de *Edge Computing* de código aberto na Universidade de Colima, utilizando sensores para monitoramento de tensão, corrente e potência ativa. Processando dados localmente com SQLite e MQTT, o sistema reduz latência e melhora a segurança em comparação a arquiteturas exclusivamente na nuvem. Sua escalabilidade e natureza open-source o tornam adaptável, mas os testes laboratoriais carecem de validação em ambientes reais.

Em contraste, (Khan et al., 2020) propuseram um sistema de gestão para casas inteligentes baseado em aprendizagem profunda, combinando Rede Neural Convolutiva 1D (1D-DCNN), memória de longo prazo bidirecional (BLSTM) e aprendizado por reforço (QL). Validado por simulações, o modelo BLSTM superou redes neurais tradicionais na previsão de carga a longo prazo, otimizando consumo e conforto. Contudo, a alta complexidade computacional pode ser inviável para microcontroladores como o ESP32-S3.

3.3 Síntese e Contribuições para o Projeto

A revisão revela que a IoT e a IA oferecem soluções complementares para eficiência energética predial: enquanto sistemas IoT como os de Joha et al. (2024) e El-Khozondar et al. (2024) destacam a viabilidade do ESP32 em monitoramento de baixo custo, abordagens preditivas como as de Ali et al. (2024) e Khan et al. (2020) ampliam o potencial de gestão proativa. Comparativamente, a *Edge Computing* (Alfonso et al., 2024) supera limitações de latência da nuvem, mas poucos estudos integram essas tecnologias em sistemas embarcados validados experimentalmente. Lacunas persistem na quantificação do impacto energético e na adaptação a cenários reais, especialmente em contextos como o moçambicano, onde a infraestrutura é limitada. Este trabalho se posiciona ao combinar o ESP32-S3 com Machine Learning na borda, buscando preencher essas lacunas com uma solução acessível, testada em laboratório e em ambiente predial, contribuindo para a eficiência energética e a sustentabilidade.

4 METODOLOGIA

Neste capítulo apresenta-se a metodologia adotada para o desenvolvimento e validação do sistema proposto. Considerando o objetivo de conceber e avaliar um protótipo tecnológico, adotou-se a metodologia *Design Science Research* (DSR) materializado na forma de um protótipo funcional, conforme a estratégia de investigação proposta por (PEFFERS et al, 2008). A DSR é particularmente adequada a pesquisas que visam o desenvolvimento de protótipos funcionais, uma vez que integra de forma sistemática as etapas de identificação do problema, concepção da solução, implementação do protótipos e avaliação de seu desempenho.

A pesquisa possui natureza experimental e adota uma abordagem mista, combinando métodos quantitativos, aplicados na análise do desempenho do sistema e na validação dos resultados experimentais, e métodos qualitativos, utilizados na definição dos requisitos, na análise da arquitetura proposta e na interpretação dos resultados obtidos

A metodologia está estruturada em seis etapas principais, cada uma com atividades desenvolvidas, visando garantir uma abordagem sistemática para o desenvolvimento e validação do sistema. As etapas incluem: Levantamento Bibliográfico, Desenvolvimento do Protótipo de Hardware, Desenvolvimento de Software, Testes em Laboratório, e Análise e interpretação de Resultados.

4.1 Revisão Bibliográfico

Esta etapa consiste no levantamento bibliográfico, que tem como objetivo fundamentar teoricamente o projeto, identificar lacunas no estado da arte e buscar informação técnica dos componentes a serem usados. Será realizada uma revisão sistemática da literatura sobre sistemas de gerenciamento de energia, *Edge Computing*, *ML* em sistemas embarcados e o uso do microcontrolador ESP32-S3 em aplicações de IoT. Para isso, foram consultadas bases de dados de algumas revistas que discutem assuntos relacionados a ciência da computação.

Foram igualmente consultados documentos oficiais das empresas produtoras dos componentes integrados aplicados no projeto do sistema, assegurando uma compreensão detalhada das especificações técnicas dos componentes, E foram aplicadas técnicas de busca e seleção de

artigos tais como busca por termo, ano de publicação e relevância do artigo em relação a pesquisa realizada.

4.1.1 Resultados da revisão bibliográfica

Com base na revisão bibliográfica foi possível obter os seguintes resultados:

- Definir a arquitetura e os requisitos funcionais do sistema proposto.
- Escolha as ferramentas, *frameworks* e componentes mais adequados para o desenvolvimento de hardware e software.
- Estabelecer métricas de desempenho para avaliar o sistema, como precisão dos sensores e de modelo de ML, latência e eficiência energética.

4.2 Desenvolvimento do Protótipo

Para o desenvolvimento do protótipo de hardware teve-se em conta os requisitos identificados no processo da revisão bibliográfica, e foram incorporados ao projeto, garantindo que todas as funcionalidades fossem atendidas, além de identificar a melhor arquitetura para o sistema

4.2.1 Requisitos

O sistema foi projetado para atender aos requisitos funcionais e não funcionais que garantem sua eficácia na monitorização e otimização de energia em edifícios prediais.

Requisitos Funcionais:

O sistema deve:

- realizar o monitoramento em tempo real das grandezas elétricas fundamentais, incluindo tensão, corrente e potência;
- permitir o controle automático e remoto de cargas elétricas;
- garantir comunicação eficiente e confiável entre a central de processamento e os módulos de aquisição de dados;
- registrar e disponibilizar os dados de consumo para análise e tomada de decisão.

Requisitos Não Funcionais

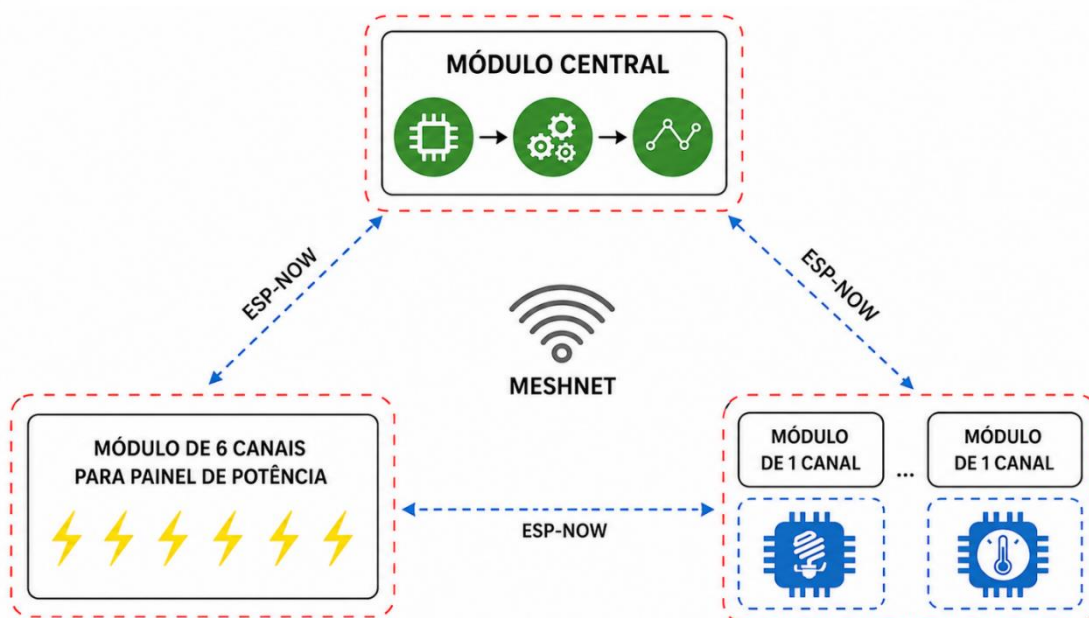
O sistema deve:

- apresentar baixa latência na execução das inferências do modelo de aprendizado de máquina;
- operar com baixo consumo de energia, adequado a sistemas embarcados;
- assegurar confiabilidade e robustez na comunicação sem a necessidade de dispositivos externos adicionais;
- permitir escalabilidade para inclusão de novos módulos e funcionalidades;
- manter tempos de resposta compatíveis com aplicações de monitoramento em tempo real.

4.2.2 Arquitetura do Sistema

A arquitetura do sistema, ilustrada na Figura 3, foi estruturada para integrar processamento local, comunicação distribuída e interação com o usuário, utilizando uma unidade central e módulos periféricos conectados por uma rede *ESP-NOW*. Esta abordagem elimina a dependência de dispositivos externos, como roteadores, e otimiza a eficiência energética ao processamento de dados na borda.

Figura 3- Arquitetura do sistema proposto



Fonte: autor

Unidade Central. A unidade central é composta por um microcontrolador ESP32-S3, equipada com um processador dual-core, responsável pelo processamento local dos dados e pela execução das inferências do modelo de ML. Este componente integra uma tela Nextion, que fornece uma interface gráfica ao usuário, permitindo a visualização de funcionalidades do sistema, controle do edifício além de permitir configurar o sistema. A central conecta-se aos módulos de sensores e atuadores por meio de uma rede *ESP-NOW*, garantindo comunicação eficiente, e atua como *gateway* ao estabelecer conexão com redes Wi-Fi externas para monitoramento remoto. O ESP32-S3 foi selecionado pela sua capacidade de suportar algoritmos de ML, comunicação Wi-Fi nativa e facilidade na integração com a tela Nextion.

Módulos Distribuídos. Foram projetados dois tipos de módulos para a leitura e controle das grandezas Elétricas. O primeiro, destinado ao quadro geral do edifício, utiliza o circuito integrado Atmel M90E32AS e relé, possibilitando a medição de parâmetros elétricos e o controle de até seis saídas independentes. O segundo, baseado no sensor HLW8032 e um relé, é conectado diretamente aos equipamentos, permitindo a monitorização e o controle individualizado de cargas específicas.

Comunicação. A comunicação entre a unidade central e os módulos distribuídos é assegurada por um protocolo da rede ESP-NOW, que permite uma interligação autónoma entre todos os elementos do sistema. Este protocolo elimina a necessidade de dispositivos externos, como roteadores, ao possibilitar que cada módulo atue como um nó de retransmissão. A escolha da comunicação ESP-NOW deveu-se pela sua capacidade de suportar ambientes complexos, dispensa a utilização de um roteador externo garantindo uma troca de dados contínuos e de baixa latência para o funcionamento do sistema.

4.2.3 Desenvolvimento de Hardware

4.2.3.1 Projeto e Simulação

Para projeção dos circuitos da central e módulos sensores e atuadores, foi adotado o software Proteus, amplamente reconhecido no meio académico por sua robustez e foco no desenvolvimento de projetos eletrônicos principalmente em simulações. Esta ferramenta possibilitou a criação de diagramas esquemáticos detalhados, a simulação do comportamento dos

componentes e circuitos além do desenvolvimento do layout de PCBs, otimizando o processo de design.

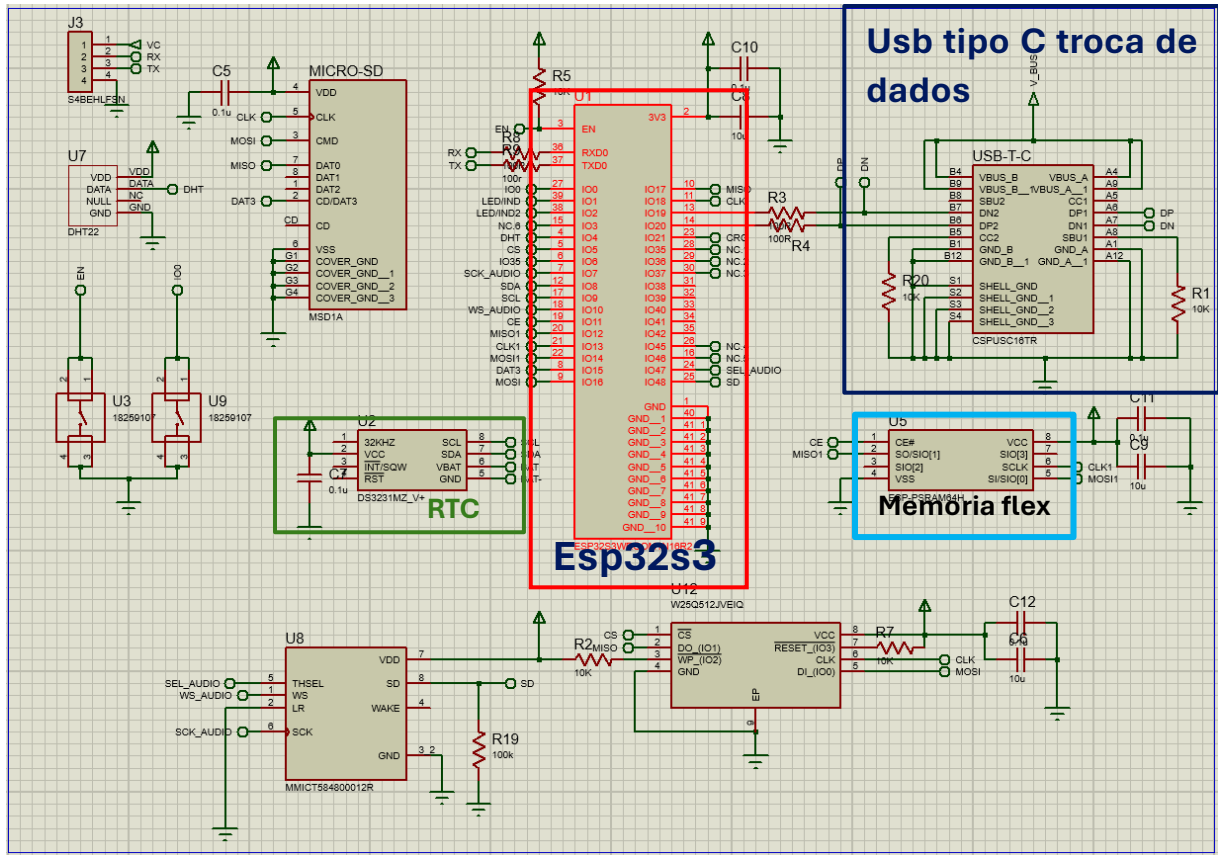
A utilização do Proteus foi crucial para validar o funcionamento dos circuitos em ambiente virtual antes da construção física do protótipo, permitindo a identificação e correção de falhas, incompatibilidades entre componentes e problemas de desempenho. Essa abordagem metodológica reduz os custos e o tempo no desenvolvimento, minimizando iterações físicas durante a prototipagem.

Antes da fabricação das placas definitivas, foram realizados testes em placas de desenvolvimento ESP32-DevKit, uma plataforma versátil que suportou a validação inicial das funcionalidades do sistema. Esses ensaios envolveram testes de comunicação entre módulos e avaliação do desempenho do *firmware*, gerando resultados essenciais para ajustar o projeto do *hardware*. Essas configurações garantiram que o protótipo final atendesse aos requisitos do projeto.

4.2.3.2 *Central*

Para um melhor detalhamento, o circuito da central será discutido em duas partes: o circuito de processamento, responsável pelas operações computacionais e de interface, e o circuito de fonte, encarregado da alimentação ELÉTRICA estável do sistema. A Figura 4 ilustra o circuito processamento.

Figura 4- Circuito de central processamento



Fonte: autor

4.2.3.3 Circuito de Processamento

O circuito de processamento constitui o núcleo funcional da unidade central, centrado no microcontrolador ESP32S3WROOM1N16R2 (U1), um módulo baseado em um processador dual-core Xtensa LX7, operando a até 240 MHz, com suporte nativo a Wi-Fi e Bluetooth 5.0. gerenciamento da interface com o usuário. Para facilitar a programação e a interação com o computador, foi incorporado um conector USB Tipo-C, escolhido por suportar a altas taxas de transferência de dados (até 5 Gbps no modo USB 3.1) e ampla disponibilidade no mercado atual.

Para garantir a sincronização temporal das operações, foi integrado o circuito integrado DS3231MZ(U2), um relógio em tempo real (RTC) de alta precisão, com compensação de temperatura e backup por bateria de lítio, capaz de fornecer dados e hora com erro máximo de ± 2 ppm. Este RTC se conecta ao ESP32S3 via interface I2C (SDA, SCL), permitindo a marcação do tempo dos dados enviados pelos sensores, essencial para análises históricas e treinamento de modelos de ML.

Foi incluído um slot para cartão MicroSD, a cessado por meio de uma interface SPI (MOSI, MISO, SCK, CS), que possibilita o armazenamento local de grandes volumes de dados enviados pelos módulos de sensores, facilitando sua posterior exportação para treinamento *offline* de modelos de ML.

Dada a complexidade do projeto, onde o ESP32S3 deve gerenciar várias tarefas simultaneamente com o processamento de dados, malha de comunicação e interface, foi adicionada a memória ESP-PSRAM64H, uma Pseudo-Static RAM de 64 Mbit, com interface paralela de alta velocidade (até 133 MHz), otimizando o desempenho em aplicações de memória dinâmica e aliviando a carga do microcontrolador em tarefas intensivas, como inferências.

Para reforçar a capacidade de armazenamento interno e suportar grande quantidade de dados, foi incorporada a memória flash W25Q512JVEIQ adicional, uma memória NOR Serial Flash de 512 Mbit (64 MB) com interface SPI de quatro linhas (Quad-SPI), operando a até 133 MHz. Esta memória oferece alta densidade, baixa latência de acesso e suporte a até 100.000 ciclos de gravação/apagamento, sendo ideal para armazenar dados enviados.

Para incrementar a interatividade do sistema, foi integrado o microfone TDK MMICT5848 um microfone digital de alta sensibilidade (faixa de -26 dBFS a -38 dBFS), ajustável. Este microfone permite a captura de comandos de voz ou detecção de eventos acústicos, ampliando a interface com o usuário ao complementar a tela Nextion, que exibe parâmetros energéticos em tempo real e suporta configurações manuais. Foi adicionado um conector pra a conexão UART (TX, RX) entre o a central. Em todos os CI formam adicionados próximos do seu pino de alimentação capacitares cerâmicos de desacoplamento para filtragem de ruído de alimentação.

4.2.3.4 *Circuito Fonte de alimentação da Central*

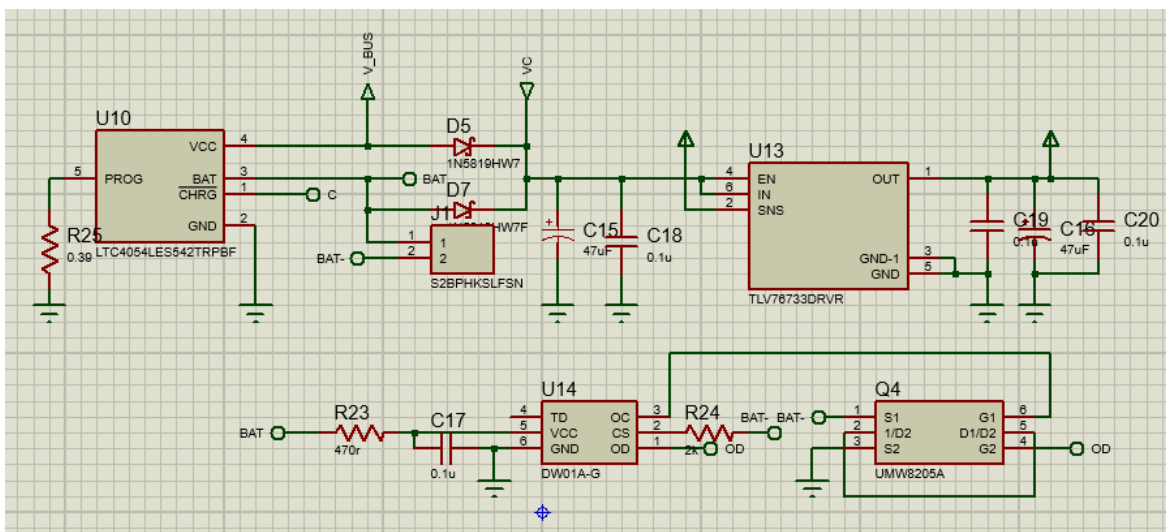
O circuito de fonte foi projetado para fornecer energia estável e contínua ao circuito de processamento, ao mesmo tempo em que carrega uma bateria de íon-lítio a 4,2 V com corrente máxima de carregamento de 400 mA. O circuito usa o regulador de carga LTC4054LES542TRPBF, configurado para gerenciar o carregamento com proteção contra sobrecarga e sobretensão, conectado a uma entrada de alimentação externa do conector USB-T-C e um conector de bateria (BAT+). Para maior controle da bateria, foi adicionado o circuito de

proteção DW01A-G um IC de gerenciamento de bateria que monitora tensão (corte a 2,4 V) e corrente, prevenindo sobrecarga e descarga excessiva da bateria.

Para regular a tensão de alimentação do circuito de processamento, foi utilizado o regulador de tensão TLV76733DRVR LDR (*Low Dropout Regulator*) de 3,3 V com capacidade de até 1 A. Este regulador se destaca por sua baixa queda de tensão (dropout de apenas 300 mV a 1 A), reduzindo perdas de energia em comparação com reguladores lineares tradicionais da família (ex.: 78L33, com dropout de 2 V), e por sua alta eficiência térmica (dissipação típica de 0,4 W em carga máxima), garantindo estabilidade mesmo em condições de alta demanda.

Foram usados dois diodos para gerir a fonte externa e a alimentação por bateria no circuito de processamento, foram incorporados dois diodos Schottky 1N5819HW7 com tensão direta de 0,45 V, posicionados de tal forma que permita o fluxo de corrente da fonte ou da bateria ao ESP32S3, impedindo que a corrente da bateria retorne ao circuito de fonte externa, garantem uma eficiência e protegem o sistema contra inversões de polaridade. Adicionalmente, foi incluído um slot para pilha CR2032, conectado ao DS3231MZ, para manter o RTC ativo na ausência das duas fontes, evitando a perda de hora.

Figura 5 - Circuito de fonte de tensão da central

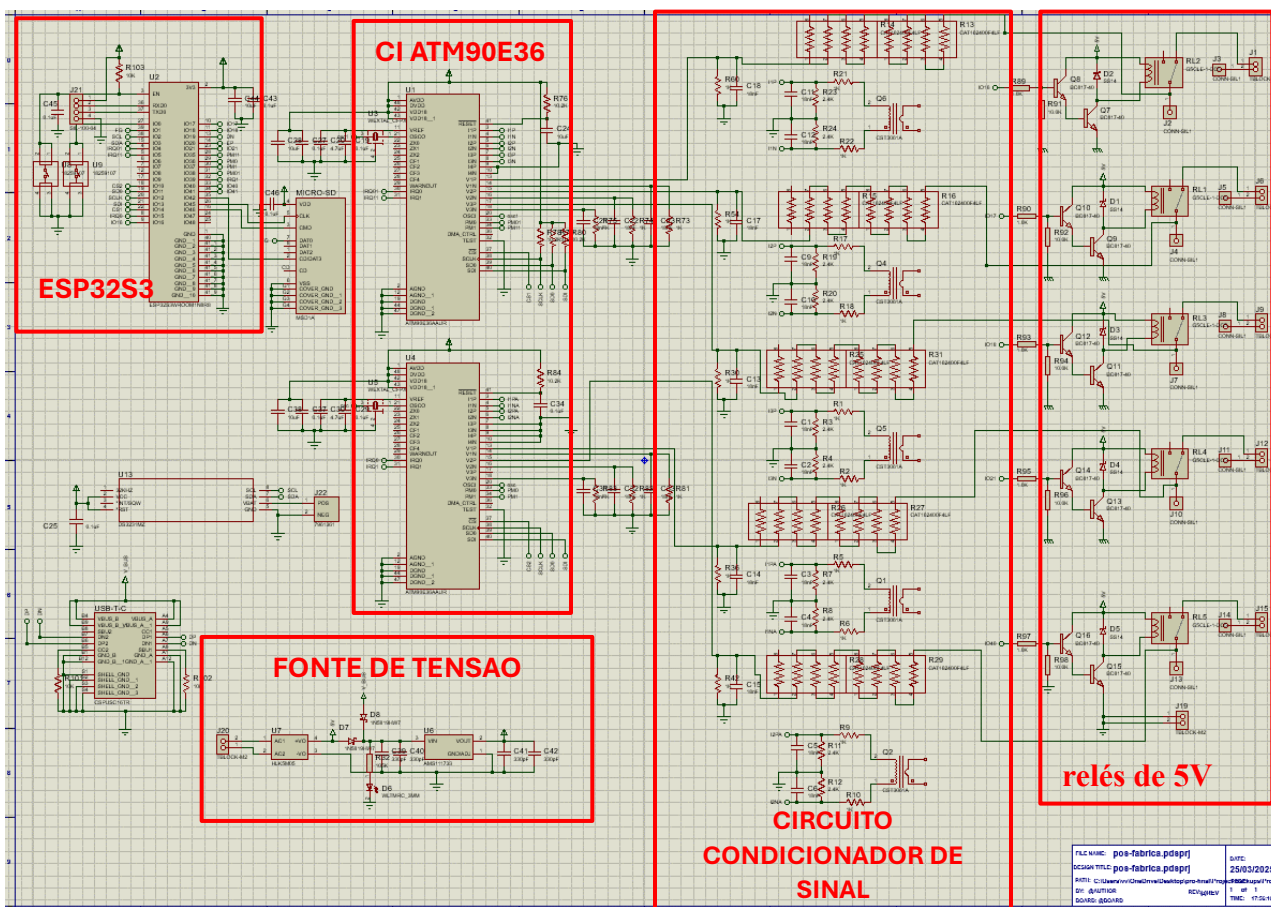


Fonte: autor

4.2.3.5 Módulo de 6 canais

Para o gerenciamento e otimização de energia predial, com foco na coleta de dados energéticos em tempo real e com controle de cargas em algumas áreas da do edifício foi projetado módulo de 5 canais, projetada para monitorar e gerenciar cinco zonas de consumo de forma independentes. O esquema, apresentado na Figura 6 ilustra o esquema do Módulo.

Figura 6 - Esquema do Módulo de 5 canais



Fonte: autor

Microcontrolador ESP32-S3(U2): Utilizado como unidade central de processamento e comunicação, o ESP32-S3 foi selecionado por sua capacidade de suportar Wi-Fi, além de possuir memória suficiente (512 KB SRAM), o ESP32-S3 é configurado com pinos GPIO para controle de relés e comunicação I2C/SPI com os circuitos integrados.

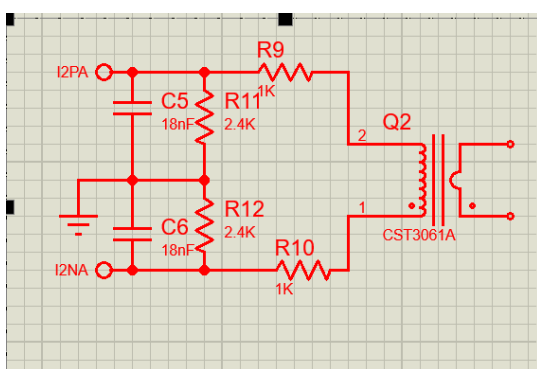
CI M90E36A (U1 E U4): Um circuito integrado de medição de energia trifásica, utilizado para a leitura precisa de corrente, tensão, fator de potência e potência em cada canal de forma independente. Conforme especificações do fabricante, o M90E36A oferece precisão de 0,1% em

precisão de energia ativa, sendo ideal para aplicações de monitoramento energético (ATMEL, 2015). No esquema, o CI está conectado ao ESP32-S3 via SPI (pinos MOSI, MISO, SCK), e aos circuitos condicionadores de sinal com filtros RC para redução de ruídos na leitura das grandezas Elétricas.

Relés de 5V (RL1 a RL5): Cinco relés de 5V foram incorporados para o controle de cargas, permitindo a ativação/desativação remota de dispositivos em cada canal. Cada relé é acionado por transístores NPN (Q11 a Q15) conectados aos pinos GPIO do ESP32-S3, com diodos de proteção (D1 a D5) para evitar picos de tensão. A escolha dos relés de 5V garantindo compatibilidade com a tensão de operação da fonte. Para cada relé possui um par de transístor na configuração *Darlington* segundo BOYLESTAD e NASHELSKY, (2013) onde os ganhos dos transístores são multiplicados reduzindo a necessidade de correntes elevadas do ESP32-S3 no momento de ativação.

Circuito de Leitura de Corrente: A leitura da corrente ELÉTRICA é feita pelo sensor de corrente CST3061A que é um transformador de corrente que apresenta razão de transformação de 5A/5mA, e complementada por filtros RC para mitigação de ruídos. Como é apresentado no esquema da Figura 7, os resistores R9, R9, e os capacitores C5, C6 formam um filtro passa-baixa com frequência de corte de 50 Hz, eliminando interferências de alta frequência, conforme recomendado pelo fabricante do CI M90E36A este circuito é replicado para todos os 5 canais.

Figura 7 - Circuito condicionador de sinal de corrente




Fonte: autor

Circuito de Leitura de Tensão: Para a medição da tensão ELÉTRICA, foi utilizado um circuito condicionador de sinal para cada canal composto por um divisor de tensão de 7 resistor de 240kΩ (R1 a R7), 1 resistor de 10kΩ (R9) e um capacitor de filtro (C81) como ilustra a figura 8.

O circuito divisor de tensão reduz a tensão de entrada (220 V AC) para níveis seguros (0-3,3 V) compatíveis com o CI M90E36A, enquanto o capacitor C49 (33nF) actua como filtro passa-baixa, eliminando ruídos de alta frequência. Para cada resistor de 240 k Ω é dissipada uma potência de: 4.07mW.

Figura 8- Circuito condicionado de sinal (tensão)



Fonte: autor

Módulo DS3231MZ: Um relógio de tempo real (RTC) foi integrado para registrar a data e hora ajudando a identificar os períodos de pico ao longo do mês, O DS3231MZ, conectado via I2C (pinos SDA, SCL), oferece soluções de ± 2 ppm, garantindo sincronização temporal confiável, conforme especificado pelo fabricante (MAXIM INTEGRATED, 2015).

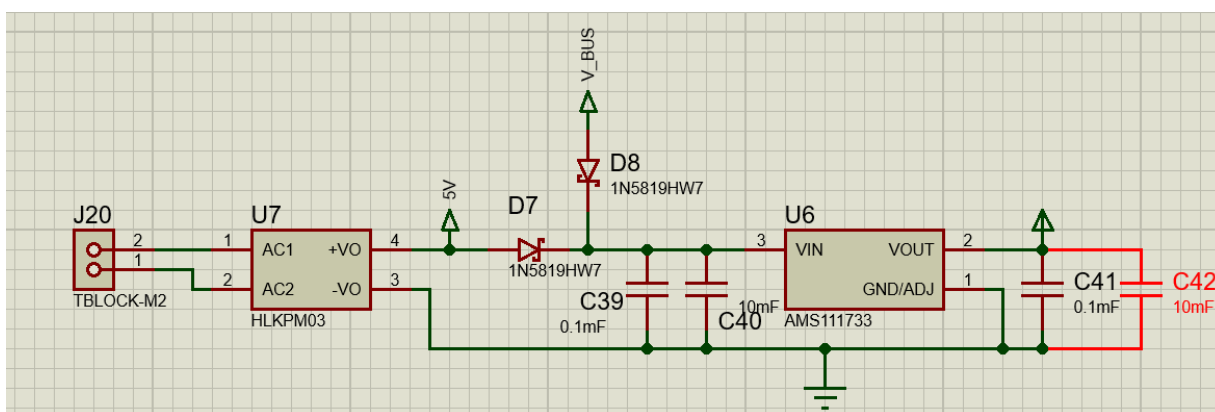
Fonte de Alimentação: A fonte de alimentação do módulo de 5 canais foi projetada para garantir a operação estável e segura do microcontrolador ESP32-S3, dos relés e dos demais componentes do circuito, atendendo aos requisitos de tensão e corrente especificados. O circuito utiliza um conversor AC-DC HLK-PM03 (U7), que reduz a tensão de entrada de 220 V AC (frequência de 50 Hz) para uma saída regulada de 5 V DC, com capacidade de corrente de até 1A, conforme especificações do fabricante (HI-LINK, 2020). Essa escolha foi motivada pela eficiência energética do HLK-PM03 (acima de 85%) e por sua compatibilidade com aplicações IoT de baixo custo.

A saída de 5 V do HLK-PM03 é utilizada diretamente para alimentar os relés de 5 V (RL1 a RL5) e como entrada para um regulador de tensão linear AMS1117-3.3, que reduz a tensão para 3,3 V, necessário para a operação do ESP32-S3 e do CI M90E36A. O AMS1117-3.3 foi selecionado por sua baixa queda de tensão (1,2 V) e capacidade de fornecer até 1 A de corrente, garantindo

estabilidade mesmo em picos de consumo. No esquema (Figura 6), o regulador AMS1117-3.3 é identificado como U6, com capacitores (C39 e C40) de 10 μF e 0,1 μF conectados na entrada do regulador e os capacitores (C41, C42) de 0,1 μF e 10 μF ambos conectados a saída do regulador, ajudam a mitigar flutuações de tensão e ruídos de alta frequência.

Para proteger o circuito durante a programação e operação, foram incorporados dois diodos (D7 e D8) em configuração de isolamento como ilustra a figura 9. O diodo D8, posicionado entre o conector USB (V_BUS) e o regulador U6, impede que a corrente fornecida pelo USB durante a programação do ESP32-S3 circule na saída do conversor HLK-PM03, evitando sobrecarga ou danos ao módulo. Da mesma forma, o diodo D7, conectado entre a saída do HLK-PM03 e o regulador, bloqueia o retorno da tensão de 5 V do HLK-PM03 ao dispositivo de programação (por exemplo, um programador USB-TTL ou computador), protegendo-o contra inversas específicas. Essa configuração de díodos, é conhecida como "Diodo ORing", é uma prática comum em sistemas de alimentação com comutação automática entre fontes, conforme descrito por BOYLESTAD e NASHELSKY, (2013) garantindo a operação segura em diferentes modos de alimentação.

Figura 9- Esquema do circuito da fonte de tensão



Fonte: autor

4.2.3.6 Módulo de 1 canal

O módulo de 1 canal foi projectado para atender à necessidade de monitoramento energético de equipamentos específicos que não estão integrados ao circuito geral de um comodo, como ar-condicionado, aquecedores ou outros dispositivos de alta potência, cuja leitura não é viável com o módulo de 5 canais devido a limitações de corrente ou configuração ELÉTRICA. Este módulo foi

desenvolvido para operar de forma independente, mas em sincronia com o sistema central permitindo a coleta de dados em tempo real.

O núcleo do módulo de 1 canal é o microcontrolador ESP8266-12E, identificado no esquema como (U6), selecionado por sua capacidade de comunicação Wi-Fi. O ESP8266-12E, está configurado para operar com uma tensão de 3,3 V, fornecida por um regulador linear AMS1117-3.3 (U3), que converte a tensão de entrada de 5 V, gerada pelo conversor AC-DC HLK-PM03 (U2), para o nível de eficiência. Capacitores de desacoplamento (C7 e C8, ambos de 10 μ F) foram aumentados aos pinos de entrada e saída do AMS1117-3.3 para mitigar flutuações de tensão e ruídos, garantindo a estabilidade do microcontrolador durante a operação.

A leitura de corrente e tensão do equipamento monitorado é realizada por meio de um circuito integrado HLW8032 (U4) e com condicionamento de sinal. Para a medição de tensão, foi implementado um divisor de tensão composto pelos resistores, circuito idênticos ao condicionador de sinal proposto no Módulo de 5 canais, que reduz a tensão de entrada (220 V AC) para níveis seguros (0-3,3 V) Um capacitor de filtro (C2, 3300 pF) foi adicionado em paralelo ao divisor para eliminar ruídos de alta frequência, com uma frequência de corte ajustada para 50 Hz, para condicionamento de sinal em sistemas IoT. A leitura de corrente é suportada pelos resistores (R19 e R20) de 1m Ω .

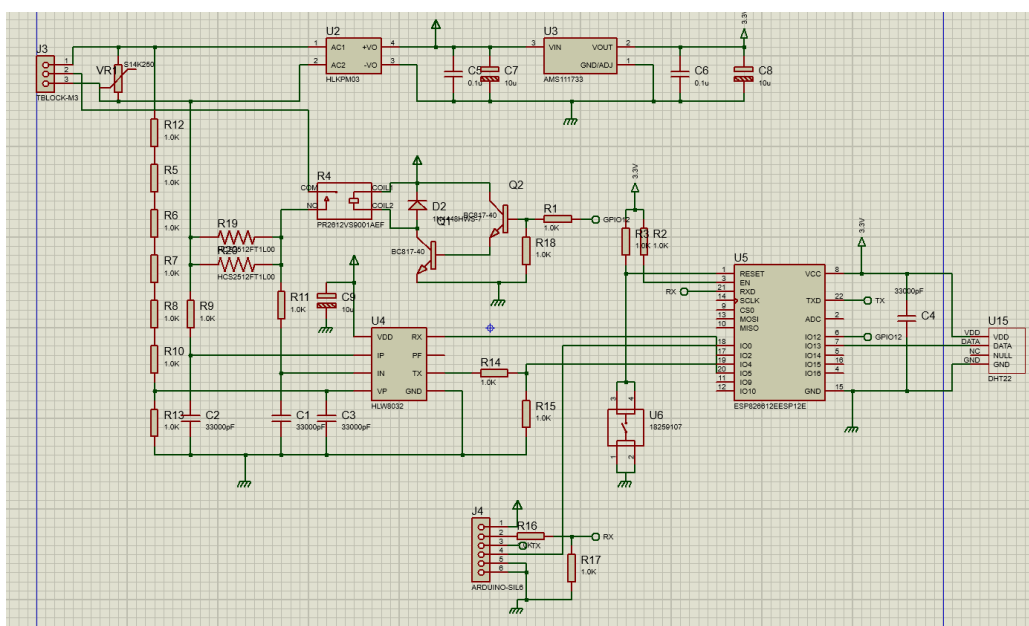
O módulo também inclui um relé de 5 V (identificado como R1), controlado por dois transístores NPN BC817-40 (Q2) conectado ao pino GPIO2 do ESP8266-12E. O relé permite a activação/desactivação remota do equipamento monitorado de acordo com os comandos enviados pela central. Um diodo de protecção (D2) foi adicionado em paralelo ao relé para evitar picos de tensão durante as trocas dos estados do rele, A comunicação com o sistema central é realizada via Wi-Fi.

Foi integrado um sensor de temperatura e umidade DHT22 (U15) ao Módulo, que também fornece dados contextuais para correlacionar o consumo energético com variáveis ambientais. O DHT22, conectado ao pino GPIO4 do ESP8266-12E, opera com uma tensão de 3,3 V e oferece isolamento de $\pm 0,5^{\circ}\text{C}$ para temperatura e $\pm 2\%$ para umidade, conforme especificações do fabricante (AOSONG, 2016). Capacitores de filtro foram adicionados à linha de alimentação do DHT22 para reduzir interferências, garantindo leituras confiáveis.

A fonte de alimentação do módulo é fornecida pelo conversor HLK-PM03 (U2), que reduz a tensão de 220 V CA para 5 V CC, com capacidade de corrente de até 600 mA e eficiência superior a 85% (HI-LINK, 2020). A saída de 5 V é utilizada para alimentar o relé e como entrada para o regulador AMS1117-3.3, que fornece 3,3 V ao ESP8266-12E, e ao DHT22.

O módulo de 1 canal foi projetado para ser compacto e independente, permitindo a sua instalação direta no circuito do equipamento monitorado, sem interferir no sistema geral do cómodo.

Figura 10- Esquema do Módulo de 1 canal




Fonte: autor

4.2.4 Projeção das Placas de Circuito Impresso (PCI)

Após a definição dos esquemáticos electrónicos do sistema, procedeu-se à fase de projecção das Placas de Circuito Impresso (PCI), utilizando o mesmo ambiente de desenvolvimento, o software Proteus. Essa etapa foi essencial para a transposição do projeto teórico para uma forma física viável e otimizada, considerando os requisitos de montagem, conexão e integração entre os componentes.

Durante a concepção das placas, utilizou-se a visualização tridimensional (3D) disponibilizada pelo software para assegurar a organização adequada dos componentes

electrónicos, bem como a disposição eficiente das trilhas e vias. A representação 3D foi fundamental para antecipar possíveis conflitos de posicionamento, facilitar a visualização do layout final e validar a compatibilidade dos componentes com seus respectivos encapsulamentos. As imagens geradas desta visualização podem ser observadas na Figura 11.



Fonte: autor

Concluída a fase de design das PCIs e após a verificação das regras de projeto (DRC – Design Rule Check), foram gerados os arquivos **Gerber**, padrão industrial necessário para a fabricação das placas. Esses arquivos incluem informações sobre as camadas de cobre, máscara de solda, serigrafia, furação e recorte, assegurando que o fabricante reproduza fielmente o projeto conforme especificado. Os arquivos Gerber foram então enviados a uma empresa especializada na fabricação de circuitos impressos. O processo de fabricação incluiu a produção física da placa, aplicação de máscaras e serigrafias, além da furação e corte final.

Finalizada a fabricação, procedeu-se à montagem dos componentes eletrônicos sobre a PCI. Essa etapa foi realizada manualmente ou com o auxílio de estação de solda, dependendo da complexidade e tipo de encapsulamento dos componentes utilizados (SMD ou PTH). Foi dada atenção especial ao posicionamento correto e à polarização dos componentes sensíveis, como díodos, capacitores eletrolíticos e circuitos integrados.

Após a montagem, iniciou-se a fase de testes funcionais preliminares. Estes testes consistiram na verificação da continuidade das trilhas, testes de alimentação e consumo de corrente, bem como a validação de sinais nos barramentos de comunicação. A etapa de testes foi crucial para assegurar o funcionamento correto do circuito e possibilitar ajustes finos no *firmware* embarcado, garantindo a confiabilidade do sistema desenvolvido.

4.3 Testes e calibração do Módulo de medição

4.3.1 Ambiente e Configuração dos Testes

Os experimentos foram conduzidos em ambiente real de operação, nas dependências da UFC-Universidade Federal de Ceará, especificamente no laboratório de eletrotécnica e em salas de aula do campus de Mocambinho-Sobral. A escolha deste ambiente teve como objetivo condições técnicas do laboratório para calibração e salas de aulas para simular condições realísticas de implantação do sistema, considerando as características construtivas típicas de edificações.

4.3.2 Equipamentos Utilizados

O multímetro digital Hikari HM-2030 é um instrumento do tipo *True RMS*, adequado para medições de tensão e corrente em corrente alternada e contínua, inclusive em condições nas quais as formas de onda não são perfeitamente senoidais. Para medições de tensão alternada nas faixas de 2 V a 200 V, o equipamento apresenta precisão de $\pm(0,5\% + 3 \text{ dígitos})$ e valores decimais, característica essencial para a análise rigorosa de linearidade. As principais especificações técnicas do instrumento, conforme o fabricante, são apresentadas na Tabela 1.

Tabela 1- Características do multímetro Hikari HM-2030

Grandeza medida	Faixa de medição	Resolução	Precisão
Tensão DC	200 mV, 2 V, 20 V, 200 V, 1000 V	0,1 mV a 1 V	$\pm(0,5\% + 3 \text{ dígitos})$
Tensão AC (True RMS)	2 V, 20 V, 200 V, 750 V	1 mV a 1 V	$\pm(0,8\% + 5 \text{ dígitos})$
Corrente DC	200 μ A, 2 mA, 20 mA, 200 mA, 20 A	0,1 μ A a 10 mA	$\pm(1,2\% + 8 \text{ dígitos})$
Corrente AC (True RMS)	20 mA, 200 mA, 20 A	10 μ A a 10 mA	$\pm(1,0\% + 5 \text{ dígitos})$
Impedância de entrada (V)	—	10 M Ω	—
Resposta em frequência (VAC)	40 Hz a 1 kHz (senoidal)	—	—
Resposta em frequência (IAC)	40 Hz a 200 Hz	—	—

Fonte: adaptado da folha de dados do multímetro

Foi usado Variac (autotransformador variável de tensão alternada). Diferentemente dos transformadores convencionais com valores fixos, o Variac permite controle gradual da tensão, tornando-se uma ferramenta importante em laboratórios, sistemas de testes elétricos, calibração de equipamentos e estudos de eficiência energética.

A tensão de para teste do sistema foi fornecida por um variac conectado à rede elétrica, possibilitando a variação contínua da tensão de saída desde 0 V até valores superiores à tensão nominal da rede. O uso do variac permitiu a definição precisa dos pontos de ensaio, a minimização de transitórios e a simulação controlada de condições reais de operação da rede elétrica.

O procedimento de calibração foi conduzido em conformidade com as recomendações do fabricante e utilizando as equações especificadas na folha de dados para o cálculo dos novos valores de ganho com base em medições de referência (MICROCHIP TECHNOLOGY IN, 2016)

4.3.3 Calibração do Módulo de medição

A calibração e validação dos sensores de tensão e corrente constituem etapas fundamentais para assegurar a confiabilidade, a precisão e a repetibilidade das medições realizadas pelo sistema proposto. Para a execução dos ensaios experimentais, foi utilizado como instrumento de referência o multímetro digital Hikari modelo HM-2030, enquanto a geração controlada das grandezas elétricas foi realizada por meio de um variac, permitindo ajustes contínuos e estáveis da tensão aplicada ao sistema sob teste.

4.3.3.1 Calibração do Sensor de Tensão

No processo de calibração do sensor de tensão inicialmente os registradores de ganho de tensão do ATM90E36 foram configurados com os valores padrão fornecidos pelo fabricante, correspondentes a ganho unitário. Em seguida, utilizando o variac, foi aplicada uma tensão alternada de 150V RMS. A tensão foi ajustada gradualmente e monitorada continuamente pelo multímetro Hikari HM-2030, conectado em paralelo ao sistema sob teste.

Após um período de estabilização de aproximadamente 30 segundos, foram registrados os valores de tensão medidos pelo ATM90E36 e pelo multímetro de referência. O novo ganho de tensão foi calculado conforme a equação recomendada pelo fabricante:

$$\text{Novo Ganho de Tensão} = \left(\frac{\text{Valor de Referência}}{\text{Valor Medido}} \right) \times \text{Ganho Existente} \quad (2)$$

O valor calculado foi gravado no registrador correspondente do ATM90E36, seguido da reinicialização do sistema para aplicação efetiva da calibração.

4.3.3.2 *Determinação da Linearidade*

A validação da linearidade do sensor de tensão foi realizada utilizando o variac para definição precisa dos pontos de ensaio. Durante este procedimento, optou-se por restringir os testes à faixa de 100 V a 200 V RMS, em incrementos de 20 V.

Essa escolha foi motivada pelas características metrológicas do multímetro de referência. Na faixa de 2 V a 200 V, o HM-2030 mantém precisão de $\pm 0,5\%$, além de apresentar resolução com casas decimais. Para tensões superiores a 200 V, o instrumento passa automaticamente para a faixa de 750 V, na qual a precisão é reduzida para $\pm 1,0\%$, e as leituras deixam de apresentar valores decimais, comprometendo a resolução necessária para uma análise detalhada de linearidade.

Para cada ponto de tensão definido como referência (100 V, 120 V, 140 V, 160 V, 180 V e 200 V), foram realizadas 10 medições consecutivas, com intervalo de 1 segundo entre leituras. Antes de cada conjunto de medições, aguardou-se um período de estabilização de 30 segundos. Os dados foram adquiridos pelo ESP32-S3 via interface SPI, com taxa de amostragem de 1 kHz, e armazenados para posterior análise estatística.

4.3.3.3 *Calibração do Sensor de Corrente*

A calibração do sensor de corrente seguiu metodologia análoga à utilizada para tensão. Foi montado um circuito série contendo o transformador de corrente, o ATM90E36 e uma carga resistiva controlada. O multímetro Hikari HM-2030 foi conectado em série para medição da corrente de referência.

A corrente de calibração inicial foi estabelecida em 1.5A RMS, valor intermediário da faixa de operação, obtido por meio do ajuste da tensão de saída do variac. Após estabilização térmica do circuito (aproximadamente 60 segundos), foram coletadas as leituras do ATM90E36 e do multímetro, sendo o novo ganho de corrente calculado pela equação:

$$\text{Novo Ganho de Corrente} = \left(\frac{\text{Valor de Referência}}{\text{Valor medido}} \right) \times \text{Ganho Existente} \quad (3)$$

4.3.3.4 *Determinação da Linearidade do Sensor de Corrente*

Após a calibração inicial, procedeu-se à validação da linearidade do sensor de corrente na faixa de operação compreendida entre 0 A e 5 A. Essa faixa foi selecionada por ser representativa do perfil de consumo associado a cargas residenciais de baixa potência, alinhando as condições do ensaio experimental e condições típicas de aplicação do sistema proposto.

Os diferentes níveis de corrente foram obtidos por meio do ajuste da tensão de saída do variac, associado à modificação controlada da configuração da carga. Para este fim, utilizou-se um banco composto por dez lâmpadas incandescentes, as quais puderam ser acionadas individualmente ou em combinações distintas, permitindo a geração de múltiplos pontos de medição distribuídos ao longo da faixa de interesse.

Para cada valor de corrente estabelecido, foram realizadas dez medições consecutivas, com intervalo de dois segundos entre leituras, após um período prévio de estabilização de trinta segundos. O intervalo adotado entre as medições teve como objetivo assegurar a estabilização das leituras e minimizar a influência de efeitos térmicos associados ao aquecimento dos filamentos das lâmpadas.

Durante todo o procedimento experimental, o multímetro digital Hikari HM-2030 permaneceu conectado em série ao circuito, fornecendo os valores de corrente de referência. Os dados adquiridos foram posteriormente processados para a obtenção da reta de linearidade e possibilitando a avaliação quantitativa da linearidade do sensor.

4.4 Validação da Comunicação entre Módulos

A comunicação entre os módulos de medição e a central de processamento constitui elemento crítico para o funcionamento do sistema proposto, influenciando diretamente a integridade dos dados coletados e a capacidade de resposta do sistema de detecção de anomalias. Esta seção apresenta a metodologia empregada nos testes de validação da comunicação via protocolo ESP-NOW.

Os dispositivos foram posicionados em duas salas de aula não adjacentes, separadas por uma terceira sala intermediária. Esta configuração resultou em distância aproximada de 20 metros entre o módulo transmissor e o receptor, com a presença de paredes de alvenaria como obstáculos físicos ao sinal de radiofrequência. Esta condição representa cenário desafiador para comunicação

sem fio, caracterizado por atenuação significativa do sinal devido à propagação através de múltiplas barreiras físicas.

4.4.1 Avaliação da Integridade de Transmissão

A avaliação da integridade da transmissão foi realizada mediante testes sistemáticos que consistiram no envio de 1.000 pacotes consecutivos em diferentes intervalos de transmissão. O objetivo desta abordagem foi caracterizar a relação entre a taxa de transmissão e a confiabilidade do sistema, identificando os limites operacionais do protocolo ESP-NOW no ambiente de teste.

Foram testados cinco intervalos distintos entre transmissões consecutivas: 50 ms, 100 ms, 250 ms, 500 ms e 1.000 ms. Para cada intervalo, registrou-se o número de pacotes efetivamente recebidos pela central de processamento, permitindo o cálculo da taxa de sucesso e da taxa de perda de pacotes.

4.4.2 Caracterização da Latência de Comunicação

Complementarmente aos testes de integridade, realizou-se caracterização detalhada da latência de comunicação em diferentes condições de carga do sistema. A latência foi definida como o intervalo de tempo decorrido entre o envio do pacote pelo módulo transmissor e sua recepção confirmada pela central de processamento.

A metodologia empregada consistiu na medição sistemática do tempo de propagação para cada um dos 1.000 pacotes transmitidos em cada condição de teste. Para cada intervalo entre transmissões, calculou-se a latência média, mínima, máxima e o desvio padrão, permitindo caracterização estatística completa do comportamento temporal do sistema.

4.5 Desenvolvimento de *firmware*

O *firmware* é o software embarcado que coordena todas as funcionalidades do sistema de monitoramento energético. Enquanto as secções anteriores abordaram o desenvolvimento e construção de hardware, a calibração dos sensores e a comunicação entre módulos, este capítulo foca exclusivamente no desenvolvimento do software que faz o sistema funcionar. A arquitetura de software foi estruturada em quatro camadas conforme o padrão de projeto *Layered Architecture* (Buschmann et al., 1996), com separação de responsabilidades:

- Camada 1: Abstração de hardware (drivers SPI, I²C, UART);

- Camada 2: Processamento de sinais (calibração, cálculo de grandezas elétricas);
- Camada 3: Comunicação (ESP-NOW, protocolo UART para display);
- Camada 4: Persistência (NVS, FAT32 para microSD)

O desenvolvimento foi realizado no ambiente Visual Studio Code utilizando a plataforma ID Arduíno para os microcontroladores ESP32. Adotou-se uma arquitetura modular visando facilitar a manutenção e permitir expansões futuras, garantindo separação clara de responsabilidades entre os diferentes componentes.

O sistema é composto por dois tipos de dispositivos: o módulo de aquisição de dados, que concentra os seis canais de medição em uma única unidade, e a central de processamento, responsável pela interface com o usuário e análise dos dados. Cada módulo funcional é implementado com tarefa independente no sistema operacional de tempo real FreeRTOS, permitindo execução concorrente de tarefas e a comunicação.

4.5.1 *Firmware do Módulo medição*

O módulo de medição integra os seis canais de medição em um único dispositivo. Este módulo é responsável por três tarefas principais: realizar a leitura de todos os seis canais de forma sequencial, armazenar essas informações no cartão microSD e transmitir o conjunto completo de dados para a central de processamento.

O *firmware* realiza a leitura sequencial dos seis canais que compõem o módulo. A estratégia implementada otimiza o processo fazendo a leitura de todos os parâmetros elétricos (tensão, corrente, potência, fator de potência, frequência, etc.) em um único comando por canal, minimizando o tempo total para adquirir os dados dos seis canais. A comunicação entre o módulo de aquisição e a central de processamento, por sua vez, utiliza o protocolo ESP-NOW, conforme validado na seção anterior.

Os parâmetros de calibração são armazenados em memória não volátil (*NVS - Non-Volatile Storage*) e carregados automaticamente sempre que o sistema reinicia ou recupera energia após uma interrupção. Durante a leitura, o *firmware* aplica automaticamente esses parâmetros de calibração que foram determinados experimentalmente, garantindo que todos os dados já estejam corrigidos antes de serem armazenados ou transmitidos.

4.5.1.1 Armazenamento em Cartão microSD

Após realizar a leitura dos seis canais, o módulo salva todos os dados em arquivo CSV no cartão microSD. Ao iniciar, o sistema verifica a existência de um arquivo com nome previamente definido no cartão. Caso o arquivo exista, o sistema continua gravando nele, adicionando novos registros ao final. Caso contrário, um novo arquivo é criado automaticamente.

Cada registro inclui a data e hora precisas e os dados de todos os seis canais: identificação do canal e seus respectivos parâmetros medidos. Esta estratégia permite continuidade na coleta de dados mesmo após reinicializações do sistema, mantendo um histórico completo e organizado.

Para evitar perda de dados em caso de queda de energia, o *firmware* usa um buffer de escrita e sincroniza periodicamente com o cartão. Isso minimiza a quantidade de dados perdidos se o sistema for desligado abruptamente.

4.5.1.2 Transmissão dos Dados

Após coletar e armazenar os dados, o módulo transmite as leituras de todos os seis canais em um único pacote via ESP-NOW para a central de processamento. Esta abordagem de consolidação reduz o *overhead* de comunicação e otimiza o uso do canal wireless.

Foi adotado a taxa de amostragem é configurável (1 segundo ou 1 minuto), e a cada intervalo configurado, o módulo envia um pacote contendo as medições simultâneas dos seis canais. O sistema implementa confirmação de recebimento com retransmissão automática caso a comunicação falhe, garantindo confiabilidade na entrega dos dados.

4.5.2 Firmware da Central de Processamento

A central de processamento recebe os pacotes de dados do módulo de aquisição contendo as informações dos seis canais, envia comando para o controle dos canais, executa o modelo de *machine learning* para detetar anomalias e fornece interface visual para o usuário através do display Nextion.

4.5.2.1 Recepção e Processamento de Dados

Quando um pacote de dados chega via ESP-NOW, o *firmware* valida sua integridade e extrai as informações dos seis canais, atualizando a base de dados em memória. O sistema também

monitora se o módulo de aquisição está transmitindo nos intervalos esperados, alertando o usuário caso detete falha de comunicação.

4.5.3 Interface com o Usuário

Para permitir que o usuário interaja com o sistema, foi desenvolvida uma interface gráfica completa no display Nextion Série Edge de 4,3 polegadas. Optou-se pelo este display por sua fácil integração com o ESP32 e por executar a interface gráfica de forma independente, reduzindo a carga de processamento do microcontrolador. A interface foi criada usando o software Nextion Editor e comunica com o ESP32 através de porta serial. Foram desenvolvidas sete telas, cada uma com uma função específica:

Tela 1 - Menu Principal: esta tela aparece assim que e pressionado em qualquer parte da tela inicial possui botões para cessar as outras telas de funções específicas funcionalidades. Como pode ser verificada na figura 12.

Figura 12 - Tela Menu



Fonte: autor

Tela 2 – controle de canais corresponde à interface de controle do sistema, sendo responsável pelo gerenciamento dos canais, permitindo seu acionamento e desligamento em tempo real pelo usuário, conforme ilustrado na Figura 13.

Figura 13- Tela de informações gerais



Fonte: autor

Tela 3 - Parâmetros Elétricos Gerais: Apresenta informações consolidadas do sistema, como consumo total dos seis canais, estatísticas de operação e histórico. Inclui gráficos de tendência e indicadores de eficiência energética (Figura 14).

Figura 14 - Parâmetros Elétricos Gerais



Fonte: autor

Tela 4 - Detalhes dos Canais: Permite visualizar todos os parâmetros de um canal específico de forma detalhada. Mostra grandezas que não aparecem na tela de visão geral e inclui gráfico com o histórico recente (Figura 15).

Figura 15 - Detalhes por canal



Fonte autor

Tela 5 - Configurações: Permite ajustar parâmetros do sistema, como taxa de amostragem, limiares de alerta, data/hora e configurações de rede. Todas as alterações são validadas antes de serem aplicadas (Figura 16).

Figura 16- Configuração do sistema



Fonte autor

Tela 6 - Análise de Anomalias: Mostra os resultados do modelo de *machine learning* de forma visual. Apresenta o nível de anomalia detetado em cada um dos seis canais, histórico de alertas e recomendações de ação. Usa cores e ícones intuitivos para facilitar a interpretação (Figura 17).

Figura 17- Análise de Anomalias



Fonte: autor

4.5.4 Comunicação com o Display

O *firmware* se comunica com o display através de comandos de texto simples via serial. Para atualizar um valor na tela, basta enviar um comando no formato "componente.atributo=valor". Isso permite atualizar apenas os elementos que mudaram, sem redesenhar a tela inteira.


O sistema implementa controle de fluxo para evitar sobrecarregar o display durante atualizações intensivas. Comandos críticos recebem confirmação de execução, garantindo que mudanças importantes foram aplicadas com sucesso.

4.6 Treinamento de ML

Esta seção apresenta os procedimentos adotados para modelagem preditiva do consumo energético a partir dos dados coletados pelo sistema desenvolvido. O objetivo foi verificar a viabilidade de previsão horária do consumo residencial, comparar abordagens de regressão e avaliar se a base de dados produzida pelo protótipo apresenta consistência suficiente para aplicação de técnicas de aprendizado de máquina.

Após os procedimentos de calibração e testes de funcionamento do protótipo, o sistema foi instalado junto ao quadro geral da residência para a coleta de dados destinados ao treinamento dos modelos, conforme ilustrado na Figura 18

Figura 18 - Protótipo instalado na residência para coleta de dados



Fonte: autor

4.6.1 Caracterização do Dataset

O conjunto de dados compreende 86.393 registros coletados ao longo de 30 dias de operação contínua, com intervalo de amostragem de 30 segundos. Embora o sistema suporte até seis canais simultâneos, a coleta foi limitada a dois canais em função da configuração da instalação elétrica monitorada, que conta com apenas dois circuitos principais de distribuição no quadro elétrico.

O Canal 3 apresentou maior variabilidade (média de 448,9 W; desvio padrão de 363,1 W), indicando presença de cargas acionadas de forma não contínua. Já o Canal 6 mostrou comportamento mais estável (média de 270,9 W; desvio padrão de 99,0 W), compatível com cargas permanentes ou de uso frequente.

No período analisado, o consumo total foi de 518,20 kWh, distribuídos de forma desigual entre os dois canais (62,4% no Canal 3 e 37,6% no Canal 6). Essa diferença não apenas caracteriza os circuitos como também influencia diretamente a dificuldade do problema de previsão, uma vez que maior variabilidade tende a aumentar o erro esperado.

4.6.2 Preparação e Pré-processamento

Os dados brutos foram agregados temporalmente de 30 segundos para intervalos de uma hora, calculando-se a média aritmética da potência em cada janela. Essa escolha se justifica por

dois motivos: a agregação horária atenua ruídos de alta frequência — oscilações de curta duração sem relevância para o horizonte de previsão adotado — e alinha a granularidade dos dados ao intervalo de predição desejado (consumo da próxima hora). Após a agregação, o dataset resultante contou com 718 amostras horárias

4.6.3 *Engenharia de Features*

Sete atributos foram construídos para caracterizar cada amostra:

1. **Potência Total** — soma do consumo dos dois canais no intervalo anterior; representa o estado agregado mais recente do sistema.
2. **W1C (Canal 3)** — consumo individual do canal de cargas intermitentes.
3. **W2C (Canal 6)** — consumo individual do canal de cargas de base.
4. **Frequência** — frequência instantânea da rede elétrica, utilizada como indicador de qualidade do fornecimento.
5. **Hora do Dia** — variável categórica (0–23) para capturar padrões de uso ao longo do dia.
6. **Dia da Semana** — variável categórica (0–6) para diferenciar o comportamento entre dias úteis e fim de semana.
7. **Final de Semana** — variável binária (0/1) que sinaliza sábado ou domingo, funcionando como simplificação do atributo anterior para modelos mais simples.

A variável-alvo foi definida como a potência total da hora imediatamente seguinte, configurando o problema como regressão supervisionada com horizonte de uma hora à frente.

4.6.4 *Estratégia de Divisão e Validação dos Dados*

Em problemas de séries temporais, embaralhar os dados antes da divisão treino/teste introduz vazamento de informação futura (*data leakage*), comprometendo a validade das métricas obtidas (Kapoor & Narayanan, 2023). Por essa razão, a divisão respeitou estritamente a ordem cronológica: os primeiros 70% dos registros (502 amostras) foram reservados para treino e validação, e os 30% restantes (216 amostras) para teste final.

O conjunto de teste permaneceu isolado durante todo o processo de desenvolvimento incluindo pré-processamento e otimização de Hiper parâmetros sendo utilizado exclusivamente na avaliação final dos modelos, evitando que qualquer informação do teste influenciasse as decisões de modelagem conforme recomenda KAPOOR e NARAYANAN, (2023). Definida a estratégia de divisão e validação dos dados, a etapa seguinte consistiu na implementação e comparação dos modelos de regressão, descritos na seção a seguir

4.6.5 Modelos de Machine Learning Implementados

Foram implementados três modelos de regressão com o objetivo de identificar a abordagem mais adequada para integração ao protótipo desenvolvido. A escolha final não foi pré-estabelecida, sendo definida com base no desempenho obtido no conjunto de teste isolado (216 amostras). A comparação seguiu ordem crescente de complexidade: Baseline por Média Histórica, *Random Forest Regressor* e *Gradient Boosting Regressor*. Essa progressão permitiu avaliar se o aumento de complexidade resultaria em ganho mensurável de desempenho para o dataset de 718 amostras horárias.

A seleção do modelo priorizou as métricas MAE e MAPE no conjunto de teste, por sua interpretação direta no contexto de consumo energético — erro em Watts e em porcentagem, respectivamente. Avaliou-se também a consistência entre os resultados da validação e do teste final — divergências superiores a 15% nas métricas principais foram interpretadas como indício de sobre ajuste, desqualificando o modelo para aplicação no protótipo independentemente do desempenho absoluto obtido. Modelos com R^2 negativo foram igualmente descartados, por indicarem desempenho inferior ao próprio baseline.

O modelo selecionado foi aquele que apresentou melhor equilíbrio entre precisão preditiva e estabilidade entre as fases de avaliação, considerando que o objetivo final é a integração em condições reais de operação, e não apenas o desempenho em ambiente controlado.

4.6.6 Métricas de Avaliação

As quatro métricas utilizadas na comparação dos modelos são apresentadas a seguir, com as respectivas equações e forma de interpretação aplicada neste trabalho. Em todas as expressões, \hat{y}_i

representa o valor previsto pelo modelo, y_i o valor real observado e n o número de amostras avaliadas.

MAE — Mean Absolute Error

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (4)$$

Expresso em Watts, o MAE representa o erro médio esperado em cada previsão. Por ser calculado em escala absoluta, permite interpretar diretamente o desvio típico do modelo no contexto do sistema monitorado — um MAE de 70 W sobre um consumo médio de 720 W tem significado operacional distinto do mesmo erro sobre uma carga de 100 W.

RMSE — Root Mean Squared Error

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (5)$$

Ao elevar os erros ao quadrado antes de calcular a média, o RMSE penaliza desvios pontuais mais severamente que o MAE. Neste trabalho, foi utilizado em conjunto com o MAE para identificar modelos com comportamento instável nos horários de pico do Canal 3 — uma diferença expressiva entre RMSE e MAE indica a ocorrência de erros isolados de grande magnitude.

MAPE — Mean Absolute Percentage Error

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100 \quad (6)$$

Ao normalizar o erro pelo valor real, o MAPE permite comparar o desempenho dos modelos independentemente da escala de consumo de cada canal. Dado que o Canal 3 apresenta média de 448,9 W e o Canal 6 de 270,9 W, a análise em percentagem evita que erros absolutos maiores no Canal 3 sejam interpretados como desempenho necessariamente inferior.

R² — Coeficiente de Determinação

$$R^2 = \frac{\sum_n^1 (\hat{y}_i - y_i)^2}{\sum_n^1 (y_i - \bar{y})^2} \quad (7)$$

Onde \bar{y} representa a média dos valores reais. O R^2 expressa a proporção da variância do consumo explicada pelo modelo: valores próximos de 1 indicam bom ajuste, valores próximos de 0 indicam desempenho equivalente à média simples, e valores negativos indicam desempenho inferior ao baseline. Conforme estabelecido na seção 6.1.4, modelos com R^2 negativo foram automaticamente desqualificados. Por ser sensível à autocorrelação presente em séries temporais, o R^2 não foi utilizado como critério isolado de seleção.

4.6.7 Integração do Modelo com o Firmware do Protótipo

Após a seleção do modelo final, a integração com o hardware seguiu uma abordagem de inferência embarcado: o modelo é treinado offline num computador e posteriormente convertido num arquivo de cabeçalho C++ (.h), incorporado diretamente no *firmware* do microcontrolador ESP32-S3 sem necessidade de comunicação externa ou servidor dedicado.

O processo de integração compreendeu três etapas. Na primeira, o modelo treinado em *Python* e convertido num arquivo modelo_consumo.h, contendo a estrutura do modelo em formato compatível com o ambiente ESP32.

Na segunda etapa, o arquivo .h gerado foi incluído no código principal do *firmware*, disponibilizando a função `prever_consumo()`, que recebe um vector de 10 features em tempo real e retorna a estimativa de consumo para o horizonte de 90 segundos seguintes (3 intervalos de 30 segundos). As *features* utilizadas na inferência embarcada correspondem a um subconjunto das construídas na fase de treino, limitadas às grandezas disponíveis em tempo real no dispositivo: potência atual dos dois canais (P1C, P2C), potência total, tensão e corrente de cada canal (V1C, I1C, V2C, I2C), médias móveis de 3 períodos e hora do dia.

Na terceira etapa, o *firmware* foi configurado para executar a previsão de forma autonomia a cada ciclo de aquisição, sem dependência de conectividade ou processamento externo. Essa

arquitetura garante que o protótipo mantém a capacidade de previsão mesmo em situações de falha de rede, tornando o sistema mais robusto para aplicação residencial contínua.

O percurso metodológico descrito neste capítulo reflete as decisões tomadas ao longo do desenvolvimento do sistema, nem sempre lineares e frequentemente condicionadas pelas características reais da instalação monitorada e pelas limitações dos recursos disponíveis. A calibração dos sensores em ambiente laboratorial, os testes de comunicação entre módulos em condições reais de obstrução, e a recolha de dados durante 30 dias de operação contínua não foram apenas etapas formais de um processo, foram os momentos em que o sistema foi confrontado com a realidade e ajustado em conformidade.


A integração do modelo de aprendizado de máquina no *firmware* do ESP32-S3 representa o ponto de convergência entre todas essas etapas: os dados recolhidos pelo hardware, tratados e validados ao longo da metodologia, alimentaram um modelo que agora opera de forma autónoma no próprio protótipo. É esse ciclo completo — da medição à previsão, sem dependência de infraestrutura externa — que o capítulo seguinte se propõe a avaliar, apresentando os resultados obtidos e discutindo em que medida o sistema desenvolvido corresponde aos objetivos e requisitos definidos.

5 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados dos testes de laboratório realizados para validação do sistema de monitoramento. A análise divide-se em três etapas: validação da precisão dos sensores, validação da comunicação entre módulos e validação do modelo de *Machine Learning*. Essa organização permite verificar tanto o funcionamento individual de cada subsistema quanto o desempenho do sistema completo.


As Figuras 19, 20 e 21 apresentam os protótipos desenvolvidos, evidenciando a central de processamento e os módulos de aquisição distribuídos, montados sobre as PCIs projetadas para o sistema.

Figura 19- Central do sistema (interface com o usuário e processamento de dados)




Fonte autor

Figura 20 - Módulo de um canal (frente e verso)



Fonte: autor

Figura 21- Módulo de 6 canais (frente e verso)



Fonte autor.

5.1 Validação da Precisão dos Sensores

A validação dos sensores é fundamental para garantir a confiabilidade das medições, pois a qualidade dos dados de entrada influencia diretamente a capacidade do modelo de ML de detectar anomalias. Esta seção apresenta os testes realizados com os sensores de tensão e corrente, comparando as leituras dos 6 canais com valores de referência conhecidos.

5.1.1 Sensores de Tensão

A Tabela 2 apresenta os resultados dos testes de linearidade dos sensores de tensão. Para cada ponto de tensão de referência foram realizadas três medições consecutivas, calculando-se a média. As incertezas expandidas situam-se entre $\pm 0,04$ V e $\pm 0,08$ V.

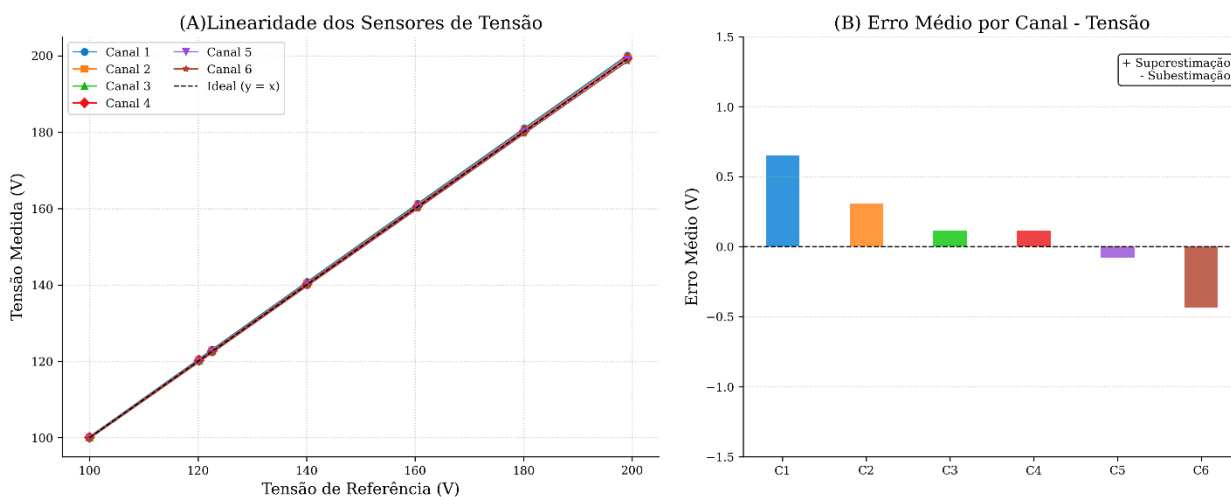
Tabela 2- Valores obtidos para validação de linearidade dos sensores de tensão

Tensão de referência (V)	Canal 1 (V)	Canal 2 (V)	Canal 3 (V)	Canal 4 (V)	Canal 5 (V)	Canal 6 (V)
100,0	100,25 ± 0,04	100,10 ± 0,05	100,00 ± 0,04	100,00 ± 0,05	99,90 ± 0,06	99,75 ± 0,07
120,2	120,60 ± 0,05	120,35 ± 0,06	120,20 ± 0,05	120,20 ± 0,06	120,05 ± 0,07	119,80 ± 0,08
122,6	123,10 ± 0,06	122,80 ± 0,05	122,65 ± 0,06	122,65 ± 0,05	122,50 ± 0,07	122,20 ± 0,08
140,1	140,80 ± 0,07	140,45 ± 0,06	140,25 ± 0,07	140,25 ± 0,06	140,05 ± 0,08	139,70 ± 0,07
160,5	161,30 ± 0,08	160,90 ± 0,07	160,65 ± 0,08	160,65 ± 0,07	160,40 ± 0,08	160,00 ± 0,08
180,1	181,00 ± 0,08	180,55 ± 0,07	180,30 ± 0,08	180,30 ± 0,07	180,05 ± 0,08	179,60 ± 0,08
199,1	200,10 ± 0,08	199,60 ± 0,07	199,35 ± 0,08	199,35 ± 0,07	199,10 ± 0,08	198,50 ± 0,08

Fonte: Autor

A Figura 22 compara os valores de tensão de referência com as tensões medidas nos seis canais. Observa-se que as curvas permanecem próximas da linha ideal, com ligeira dispersão em tensões mais elevadas.

Figura 22 - Linearidade da tensão(A). Erro medio(B)



Fonte: Autor

Os dados demonstram comportamento linear adequado ao longo da faixa de operação (100 V a 200 V). A regressão linear pelo método dos mínimos quadrados resultou em coeficientes de determinação (R^2) superiores a 0,9999 para todos os canais.

Tabela 3 - Indicadores de desempenho dos sensores de tensão

Canal	R^2	Erro médio (%)	Erro Máximo (%)	Incerteza média (V)	ENL (%)
1	0,9999	+0,68	+0,50	$\pm 0,06$	0,59
2	0,9999	+0,23	+0,35	$\pm 0,06$	0,42
3	0,9999	+0,11	+0,20	$\pm 0,06$	0,31
4	0,9999	+0,11	+0,20	$\pm 0,06$	0,31
5	0,9999	-0,03	+0,10	$\pm 0,07$	0,20
6	0,9999	-0,18	-0,10	$\pm 0,07$	0,48

Fonte: Autor

Nota: ENL (Erro de Não-Linearidade) calculado como o desvio máximo em relação à reta de regressão normalizado pela faixa de medição.

Os valores de R^2 superiores a 0,9999 indicam que mais de 99,99% da variação observada nas medições segue uma relação linear. O erro de não-linearidade situa-se entre 0,20% e 0,59%, confirmando a adequação dos divisores resistivos para esta aplicação.

A análise comparativa entre canais revela diferenças sistemáticas. O Canal 1 apresenta sobrestimação consistente (erro entre +0,25% e +0,50%), enquanto o Canal 6 exibe subestimação (-0,25% a -0,30%). Os Canais 3 e 4 mostram maior proximidade aos valores de referência, com erros inferiores a $\pm 0,20\%$. A dispersão inter-canais de 0,5 V a 0,8 V é compatível com a tolerância nominal de 1% dos resistores.

O crescimento das incertezas de $\pm 0,04$ V para $\pm 0,08$ V com o aumento da tensão reflete o efeito cumulativo da tolerância dos resistores em série nos divisores de tensão, manifestando-se de forma mais pronunciada em amplitudes elevadas. Contribuições adicionais incluem saturação parcial dos componentes eletrônicos próximos ao limite superior da faixa e aumento do ruído térmico proporcional à amplitude do sinal.

5.1.2 Sensores de Corrente

A Tabela 4 apresenta os resultados dos testes de linearidade dos sensores de corrente. Os valores correspondem às médias de três medições sucessivas para cada nível de corrente de referência, com incertezas expandidas entre $\pm 0,015$ A e $\pm 0,020$ A.

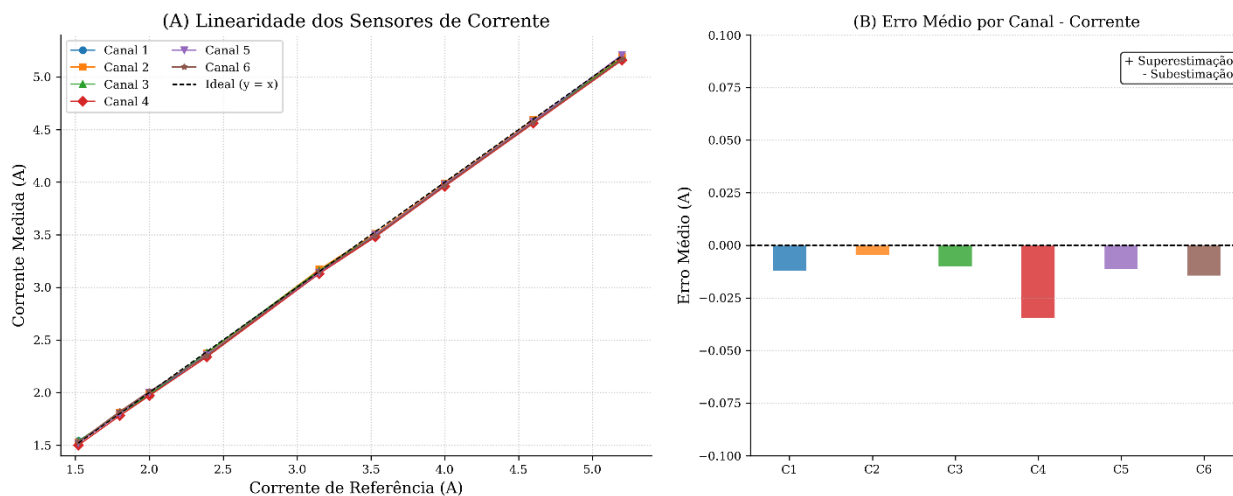
Tabela 4- Dados de validação dos sensores de corrente

I_ref (A)	Canal 1 (A)	Canal 2 (A)	Canal 3 (A)	Canal 4 (A)	Canal 5 (A)	Canal 6 (A)
1,52	1,54 ± 0,015	1,53 ± 0,015	1,54 ± 0,015	1,50 ± 0,020	1,52 ± 0,015	1,53 ± 0,015
1,80	1,80 ± 0,015	1,81 ± 0,015	1,80 ± 0,015	1,78 ± 0,020	1,80 ± 0,015	1,82 ± 0,015
2,00	1,98 ± 0,015	1,99 ± 0,015	1,98 ± 0,015	1,97 ± 0,020	2,00 ± 0,015	2,01 ± 0,015
2,39	2,36 ± 0,015	2,37 ± 0,015	2,38 ± 0,015	2,34 ± 0,020	2,36 ± 0,015	2,35 ± 0,015
3,15	3,16 ± 0,015	3,17 ± 0,015	3,16 ± 0,015	3,13 ± 0,020	3,14 ± 0,015	3,15 ± 0,015
3,53	3,50 ± 0,015	3,51 ± 0,015	3,50 ± 0,015	3,48 ± 0,020	3,50 ± 0,015	3,49 ± 0,015
4,00	3,98 ± 0,015	3,99 ± 0,015	3,98 ± 0,015	3,96 ± 0,020	3,98 ± 0,015	3,97 ± 0,015
4,60	4,58 ± 0,015	4,59 ± 0,015	4,58 ± 0,015	4,56 ± 0,020	4,58 ± 0,015	4,57 ± 0,015
5,20	5,18 ± 0,015	5,19 ± 0,015	5,18 ± 0,015	5,16 ± 0,020	5,21 ± 0,015	5,17 ± 0,015

Fonte: Autor

A figura 23 apresenta a validação dos transformadores de corrente ZMCT103C na faixa de 1,52 A a 5,20 A. A linearidade dos seis canais é satisfatória, com coeficientes de determinação R^2 superiores a 0,9998.

Figura 23 - Linearidade e erro médio: (A) Curvas de linearidade; (B) Erro médio por canal



Fonte: Autor

Observa-se na Figura 23 (A) que as curvas de todos os canais apresentam aderência à linha de referência ideal, com comportamento praticamente sobreposto. Os valores de R^2 superiores a 0,9998 confirmam a linearidade observada visualmente, indicando que mais de 99,98% da variação nas medições segue relação linear. Os transformadores ZMCT103C demonstram resposta linear consistente ao longo da faixa investigada.

A análise da Figura 23 (B) revela que cinco canais apresentam erros médios absolutos inferiores a 0,01 A: Canal 1 (-0,009 A, -0,28%), Canal 2 (+0,003 A, +0,09%), Canal 3 (-0,006 A, -0,18%), Canal 5 (-0,004 A, -0,13%) e Canal 6 (-0,009 A, -0,28%).

O Canal 4 apresenta subestimação sistemática de -0,033 A (-1,03%), sugerindo variação na relação de transformação ou no circuito de condicionamento específico deste canal. Este desvio, embora superior aos demais, permanece dentro de limites aceitáveis. A dispersão inter-canais de 0,036 A representa aproximadamente 0,98% da faixa de medição testada.

Tabela 5- Indicadores de desempenho dos sensores de corrente

Canal	R ²	Erro médio (%)	Erro máximo (%)	Incerteza (A)	ENL (%)
1	0,9999	-0,28	+1,32	±0,015	0,38
2	0,9999	-0,09	+1,11	±0,015	0,32
3	0,9999	-0,18	+1,32	±0,015	0,35
4	0,9998	-1,03	-1,32	±0,020	0,42
5	0,9999	-0,13	+1,11	±0,015	0,29
6	0,9999	-0,28	+0,50	±0,015	0,27

Fonte: Autor

Nota: ENL (Erro de Não-Linearidade) calculado como o desvio máximo em relação à reta de regressão normalizado pela faixa de medição.

Os valores de R² superiores a 0,9998 confirmam linearidade excelente. O erro de não-linearidade situa-se entre 0,27% e 0,42%, valores compatíveis com as características dos transformadores ZMCT103C.

O padrão de erros observado caracteriza-se pelo agrupamento de cinco canais com desempenho similar e um canal com desvio moderado. Este comportamento reflete variações individuais na relação de transformação dos transformadores ou diferenças nos circuitos de condicionamento. Diferente dos sensores de tensão, onde os erros crescem progressivamente com a amplitude (devido aos resistores em série), os transformadores de corrente apresentam desvios predominantemente individualizados por canal.

A dispersão das medições repetidas apresenta característica distinta. Cinco canais exibem incerteza constante de ±0,015 A ao longo de toda a faixa, enquanto o Canal 4 apresenta ±0,020 A. A constância das incertezas em amplitude absoluta, independente da corrente medida, indica que a variabilidade é dominada por fontes de ruído de amplitude fixa (ruído térmico no resistor de Burden, ruído eletrônico do circuito de condicionamento e quantização do conversor A/D).

5.1.3 Adequação do Sistema de Medição aos Objetivos

Tabela 6 - Indicadores de desempenho do sistema de medição

Grandeza	R ² médio	Erro médio (%)	Erro máximo (%)	Dispersão inter-canalais	Incerteza relativa media
Tensão	0,99997	±0,17	±0,24	0,92 V (0,93%)	0,04%
Corrente	0,99995	±0,30	±0,95	0,036 A (0,98%)	0,5% (> 3A)

Fonte: Autor

O sistema de medição apresenta linearidade adequada para ambas as grandezas ($R^2 > 0,9998$), com erros médios inferiores a $\pm 0,35\%$ e dispersão inter-canalais próxima de 1% da faixa de medição. Estes resultados validam a arquitetura proposta baseada no CI ATM90E36 com divisores resistivos para tensão e transformadores ZMCT103C para corrente.

Os resultados são compatíveis com trabalhos correlatos na literatura. Guevara et al. (2022) desenvolveram sistema de baixo custo baseado em IoT para monitoramento de variáveis elétricas utilizando o chip Atmel M90E32AS, reportando erros de 0,9% para tensão e 7% para corrente após validação em laboratório.

No presente trabalho, os erros médios de $\pm 0,17\%$ (tensão) e $\pm 0,30\%$ (corrente) demonstram desempenho metrológico superior, particularmente para corrente, onde a melhoria é significativa (23 vezes menor). Esta diferença pode ser atribuída ao uso dos transformadores ZMCT103C e ao processo de validação adotado.

A linearidade obtida ($R^2 > 0,9998$) e a análise sistemática da dispersão inter-canalais fornecem base sólida para confiabilidade na alimentação do modelo de Machine Learning para detecção de anomalias. A qualidade das medições de tensão e corrente influencia diretamente o desempenho do modelo de ML, que depende de dados precisos para aprender padrões operacionais e detectar desvios anormais.

5.2 Validação da Comunicação entre Módulos

A comunicação entre os módulos de medição e a central de processamento constitui elemento crítico para o funcionamento do sistema, influenciando diretamente a integridade dos dados coletados e a capacidade de resposta do sistema de detecção de anomalias. Esta seção apresenta os resultados dos testes de validação da comunicação via ESP-NOW.

5.2.1 Integridade da Transmissão de Dados

Os testes de integridade foram conduzidos em ambiente fechado, com distância mínima de 20 metros entre transmissor e receptor, correspondente à separação entre duas salas de aula com paredes de alvenaria intermediárias. Esta condição representa cenário desafiador para comunicação sem fio devido à atenuação causada por obstáculos físicos.

A Tabela 7 apresenta os resultados obtidos nos testes de transmissão de 1000 pacotes consecutivos em diferentes intervalos de envio.

Tabela 7 -Taxa de sucesso na transmissão de dados em função do intervalo entre envios

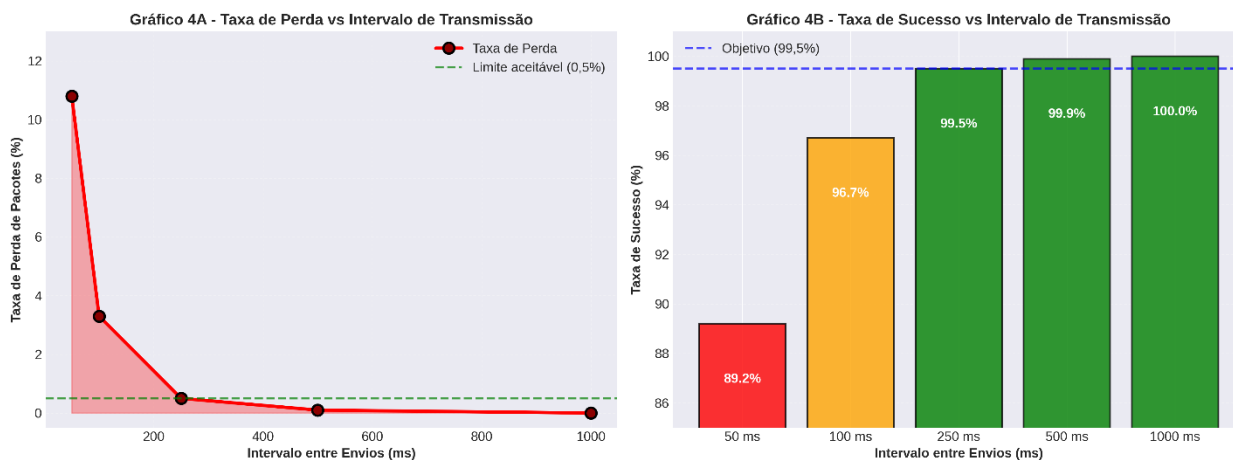
Intervalo entre envios (ms)	Pacotes enviados	Pacotes recebidos	Taxa de sucesso (%)	Pacotes perdidos
50	1000	892	89,2	108
100	1000	967	96,7	33
250	1000	995	99,5	5
500	1000	999	99,9	1
1000	1000	1000	100,0	0

Fonte: Autor

Os resultados demonstram que a taxa de perda de pacotes está diretamente relacionada ao intervalo entre transmissões consecutivas. Para intervalos de 50 ms, observou-se perda de 10,8% dos pacotes, indicando saturação do canal de comunicação ou limitação no processamento das confirmações. Com intervalo de 100 ms, a taxa de sucesso aumentou para 96,7%, mostrando melhoria significativa.

Para intervalos de 250 ms ou superiores, a taxa de sucesso excedeu 99,5%, atingindo 100% com intervalo de 1000 ms. Estes resultados indicam que o sistema ESP-NOW opera de forma confiável quando há tempo adequado para processamento das confirmações entre transmissões sucessivas. A Figura24 ilustra o comportamento da taxa de perda e da taxa de sucesso em função do intervalo entre transmissões.

Figura 24 -Taxa de sucesso na transmissão de dados em função do intervalo entre envios



Fonte: Autor

A análise a figura 24 (A) revela comportamento exponencial decrescente da taxa de perda. Para intervalos inferiores a 100 ms, a taxa de perda cresce acentuadamente, atingindo 10,8% em 50 ms. Este comportamento sugere limitação na capacidade de processamento das confirmações quando múltiplos pacotes são transmitidos em rápida sucessão. O protocolo ESP-NOW opera em modo half-duplex, onde a transmissão de confirmações compete com a recepção de novos pacotes, explicando a degradação observada em alta taxa de transmissão.

A figura 24 (B) complementa esta análise mostrando que a taxa de sucesso atinge valores superiores a 99,5% para intervalos de 250 ms ou maiores. Este limiar representa o ponto de operação adequado do sistema, onde a confiabilidade da transmissão é assegurada sem comprometer significativamente a latência total.

Para a aplicação proposta de monitoramento energético, onde as medições são amostradas em intervalos de 1 segundo ou superiores, o intervalo de 250 ms entre transmissões de diferentes módulos mostra-se adequado, garantindo taxa de sucesso superior a 99,5% com latência previsível.

5.2.2 Latência e Sincronização

A latência de comunicação foi avaliada sob diferentes condições de carga do sistema, por meio do envio de 1000 pacotes de dados para cada cenário. A medição considerou o tempo total de envio e o tempo de resposta do dispositivo. A Tabela 8 apresenta as estatísticas de latência obtidas

Tabela 8- Latência de comunicação em diferentes intervalos de transmissão

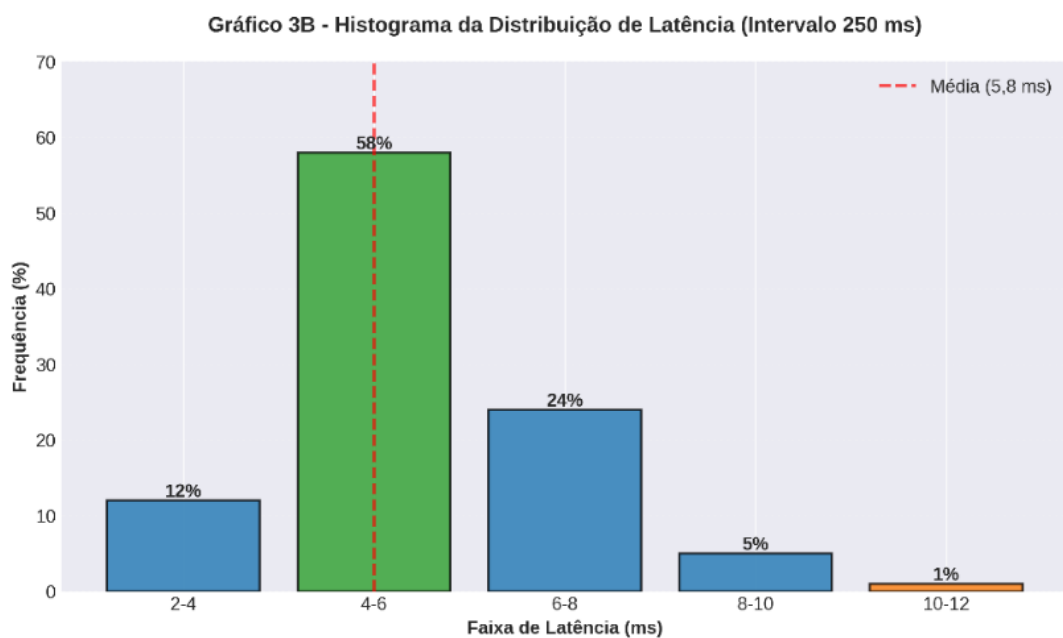
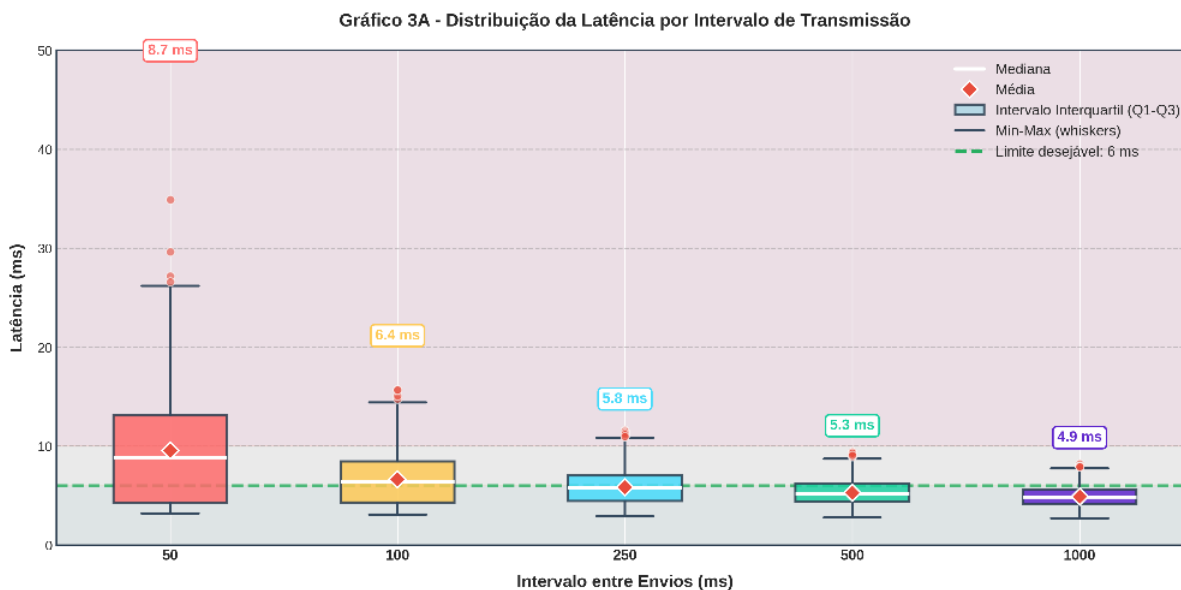
Intervalo entre envios (ms)	Latência média (ms)	Latência mínima (ms)	Latência máxima (ms)	Desvio padrão (ms)
50	8,7	3,2	47,3	6,8
100	6,4	3,1	18,5	3,2
250	5,8	2,9	12,1	1,9
500	5,3	2,8	9,4	1,4
1000	4,9	2,7	8,2	1,1

Fonte: Autor

A latência média situou-se entre 4,9ms e 8,7ms, dependendo do intervalo entre transmissões. Observa-se que intervalos menores resultam em latências médias mais elevadas e maior variabilidade (desvio padrão de 6,8 ms para intervalo de 50 ms). Este comportamento pode ser atribuído ao congestionamento do canal de comunicação e à fila de processamento de pacotes no receptor.

Para intervalos de 250 ms ou superiores, a latência estabilizou em torno de 5 ms, com desvio padrão inferior a 2 ms. A latência mínima observada foi de aproximadamente 3 ms em todas as condições, representando o tempo de propagação e processamento em condições ideais sem interferências. A figura 25 ilustra a distribuição da latência para diferentes intervalos de transmissão.

Figura 25- Latência de comunicação: (A) Box plot comparativo; (B) Histograma



Fonte: Autor

A análise estatística revela que 95% das transmissões com intervalo de 250 ms apresentaram latência inferior a 9 ms, confirmando a previsibilidade temporal do sistema nesta condição operacional.

5.2.3 Adequação aos Requisitos do Sistema

Os testes de comunicação validaram que o protocolo ESP-NOW atende aos requisitos do sistema de monitoramento proposto. A Tabela 9 sintetiza os principais indicadores de desempenho.

Tabela 9 - Síntese do desempenho da comunicação ESP-NOW

Métrica	Valor (intervalo 250 ms)	Adequação
Taxa de sucesso	99,5%	Excelente
Taxa de perda	0,5%	Dentro do aceitável (<1%)
Latência média	5,8 ms	Adequada
Desvio padrão da latência	1,9 ms	Baixa variabilidade
Latência máxima observada	12,1 ms	Aceitável
Distância testada	20 m (com obstáculos)	Suficiente para aplicação em edifícios prediais

Fonte: Autor

Com intervalo de transmissão de 250 ms ou superior, o sistema apresenta taxa de sucesso superior a 99,5%, latência média inferior a 6 ms com baixa variabilidade, e comunicação estável em distâncias até 20 metros com obstáculos. Estes parâmetros são adequados para comunicação em ambientes prediais típicos.

Na aplicação proposta de monitoramento energético, o módulo de medição possui 6 canais de aquisição, mas todos os dados são consolidados e transmitidos em um único pacote. Considerando taxa de amostragem configurável de 1 segundo ou 1 minuto, o módulo envia um pacote por intervalo de amostragem contendo as leituras simultâneas dos 6 canais de todos os dados energéticos de todos os canais. Esta arquitetura simplifica o protocolo de comunicação e minimiza o tráfego na rede.

Para amostragem de 1 segundo, o sistema transmite um pacote contendo as leituras dos 6 canais a cada segundo, intervalo 4 vezes superior aos 250 ms mínimos necessários para garantir taxa de sucesso de 99,5%. Na configuração de amostragem de 1 minuto, o intervalo entre transmissões (60 segundos) é 240 vezes maior que o mínimo requerido, proporcionando margem ainda mais ampla. Esta diferença significa que, mesmo considerando variações nas condições de propagação ou eventuais picos de interferência, o sistema mantém-se distante dos limites críticos de operação, garantindo confiabilidade superior a 99,5% em ambas as configurações de amostragem.

A latência observada (inferior a 6 ms em condições normais) é desprezível comparada aos intervalos de amostragem utilizados. Para amostragem de 1 segundo, a latência representa menos de 0,6% do período, enquanto para amostragem de 1 minuto representa apenas 0,01%. Mesmo considerando o pior caso observado nos testes (latência máxima de 12,1 ms), o atraso introduzido pela comunicação permanece inferior a 1,3% do intervalo de 1 segundo, não impactando a sincronização temporal dos dados ou o processamento pelo modelo de *Machine Learning*.

O sistema de comunicação desenvolvido mostra-se, portanto, plenamente adequado para suportar a arquitetura proposta de monitoramento com processamento centralizado, oferecendo confiabilidade superior a 99,5%, latência negligenciável e operação com ampla margem de segurança em relação aos requisitos temporais da aplicação.

5.3 Validação do Desempenho do Modelo de ML

A Tabela 10 apresenta a comparação de desempenho dos três modelos utilizando quatro métricas: MAE (*Mean Absolute Error*), RMSE (*Root Mean Squared Error*), MAPE (*Mean Absolute Percentage Error*) e R^2 (Coeficiente de Determinação).

Tabela 10 – Tabela comparativa de desempenho

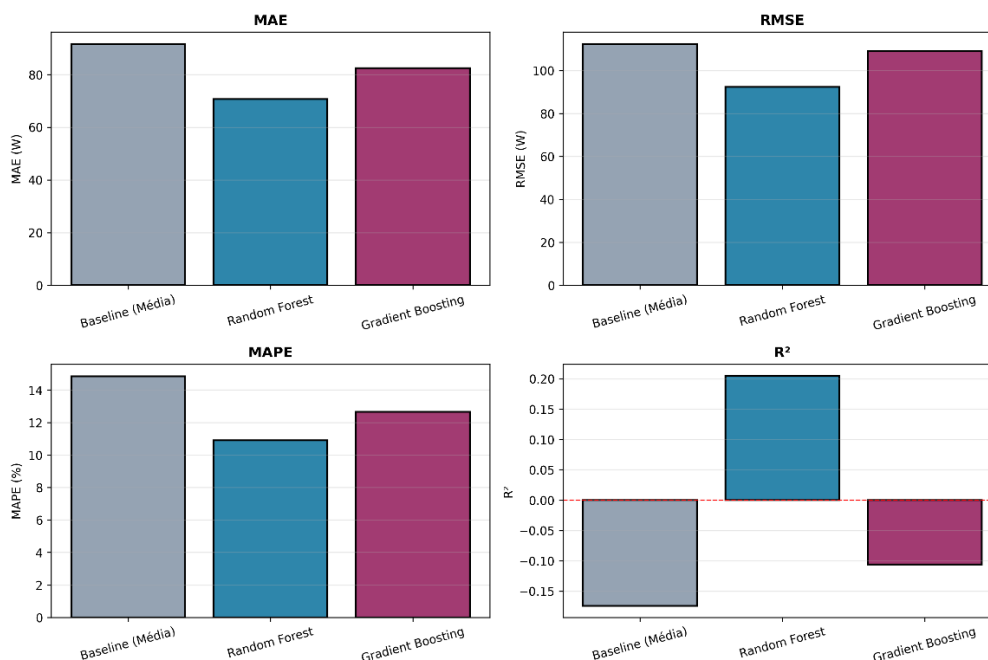
Modelo	MAE (W)	RMSE (W)	MAPE (%)	R^2
Baseline (Média)	91.53	112.27	14.85	-0.1743
Random Forest	70.71	92.36	10.91	0.2051
Gradient Boosting	82.42	108.96	12.65	-0.1061

Fonte: Autor

O modelo *Random Forest* apresentou melhor desempenho geral, com MAE de 70,71W (22,7% inferior ao baseline), MAPE de 10,91% e R^2 de 0,2051. O *Gradient Boosting* obteve desempenho intermediário (MAE de 82,42W), enquanto o *baseline* apresentou MAE de 91,53W.

A Figura 26 ilustram graficamente as previsões de cada modelo comparadas aos valores reais do conjunto de teste. Observa-se que o *Random Forest* consegue capturar melhor as variações de consumo, enquanto o *baseline* mantém previsão constante.

Figura 26- Métricas comparativas



Fonte: autor

5.3.1 Desempenho dos modelos no microcontrolador

Além dos critérios de desempenho preditivo (MAE, RMSE, MAPE, R^2) a seleção do modelo final considerou também a viabilidade de implementação futura em sistemas embarcados. Esta consideração é relevante uma vez que a integração do modelo de previsão diretamente no microcontrolador ESP32-S3 do protótipo desenvolvido permitiria operação autônoma do sistema, eliminando dependência de conectividade com servidores externos e reduzindo latência de resposta.

Os três modelos implementados apresentam diferentes requisitos computacionais para execução em sistemas embarcados: A Tabela 11 apresenta análise comparativa integrada dos três modelos implementados, considerando simultaneamente dois critérios de avaliação: requisitos de memória flash, tempo de inferência estimado. O estudo foi feito incluindo os adicionado os modelos ao código geral do sistema onde inclui o processo de armazenamento, leitura dos dados, e calibração do sistema.

Tabela 11 - Desempenho do hardware

Modelo	Memoria flesh (%)	Tempo de inferência
Base (Media histórica)	68,6%	<5ms
Random Forest Regressor	80,4%	15ms
Gradient Boosting	75%	30 ms

Fonte: Autor

A análise comparativa apresentada na Tabela 11 demonstra que o *Random Forest Regressor* atende simultaneamente a critérios de implementação: (i) desempenho preditivo superior (MAE de 70,71W, 22,7% melhor que baseline); e (ii) viabilidade comprovada de implementação embarcada no hardware do protótipo desenvolvido. Esta convergência de critérios fundamenta a seleção do *Random Forest Regressor* como modelo final.

6 CONCLUSÃO

Este trabalho apresentou o desenvolvimento, implementação e validação de um sistema de gerenciamento e otimização de energia predial baseado em *Edge Computing*, utilizando o microcontrolador ESP32-S3 e técnicas de Machine Learning. O desenvolvimento percorreu desde a revisão bibliográfica ao protótipo funcional testado em ambiente laboratorial permitindo a verificação da viabilidade técnica da proposta e avaliar o desempenho de cada subsistema.

A etapa de validação dos sensores demonstrou que o sistema de medição atinge uma linearidade aceitável para tensão e corrente, com coeficientes de determinação superiores a 0,9998 em todos os seis canais. Os erros médios obtidos $\pm 0,17\%$ para tensão e $\pm 0,30\%$ para corrente, estes dados posicionam o sistema em patamar igual ou próximo ao reportado em trabalhos correlatos na literatura, especialmente para a grandeza de corrente, onde houve uma melhoria em relação a GUEVARA e colab et all (2022). Estes resultados validam o circuito usado para o condicionamento de sinal adotada e confirmam que a qualidade dos dados de entrada é suficiente para o treinamento e a inferência do modelo de Machine Learning.

A comunicação entre os módulos de medição e a central de processamento, implementada via protocolo ESP-NOW, demonstrou comportamento confiável no ambiente de testes. Com intervalo de transmissão de 250 ms, o sistema atingiu taxa de sucesso de 99,5%, latência média de 5,8 ms e desvio padrão de 1,9 ms, em condições com 20 metros de distância e paredes de alvenaria como obstáculos. Dado que as taxas de amostragem configuradas no sistema são de 1 segundo e 1 minuto, o protocolo opera com ampla margem de segurança em relação aos limites críticos, garantindo integridade dos dados e sincronização temporal adequada ao processamento pelo modelo de ML.

Na etapa de modelagem preditiva, foram comparados três modelos de regressão supervisionada nomeadamente: *Baseline* por Média Histórica, *Random Forest Regressor* e *Gradient Boosting Regressor* aplicados a um conjunto de que inicialmente era de 86.393 coletadas em 30 dias de operação contínua em intervalos de 30 segundos que depois de processados foram agragados para 718 amostras horárias. O Random Forest Regressor destacou-se com melhor equilíbrio entre desempenho preditivo (MAE de 70,71 W, 22,7% inferior ao baseline; MAPE de 10,91%) e viabilidade de implementação embarcada, ocupando 80,4% da memória flash do ESP32-S3 com tempo de inferência de 15 ms. Estes parâmetros confirmam a factibilidade de integrar o

modelo diretamente no firmware do protótipo, eliminando a dependência de conectividade externa e tornando o sistema operacionalmente autônomo.

Em conjunto, os resultados obtidos demonstram que a combinação entre hardware de baixo custo, protocolo de comunicação sem infraestrutura adicional e modelo de aprendizado de máquina embarcado constitui uma abordagem técnica viável para o gerenciamento energético predial. O sistema proposto responde à pergunta de pesquisa formulada: é possível gerenciar e otimizar o consumo de energia em edifícios prediais utilizando Edge Computing com ML no ESP32-S3, com precisão de medição e confiabilidade de comunicação adequadas a aplicações reais.

Como limitações do trabalho, destaca-se que o modelo de ML foi treinado com dados de apenas dois canais em operação simultânea, durante 30 dias, o que restringe a generalização dos resultados a cenários de maior complexidade elétrica. O R^2 de 0,2051 obtido pelo Random Forest indica que parcela significativa da variância do consumo ainda não é capturada pelo modelo, refletindo a natureza estocástica do perfil de consumo do ambiente monitorado. A funcionalidade de detecção de anomalias, embora prevista na arquitetura e na interface com o usuário, permanece como etapa a ser concluída no desenvolvimento do sistema.

6.1 Trabalhos futuros

Como trabalhos futuros, recomenda-se: (i) expandir a coleta de dados para os seis canais simultâneos e por período mais longo, com vistas a enriquecer o dataset de treinamento e melhorar as métricas preditivas; (ii) implementar e validar o módulo de detecção de anomalias com base nos dados históricos coletados; e (iii) realizar testes de validação em ambiente predial real, com cargas elétricas de diferentes perfis.

Os resultados alcançados neste trabalho contribuem para o avanço do estado da arte em sistemas embarcados de monitoramento energético, oferecendo uma solução acessível, validada experimentalmente e com potencial de replicação em diferentes contextos urbanos e prediais.

6.2 Contribuições

Como resultado desta pesquisa, foram realizadas as seguintes contribuições científicas:

- Artigo científico publicado à *International Journal of Computer Applications*, intitulado “Desenvolvimento De Um Sistema De Gerenciamento De Energia Em Edifícios Prediais Baseado Em *Edge Computing* E *Machine Learning*”, baseado no desenvolvimento e validação do sistema proposto.
- Resumo expandido submetido ao **III Congresso da Pós-Graduação** e ao **I Congresso Internacional de Ciência, Inovação e Tecnologia**, contemplando os principais resultados e contribuições deste trabalho.

7 BIBLIOGRAFIA

- Boylestad, R. L., & Nashelsky, L. (2013). *dispositivos eletronicos e teoria de circuitos* (11th ed.).
- Carreiro, F. B. ; Nascimento, J. F., & Sousa, G. M. L. (2022). Modelagem e Desenvolvimento de uma Solução de IoT e Gêmeo Digital para Medição de Consumo de Energia Residencial. *Proceedings Do XXIV Congresso Brasileiro de Automática*, 1513–1520. <https://doi.org/10.20906/cba2022/3380>
- de Souza, D. F., da Silva, P. P. F., Fontenele, L. F. A., Barbosa, G. D., & de Oliveira Jesus, M. (2019). Efficiency, quality, and environmental impacts: A comparative study of residential artificial lighting. *Energy Reports*, 5, 409–424. <https://doi.org/10.1016/j.egy.2019.03.009>
- Dvali, M. F., & Belonin, M. D. (2020). Prospects for deep and ultradeep oil and gas deposits in u.s.s.r. *International Geology Review*, 8(6), 665–675. <https://doi.org/10.1080/00206816609474324>
- El-Khozondar, H. J., Mtair, S. Y., Qoffa, K. O., Qasem, O. I., Munyarawi, A. H., Nassar, Y. F., Bayoumi, E. H. E., & Halim, A. A. E. B. A. El. (2024). A smart energy monitoring system using ESP32 microcontroller. *E-Prime - Advances in Electrical Engineering, Electronics and Energy*, 9(June), 100666. <https://doi.org/10.1016/j.prime.2024.100666>
- FCCC. (2015). Acordo de Paris. In *convemção Quadro sobre Mudança do Clima: Vol. CP/2015/L*.
- Guevara, N. E., Bolaños, Y. H., Diago, J. P., & Segura, J. M. (2022). HardwareX Development of a low-cost IoT system based on LoRaWAN for monitoring variables related to electrical energy consumption in low voltage networks. *HardwareX*, 12, e00330. <https://doi.org/10.1016/j.ohx.2022.e00330>
- Guzueva, E. R., Kulpeiis, Y. A., & Smagulova, K. K. (2024). Socio-Economic Impacts and Energy Efficiency of Smart Housing in Smart City Initiatives. *BIO Web of Conferences*, 140. <https://doi.org/10.1051/bioconf/202414002008>
- Hua, H., Li, Y., Wang, T., Dong, N., Li, W., & Cao, J. (2023). Edge Computing with Artificial Intelligence: A Machine Learning Perspective. *ACM Computing Surveys*, 55(9), 1–35. <https://doi.org/10.1145/3555802>
- IEA. (2022). Energy Efficiency. In *Energy Efficiency 2022*. <https://iea.blob.core.windows.net/assets/7741739e-8e7f-4afa-a77f-49dadd51cb52/EnergyEfficiency2022.pdf>
- Ifechukwu Gil-Ozoudeh, Obinna Iwuanyanwu, Azubuike Chukwudi Okwandu, & Chidiebere Somadina Ike. (2022). The role of passive design strategies in enhancing energy efficiency in green buildings. *Engineering Science & Technology Journal*, 3(2), 71–91. <https://doi.org/10.51594/estj.v3i2.1519>
- Joha, M. I., Nazim, M. S., & Zubair, M. I. (2023). Smart Energy Metering, Control, and Protection System for Making a Smart Home Using IoT. *2023 26th International Conference on Computer and Information Technology, ICCIT 2023, December*, 1–6. <https://doi.org/10.1109/ICCIT60459.2023.10441201>

- Jouini, O., Sethom, K., Namoun, A., Aljohani, N., Alanazi, M. H., & Alanazi, M. N. (2024a). *A Survey of Machine Learning in Edge Computing : Techniques* ,. 1–34.
- Jouini, O., Sethom, K., Namoun, A., Aljohani, N., Alanazi, M. H., & Alanazi, M. N. (2024b). A Survey of Machine Learning in Edge Computing: Techniques, Frameworks, Applications, Issues, and Research Directions. *Technologies*, 12(6), 81. <https://doi.org/10.3390/technologies12060081>
- Kapoor, S., & Narayanan, A. (2023). Article Leakage and the reproducibility crisis in machine-learning-based science. *Patterns*, 4(9), 100804. <https://doi.org/10.1016/j.patter.2023.100804>
- Khan, M., Seo, J., & Kim, D. (2020). Towards energy efficient home automation: A deep learning approach. *Sensors (Switzerland)*, 20(24), 1–18. <https://doi.org/10.3390/s20247187>
- Khouas, A. R., Bouadjenek, M. R., Hacid, H., & Aryal, S. (2024). *Training Machine Learning models at the Edge: A Survey*. <http://arxiv.org/abs/2403.02619>
- Korneeva, E., Omarova, A., & Nurova, O. (2024). Adoption of smart energy technologies in the context of sustainable development. *E3S Web of Conferences*, 531. <https://doi.org/10.1051/e3sconf/202453102001>
- Mai, N. J., & Spohn, M. A. (2023). Revisão sistemática de Internet das Coisas aplicada em restaurantes e bares. *Revista Brasileira de Computação Aplicada*, 15(3), 48–62. <https://doi.org/10.5335/rbca.v15i3.14931>
- Mehta, R., Sahni, J., & Khanna, K. (2018). Internet of Things: Vision, Applications and Challenges. *Procedia Computer Science*, 132, 1263–1269. <https://doi.org/10.1016/j.procs.2018.05.042>
- MICROCHIP TECHNOLOGY IN. (2016). *Atmel M90E36A*.
- Nascimento, E. F., & Oliveira, P. P. (2025). *Revista Multidisciplinar do Nordeste Mineiro , v . 07 , 2025 ISSN 2178-6925 PARA REDUÇÃO DO CONSUMO ENERGÉTICO E SUSTENTABILIDADE ENERGY EFFICIENCY IN BUILDINGS : STRATEGIES AND TECHNOLOGIES FOR ENERGY CONSUMPTION REDUCTION AND SUSTAINABILITY Elias Ferrei*. <https://doi.org/10.61164/rmnm.v7i1.3771>
- Peffer, K. E. N., Tuunanen, T., & Rothenberger, M. A. (2008). A Design Science Research Methodology for Information Systems Research. *Journal of Management Information Systems*, 24(3), 45–77. <https://doi.org/10.2753/MIS0742-1222240302>
- Rahaman, M. M. (2022). A Review on Internet of Things-IoT- Architecture , Technologies , Future Applications & Challenges. *International Journal of Science and Business*, 14(1), 80–92. <https://doi.org/10.5281/zenodo.7066810>
- ROSAS, P. (2022). *O que é a arquitetura passiva, com casas onde não se passa calor nem frio e que quase não consomem energia*. <https://www.bbc.com/portuguese/geral-62434458>
- SERRANO, T. M. (2020). *PROJETO E DESENVOLVIMENTO DE UMA TOMADA IOT COM MEDIÇÃO E MONITORAMENTO AVANÇADO DE ENERGIA ELÉTRICA (Vol. 2507, Issue February)*.

- Sousa, A. R. M. de, Santos, P. R. dos, Fonseca, W. da S., Manito, A. R. A., Araújo, R. C. F., & Lobato, E. P. de S. (2019). Automação residencial e eficiência energética: Um estudo de caso. *Engenharia No Século XXI – Volume 11, January*. <https://doi.org/10.36229/978-85-7042-190-6.cap.16>
- Xu, L. Da, He, W., & Li, S. (2014). Internet of things in industries: A survey. *IEEE Transactions on Industrial Informatics*, *10*(4), 2233–2243. <https://doi.org/10.1109/TII.2014.2300753>