



UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA

Nerval de Jesus Santos Junior

***GreenFramework: Um Framework para
Monitoramento Inteligente de Recursos
Energéticos em Cidades Inteligentes***

São Luís - MA
2025

Nerval de Jesus Santos Junior

***GreenFramework: Um Framework para Monitoramento
Inteligente de Recursos Energéticos em Cidades
Inteligentes***

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica, área Ciência da Computação, ao Programa de Pós-Graduação em Engenharia Elétrica, da Universidade Federal do Maranhão.

Programa de Pós-graduação em Engenharia Elétrica
Universidade Federal do Maranhão

Orientador: Prof. Dr. Denivaldo Cicero Pavão Lopes
Coorientador: Prof. Dr. Shigeaki Leite de Lima

São Luís - MA
2025

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

de Jesus Santos Junior, Nerval.

GreenFramework: Um Framework para Monitoramento
Inteligente de Recursos Energéticos em Cidades
Inteligentes / Nerval de Jesus Santos Junior. - 2025.
175 f.

Orientador(a): Denivaldo Cicero Pavão Lopes.
Dissertação (Mestrado) - Programa de Pós-graduação em
Engenharia Elétrica/ccet, Universidade Federal do
Maranhão, Ufma, 2025.

1. Cidades Inteligentes. 2. Monitoramento Energético
e Hídrico. 3. Internet Of Things. 4. Machine Learning.
I. Cicero Pavão Lopes, Denivaldo. II. Título.

Nerval de Jesus Santos Junior

GreenFramework: Um Framework para Monitoramento Inteligente de Recursos Energéticos em Cidades Inteligentes

Dissertação de mestrado aprovada em São Luís - MA, 01 de dezembro de 2025.

**Prof. Dr. Denivaldo Cicero Pavão
Lopes
Orientador**
Universidade Federal do Maranhão

**Prof. Dr. Shigeaki Leite de Lima
Coorientador**
Universidade Federal do Maranhão

**Dr. Denisson Queiroz Oliveira
Examinador Interno**
Universidade Federal do Maranhão

**Dr. Cleonilson Protásio de Souza
Examinador Externo**
Universidade Federal da Paraíba

**Dr. Ricardo de Andrade Lira Rabelo
Examinador Externo**
Universidade Federal do Piauí

**Dr. Marcos Didonet Del Fabro
Examinador Externo**
CEA-LIST/France

Aos meus pais, irmãos e namorada.

Aos amigos, pelo apoio e companheirismo.

Agradecimentos

Agradeço antes de tudo à Deus, que me deu força, saúde e inteligência, para superar as dificuldades. À minha família, minha avó Vitória Dominici, que sempre me deu todo o amor do mundo, amor esse que é essencial para eu ser quem eu sou.

Agradeço aos meus pais, que foram essenciais para a minha caminhada até aqui: à Minha mãe, Marília Márcia Dominici, a quem devo muito amor e sempre me apoiou, me deu suporte em muitos momentos, pela educação, amor, carinho e apoio incondicional, sem os quais seria impossível trilhar o caminho que sigo. Aos familiares que se fazem presentes nos momentos de dificuldade e também nos de alegria.

Aos meus amigos(as) do Instituto de Energia Elétrica e do mestrado, Diego Cosme, Hellen Souza, Rafael Veras, Amiron Serra, Leonilson Veras, Wender Figueiredo, Adriel José, Fabricio Santos, Anna Dulce Espindola, Nilton Rodrigues, Fabrício Almeida, Hanani Santos, Adrielle Silva, Luis Felipe, George Colares, Raiane Freitas, Juan Ibanez, Davi Borges, Wenllson Leite, Rafael Quezada, Mayara Martins, Aline Mayara e Isabelle Oliveira pelo fundamental apoio, incentivo, por compartilhar momentos no almoço, no café, nas viagens, fazendo multirão para resolver os problemas e pela companhia de estudo ao longo do período do mestrado.

Aos meus amigos da graduação (Elpidio Neto, Leandro Lisboa, Delryson Saraiva, André Gomes, Nilton Maciel a todos meus amigos que sempre me apoiaram). Aos que estão longe e aos que estão perto. Sem eles, não daria para sorrir depois das dificuldades.

Ao meu orientador, Prof. Dr. Denivaldo Cicero Pavão Lopes e co-orientador Prof. Dr. Shigeaki Leite Lima, que dedicaram tempo e acreditaram que seria possível este trabalho, pela orientação, paciência e pelo apoio ao longo do tempo em que trabalhamos juntos. Ao Prof. Dr. Osvaldo Ronald Saavedra Mendez pelos ensinamentos ao longo desse período de mestrado. Agradeço também ao Prof. Dr. José Gomes e à Prof. Dra. Silvangela Barcelos pelos esclarecimentos sobre temas técnicos na área de Engenharia Elétrica.

Em especial agradeço a minha namorada e companheira, Nathalia Soares, pela compreensão, incentivo, amor e pela sua paciência em ouvir minhas reclamações e em revisar este trabalho, que desde sempre me apoiou e me mostrou que sou capaz do que eu quiser, em todos as áreas da minha vida. Amo você, meu amor!

À Coordenação de Pós-Graduação em Engenharia Elétrica e à EMAP pelo financiamento do projeto de P&D GreenMonitoring (Processo: APP-4506/23, Edital FAPEMA/EMAP nº07/2023), fornecendo recursos e bolsas.

A todos que contribuíram para esta conquista: meus sinceros agradecimentos.

"Estamos aqui para fazer alguma diferença no universo, se não, por que estar aqui?"

(Steve Jobs)

Resumo

Diante do aumento da demanda energética global e da expansão de cidades inteligentes com uso de IoT para a gestão integrada de energia elétrica e recursos hídricos, instituições públicas como a UFMA enfrentam a ausência de ferramentas de monitoramento de baixo custo, resultando em desperdícios, altos custos operacionais e elevadas emissões de CO₂ devido à ineficiência no gerenciamento de cargas prediais. Neste trabalho, propõe-se o framework GreenMonitoring que é baseado em IoT, Inteligência Artificial e MDE para suportar o monitoramento inteligente de energia elétrica e água em prédios. O framework integra dados desde a coleta, via sensores, até a disponibilização por meio de Application Programming Interfaces (APIs) ou um front-end como aplicação Web. A motivação do estudo decorre da necessidade de alinhar a gestão institucional aos Objetivos de Desenvolvimento Sustentável (ODS 7 e 11), superar a escassez de plataformas modulares de código aberto, a predominância de sistemas proprietários complexos e caros, a reduzida integração do nexo água-energia em *campi* universitários e a falta de *interfaces* intuitivas para usuários não técnicos, partindo da hipótese de que um *framework* baseado em IoT e *machine learning* pode identificar padrões de consumo, detectar anomalias e prever demandas com alta precisão, reduzindo significativamente o desperdício de ambos os recursos. Propõe-se o *GreenFramework*, uma arquitetura modular e escalável para gestão integrada de recursos, instanciada neste trabalho como *GreenMonitoring*. No estudo de caso, o GreenMonitoring foi implantado para monitorar subestações de energia elétrica e entrada de água em prédios da UFMA. Assim, medições de energia elétrica foram feitas em seis prédios da UFMA, identificando-se picos de demanda entre 13h e 17h, desperdícios em horários de baixa ocupação e emissões de CO₂ calculadas com base no fator mensal do MCTI, além de modelos preditivos com excelente desempenho (R^2 de até 0,9725 no prédio do Centro de Ciências Exatas e Tecnologia — CCET); quanto ao consumo hídrico, foi instalado apenas um medidor no Instituto de Energia Elétrica (IEE) — devido à grande distância física dos pontos de medição de água em relação aos de energia, o que dificultou a instalação em múltiplos prédios —, tendo o equipamento funcionado corretamente, com coleta e transmissão de dados plenamente validadas, embora análises quantitativas mais aprofundadas e identificação de picos de consumo hídrico tenham ficado como perspectiva futura de expansão.

Palavras-chave: Cidades inteligentes; Monitoramento energético e hídrico; *Internet of Things*; *Machine Learning*.

Abstract

Amid the rising global energy demand and the expansion of smart cities utilizing IoT for integrated management of electricity and water resources, public institutions such as UFMA face a lack of low-cost monitoring tools, leading to waste, high operational costs, and elevated CO₂ emissions due to inefficiencies in building load management. This work proposes the GreenMonitoring framework, based on IoT, Artificial Intelligence, and Model-Driven Engineering (MDE), to support intelligent monitoring of electricity and water in buildings. The framework integrates data from collection via sensors to availability through Application Programming Interfaces (APIs) or a web application front-end. The study's motivation stems from the need to align institutional management with the Sustainable Development Goals (SDG 7 and 11), overcome the scarcity of modular open-source platforms, the predominance of complex and expensive proprietary systems, the limited integration of the water-energy nexus in university campuses, and the lack of intuitive interfaces for non-technical users, based on the hypothesis that an IoT- and machine learning-based framework can identify consumption patterns, detect anomalies, and predict demands with high accuracy, significantly reducing waste of both resources. The GreenFramework is proposed as a modular and scalable architecture for integrated resource management, instantiated in this work as GreenMonitoring. In the case study, GreenMonitoring was deployed to monitor electrical substations and water intake in UFMA buildings. Electricity measurements were conducted in six UFMA buildings, identifying demand peaks between 1 p.m. and 5 p.m., waste during low-occupancy hours, and CO₂ emissions calculated based on the monthly MCTI factor, along with predictive models showing excellent performance (R^2 up to 0.9725 in the Center for Exact Sciences and Technology building — CCET); for water consumption, only one meter was installed at the Institute of Electrical Energy (IEE)—due to the large physical distance between water and energy measurement points, which hindered installation in multiple buildings—with the equipment functioning correctly and data collection and transmission fully validated, although deeper quantitative analyses and identification of water consumption peaks remain as future expansion prospects.

Keywords: Smart cities; Energy and water monitoring; Internet of Things; Machine Learning.

Listas de ilustrações

Figura 1 – Participação das fontes no crescimento da demanda energética global em 2024.	19
Figura 2 – Participação da energia renovável no consumo final global de energia por setor, caso principal, 2010-2030.	20
Figura 3 – Sensoriamento da rede elétrica em cidades e edifícios inteligentes: integração de sistemas para gestão de recursos.	30
Figura 4 – Modelo conceitual de sistemas IoT de missão crítica (MC-IoT).	31
Figura 5 – Camadas de rede para IoT.	32
Figura 6 – Fluxo de dados MQTT.	33
Figura 7 – Comunicação entre cliente e servidor usando protocolo HTTP.	34
Figura 8 – Técnicas para avaliação do desempenho energético de edifícios ativos, com ênfase em medidores inteligentes e fluxos de energia.	35
Figura 9 – Visão geral das técnicas de inteligência artificial em redes inteligentes distribuídas.	36
Figura 10 – Estrutura do LSTM.	39
Figura 11 – Comparação entre RNN e LSTM: (a) RNN contém uma única camada, e (b) LSTM contém quatro camadas interagindo.	40
Figura 12 – Relação entre modelo, metamodelo e interoperabilidade na MDA . . .	41
Figura 13 – Camadas da Arquitetura do Domain-Driven Design.	43
Figura 14 – Arquitetura de Referência para Plataformas de Cidades Inteligentes. .	44
Figura 15 – Fluxo metodológico da Revisão Sistemática da Literatura.	47
Figura 16 – Diagrama PRISMA do fluxo de seleção de estudos.	51
Figura 17 – Diagrama de Venn ilustrando a relação hierárquica entre os conjuntos de busca, representando a interseção dos três conjuntos após a aplicação dos filtros.	52
Figura 18 – Distribuição percentual por área de conhecimento (gráficos de pizza superiores) e número de documentos por ano (gráficos de linha inferiores) para os três conjuntos de busca: (a) Sistemas de Gerenciamento de Energia; (b) Edifícios Inteligentes; (c) Edifícios Inteligentes com IoT. .	53
Figura 19 – Países Mais Citados na Literatura Analisada.	55
Figura 20 – Países de Autores Correspondentes: Produção e Colaboração.	56
Figura 21 – Produção por País ao Longo do Tempo.	56
Figura 22 – Mapa de Colaboração entre Países.	57
Figura 23 – Autores Mais Relevantes.	58
Figura 24 – Rede de Co-Ocorrência de Palavras-Chave: <i>clusters</i> Temáticos.	59

Figura 25 – Arquitetura da plataforma <i>InterSCity</i> , destacando os microsserviços principais e suas interações.	69
Figura 26 – Arquitetura modular da plataforma <i>InterSCity</i> , exibindo seus microsserviços constituintes.	69
Figura 27 – Fluxo de registro de um dispositivo na plataforma <i>InterSCity</i>	70
Figura 28 – Medição do tempo para envio de comando a um atuador.	72
Figura 29 – Operação do sistema via MQTT.	72
Figura 30 – Operação do sistema via webhook.	73
Figura 31 – API <i>gateway</i> do <i>InterSCity</i>	74
Figura 32 – Balanceamento de carga HTTP no <i>InterSCity</i>	75
Figura 33 – Diagrama de casos de uso para autenticação no <i>GreenFramework</i>	83
Figura 34 – Diagrama de Casos de Uso – Módulo de Autenticação	84
Figura 35 – Diagrama de Casos de Uso - Dados do Sensor (CRUD + MQTT)	84
Figura 36 – Diagrama de Casos de Uso - Tipos de Sensores	85
Figura 37 – Diagrama de classes do <i>GreenFramework</i>	86
Figura 38 – Diagrama de sequência para autenticação no <i>GreenFramework</i>	88
Figura 39 – Diagrama de sequência geral do <i>GreenFramework</i>	89
Figura 40 – Diagrama de componentes do <i>GreenFramework</i>	90
Figura 41 – Diagrama de implantação lógica do <i>GreenFramework</i>	90
Figura 42 – Arquitetura <i>top-down</i> do <i>GreenFramework</i>	92
Figura 43 – Arquitetura do sistema <i>GreenMonitoring</i>	94
Figura 44 – Árvore hierárquica da estrutura JSON genérica.	96
Figura 45 – Visão geral do medidor Telik Trafo.	97
Figura 46 – Conexão do medidor de energia ao <i>gateway IoT</i>	97
Figura 47 – Árvore hierárquica da estrutura JSON para um medidor de energia.	99
Figura 48 – Medidor de água ZLW-3 (Eletra) instalado em campo, com <i>display</i> de volume e vazão.	100
Figura 49 – Árvore hierárquica da estrutura JSON para um medidor de água.	102
Figura 50 – Sinal de pulso do sensor de vazão capturado em osciloscópio.	102
Figura 51 – Diagrama de entidade-relacionamento do banco de dados.	108
Figura 52 – Interface <i>Swagger UI</i> da API <i>GreenMonitoring</i>	111
Figura 53 – <i>Landing page</i> da aplicação com destaque para os botões de ação.	115
Figura 54 – Comparação entre telas de <i>login</i> (esquerda) e cadastro (direita).	116
Figura 55 – Ícones de configuração no <i>dashboard</i>	117
Figura 56 – Painel de Controle do <i>GreenMonitoring</i>	119
Figura 57 – Gráficos comparativos de tensão e corrente por medidor.	120
Figura 58 – Resumo acumulado de energia e gráficos de consumo.	120
Figura 59 – Gráficos de potência com painel de medidores e opções de exportação.	121
Figura 60 – Opções de download de gráficos e dados.	122

Figura 61 – Interface de filtros para geração de relatórios com seleção de medidores, intervalo de datas e configurações de energia.	123
Figura 62 – Painel de emissões de CO ₂ com indicadores consolidados e gráficos de fatores de emissão e emissões por período.	124
Figura 63 – Quadro sinóptico da infraestrutura energética da UFMA.	127
Figura 64 – Representação detalhada do Quadro de Medição de Energia (QME).	129
Figura 65 – Perfil médio diário de energia ativa (em kWh) – Medidor CCH.	131
Figura 66 – Perfil médio diário de energia ativa (em kWh) – Medidor CCSO.	131
Figura 67 – Perfil médio diário de energia ativa (em kWh) – Medidor CCET.	132
Figura 68 – Perfil médio diário de energia ativa (em kWh) – Medidor ODONTO.	132
Figura 69 – Perfil médio diário de energia ativa (em kWh) – Medidor PF.	133
Figura 70 – Perfil médio diário de energia ativa (em kWh) – Medidor IEE.	133
Figura 71 – Gráficos de uso de CPU e memória dos contêineres do GreenMonitoring ao longo de um período de operação.	136
Figura 72 – Métricas detalhadas dos contêineres em execução no ambiente do GreenMonitoring.	136
Figura 73 – Análise de Desempenho dos Brokers MQTT. (a) Utilização média de CPU e memória por contêiner; (b) Distribuição do uso de CPU e memória; (c) Jitter médio por broker; (d) Largura de banda total; (e) Latência média por broker e Quality of Service (QoS); (f) PDR por broker e QoS.	139
Figura 74 – Gráficos de Distribuição Estatística e Tendência. (a) Boxplot da Largura de Banda Total; (b) Boxplot da Latência Média; (c) Boxplot do Número de Mensagens; (d) Gráfico de Tendência da Largura de Banda Total por QoS; (e) Gráfico de Tendência da Latência Média por QoS; (f) Gráfico de Tendência do Número de Mensagens por QoS.	141
Figura 75 – Padrão médio semanal de energia ativa (em kWh) – Medidor CCH.	142
Figura 76 – Padrão médio semanal de energia ativa (em kWh) – Medidor CCET.	143
Figura 77 – Padrão médio semanal de energia ativa (em kWh) – Medidor CCSO.	143
Figura 78 – Padrão médio semanal de energia ativa (em kWh) – Medidor IEE.	144
Figura 79 – Padrão médio semanal de energia ativa (em kWh) – Medidor PF.	144
Figura 80 – Padrão médio semanal de energia ativa (em kWh) – Medidor ODONTO.	145
Figura 81 – Previsão LSTM para o Instituto de Energia Elétrica (IEE). O perfil altamente estável, com operação 24/7 de laboratórios de alta potência, é capturado com precisão. Erro médio absoluto (MAE) de apenas 0,29,kW, o menor entre todos os prédios.	147

- Figura 82 – *Zoom* diário (29/10–01/11/2025) para o IEE. A linha vermelha tracejada acompanha quase perfeitamente a curva real, inclusive nos pequenos platôs noturnos (1–2,kW) e nos picos de inicialização matinal (6,kW às 7h). A estabilidade operacional contínua torna o padrão altamente previsível. 147
- Figura 83 – Previsão *LSTM* para o Centro de Ciências Sociais e Organizações (CCSO). São observados picos noturnos intensos (18h–22h) causados por eventos acadêmicos e climatização. Apesar do *MAPE* elevado (184,82%), o *MAE* permanece em **2,06,kW**, indicando boa performance em escala absoluta. 148
- Figura 84 – *Zoom* diário para o CCSO. O aumento abrupto às 18h (25,kW) e o decaimento gradual até a madrugada são antecipados corretamente. Pequenos *overshoots* nos picos são compensados por uma trajetória geral robusta, mesmo com variabilidade causada por eventos não programados. 148
- Figura 85 – Previsão *LSTM* para o Centro de Ciências Exatas e Tecnologia (CCET). Melhor desempenho global: $R^2 = 0,9725$ e *MAPE* de apenas **8,96%**. O padrão regular de aulas e laboratórios favorece a aprendizagem temporal da rede. 149
- Figura 86 – *Zoom* diário para o CCET. Os picos duplos diários (55,kW às 8h e 14h), os vales intermediários e o *shutdown* noturno são reproduzidos com alta fidelidade. A regularidade acadêmica resulta em sobreposição quase perfeita entre as curvas. 149
- Figura 87 – Previsão *LSTM* para o Centro de Ciências Humanas (CCH). Transições bruscas às 17h (ligações de *chillers*) geram leve *overshooting*, mas a trajetória é recuperada rapidamente. $R^2 = 0,9324$ demonstra excelente capacidade preditiva. 150
- Figura 88 – *Zoom* diário para o CCH. O salto às 17h (50,kW) é previsto com precisão, embora com leve antecipação. O ajuste ao platô de climatização e o acompanhamento do decaimento noturno são realizados rapidamente, evidenciando robustez frente a mudanças abruptas. 150
- Figura 89 – Previsão *LSTM* para a Faculdade de Odontologia. Perfil intermediário com clínicas funcionando até 21h. O decaimento noturno é antecipado corretamente, com *MAE* de **1,67,kW**. 151
- Figura 90 – *Zoom* diário para Odontologia. O padrão de clínicas — pico matinal (18,kW às 8h), platô até 21h e queda acentuada — é seguido de perto pela curva vermelha. Pequenos desvios noturnos refletem horários variáveis de atendimento, mas sem impacto significativo. 151

Figura 91 – Previsão <i>LSTM</i> para o Prédio da Farmácia (PF). Maior variabilidade é observada devido a laboratórios de pesquisa com horários irregulares. Ainda assim, $R^2 = 0,9012$ indica aderência robusta mesmo em cenários desafiadores.	152
Figura 92 – <i>Zoom</i> diário para Farmácia (PF). Picos irregulares e decaimentos noturnos são acompanhados, com desvios maiores em transições rápidas. A variabilidade de pesquisa laboratorial desafia a generalização, mas a previsão permanece útil.	152
Figura 93 – Curva de perda (<i>MSE</i>) durante o treinamento e validação do modelo <i>LSTM</i> (média dos seis prédios).	154

Lista de Códigos

1	Configuração do <i>Docker Compose</i> para o <i>GreenMonitoring</i>	95
2	Exemplo de <i>payload</i> complexo de medidor de energia.	99
3	Exemplo de <i>payload</i> simples de medidor de água.	101
4	Configuração, inicialização e processamento de mensagens do cliente <i>MQTT</i>	104
5	<i>Handler</i> principal de mensagens <i>MQTT</i>	105
6	Processamento de dados de monitoramento.	106
7	Persistência de dados de sensores.	107
8	Exemplo de resposta da <i>API</i> em <i>JSON</i>	110
9	Recuperação de dados com filtros.	110
10	Implementação do cálculo de emissões (classe <code>EmissionsCalculator</code>). . .	113

Lista de tabelas

Tabela 1 – Operações CRUD em API RESTful.	34
Tabela 2 – Conjuntos de palavras-chave usados na <i>string</i> de busca.	48
Tabela 3 – Critérios de inclusão (IC) e exclusão (EC).	49
Tabela 4 – Itens do formulário de extração de dados.	50
Tabela 5 – Informações Principais sobre os Dados	54
Tabela 6 – Principais Fontes de Artigos por Número.	57
Tabela 7 – Comparação entre protocolos de comunicação para IoT.	64
Tabela 8 – Desempenho comparativo de modelos de previsão em (MA et al., 2025) (edifícios de escritórios, dados horários BEMS).	66
Tabela 9 – Comparação de modelos preditivos de última geração em edifícios institucionais/comerciais.	67
Tabela 10 – <i>Technology stack</i> dos microsserviços da <i>InterSCity</i>	71
Tabela 11 – Comparação de abordagens para escalabilidade em sistemas IoT. . .	76
Tabela 12 – Comparação de soluções de monitoramento baseadas em IoT.	79
Tabela 13 – Requisitos para monitoramento energético no <i>GreenFramework</i>	81
Tabela 14 – Comparativo entre os princípios da <i>InterSCity</i> e o <i>GreenFramework</i> . .	91
Tabela 15 – Comparação entre componentes do <i>GreenMonitoring</i> e <i>InterSCity</i> . . .	93
Tabela 16 – Níveis de <i>Quality of Service</i> (<i>QoS</i>) no <i>MQTT</i>	103
Tabela 17 – Hierarquia de dados no <i>GreenMonitoring</i> vs <i>InterSCity</i>	109
Tabela 18 – Comparação detalhada: <i>GreenMonitoring</i> vs <i>InterSCity</i>	109
Tabela 19 – Medidores exibidos no <i>dashboard</i> (atualizado em 02/11/2025).	116
Tabela 20 – Cobertura de requisitos na implementação.	125
Tabela 21 – Especificações do hardware de execução	134
Tabela 22 – Tecnologias e versões do software principal	134
Tabela 23 – Dependências Python críticas	134
Tabela 24 – Métricas de desempenho dos contêineres do <i>GreenMonitoring</i> (Parte 1). .	137
Tabela 25 – Métricas de desempenho dos contêineres do <i>GreenMonitoring</i> (Parte 2). .	137
Tabela 26 – Métricas de desempenho do modelo <i>LSTM</i> no conjunto de teste (01– 15/03/2025).	153
Tabela 27 – Comparação de modelos preditivos em edifícios institucionais/comerciais com os resultados do presente trabalho.	156
Tabela 28 – Comparação de soluções de monitoramento baseadas em IoT com o estado da arte e o presente trabalho.	156
Tabela 29 – Publicação científica diretamente relacionada ao tema da dissertação	160
Tabela 30 – Outras publicações científicas derivadas de pesquisas paralelas . . .	160

Lista de abreviaturas e siglas

AIE	Agência Internacional de Energia
AMQP	Advanced Message Queuing Protocol
ANEEL	Agência Nacional de Energia Elétrica
ANN	Rede Neural Artificial
ARIMA	AutoRegressive Integrated Moving Average
BLE	Bluetooth Low Energy
CoAP	Constrained Application Protocol
COP28	28 ^a Conferência das Partes da Convenção-Quadro das Nações Unidas sobre Mudança do Clima
CPS	Sistemas Ciberfísicos
DDD	Domain-Driven Design
EMF	Eclipse Modeling Framework
EMS	Energy Management System
EPE	Empresa de Pesquisa Energética
FTP	File Transfer Protocol
GBR	Gradient Boosting Regressor
GD	Geração Distribuída
GEE	Gases de Efeito Estufa
GHG	Greenhouse Gas Protocol
GRU	Gated Recurrent Unit
HATEOAS	Hypermedia as the Engine of Application State
HCA	Clustering Hierárquico
HEFCE	Higher Education Funding Council for England
HED	High-End Device

HTTP	HyperText Transfer Protocol
HVAC	Heating, Ventilation, and Air Conditioning
IEA	International Energy Agency
IEC	International Electrotechnical Commission
IME-USP	Instituto de Matemática e Estatística da Universidade de São Paulo
INCT	Instituto Nacional de Ciência e Tecnologia
IoT	Internet of Things
IRENA	International Renewable Energy Agency
ISO	International Organization for Standardization
JSON	JavaScript Object Notation
JWT	JSON Web Token
LDAP	Lightweight Directory Access Protocol
LoRaWAN	Long Range Wide Area Network
LSTM	Long Short-Term Memory
M2T	Model-to-Text
M@rt	Modelos em Tempo de Execução
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MCS	Mobile CrowdSensing
MDE	Model-Driven Engineering
MDE4ML	Model-Driven Engineering for Machine Learning
MDA	Model-Driven Architecture
ML	Machine Learning
MPL	Mozilla Public License
MQTT	Message Queuing Telemetry Transport
MR	Multiple Regression

NBR	Norma Brasileira
O-DF	Open Data Format
O-MI	Open Messaging Interface
ODS	Objetivos de Desenvolvimento Sustentável
OpenVPN	Open Virtual Private Network
PPCA	Probabilistic Principal Component Analysis
PROCEL	Programa Nacional de Conservação de Energia Elétrica
PUC-Rio	Pontifícia Universidade Católica do Rio de Janeiro
PV	Fotovoltaica
QME	Quadro de Medição de Energia
RBFNN	Radial Basis Function Neural Network
RF	Random Forest
RNN	Recurrent Neural Network
RSL	Revisão Sistemática da Literatura
RMSE	Root Mean Square Error
SCADA	Supervisory Control and Data Acquisition
SGME	Sistema de Gerenciamento e Monitoramento de Energia
SMTP	Simple Mail Transfer Protocol
SPSS	Statistical Package for the Social Sciences
SSL	Secure Sockets Layer
TCP	Transmission Control Protocol
TF-IDF	Term Frequency-Inverse Document Frequency
TLS	Transport Layer Security
UDP	User Datagram Protocol
UFMA	Universidade Federal do Maranhão
UML	Unified Modeling Language

UUID	Universally Unique Identifier
WWR	Window-to-Wall Ratio
CIM	Computation Independent Model
PSM	Platform-Specific Model
Green IoT	Green Internet of Things
MC-IoT	Mission-Critical Internet of Things
IP	Internet Protocol
QoS	Quality of Service
REST	Representational State Transfer
AutoML	Automated Machine Learning
DA/ML	Data Analysis and Machine Learning
ISO 50001	International standard for energy management systems

Lista de símbolos

$p(t)$	Potência instantânea
$v(t)$	Tensão instantânea em função do tempo
$i(t)$	Corrente instantânea em função do tempo
w	Energia consumida, calculada pela integral da potência ao longo do tempo
S	Potência aparente
P	Potência ativa
Q	Potência reativa
V_{RMS}	Valor eficaz (RMS) da tensão
I_{RMS}	Valor eficaz (RMS) da corrente
θ	Ângulo de defasagem entre tensão e corrente
h_t	Estado oculto em uma rede neural recorrente (RNN) ou LSTM no instante t
h_{t-1}	Estado oculto no instante anterior em RNN ou LSTM
x_t	Entrada no instante t em RNN, LSTM ou GRU
y_t	Saída no instante t em RNN
σ	Função sigmoide, usada em RNN, LSTM e GRU
W_h, W_x, W_y	Matrizes de pesos em RNN
b_h, b_y	Vetores de viés em RNN
ϕ	Função de ativação de saída em RNN
f_t	Porta de esquecimento em LSTM
i_t	Porta de entrada em LSTM
o_t	Porta de saída em LSTM
c_t	Estado da célula em LSTM no instante t

c_{t-1}	Estado da célula anterior em LSTM
\tilde{C}_t	Candidato ao estado da célula em LSTM
W_f, W_i, W_o, W_g	Matrizes de pesos das portas de esquecimento, entrada, saída e candidato em LSTM
b_f, b_i, b_o, b_g	Vetores de viés das portas em LSTM
g_t	Candidato ao estado da célula em LSTM (equação alternativa)
z_t	Porta de atualização em GRU
r_t	Porta de reinicialização em GRU
\tilde{h}_t	Candidato ao estado oculto em GRU
W_z, W_r, W	Matrizes de pesos em GRU
M_0, M_1, M_2, M_3	Níveis de abstração na arquitetura MDA

Sumário

1	INTRODUÇÃO	19
1.1	Contextualização	19
1.2	Caracterização do Problema	21
1.2.1	Do Contexto Global à Realidade Institucional	21
1.2.2	A Lacuna de Gestão e a Oportunidade Tecnológica	22
1.2.3	O Posicionamento da Proposta	22
1.3	Motivação	23
1.4	Hipóteses de Pesquisa	23
1.5	Solução Proposta	24
1.6	Justificativa	24
1.7	Objetivos Gerais e Específicos	25
1.8	Metodologia de Pesquisa	25
1.8.1	Revisão Sistemática da Literatura	26
1.8.2	Definição de Requisitos e Modelagem Conceitual	26
1.8.3	Desenvolvimento e Implementação do <i>Framework</i>	26
1.8.4	Validação Experimental e Análise de Resultados	27
1.9	Contribuições Esperadas	27
1.10	Estrutura da Dissertação	28
2	FUNDAMENTAÇÃO TEÓRICA	29
2.1	Cidades Inteligentes e Edifícios Inteligentes	29
2.2	Tecnologias IoT para Monitoramento Energético	31
2.2.1	IoT e Green IoT	31
2.2.2	Camadas de Rede e Protocolos de Comunicação	32
2.2.3	Medidores Inteligentes e Redes Inteligentes	35
2.3	Aprendizado de Máquina Aplicado a <i>Smart Grids</i>	35
2.4	Engenharia Dirigida por Modelos (MDE)	40
2.5	Arquiteturas de Referência	44
3	ESTADO DA ARTE	46
3.1	Revisão Sistemática da Literatura	46
3.1.1	Metodologia Empregada na Revisão Bibliográfica	46
3.1.2	Objetivos e Questões de Pesquisa	47
3.1.3	Estratégia de Pesquisa	48
3.1.4	Critérios de Seleção	49

3.1.5	Extração de Dados	49
3.1.6	Visão Geral dos Estudos Revisados	50
3.1.7	Informações Principais sobre os Dados	54
3.1.8	Produtividade e Colaboração Geográfica	55
3.1.9	Principais Fontes por Número de Artigos	57
3.1.10	Autoria e Estruturação Temática	57
3.1.11	Extração e Síntese dos Resultados	60
3.2	Trabalhos Relacionados	60
3.2.1	Medição e Aquisição de Dados	61
3.2.2	Fluxos de Trabalho e Protocolos de Comunicação	63
3.2.3	Análise e Inteligência Preditiva	64
3.2.4	Gestão Integrada e Escalabilidade	68
3.2.5	Sustentabilidade e Eficiência Energética	77
3.3	Síntese	78
4	FRAMEWORK PARA SUPORTE AO MONITORAMENTO DE ENERGIA ELÉTRICA E RECURSOS HÍDRICOS EM EDIFÍCIOS E CIDADES INTELIGENTES	81
4.1	Identificação dos Requisitos para Monitoramento de Energia Elétrica e Recurso Hídrico	81
4.2	Modelagem Conceitual do <i>GreenFramework</i>	82
4.2.1	Diagrama de Casos de Uso	82
4.2.2	Diagrama de Classes	85
4.2.3	Diagramas de Sequência	87
4.2.4	Arquitetura de Implantação	89
4.3	Extensão para o <i>GreenMonitoring</i>	91
5	PROTOTIPAGEM DO <i>GREENMONITORING</i>	93
5.1	Arquitetura Geral do Sistema	93
5.2	Camada de <i>Hardware</i>	95
5.2.1	Medidor Telik Trafo para Medição de Energia Elétrica	96
5.2.2	Medição de Água com Sensores de Vazão	100
5.3	Camada de Comunicação	103
5.4	Camada de Persistência de Dados (Banco de Dados)	107
5.5	Camada de API	109
5.6	Cálculo de Emissões de GEE	111
5.7	Camada de Consumo	114
5.7.1	Extensibilidade e Modularidade da Plataforma	114
5.7.2	Aplicação Web <i>GreenMonitoring</i>	114

6	ESTUDO DE CASO: APLICAÇÃO DO <i>GREENMONITORING</i> NA UFMA	126
6.1	Avaliação Experimental	126
6.1.1	Montagem dos QME	128
6.1.2	Instalações dos QME	130
6.1.3	Persistência dos Dados	130
6.1.4	Análise de Padrões de Consumo	130
6.2	Desempenho do <i>GreenMonitoring</i>	134
6.2.1	Escalabilidade e Latência	135
6.2.2	Uso de Recursos Computacionais	135
6.2.3	Métricas de Contêineres	136
6.2.4	Análise de Escalabilidade e Confiabilidade	138
6.3	Análises Sobre as Medidas Elétricas e Reduções de CO ₂	141
6.3.1	Padrões Semanais de Consumo	142
6.3.2	Previsão de Potência Ativa Utilizando Redes <i>LSTM</i>	145
6.4	Comparação com os Trabalhos Existentes (Estado da Arte)	154
7	CONCLUSÃO	158
7.1	Objetivos Alcançados	158
7.2	Contribuições Científicas e Tecnológicas	159
7.3	Limitações do Estudo	159
7.4	Trabalhos Futuros	159
7.5	Publicações Derivadas	160
	REFERÊNCIAS	161

1 Introdução

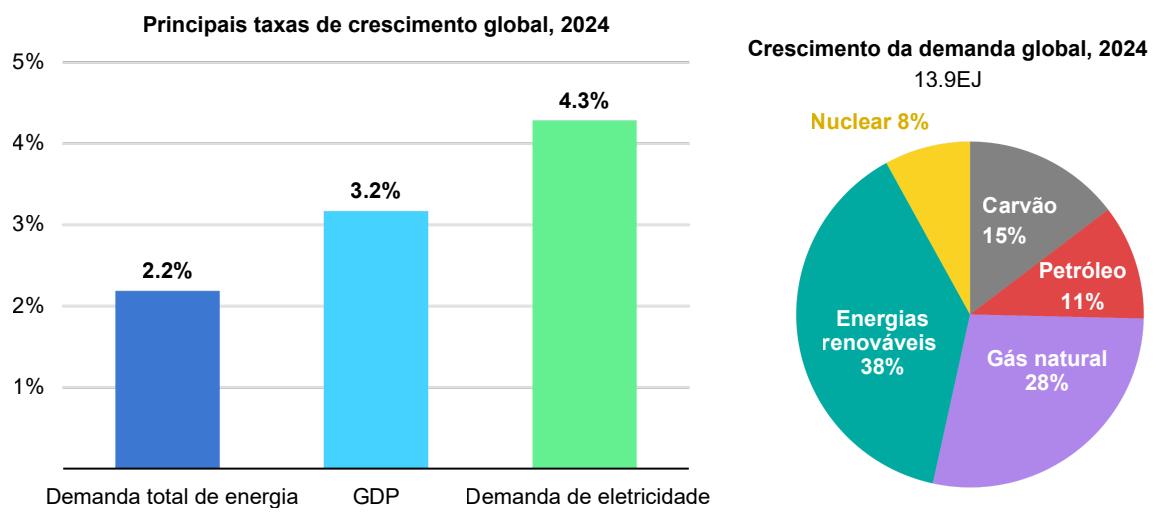
Neste capítulo, os elementos básicos para contextualização, motivação da pesquisa, definição do problema e dos objetivos para o desenvolvimento da solução *GreenMonitoring* são apresentados. As bases conceituais e metodológicas para o desenvolvimento do *framework* de monitoramento inteligente voltado à gestão eficiente de recursos energéticos e hídricos em ambientes institucionais e de cidades inteligentes são estabelecidas.

1.1 Contextualização

O cenário energético global é marcado por uma crise que envolve o crescimento da demanda, a volatilidade de preços e impactos ambientais. Essa crise acelera a transição para fontes renováveis. A demanda global por energia cresceu 2,2% em 2024, conforme detalhado na Figura 1, com o setor elétrico registrando um aumento de 4,3% na demanda por eletricidade. Esse crescimento foi impulsionado por temperaturas recordes, pela eletrificação de transportes e pela expansão de *data centers* (AIE, 2025, p. 5).

Na Figura 1, a participação das fontes no crescimento da demanda energética global em 2024 é ilustrada, destacando o papel das renováveis e dos combustíveis fósseis nessa expansão.

Figura 1 – Participação das fontes no crescimento da demanda energética global em 2024.



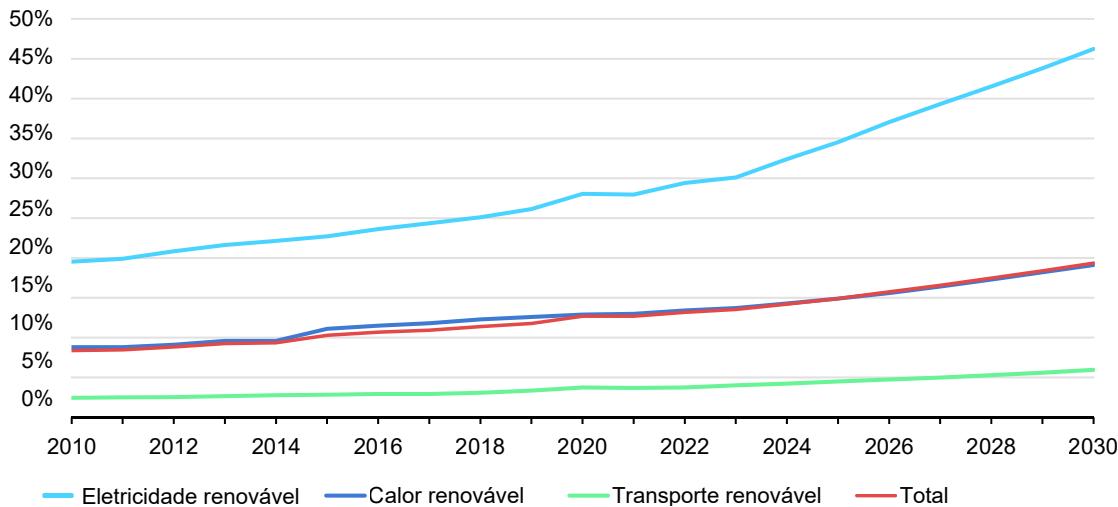
Fonte: Adaptado de (AIE, 2025, p. 8).

As energias renováveis representaram 38% do crescimento na oferta energética, com 80% da expansão na geração elétrica proveniente de fontes de baixa emissão. A energia solar fotovoltaica (do inglês *Photovoltaic*, PV) adicionou 553 GW globalmente,

dos quais 16,5 GW no Brasil, triplicando a expansão de 2023 (AIE, 2025, p. 28-29). Esse cenário reforça a urgência de soluções baseadas em cidades inteligentes, que integram tecnologias como Internet das Coisas (do inglês *Internet of Things*, IoT) para gerenciar picos de consumo e otimizar redes elétricas (AMIN; ERIXNO; RAHIM, 2024; Agência Nacional de Energia Elétrica (ANEEL), 2023).

De acordo com a *International Energy Agency* (IEA), o consumo de energia renovável está projetado para aumentar aproximadamente 60% entre 2024 e 2030, elevando a participação dessas fontes no consumo final de energia de 13% em 2023 para cerca de 20% em 2030 (IEA, 2024). Essa projeção é ilustrada na Figura 2, na qual o aumento da participação da eletricidade renovável para cerca de 40% até 2030 é destacado, evidenciando a necessidade de estratégias multifacetadas para acelerar essa transição.

Figura 2 – Participação da energia renovável no consumo final global de energia por setor, caso principal, 2010-2030.



Fonte: Adaptado de (IEA, 2024).

Apesar do potencial das energias renováveis, o consumo ineficiente de recursos, resultante da urbanização acelerada, gera desafios ambientais significativos. Esse consumo contribui para o aumento das emissões de gases de efeito estufa (GEE), particularmente dióxido de carbono (CO₂) (LEITE; ALVES; PICCHI, 2020; BENVINDO, 2024). O *Greenhouse Gas Protocol* (GHG Protocol), metodologia reconhecida para a quantificação e gestão de emissões, indica que o setor de construção é responsável por aproximadamente um terço das emissões globais de GEE. Nesse contexto, os sistemas de climatização (*Heating, Ventilation and Air Conditioning*, HVAC) emergem como um dos principais vetores de consumo energético (LEITE; ALVES; PICCHI, 2020; JABER; SALEH; ALI, 2019).

Nesse contexto de imperativo global de eficiência energética e mitigação das

mudanças climáticas, a atenção é voltada para os grandes consumidores institucionais, nos quais o desperdício se traduz diretamente em impactos econômicos e ambientais mensuráveis.

A integração de fontes renováveis com sistemas de monitoramento inteligente torna-se imperativa. A meta global da COP28 de triplicar a capacidade renovável até 2030 reforça a necessidade de soluções como o *GreenMonitoring*, que utiliza IoT e *Machine Learning* (ML) para otimizar recursos e promover sustentabilidade em contextos institucionais e urbanos ([International Renewable Energy Agency, 2025](#)). Tais desafios globais, confirmados pela análise bibliométrica (Capítulo 3) que demonstra o auge da pesquisa em 2024.

1.2 Caracterização do Problema

O consumo de energia elétrica é um elemento estratégico para setores como a indústria, o comércio e os serviços públicos. No entanto, o aumento da demanda por energia elétrica sobrecarrega os sistemas existentes. Em alinhamento com os desafios globais de emissões e alta demanda por energia elétrica já estabelecidos (Seção 1.1), o foco é direcionado para os grandes consumidores de energia elétrica institucionais.

1.2.1 Do Contexto Global à Realidade Institucional

O cenário global de alta demanda por energia elétrica e combate as emissões de CO₂ se observa também em instituições públicas e privadas. Por exemplo, as universidades federais, por sua natureza de funcionamento contínuo, grande área física e diversidade de atividades, são grandes consumidoras de recursos como energia elétrica e água ([SANTOS et al., 2024; BROGGIO; SERRA; MATA-LIMA, 2025](#)). Instituições de ponta globalmente, como a Universidade de São Paulo (USP) e o Massachusetts Institute of Technology (MIT), já reconhecem esta questão em suas políticas, com diretrizes específicas para gestão integrada de energia e abertura de dados de consumo, servindo como referência para o setor ([Universidade de São Paulo, 2023; Massachusetts Institute of Technology, 2017; Massachusetts Institute of Technology, 2025](#)). O caso da Universidade Federal do Maranhão (UFMA) é emblemático: em 2023, a instituição registrou gastos de R\$ 11.287.085,95 com energia elétrica e água, equivalente a 10% de seu orçamento. Esse valor corresponde a aproximadamente 2.044 toneladas de CO₂ emitidas, calculadas com base no GHG Protocol considerando o fator de emissão médio da rede elétrica brasileira de cerca de 0,13 kg CO₂/kWh ([UFMA, 2023; UFMA, 2025](#)).

Desperdícios, como iluminação e climatização de salas vazias e equipamentos ligados fora do horário de expediente, intensificam esses custos e o impacto ambiental. A falta de um sistema de monitoramento em tempo real impede a identificação precisa desses

desperdícios e a tomada de decisões embasadas. Iniciativas como os projetos de geração solar fotovoltaica premiados da USP ([Universidade de São Paulo, 2015](#)) e a abordagem de gestão energética da UFMG ([Universidade Federal de Minas Gerais, 2025](#)) evidenciam o movimento em direção à autossuficiência e eficiência, mas também destacam a necessidade contínua de modernização e integração de sistemas de monitoramento, como apontado em análise recente da iluminação do Campus Butantã da USP ([FAJERSZTAJN, 2025](#)).

1.2.2 A Lacuna de Gestão e a Oportunidade Tecnológica

Nesse contexto, surge a necessidade de ferramentas de gestão (*management*) energética acessíveis. Iniciativas como o Programa Nacional de Conservação de Energia Elétrica (PROCEL) e regulamentações da Agência Nacional de Energia Elétrica (ANEEL) incentivam a eficiência, mas a adoção de práticas sustentáveis é limitada pela falta de ferramentas acessíveis ([Programa Nacional de Conservação de Energia Elétrica \(PROCEL\), 2023](#); [Agência Nacional de Energia Elétrica \(ANEEL\), 2023](#)). Soluções comerciais, como sistemas de Controle Supervisório e Aquisição de Dados (do inglês, *Supervisory control and data acquisition - SCADA*), são custosas e complexas, inadequadas para instituições com restrições orçamentárias ([CHÉVEZ; MARTINI, 2024](#)).

É justamente nesta lacuna que este trabalho se insere. Conforme detalhado na Revisão Bibliográfica (Capítulo 3), a carência de sistemas acessíveis e escaláveis para monitoramento em tempo real que integrem IoT, ML e Engenharia Dirigida por Modelos (*Model-Driven Engineering, MDE*) é identificada. Essa integração é crucial para lidar com a complexidade de interoperabilidade em sistemas heterogêneos, tornando viável a coleta e análise unificada de dados. Adicionalmente, há uma necessidade premente de soluções escaláveis que possam ser adaptadas a contextos com restrições orçamentárias, permitindo a expansão sem custos proibitivos.

1.2.3 O Posicionamento da Proposta

A ausência de uma ferramenta própria, de baixo custo e focada em gestão (*management*) na UFMA – realidade comum a diversas instituições públicas do país – justifica a criação desta aplicação. A proposta do *GreenMonitoring* é, portanto, inovadora no contexto da UFMA e de instituições similares, atuando como o elo entre os dados de consumo e a tomada de decisão estratégica. O sistema proposto, validado inicialmente no estudo de caso da UFMA, permitirá não apenas o monitoramento, mas conhecer os padrões de desperdício, alinhando-se às metas de sustentabilidade globais e servindo como uma alternativa viável às soluções comerciais caras, apto a ser implantado em diversos setores.

1.3 Motivação

Diante do aumento global da demanda energética, que cresceu 2.2% em 2024 e continua a se expandir independentemente do tipo de fonte — fóssil ou renovável —, o consumo ineficiente em contextos institucionais e industriais agrava desafios ambientais e econômicos (AIE, 2025). A motivação para este trabalho fundamenta-se na necessidade de abordar esse consumo ineficiente, alinhando-se às metas de sustentabilidade dos Objetivos de Desenvolvimento Sustentável (ODS) 7 e 11. O crescimento de 140% nas vendas de veículos elétricos e a adição de 16,5 GW em nova capacidade solar no Brasil reforçam a relevância de soluções que utilizam tecnologias como IoT e ML para reduzir desperdícios (AIE, 2025, p. 23, 29). A existência de iniciativas de referência, como as da USP e MIT, demonstra a viabilidade e o valor estratégico deste tipo de solução, motivando a criação de uma alternativa de baixo custo e alto impacto.

A implementação da solução propicia a redução de desperdícios, como os observados na UFMA, e promove a transição para uma gestão energética alinhada à norma NBR ISO 50.001/2018 (International Organization for Standardization (ISO), 2018). Adicionalmente, o desenvolvimento de um *framework* de código aberto (*open-source*) e modular aborda explicitamente a lacuna de acessibilidade e custo identificada, oferecendo uma alternativa viável para instituições públicas e outros setores da economia.

1.4 Hipóteses de Pesquisa

Assume-se que as informações manipuladas em aplicações de *Smart Buildings* e ambientes industriais possuem características específicas do domínio dos Sistemas de Energia Elétrica, incluindo: características de equipamentos (transformadores, chaves, linhas), medições (tensão, corrente, frequência), descrição de consumidores e produtores de energia, e representação da topologia da rede elétrica.

Consequentemente, parte-se da premissa que um *framework* baseado em IoT, ML e MDE pode: (i) identificar padrões de consumo energético e hídrico mediante variáveis contextuais; (ii) detectar anomalias para reduzir desperdícios; e (iii) garantir escalabilidade e interoperabilidade em ambientes com restrições, promovendo eficiência e sustentabilidade. Especificamente, postula-se que um *framework* baseado em MDE pode reduzir o consumo energético de edifícios e instalações através de monitoramento em tempo real e detecção de anomalias. Os resultados desta dissertação (Capítulo 6) confirmaram positivamente todas as hipóteses levantadas.

1.5 Solução Proposta

Neste trabalho, o *GreenMonitoring* é proposto como um *framework* baseado em IoT e MDE para monitoramento inteligente de energia e água. O *framework* integra dados desde a coleta, via sensores, até a disponibilização em *Application Programming Interfaces* (APIs).

A arquitetura em camadas e a padronização de dados reduzem erros e agilizam o desenvolvimento, enquanto a MDE abstrai complexidades técnicas, separando a lógica de negócio das especificidades de *hardware* e *software*. O *framework* utiliza o protocolo de enfileiramento de mensagens para telemetria (*Message Queuing Telemetry Transport*, MQTT) — escolhido por sua baixa latência e otimização para ambientes de rede restritos — para transmissão eficiente, e ML — notavelmente modelos de séries temporais como *Long Short-Term Memory* (LSTM), justificados pela necessidade de previsão precisa de carga — para análise preditiva e detecção de anomalias, alinhando-se à norma NBR ISO 50.001/2018 ([International Organization for Standardization \(ISO\)](#), 2018).

Como prova de conceito, o *framework* será implementado e validado em um estudo de caso na UFMA, servindo como base para demonstrar sua aplicabilidade na identificação de padrões de consumo, redução de desperdícios e promoção da sustentabilidade em um ambiente real, com potencial de replicação em outros contextos.

1.6 Justificativa

O desenvolvimento do *GreenMonitoring* justifica-se pela sua relevância social, econômica e científica, abordando diretamente as lacunas identificadas na Revisão Bibliográfica (Capítulo 3) e na Caracterização do Problema (Seção 1.2).

A relevância social reside na contribuição para a sustentabilidade ambiental e o bem-estar coletivo, alinhando-se aos Objetivos de Desenvolvimento Sustentável (ODS) 7 (energia acessível e limpa) e 11 (*smart cities* e comunidades sustentáveis). Em consonância com a dimensão do problema global de emissões de GEE, o *GreenMonitoring*, ao integrar IoT para monitoramento em tempo real e ML para detecção de anomalias, promove a redução no consumo energético (conforme hipótese na Seção 1.4), mitigando impactos ambientais. Ele democratiza o acesso a tecnologias de gestão energética, antes restritas a grandes orçamentos como os de USP e MIT, para um espectro mais amplo de organizações, reduzindo a pegada de carbono e contribuindo para metas globais como o triplo da capacidade renovável até 2030 (COP28) ([International Renewable Energy Agency](#), 2025).

A relevância econômica decorre da otimização de custos operacionais em setores vulneráveis a restrições orçamentárias. O *GreenMonitoring* oferece uma alternativa modular e escalável, superando o custo proibitivo de soluções comerciais, como SCADA,

e complementando iniciativas existentes (como as de UFMG) com uma camada de inteligência acessível. Estudos indicam potencial de economia de 15–30% em consumo energético com monitoramento inteligente ([SHARMA et al., 2025](#)), o que, aplicado à realidade da UFMA, poderia gerar economias anuais superiores a R\$ 2 milhões (equivalentes a cerca de 10% do orçamento registrado em 2023), liberando recursos para outras áreas essenciais. Em escala urbana, industrial ou comercial, a integração com fontes renováveis otimiza as redes e impulsiona a competitividade econômica, alinhando-se à norma NBR ISO 50.001:2018 para gestão energética eficiente ([International Organization for Standardization \(ISO\), 2018](#)).

A relevância científica se manifesta no avanço do conhecimento em engenharia de *software* aplicada à sustentabilidade, preenchendo lacunas na interseção de IoT, ML e MDE, conforme identificado na Revisão Bibliográfica. O *GreenMonitoring* inova ao propor uma arquitetura em camadas com padronização de dados via MDE, protocolo MQTT e modelos LSTM para previsão precisa, validada em caso real (UFMA). Essa contribuição experimental gera *datasets* quantitativos sobre padrões de consumo, fomenta replicabilidade *open-source* e serve como base para pesquisas futuras, enriquecendo o estado da arte em monitoramento inteligente.

1.7 Objetivos Gerais e Específicos

O objetivo geral deste trabalho consiste em desenvolver um *framework* baseado em MDE para monitoramento inteligente de recursos energéticos. Para atingir este objetivo, os seguintes objetivos específicos foram estabelecidos:

1. Identificar as principais abordagens, lacunas e tecnologias utilizadas no estado da arte, por meio de uma revisão sistemática da literatura;
2. Especificar requisitos funcionais e não funcionais que garantam interoperabilidade, escalabilidade e conformidade com padrões internacionais;
3. Desenvolver uma arquitetura modular, integrando coleta de dados via MQTT, persistência e processamento;
4. Validar o *framework* em ambiente real na UFMA, com implantação em sete prédios.

1.8 Metodologia de Pesquisa

Esta pesquisa adotou uma abordagem mista, combinando métodos qualitativos e quantitativos, com ênfase no desenvolvimento aplicado e na validação experimental. A metodologia foi estruturada em etapas sequenciais, alinhadas aos objetivos gerais

e específicos delineados na proposta de dissertação e executados na dissertação final. Baseada na proposta inicial de abril de 2025, que previa o desenvolvimento do *framework GreenMonitoring* como uma solução modular baseada em *IoT* para monitoramento energético na *UFMA*, a execução evoluiu para o *GreenFramework*, incorporando avanços em *MDE*, *ML* e validação em ambiente real. A seguir, descrevem-se as etapas principais, destacando o que foi planejado na proposta e como ocorreu na dissertação.

1.8.1 Revisão Sistemática da Literatura

Na proposta, previa-se uma análise da literatura para identificar lacunas em soluções de monitoramento energético, com foco em *IoT*, protocolos como *MQTT* e algoritmos de *ML* para previsão de consumo e detecção de anomalias. Na dissertação, essa etapa foi executada por meio de uma revisão sistemática da literatura (*RSL*), seguindo diretrizes como as de Kitchenham ([KEELE et al., 2007](#)). Foram definidas questões de pesquisa, como “Quais tecnologias de *IoT* são usadas em monitoramento energético?” e critérios de inclusão/exclusão. Bases de dados como *Scopus*, *IEEE Xplore* e *Web of Science* foram consultadas, resultando na seleção de 56 estudos primários. A análise bibliométrica identificou tendências, como o predomínio de sensores não invasivos e modelos *LSTM* para previsão, confirmando lacunas em soluções acessíveis para instituições públicas com infraestrutura heterogênea.

1.8.2 Definição de Requisitos e Modelagem Conceitual

A proposta enfatizava a formulação do problema, investigando estratégias para superar barreiras de interoperabilidade e escalabilidade em sistemas com dados limitados. Na dissertação, os requisitos funcionais e não funcionais foram definidos com base na *RSL* e no contexto da *UFMA*. Utilizando *MDE*, foram criados diagramas *UML*, como de classes, sequências e implantação, para modelar o *GreenFramework*. Essa etapa garantiu modularidade, permitindo a extensão para variáveis como água e emissões de *GEE*, alinhado à norma *NBR ISO 50.001/2018*.

1.8.3 Desenvolvimento e Implementação do *Framework*

Planejado na proposta como uma prova de conceito na *UFMA*, integrando sensores *Telik Trafo*, *MQTT* e *ML*, o desenvolvimento na dissertação ocorreu em camadas: *hardware* (sensores para medição de potência ativa, reativa e aparente, além de sensores de pulso para aquisição de consumo hídrico, nos quais o volume e o fluxo de água são calculados por meio do pulso e do tempo), comunicação (*MQTT* para transmissão), persistência (banco de dados *PostgreSQL*), *API* (*RESTful* para integração) e consumo (aplicação *web* com *dashboards*). O *framework* foi implementado em código aberto, utilizando *Python*

para *ML* (modelos *LSTM* e *Random Forest*) e *Docker* para conteinerização, promovendo escalabilidade. A modularidade do Quadro de Medição de Energia (QME) e da arquitetura *backend* foi projetada para garantir a escalabilidade de *hardware*: a aplicação suporta a conexão e integração de dados de qualquer tipo de sensor que utilize comunicação via *MQTT* ou *API RESTful* para envio de dados. A extensão para *GreenMonitoring* incluiu cálculo de emissões de *GEE* e previsão de consumo, com adaptações para infraestrutura legada.

1.8.4 Validação Experimental e Análise de Resultados

A proposta buscava investigar adaptações de técnicas preditivas para ambientes com dados escassos, promovendo eficiência energética. Na dissertação, a validação ocorreu por meio de experimentos na *UFMA*: A instalação dos 6 Quadros de Medição de Energia (QMEs) foi realizada pela própria equipe do grupo de pesquisa. A coleta de dados total abrangeu um período de 12 meses (2025); no entanto, devido à instalação escalonada dos medidores em alguns prédios, para fins de comparação na previsão e análise, decidiu-se utilizar somente os dados referentes aos últimos 6 meses de aquisição. A análise de padrões semanais identificou reduções potenciais de 15–30% em desperdícios. Métricas como *MAE* e *RMSE* validaram os modelos *LSTM* para previsão de potência ativa total, com comparação ao estado da arte. Testes de escalabilidade avaliaram o uso de recursos computacionais, confirmando a robustez do *framework*. Os resultados subsidiaram políticas institucionais, alinhando-se aos *ODS* 7 e 11.

Essa metodologia permitiu uma transição do planejamento conceitual para a execução prática, resultando em um *framework* modular e escalável, com contribuições para a gestão de recursos em cidades inteligentes.

1.9 Contribuições Esperadas

Contribuições para a área de engenharia de *software* aplicada à sustentabilidade são oferecidas neste trabalho. Um dos principais aportes é a proposição e implementação de um *framework* de código aberto voltado para o monitoramento de recursos. Essa iniciativa promove a replicabilidade e a adaptação da solução em diferentes contextos, permitindo que desenvolvedores e instituições personalizem o *framework* conforme suas necessidades específicas, fomentando a disseminação de práticas sustentáveis por meio de tecnologia acessível.

Além disso, o estudo valida, de forma experimental, a aplicação prática de conceitos de MDE no domínio da IoT e da eficiência energética. Por meio dessa abordagem, é demonstrado como a abstração proporcionada por modelos pode simplificar o processo

de desenvolvimento e facilitar a integração de sistemas complexos, reduzindo a curva de aprendizado e otimizando a implementação de soluções tecnológicas voltadas para a sustentabilidade.

Outro aspecto relevante é a geração de análises quantitativas e de um conjunto de *datasets* relacionados aos padrões de consumo em ambientes institucionais. Esses resultados oferecem uma base sólida para futuras pesquisas, permitindo que outros estudos explorem e ampliem o conhecimento sobre o uso eficiente de recursos em contextos semelhantes, contribuindo para o avanço científico na área.

Por fim, uma solução de baixo custo, projetada para ser adotada por instituições públicas, é disponibilizada publicamente neste trabalho. Essa solução visa não apenas reduzir os gastos operacionais, mas também minimizar o impacto ambiental, alinhando-se aos objetivos de sustentabilidade. Com isso, espera-se que a iniciativa sirva como um modelo prático e escalável para organizações que buscam otimizar seus recursos e adotar práticas mais responsáveis em relação ao meio ambiente.

1.10 Estrutura da Dissertação

Esta dissertação está organizada em seis capítulos, que acompanham o fluxo da metodologia, desde a identificação da lacuna (Capítulos 2-3) até a validação da solução (Capítulo 6):

- **Capítulo 2 – Fundamentação Teórica:** Conceitos de IoT, ML, MDE e eficiência energética são explorados;
- **Capítulo 3 – Estado da Arte:** A bibliometria e os métodos da análise sistemática são apresentados. Além disso, analisa tecnologias e estudos sobre IoT, ML, MDE e monitoramento energético, conectando-os às lacunas que o *GreenMonitoring* se propõe a resolver;
- **Capítulo 4 – Projeto e Arquitetura:** A arquitetura do *GreenMonitoring* é descrita;
- **Capítulo 5 – Implementação:** A aplicação prática dos requisitos no *framework* é apresentada;
- **Capítulo 6 – Resultados:** Os resultados da implementação e validação são expostos;
- **Capítulo 7 – Conclusão:** Os achados, contribuições e sugestões para trabalhos futuros são sintetizados.

2 Fundamentação Teórica

Neste capítulo, os conceitos teóricos fundamentais que sustentam o desenvolvimento do *framework GreenMonitoring* são apresentados. Os pilares tecnológicos e metodológicos essenciais para a compreensão da arquitetura proposta são abordados, incluindo conceitos de cidades inteligentes, tecnologias IoT, aprendizado de máquina, engenharia dirigida por modelos, eficiência energética e gestão de recursos hídricos. Essa fundamentação estabelece a base teórica necessária para contextualizar as decisões de projeto e de implementação detalhadas nos capítulos subsequentes.

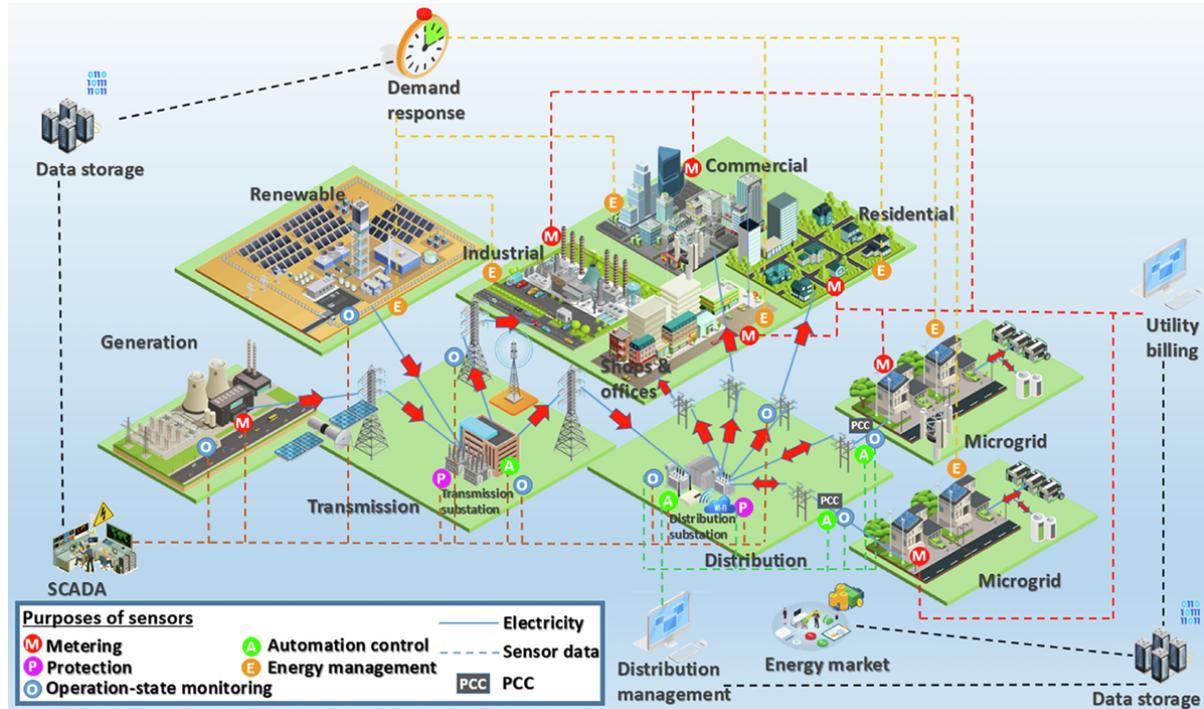
2.1 Cidades Inteligentes e Edifícios Inteligentes

Cidades inteligentes (do inglês *smart cities*) são definidas como ambientes urbanos nos quais tecnologias digitais e de comunicação são utilizadas para otimizar a gestão de recursos, melhorar a qualidade de vida e promover a sustentabilidade. Edifícios inteligentes (do inglês *smart buildings*) representam unidades básicas nesse ecossistema, integrando sistemas automatizados para gerenciar energia, água e outros recursos de forma eficiente ([BOIANI et al., 2021; MOREIRA; MACKE, 2023](#)).

Os componentes essenciais desses ecossistemas incluem a IoT para coleta de dados em tempo real, *big data* para armazenamento e processamento de grandes volumes de informação, e *analytics* para extração de *insights*. Na aplicação específica em eficiência energética, esses componentes possibilitam, em geral, a implementação de redes elétricas inteligentes (do inglês *smart grids*) que equilibram oferta e demanda de energia elétrica, integrando fontes renováveis e otimizando a distribuição de energia elétrica ([AHMAD et al., 2022](#)).

Aplicações específicas em eficiência energética envolvem monitoramento de consumo, detecção de desperdícios e otimização de sistemas, como em redes elétricas integradas. Na Figura 3, a integração de sistemas de sensoriamento em redes elétricas de cidades e edifícios inteligentes é ilustrada, destacando-se os pontos de medição em subestações e transformadores, os dispositivos de proteção e a comunicação com sensores IoT. Essa integração contribui, possivelmente, para a redução de perdas e a promoção de sustentabilidade, ao permitir ajustes dinâmicos baseados em dados coletados ([PONG et al., 2021](#)).

Figura 3 – Sensoriamento da rede elétrica em cidades e edifícios inteligentes: integração de sistemas para gestão de recursos.



Fonte: Adaptado de PONG et al.(2021).

O sensoriamento é considerado o núcleo para o monitoramento de energia, abrangendo a coleta de dados de Medição (M), Proteção (P), Automação e Controle (A), Gerenciamento de Energia (E) e Monitoramento do Estado de Operação (O) em toda a infraestrutura elétrica. Esses pontos de sensoriamento estão distribuídos desde a Geração (convencional e renovável), passando pela Transmissão (Subestações de Transmissão) e Distribuição (Subestações de Distribuição e linhas urbanas), até os pontos de Consumo (setores Residencial, Comercial e Industrial) (PONG et al., 2021).

Os dados coletados são então integrados a uma camada de comunicação, sendo direcionados a sistemas de SCADA e a Bases de Dados (*Data Storage*). Essa central de informação e controle viabiliza funções avançadas, como o Faturamento (*Utility billing*), o Gerenciamento de Distribuição (*Distribution management*) e a otimização do Mercado de Energia (*Energy market*). Crucialmente, a integração da informação permite a coordenação das Microrredes (*Microgrids*), conectadas à rede principal por meio de Pontos de Acoplamento Comum (PCC), e a implementação de mecanismos de Resposta à Demanda (*Demand response*), que atuam sobre as cargas dos consumidores.

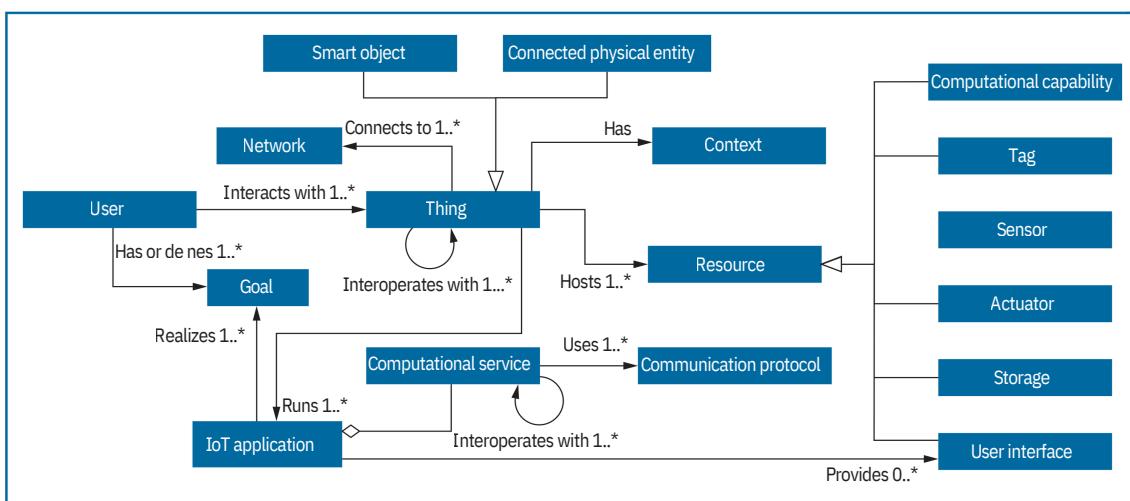
2.2 Tecnologias IoT para Monitoramento Energético

Cidades inteligentes utilizam tecnologias IoT como atuadores, automações de controle, medidores inteligentes e proteções para gerenciar recursos de forma eficiente. Dados de sensores são enviados para bases de dados, visualizados e controlados em sistemas SCADA, permitindo previsão de demanda, e resposta à demanda com base em dados históricos (PONG et al., 2021). A seguir, as tecnologias que sustentam esse ecossistema são detalhadas.

2.2.1 IoT e Green IoT

A IoT interconecta dispositivos físicos com sensores, *software* e conectividade, permitindo a coleta, transmissão e processamento de dados (MARINAKIS; DOUKAS, 2018). No contexto de sistemas IoT, um modelo conceitual é frequentemente utilizado para estruturar e visualizar suas entidades fundamentais e inter-relações (CICCOZZI et al., 2017). Na Figura 4, esse modelo conceitual é ilustrado. Conceitos-chave, como a *Thing*, que pode ser uma *Smart object* ou uma *Connected physical entity*, são apresentados.

Figura 4 – Modelo conceitual de sistemas IoT de missão crítica (MC-IoT).



Fonte: (CICCOZZI et al., 2017).

A *Thing* interage com o Usuário e outros dispositivos, possuindo um Contexto e hospedando um ou mais Recursos. Os Recursos podem ser Sensores, Atuadores, capacidade computacional, armazenamento ou interfaces de usuário. O sistema é orientado por um Objetivo definido pelo Usuário, que é alcançado por meio de uma Aplicação IoT que executa um ou mais Serviços Computacionais. Estes serviços exploram Protocolos de comunicação e interagem com os recursos das Coisas através de uma Rede.

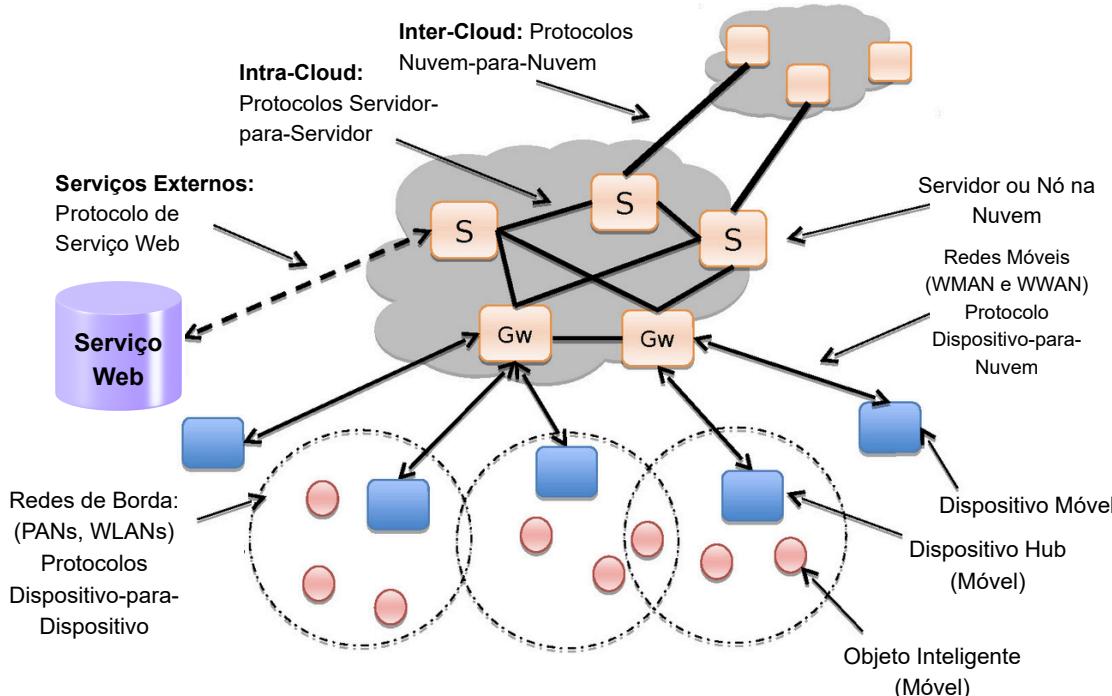
Conforme descrito por CICCOZZI et al. (2017), os sistemas MC-IoT são caracterizados por aplicações que exigem, em geral, alta disponibilidade, confiabilidade, segurança e conformidade regulatória, além de escalabilidade e adaptabilidade em ambientes heterogêneos.

O conceito de Green IoT amplia a IoT ao priorizar soluções de baixo consumo energético e impacto ambiental reduzido, alinhando-se aos ODS (POYYAMOZHI et al., 2024). Sensores de baixo custo e arquiteturas otimizadas reduzem o consumo energético, enquanto desafios como segurança de dados e interoperabilidade demandam *frameworks* modulares (POYYAMOZHI et al., 2024; ALFALOUJI et al., 2022).

2.2.2 Camadas de Rede e Protocolos de Comunicação

A comunicação em IoT segue camadas: aplicação, transporte, rede, *enlace* e física (KUROSE; ROSS, 2010). Arquiteturas de redes de sensores para monitoramento energético organizam-se em camadas: borda, nuvem e inter-nuvem, viabilizando comunicação (*Machine-to-Machine*) e processamento de fluxos de dados (BATISTA et al., 2016). Na Figura 5, as camadas são apresentadas, destacando a integração de dispositivos heterogêneos para escalabilidade. Tal arquitetura justifica a adoção de protocolos de comunicação no *GreenMonitoring*, como MQTT, por suportarem infraestruturas variadas com baixo *overhead* (BATISTA et al., 2016).

Figura 5 – Camadas de rede para IoT.

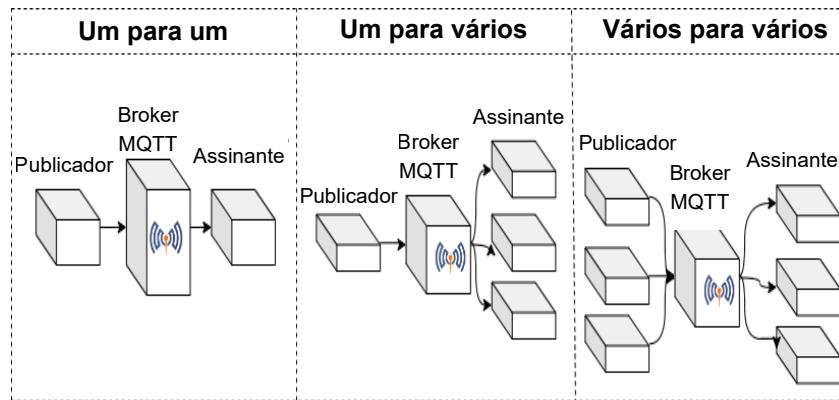


Fonte: (BATISTA et al., 2016).

O primeiro nível é a Rede de Borda, onde Objetos Inteligentes (sensores, atuadores) se comunicam em nível Dispositivo-para-Dispositivo. O segundo nível envolve a conexão entre os dispositivos e a Nuvem (*Cloud*) por meio dos *Gateways* (Gw) ou Dispositivos Hub, utilizando Redes Móveis e o protocolo Dispositivo-para-Nuvem. O terceiro nível se estabelece na Nuvem, onde os Servidores (S) se comunicam entre si (protocolo Servidor-para-Servidor ou *Intra-Cloud*) e com outros serviços externos (*Inter-Cloud*), como um Serviço *Web* (protocolo de Serviço *Web*), demonstrando a escalabilidade e a interoperabilidade necessárias para a gestão de cidades inteligentes (BATISTA et al., 2016).

Protocolos de comunicação incluem o MQTT, baseado em publicar/inscrever, eficiente para redes de baixa largura de banda (ALFALOUJI et al., 2022; CUNHA; BATISTA, 2022). Na Figura 6, o fluxo MQTT é ilustrado, com o *broker* intermediando mensagens. Essa configuração reduz o *overhead* e suporta dispositivos com restrições de recursos (JUTADHAMAKORN et al., 2017).

Figura 6 – Fluxo de dados MQTT.



Fonte: Baseado em JUTADHAMAKORN et al.(2017).

Três modelos de comunicação são apresentados: Um para um; Um para vários; e Vários para vários. Em todos os casos, o elemento central é o *Broker MQTT*, responsável por receber as mensagens do Publicador e entregá-las aos Assinantes que demonstraram interesse no tópico. O modelo *publisher/subscriber* desacopla o envio da recepção, otimizando o consumo de banda e recursos, sendo ideal para o sensoriamento de redes elétricas.

O protocolo de transferência de hipertexto (do inglês *HyperText Transfer Protocol*, HTTP) suporta *APIs RESTful* para acesso síncrono, conforme a Tabela 1, na qual operações CRUD (*Create, Read, Update e Delete*) para gerenciamento de recursos como medidores são detalhadas (KUROSE; ROSS, 2010). O protocolo de aplicação restrita (do inglês *Constrained Application Protocol*, CoAP), baseado em UDP (*User Datagram Protocol*), é leve para dispositivos restritos, permitindo monitoramento energético em

ambientes de baixa potência com métodos como GET e POST (WAQAS; HUMPHRIES, 2024).

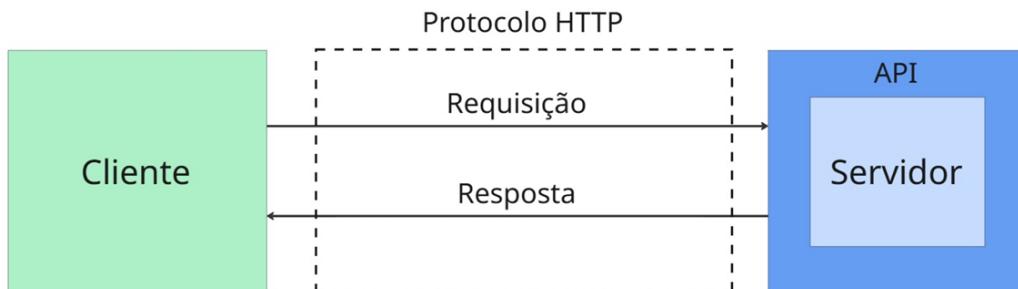
Tabela 1 – Operações CRUD em API RESTful.

Operação	URL	Ação
POST	/medidores	Criar novo medidor
GET	/medidores	Listar todos os medidores
GET	/medidores/{id}	Mostrar medidor específico
PUT	/medidores/{id}	Atualizar medidor específico
DELETE	/medidores/{id}	Apagar medidor específico
PUT	/medidores	Atualizar coleção (operação rara)
DELETE	/medidores	Apagar coleção (operação rara)

Na Tabela 1, a correspondência entre os métodos HTTP e as operações básicas de persistência de dados em uma interface RESTful é apresentada. Esta padronização é essencial para a criação de APIs (*Application Programming Interfaces*) que permitem o gerenciamento programático de recursos, como a criação (POST), leitura (GET), atualização (PUT) e remoção (DELETE) de registros de medidores elétricos no sistema.

Na Figura 7, o fluxo de comunicação entre cliente e servidor usando protocolo HTTP é ilustrado, destacando a estrutura de requisições e respostas.

Figura 7 – Comunicação entre cliente e servidor usando protocolo HTTP.



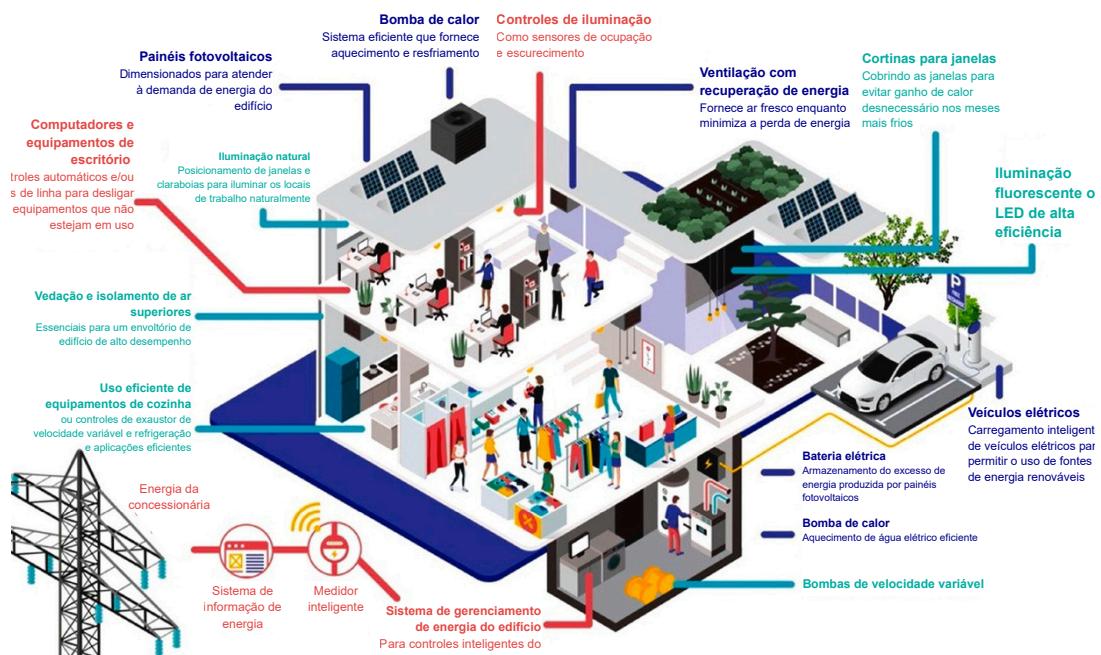
Fonte: Adaptado de SOUZA et al.(2025).

A Figura 7 ilustra o fluxo de comunicação cliente e servidor por meio do protocolo HTTP. O cliente inicia a interação enviando uma requisição HTTP contendo o método, a URL do recurso e, quando necessário, cabeçalhos e corpo da mensagem. O servidor processa a requisição por intermédio da API, executa a operação solicitada e retorna uma resposta contendo o código de *status* HTTP (por exemplo, 200 OK, 201 Created, 404 Not Found), cabeçalhos e, se aplicável, os dados solicitados ou atualizados. Esse padrão request-response é a base do gerenciamento programático de recursos em arquiteturas RESTful, conforme as operações CRUD apresentadas na Tabela 1.

2.2.3 Medidores Inteligentes e Redes Inteligentes

Medidores inteligentes convertem medições em dados digitais para monitoramento de energia elétrica, água e gás ([Agência Nacional de Energia Elétrica \(ANEEL\), 2021](#)). As técnicas para avaliação de desempenho energético são ilustradas na Figura 8, na qual medidores gerenciando fluxos são destacados. Essa representação enfatiza a integração de medidores inteligentes para análise de consumo e otimização em edifícios ([AHMAD et al., 2022](#)).

Figura 8 – Técnicas para avaliação do desempenho energético de edifícios ativos, com ênfase em medidores inteligentes e fluxos de energia.



Fonte: Adaptado de ([AHMAD et al., 2022](#)).

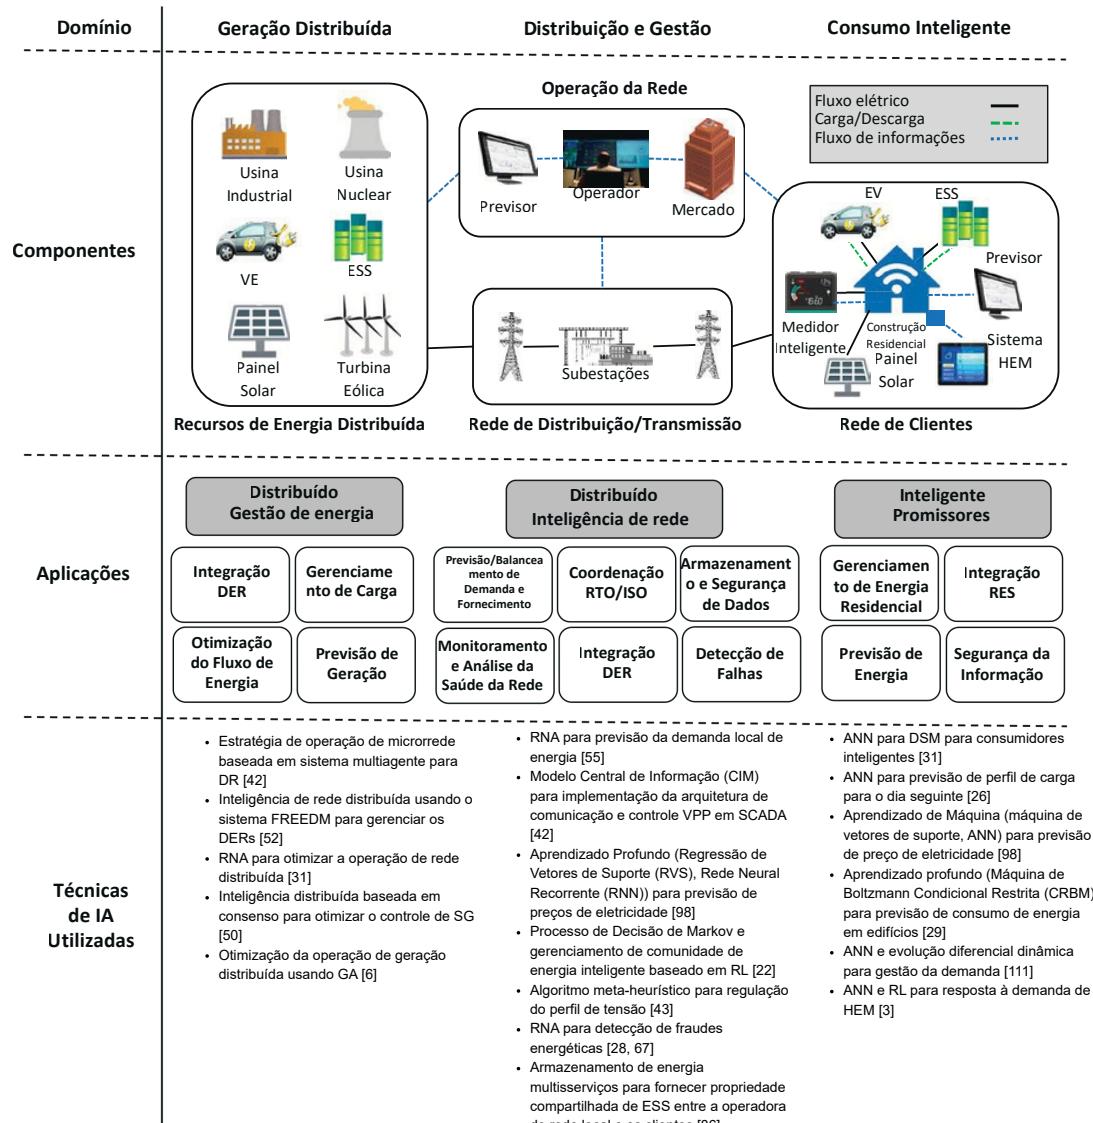
Smart grids integram tecnologias de IoT para a análise de dados em tempo real, promovendo, em geral, o uso racional de energia elétrica e o suporte à geração distribuída de energia elétrica ([POYYAMOZHI et al., 2024](#)). A medição precisa de energia elétrica é fundamental para essa gestão.

2.3 Aprendizado de Máquina Aplicado a *Smart Grids*

O ML compreende técnicas computacionais que permitem a sistemas aprenderem padrões a partir de dados sem programação explícita. Na gestão energética, essas técnicas são aplicadas para previsão de consumo, detecção de anomalias e otimização de sistemas ([AHMAD et al., 2022](#)).

A otimização de sistemas energéticos aplica ML para balancear cargas e prever demandas, integrando técnicas como aprendizado por reforço (do inglês *Reinforcement Learning*) para minimizar custos e emissões (ALI; CHOI, 2020). Na Figura 9, algumas técnicas de inteligência artificial em redes inteligentes são apresentadas, destacando aplicações em previsão e otimização distribuída (ALI; CHOI, 2020).

Figura 9 – Visão geral das técnicas de inteligência artificial em redes inteligentes distribuídas.



Fonte: Adaptado de (ALI; CHOI, 2020).

Técnicas de previsão de consumo utilizam séries temporais e redes neurais recorrentes (do inglês *Recurrent Neural Networks*, RNN), que processam dados sequenciais atualizando estados ocultos com base em entradas atuais e estados anteriores (DIAS, 2023). A

arquitetura das RNN atualiza o estado oculto h_t conforme:

$$h_t = \sigma(W_h \cdot h_{t-1} + W_x \cdot x_t + b_h) \quad (2.1)$$

$$y_t = \phi(W_y \cdot h_t + b_y) \quad (2.2)$$

Na Equação 2.1, que define a atualização do estado oculto, e na Equação 2.2, que define a saída no instante t , as variáveis representam:

- x_t : Vetor de entrada no instante de tempo t ;
- h_t : Estado oculto (ou estado de memória) calculado no instante t ;
- h_{t-1} : Estado oculto do instante de tempo anterior ($t - 1$), servindo como a memória da rede;
- y_t : Vetor de saída no instante t (por exemplo, a previsão de consumo);
- W_x : Matriz de pesos que conecta a entrada x_t à camada oculta;
- W_h : Matriz de pesos que conecta o estado oculto anterior h_{t-1} ao estado oculto atual h_t (conexão recorrente);
- W_y : Matriz de pesos que conecta o estado oculto h_t à camada de saída;
- b_h : Vetor de viés (bias) da camada oculta;
- b_y : Vetor de viés (bias) da camada de saída;
- σ : Função de ativação não linear (frequentemente a sigmoide ou tanh), aplicada à camada oculta;
- ϕ : Função de ativação da camada de saída (pode ser linear, sigmoide ou softmax).

As RNN são eficientes para previsões de curto prazo, mas enfrentam problemas de desvanecimento do gradiente ou explosão do gradiente, limitando sua capacidade em dependências de longo prazo (WAQAS; HUMPHRIES, 2024).

Para superar essas limitações, as redes de memória de longo curto prazo (do inglês *Long Short-Term Memory*, LSTM), uma variante avançada das RNN, foram desenvolvidas. As LSTM introduzem uma célula de memória (c_t) e um sistema de portas (*gates*) que regulam explicitamente o fluxo de informação, permitindo a retenção seletiva de dados por longos períodos (WAQAS; HUMPHRIES, 2024).

Cada célula LSTM contém três portas principais, que atuam como filtros, conforme ilustrado na Figura 10 e descrito pelas Equações (2.3) a (2.8):

1. **Porta de Esquecimento (*forget gate*, f_t):** Decide qual informação do estado da célula anterior (c_{t-1}) deve ser descartada ou mantida;
2. **Porta de Entrada (*input gate*, i_t):** Determina qual nova informação da entrada atual (x_t) é relevante e deve ser armazenada na célula;
3. **Porta de Saída (*output gate*, o_t):** Controla qual porção do estado da célula será utilizada para calcular o estado oculto (h_t) e ser transmitida como a saída da célula no instante t .

Segundo NGUYEN et al.(2021), a operação matemática da célula LSTM pode ser descrita pelas seguintes equações:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (2.3)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (2.4)$$

$$g_t = \tanh(W_g \cdot [h_{t-1}, x_t] + b_g), \quad (2.5)$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes g_t, \quad (2.6)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (2.7)$$

$$h_t = o_t \otimes \tanh(c_t), \quad (2.8)$$

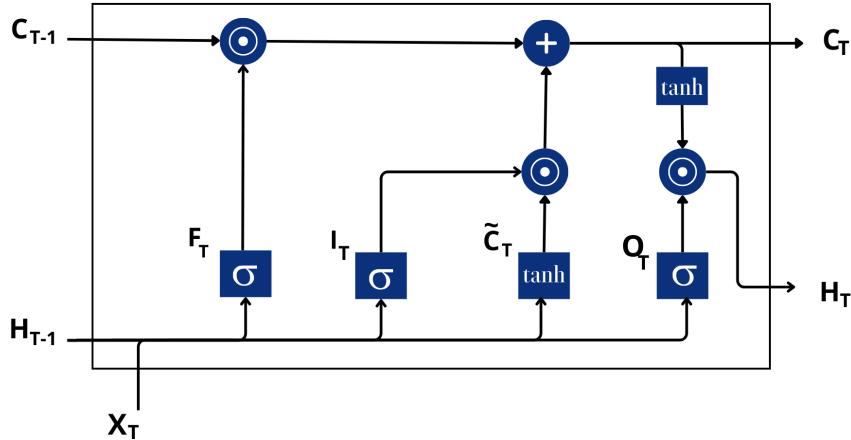
sendo:

- x_t : Vetor de entrada no instante t ;
- h_t : Estado oculto (saída da célula) no instante t ;
- c_t : Estado da célula (memória de longo prazo) no instante t ;
- f_t, i_t, o_t : Vetores das portas de Esquecimento, Entrada e Saída, respectivamente;
- g_t (ou \tilde{C}_t): Candidato a novo estado da célula, gerado pela função \tanh ;
- W e b : Matrizes de pesos e vetores de viés (bias) para cada porta;
- σ : Função de ativação sigmoide, que restringe os valores das portas entre 0 e 1;
- \tanh : Função de tangente hiperbólica, usada para normalizar os valores;
- $[h_{t-1}, x_t]$: Representa a concatenação do estado oculto anterior e da entrada atual;
- \otimes : Representa a operação de multiplicação elemento-por-elemento.

Essa estrutura garante que a LSTM mantenha informações relevantes por longos períodos, sendo ideal para séries temporais complexas em energia elétrica e monitoramento

hídrico (MALEKI; MALEKI; JENNINGS, 2021; NGUYEN et al., 2021). Na Figura 10, o fluxo de informação dentro da célula é ilustrado, destacando a interação das portas no controle da memória.

Figura 10 – Estrutura do LSTM.



Fonte: Adaptado de SHANG et al.(2019).

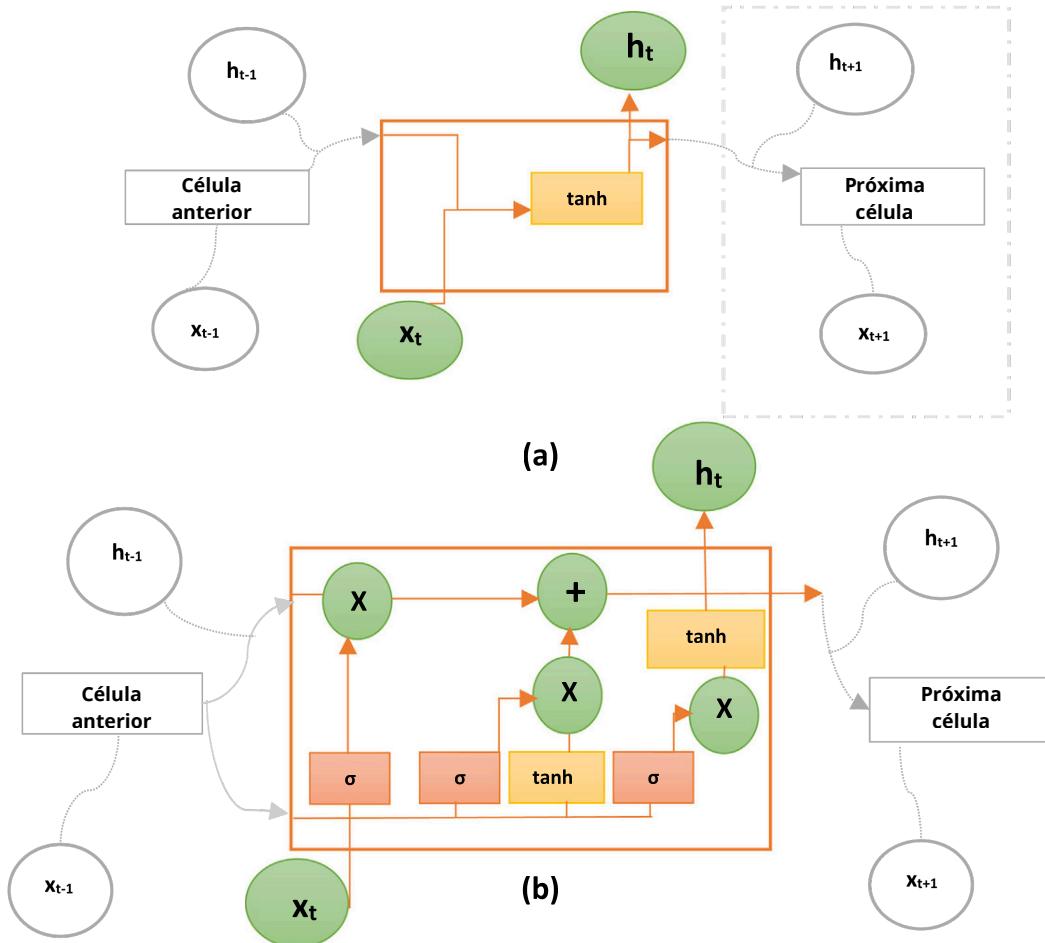
As LSTM demonstram grande eficácia na previsão de picos de consumo elétrico com base em séries temporais de dados e fatores contextuais, como temperatura, capturando padrões sazonais e diários (TARIQ et al., 2024). Em aplicações hidrológicas, as LSTM superam as RNN, com melhorias significativas em previsões de níveis de água, devido à sua capacidade de modelar dependências temporais complexas (WAQAS; HUMPHRIES, 2024).

Na Figura 11, a diferença estrutural entre RNN e LSTM é ilustrada, destacando a memória curta das RNN (setas simples) e a memória longa das LSTM viabilizada pelas portas de controle.

Na Figura 11, a comparação das estruturas básicas de processamento sequencial é apresentada. O diagrama (a) representa uma célula de uma Rede Neural Recorrente (RNN) padrão. Nessa arquitetura, o estado oculto anterior (h_{t-1}) e a entrada atual (x_t) são combinados, passando por uma única função de ativação (tanh) para produzir o estado oculto atual (h_t). Essa estrutura simples é responsável pela propagação de gradientes que leva ao problema do desvanecimento do gradiente, limitando a capacidade da RNN de modelar dependências temporais longas.

Em contraste, o diagrama (b) ilustra a arquitetura interna da célula LSTM, que opera com quatro camadas interativas. A LSTM recebe o estado oculto anterior (h_{t-1}) e a entrada atual (x_t), mas utiliza portas reguladoras (representadas pelas caixas com σ - função sigmoide) e operações de ponto de multiplicação (\times) e soma (+) para controlar o fluxo de informação. Essa complexidade adicional, que inclui funções de

Figura 11 – Comparação entre RNN e LSTM: (a) RNN contém uma única camada, e (b) LSTM contém quatro camadas interagindo.



Fonte: ([WAQAS; HUMPHRIES, 2024](#)).

ativação tanh e a presença de três portas (entrada, esquecimento e saída), permite que a LSTM mantenha uma memória de longo prazo (estado da célula) ao longo das iterações, resolvendo o problema do desvanecimento do gradiente. Essa diferença estrutural enfatiza, possivelmente, a capacidade da LSTM de lidar com sequências longas e dependências complexas, essenciais para a previsão energética.

2.4 Engenharia Dirigida por Modelos (MDE)

A MDE é uma abordagem para o desenvolvimento de *software*, posicionando os modelos como artefatos no centro de todo o processo. Essa abordagem eleva o nível de abstração, permitindo automações nas transformações ao longo do ciclo de vida do sistema, o que resulta em ganhos de produtividade, portabilidade, interoperabilidade e manutenção ([CORTELLESSA et al., 2022](#)). Ao desconectar a lógica de negócios das peculiaridades técnicas das plataformas, a MDE se mostra especialmente adequada para

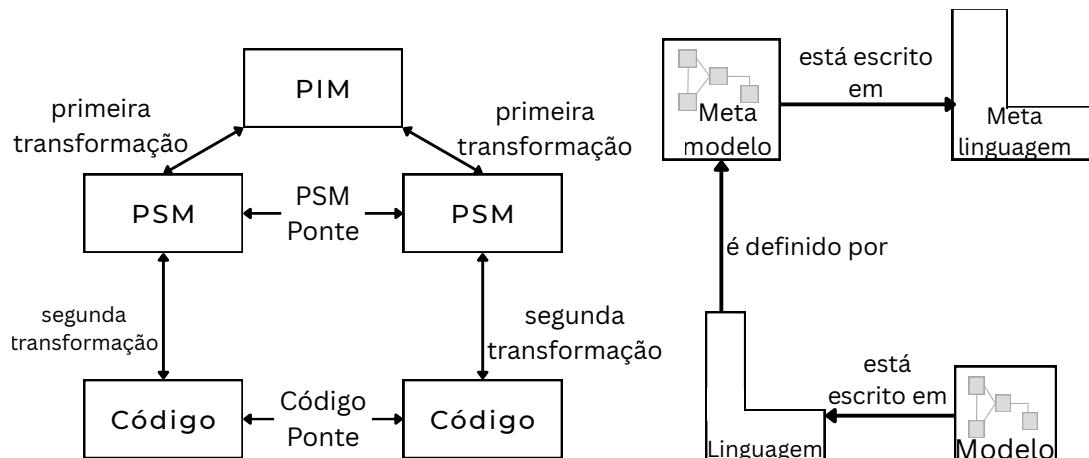
ambientes complexos, como os de *smart cities* e IoT, nos quais a diversidade de dispositivos, protocolos e fontes de dados exige uma coordenação precisa e eficiente (BERNARDINO; GIBERTONI, 2024).

Essa perspectiva ganha forma concreta por meio da *Model-Driven Architecture* (MDA), lançada pelo *Object Management Group* (OMG) em 2001 e adotada como alicerce para seus padrões subsequentes (Object Management Group, 2025; BERNARDINO; GIBERTONI, 2024). A MDA surge em resposta aos dilemas enfrentados por líderes de TI, como a integração de sistemas legados a novas plataformas, ao mesmo tempo em que preserva investimentos na lógica essencial dos negócios, mesmo diante da rápida evolução tecnológica. Um modelo, aqui, representa uma especificação formal da função, estrutura ou comportamento de uma aplicação ou sistema (DANIEL; CABOT, 2024).

O processo típico da MDA começa com a análise e especificação do sistema em um *Computation Independent Model* (CIM), que se concentra no ambiente e nos requisitos. Esse modelo evolui para um *Platform Independent Model* (PIM), que incorpora as informações computacionais da aplicação, mas ignora particularidades da tecnologia subjacente. Finalmente, o PIM é transformado em um *Platform Specific Model* (PSM), que integra descrições e elementos adaptados à plataforma-alvo (de Araújo Silva et al., 2021). Essa distinção clara entre o “o quê” do sistema — capturado no PIM — e o “como” — delineado no PSM — facilita transformações automatizadas. Um único PIM pode gerar implementações em múltiplas plataformas sem intervenções manuais, garantindo durabilidade e estabilidade ao modelo de alto nível (de Araújo Silva et al., 2021; SOMMA et al., 2025).

Como ilustrado na Figura 12, esse fluxo não apenas fomenta a portabilidade, mas também a interoperabilidade e o reuso.

Figura 12 – Relação entre modelo, metamodelo e interoperabilidade na MDA



Fonte: Adaptado de KLEPPE; WARMER; BAST(2003).

A portabilidade decorre da independência dos modelos de alto nível em relação aos detalhes técnicos inferiores; assim, alterações na plataforma subjacente não demandam reescrita dos modelos superiores, que podem ser adaptados diretamente à nova infraestrutura.

A interoperabilidade, por outro lado, atende à demanda recorrente de que aplicações se comuniquem em contextos heterogêneos e distribuídos ([SOMMA et al., 2025](#); [IHIRWE et al., 2024](#)). Na MDA, isso se materializa via mapeamentos horizontais de modelos e interações, onde conexões em níveis superiores são refinadas em canais de comunicação ou bancos de dados compartilhados entre plataformas específicas. Tal refinamento pode ser interpretado como a maturação de um modelo único de alto nível em múltiplos modelos operacionais, assegurando interações coesas entre sistemas, mesmo sob controle limitado sobre elementos externos.

O reuso, por sua vez, desponta como elemento pivotal para impulsionar a produtividade e a qualidade, incentivando a formação de famílias de aplicações, análogas a linhas de produção de *software*. Modelos e práticas consolidadas são reaplicados, particularmente em domínios específicos, minimizando esforços de desenvolvimento e reduzindo erros.

A base formal para definir metamodelos é provida pelo *Meta Object Facility* (MOF) 2.5.1 ([Object Management Group, 2016](#)), um padrão da OMG ancorado em um subconjunto simplificado do diagrama de classes do UML 2. O MOF delinea o *Essential MOF* (EMOF), um núcleo minimalista para metamodelos leves, e o *Complete MOF* (CMOF), uma variante mais robusta com capacidades de reflexão, pacotes e restrições em OCL. Ele também integra o XMI para serialização de modelos e metamodelos, além de identificadores únicos, tags genéricas e operações reflexivas aplicáveis a qualquer metamodelo.

Embora a MDA possa ser praticada sem ferramentas sofisticadas, seu emprego é importante para maximizar vantagens como produtividade e qualidade. Essas ferramentas são concebidas para criar, interpretar, comparar, alinhar, medir, verificar e transformar modelos ou metamodelos, categorizadas em criação (para modelos iniciais ou edições derivadas), análise (para checagem de completude e inconsistências), transformação (para conversão em código ou documentação), composição, teste, simulação, gerenciamento de metadados e engenharia reversa.

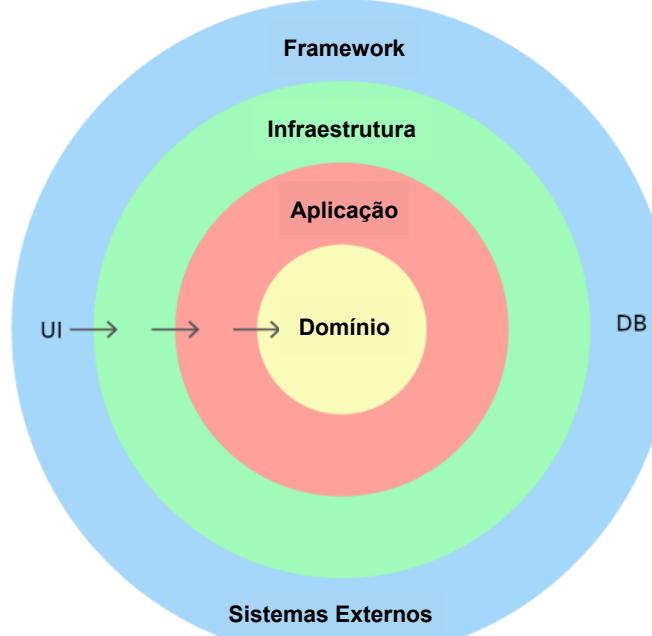
No âmbito da arquitetura de *software*, a MDA consegue se alinhar, uma vez que a maioria de seus modelos reflete visões arquiteturais. Modelos de domínio e de sistema atuam como abstrações que capturam perspectivas variadas da arquitetura, enquanto ferramentas de geração de código incorporam detalhes de implementação. A UML, estendida por perfis, funciona como linguagem de descrição de arquitetura (ADL) na MDA. Além disso, a abordagem acomoda requisitos não funcionais, como desempenho, reuso, interoperabilidade e segurança, ao embuti-los nos modelos, estender a UML para

representá-los e aplicar regras de mapeamento nas transformações.

A MDE posiciona modelos como elementos centrais no desenvolvimento de *software*, facilitando abstração, reutilização e integração em sistemas complexos como os baseados em IoT e aprendizado de máquina (SOMMA et al., 2025; NAVeed et al., 2024; MOIN, 2021). Modelos independentes de plataforma são transformados em modelos específicos, utilizando ferramentas como o Eclipse Modeling Framework (EMF), para gerenciar heterogeneidade e escalabilidade (CORTELLESSA et al., 2022; MOIN, 2021).

O *Domain-Driven Design* (DDD) complementa a MDE ao dividir a arquitetura em camadas: domínio, aplicação, infraestrutura e interface de usuário. Na Figura 13, essa divisão é ilustrada, onde a camada de domínio encapsula a lógica de negócios, como entidades de medição energética, independentes de tecnologias externas; a camada de aplicação coordena fluxos de dados; a camada de infraestrutura gerencia bancos de dados e comunicação; e a camada de interface apresenta informações via painéis web. Essa estrutura promove modularidade e adaptação a contextos institucionais (P; H, 2023).

Figura 13 – Camadas da Arquitetura do Domain-Driven Design.



Fonte: Adaptado de (P; H, 2023).

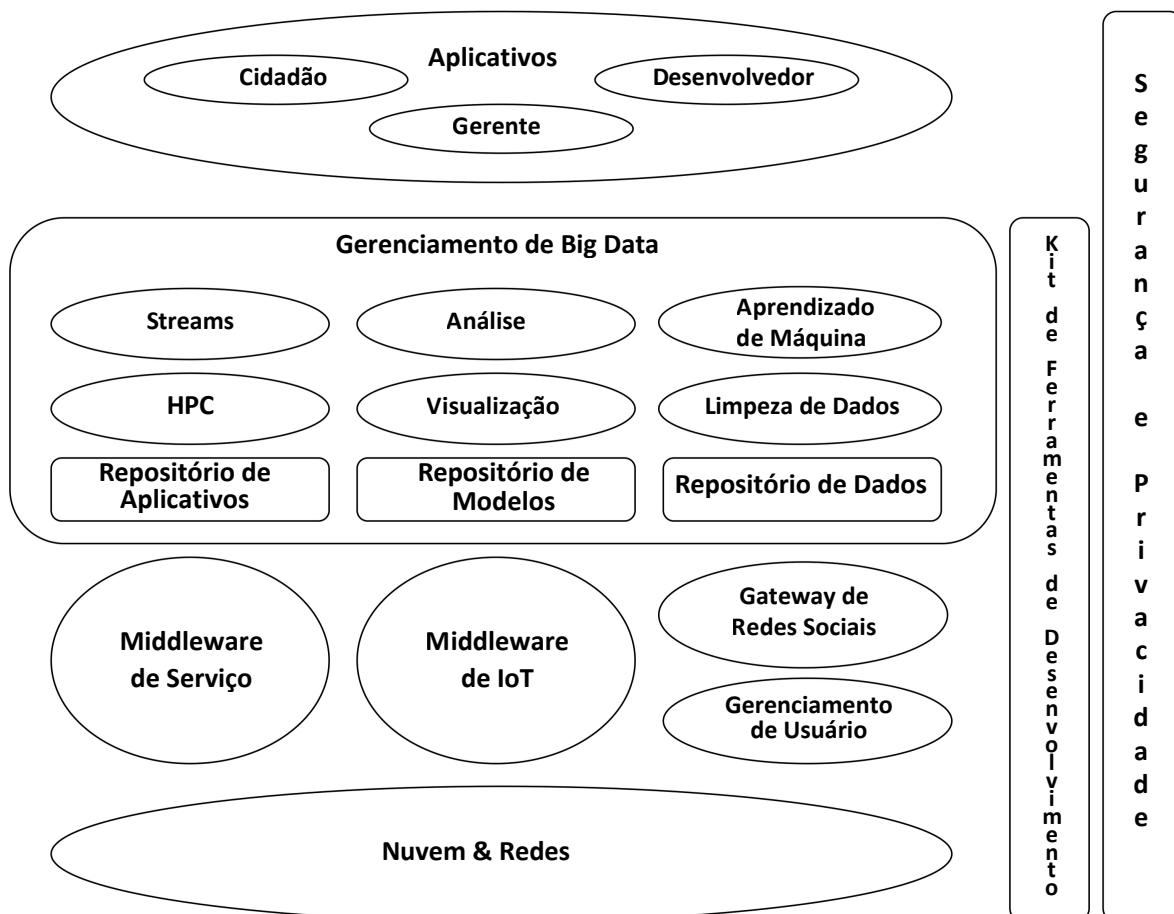
Na Figura 13, a arquitetura do DDD é apresentada como um conjunto de círculos concêntricos, destacando a separação de responsabilidades para promover a coesão e a independência. O núcleo é o Domínio, que contém as regras de negócio essenciais e as entidades de medição e gerenciamento energético. Ao redor do Domínio, encontra-se a camada de Aplicação, que coordena as tarefas e fluxos. A camada de Infraestrutura lida com detalhes técnicos, como persistência de dados e comunicação com sistemas

externos. Por fim, o anel externo representa o *Framework* de suporte. A camada mais externa interage com a Interface do Usuário e Sistemas Externos, garantindo que as dependências fluam sempre do exterior para o interior, protegendo o Domínio contra alterações tecnológicas externas.

2.5 Arquiteturas de Referência

As arquiteturas de referência para cidades inteligentes fornecem padrões e melhores práticas para o desenvolvimento de soluções escaláveis e interoperáveis. A plataforma *InterSCity* representa uma dessas referências, oferecendo uma infraestrutura de *middleware* baseada em microsserviços para integração de dispositivos IoT e desenvolvimento de aplicações urbanas (ESPOSTE et al., 2017). Na Figura 14, essa arquitetura é ilustrada, destacando camadas para gerenciamento de dados e integração urbana (BATISTA et al., 2016).

Figura 14 – Arquitetura de Referência para Plataformas de Cidades Inteligentes.



Fonte: (BATISTA et al., 2016).

Na Figura 14, uma arquitetura de referência em quatro camadas principais é ilustrada. A base é a camada de Nuvem e Redes, responsável pela infraestrutura de comunicação subjacente. Acima, o *Middleware* atua como o motor de integração, dividindo-se em *Middleware* de IoT (para gerenciar a heterogeneidade dos dispositivos) e *Middleware* de Serviço (para expor funcionalidades), além de incluir *gateway* de Redes Sociais e Gerenciamento de Usuário. A camada central é o Gerenciamento de *Big Data*, que hospeda serviços como *Streams*, Análise, Aprendizado de Máquina, Visualização, Limpeza de Dados e repositórios para Aplicativos, Modelos e Dados. No topo, a camada de Aplicativos é acessada por diferentes *stakeholders* (Cidadão, Desenvolvedor e Gerente). Toda a arquitetura é envolta por elementos de Segurança e Privacidade, Kit de Ferramentas e Desenvolvimento, essenciais para a sustentabilidade da plataforma.

Frameworks de monitoramento energético, como FIWARE e CitySDK, suportam integração de dados para otimização. Padrões de integração de sistemas heterogêneos incluem IEEE 2030.5 para comunicação em redes inteligentes e ontologias IEC (*International Electrotechnical Commission*) para interoperabilidade ([MOIN, 2021](#)).

A gestão eficiente de recursos hídricos em *smart cities* e edifícios inteligentes é tão crucial quanto a gestão energética, alinhando-se diretamente aos ODS 6 (Água Limpa e Saneamento). O principal desafio no setor público e institucional é o alto índice de perdas por vazamentos e o *Non-Revenue Water* (água que é produzida e fornecida, mas não gera receita), que pode atingir volumes significativos em grandes campi universitários ou edifícios antigos.

O monitoramento hídrico inteligente utiliza sensores de vazão e pressão acoplados à rede IoT para coletar dados em tempo real, gerando um perfil de consumo detalhado. A análise desses perfis permite a detecção de vazamentos, que se manifestam como padrões de consumo anormais (por exemplo, vazão constante durante períodos de inatividade, como madrugadas ou feriados).

Este capítulo estabeleceu os pilares teóricos que sustentam o desenvolvimento do *framework GreenMonitoring*, abordando desde os conceitos de cidades e edifícios inteligentes até os detalhes tecnológicos de IoT, redes elétricas, aprendizado de máquina e engenharia dirigida por modelos. O próximo capítulo, Estado da Arte, avança nesta discussão ao realizar uma análise sistemática da literatura, com o objetivo de mapear como essas tecnologias têm sido efetivamente integradas, identificar as lacunas existentes nas soluções atuais e, assim, posicionar de forma precisa a contribuição do *GreenMonitoring* no cenário científico e tecnológico.

3 Estado da Arte

Neste capítulo, o estado da arte em sistemas de monitoramento de energia elétrica e hídrico será apresentado com ênfase em contextos institucionais como universidades. A análise fundamenta-se em uma revisão sistemática da literatura (Seção 3.1) que mapeou as principais abordagens tecnológicas, protocolos, sensores IoT e técnicas de aprendizado de máquina entre 2020 e 2025. A partir dos resultados sistematizados, apresenta-se uma discussão crítica dos trabalhos relacionados (Seção 3.2), organizada segundo as cinco questões de pesquisa (QP1–QP5), culminando em uma síntese comparativa que posiciona a contribuição original deste trabalho — o *framework GreenMonitoring*.

3.1 Revisão Sistemática da Literatura

A metodologia da revisão sistemática conduzida para mapear o estado da arte segue as diretrizes de Kitchenham e Charters ([KEELE et al., 2007](#)), garantindo rigor científico, reproduzibilidade e minimização de vieses. O objetivo é identificar abordagens tecnológicas consolidadas, protocolos de comunicação, sensores IoT e técnicas de aprendizado de máquina, com foco na interseção entre Internet das Coisas, gestão de recursos e escalabilidade urbana. A análise diagnóstica lacunas de pesquisa que fundamentam o desenvolvimento do *framework GreenMonitoring*, alinhado aos princípios de engenharia de *software* baseada em evidências.

A estrutura organiza-se em quatro eixos: (i) protocolo metodológico; (ii) objetivos e questões de pesquisa; (iii) estratégia de busca, análise bibliométrica e critérios de seleção; (iv) amostragem, extração e síntese dos resultados.

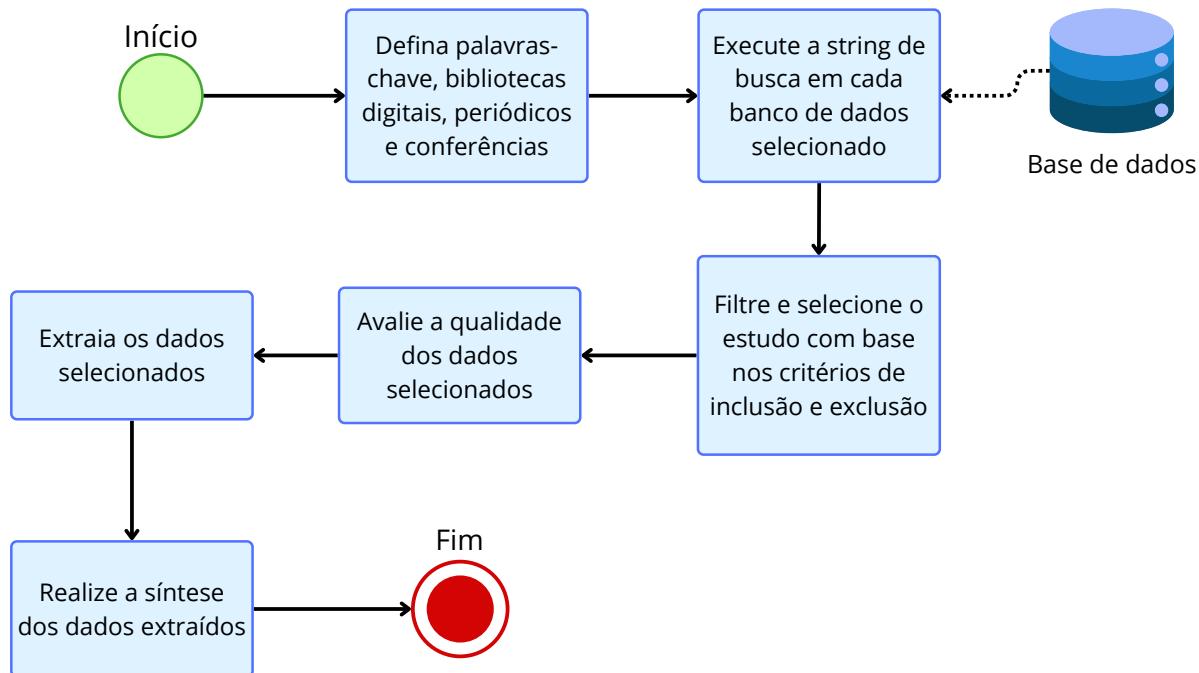
3.1.1 Metodologia Empregada na Revisão Bibliográfica

Para garantir o rigor científico, a reproduzibilidade e a minimização de vieses na coleta e análise da literatura, esta revisão sistemática da literatura segue as diretrizes do protocolo estabelecido por Kitchenham e Charters para a condução de revisões sistemáticas em engenharia de *software* ([KEELE et al., 2007](#)). O protocolo estrutura o processo em etapas sequenciais, que abrangem o planejamento, execução e análise de resultados.

Na Figura 15, o fluxo metodológico adaptado do protocolo de Kitchenham é ilustrado, destacando as etapas essenciais adotadas nesta pesquisa. O processo inicia-se com a definição das palavras-chave e a identificação das fontes de pesquisa, como bibliotecas digitais, periódicos e conferências. Em seguida, a *string* de busca é executada

nas bases de dados selecionadas. Os resultados são submetidos a filtro e seleção de estudos, com base em critérios de inclusão e exclusão preestabelecidos.

Figura 15 – Fluxo metodológico da Revisão Sistemática da Literatura.



Fonte: Adaptado de ([KEELE et al., 2007](#)).

3.1.2 Objetivos e Questões de Pesquisa

O objetivo principal sugere-se como mapear soluções tecnológicas para monitoramento e gestão de recursos energéticos e hídricos em cidades inteligentes, com ênfase nos pilares do *GreenMonitoring*: Internet das Coisas, aprendizado de máquina e escalabilidade.

Para guiar a busca, extração e análise, cinco **questões de pesquisa (QP)** operacionais foram definidas:

- **(QP1)** Quais são as principais fontes de dados e sensores IoT utilizados no monitoramento de recursos energéticos e hídricos em cidades inteligentes?

Justificativa: Identificar dispositivos viáveis para integração em infraestruturas heterogêneas, como campi universitários, viabilizando a coleta de dados contextuais em tempo real no *GreenMonitoring*;

- **(QP2)** Qual é o fluxo de trabalho típico para coleta, transmissão e análise de dados usando protocolos como MQTT em sistemas distribuídos?

Justificativa: Mapear arquiteturas de comunicação leves e escaláveis, fundamentais para definir a camada de integração de dados do *GreenMonitoring* em ambientes urbanos e institucionais;

- **(QP3)** Quais técnicas de aprendizado de máquina são aplicadas para previsão de consumo e detecção de anomalias em dados energéticos e hídricos?

Justificativa: Fundamentar a seleção de algoritmos preditivos com alta acurácia e baixo custo computacional, essenciais para promover eficiência energética no *framework*;

- **(QP4)** Como computação em nuvem e contêineres (*Docker*) contribuem para a escalabilidade e disponibilidade de sistemas de monitoramento?

Justificativa: Avaliar soluções de implantação de baixo custo e alta disponibilidade, adequadas a instituições públicas com restrições orçamentárias;

- **(QP5)** Como as soluções existentes impactam a escalabilidade, sustentabilidade e eficiência energética em contextos urbanos?

Justificativa: Mapear limitações das abordagens atuais para justificar a proposição de um *framework* modular, acessível e baseado em engenharia dirigida por modelos.

3.1.3 Estratégia de Pesquisa

A estratégia de pesquisa foi delineada para garantir uma recuperação abrangente e direcionada da literatura. A busca por artigos foi feita ao longo dos últimos 18 (dezoito) meses e atualizada pela última vez em 28 de outubro de 2025 nas bases de dados científicas de alto impacto, incluindo IEEE Xplore¹, ScienceDirect², Scopus³ e Web of Science⁴ abrangendo o período de 2020 a 2025 para focar nos avanços mais recentes. A *string* foi construída com base em dois conjuntos de termos, conforme apresentado na Tabela 2.

Tabela 2 – Conjuntos de palavras-chave usados na *string* de busca.

Conjunto	Palavras-chave e sinônimos
A — Monitoramento	energy monitoring, energy management system, BEMS, smart meter, water monitoring, smart water grid, campus energy
B — IoT	internet of things, IoT, sensor network
C — Contexto Urbano	smart city, smart campus, smart building, sustainable city, university campus

Na Tabela 2, os conjuntos de palavras-chave e sinônimos utilizados na construção da *string* de busca são detalhados. O Conjunto A abrange termos relacionados ao monitoramento de energia e água; o Conjunto B refere-se à IoT; e o Conjunto C contextualiza o ambiente urbano e institucional. Essa estrutura possibilita, em geral, uma busca abrangente e focada.

¹ <<https://ieeexplore.ieee.org/Xplore/home.jsp>>

² <<https://www.sciencedirect.com/>>

³ <<https://www.scopus.com/home.uri>>

⁴ <<https://www.webofscience.com/wos/>>

A *string* final, validada com artigos de controle na Scopus, foi aplicada uniformemente:

String de Busca

```
(("energy monitoring" OR "energy management system" OR "BEMS" OR  
"smart meter") AND ("internet of things" OR "IoT") AND ("smart  
buildings" OR "smart campus" OR "smart city")) AND (2020:2025)
```

Essa *string* de busca, apresentada no quadro acima, combina os conjuntos de termos com operadores lógicos para refinar os resultados, limitando o período de publicação entre 2020 e 2025.

3.1.4 Critérios de Seleção

Os critérios de inclusão e exclusão, apresentados na Tabela 3, foram aplicados por dois pesquisadores de forma independente, com triagem inicial por título e resumo, seguida de leitura completa.

Tabela 3 – Critérios de inclusão (IC) e exclusão (EC).

Inclusão	Exclusão
(IC1) Uso de sensores IoT para monitoramento em tempo real.	(EC1) Ausência de coleta de dados em tempo real.
(IC2) Aplicação de aprendizado de máquina.	(EC2) Sem estudo de caso ou aplicação prática.
(IC3) Abordagem de escalabilidade com nuvem ou contêineres.	(EC3) Foco exclusivo em indústria ou residências.
(IC4) Artigo completo em inglês (2020–2025).	(EC4) Literatura cinza, revisões, teses.

Na Tabela 3, os critérios de inclusão (IC) e exclusão (EC) são detalhados. Os critérios IC1 a IC4 garantem a relevância tecnológica, temporal e linguística dos estudos, enquanto os EC1 a EC4 eliminam trabalhos irrelevantes ou inadequados para a análise sistemática.

3.1.5 Extração de Dados

A extração seguiu formulário padronizado, conforme apresentado na Tabela 4, estruturado para responder às QPs.

Tabela 4 – Itens do formulário de extração de dados.

ID	Informação extraída
I1	Referência (autores, ano)
I2	Objetivo e resultados principais
I3	Sensores e fontes de dados
I4	Protocolos de comunicação
I5	Técnicas de aprendizado de máquina
I6	Uso de nuvem e contêineres
I7	Estudo de caso e escala
I8	Limitações identificadas

Na Tabela 4, os itens do formulário de extração de dados são listados. Cada ID (I1 a I8) corresponde a informações específicas extraídas dos estudos primários, permitindo uma síntese estruturada e alinhada às questões de pesquisa.

3.1.6 Visão Geral dos Estudos Revisados

A análise dos estudos primários selecionados possibilita caracterizar o panorama atual do monitoramento energético e hídrico com IoT. Esta seção apresenta os resultados do processo de seleção, a distribuição dos estudos por tipo de recurso monitorado, os sensores mais utilizados e as técnicas de aprendizado de máquina predominantes.

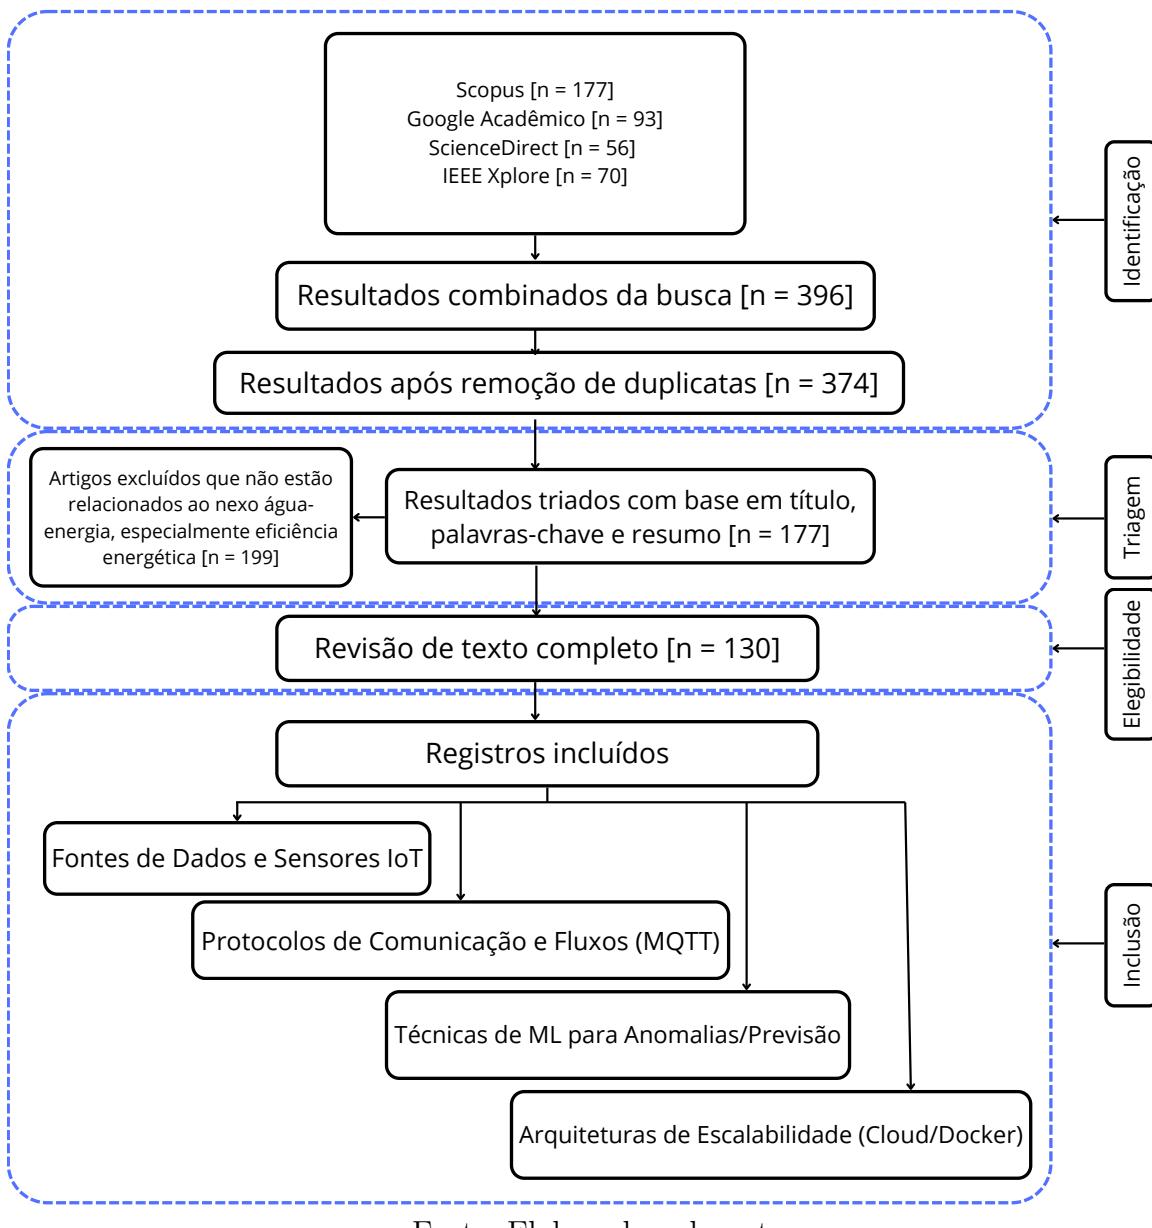
Os documentos selecionados foram submetidos a um processo de amostragem complementar (conglomerados e estratificada) para garantir representatividade da literatura e evitar vieses de fontes ou temas, seguido pela triagem baseada no fluxo metodológico PRISMA (do inglês *Preferred Reporting Items for Systematic Reviews and Meta-Analyses*).

O fluxo de seleção seguiu o protocolo PRISMA, conforme ilustrado na Figura 16. Foram identificados 395 registros nas bases de dados. Após remoção de duplicatas, 374 documentos foram triados por título e resumo, resultando em 177 candidatos. A leitura completa levou à inclusão de 130 estudos primários.

Na Figura 16, o diagrama PRISMA do fluxo de seleção de estudos é apresentado, detalhando as etapas de identificação, triagem, elegibilidade e inclusão. Esse fluxo garante transparência e reproduzibilidade no processo de seleção.

Para realizar a análise bibliométrica na revisão de literatura, uma abordagem sistemática e progressiva de buscas na base de dados Scopus foi adotada, utilizando *strings* de pesquisa refinadas para identificar publicações relevantes ao tema de sistemas de gerenciamento de energia em edifícios inteligentes, com ênfase em plataformas de monitoramento e visualização em tempo real. Essa análise possibilitou mapear a evolução temporal das publicações, as áreas de conhecimento predominantes e o afunilamento dos resultados para focar em estudos mais específicos e recentes.

Figura 16 – Diagrama PRISMA do fluxo de seleção de estudos.



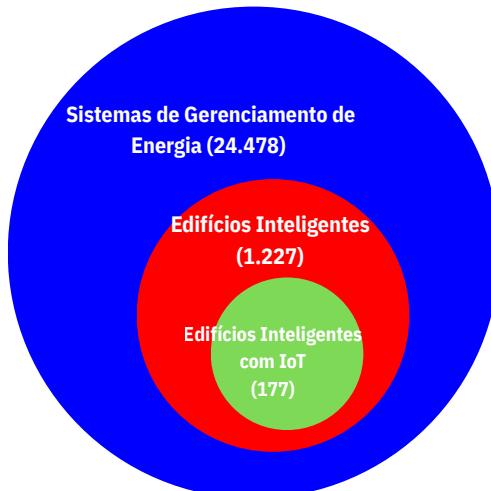
Fonte: Elaborado pelo autor.

O processo foi estruturado em etapas sequenciais, inspirado em um diagrama de Venn, onde três conjuntos conceituais principais foram interseccionados: (1) termos relacionados a sistemas de gerenciamento de energia; (2) contexto de aplicação em edifícios e campi inteligentes; e (3) IoT. A seguir, cada etapa é descrita detalhadamente, incluindo as *strings* de busca utilizadas, os resultados quantitativos, as tendências observadas e as distribuições percentuais por áreas temáticas.

Na Figura 17, o processo hierárquico de filtragem é ilustrado. Embora o diagrama de Venn seja representativo e não em escala, a progressiva afunilação da pesquisa é evidenciada: partindo de um conjunto vasto de publicações sobre gerenciamento de energia (Conjunto 1), a busca é restringida a sistemas aplicados em edifícios inteligentes (Conjunto

2) e, finalmente, focada nas soluções que incorporam a IoT (Conjunto 3), resultando em 177 documentos específicos e relevantes para a tese. Por meio da interseção dos conjuntos, o afunilamento que concentra os resultados em estudos pertinentes ao tema é destacado.

Figura 17 – Diagrama de Venn ilustrando a relação hierárquica entre os conjuntos de busca, representando a interseção dos três conjuntos após a aplicação dos filtros.

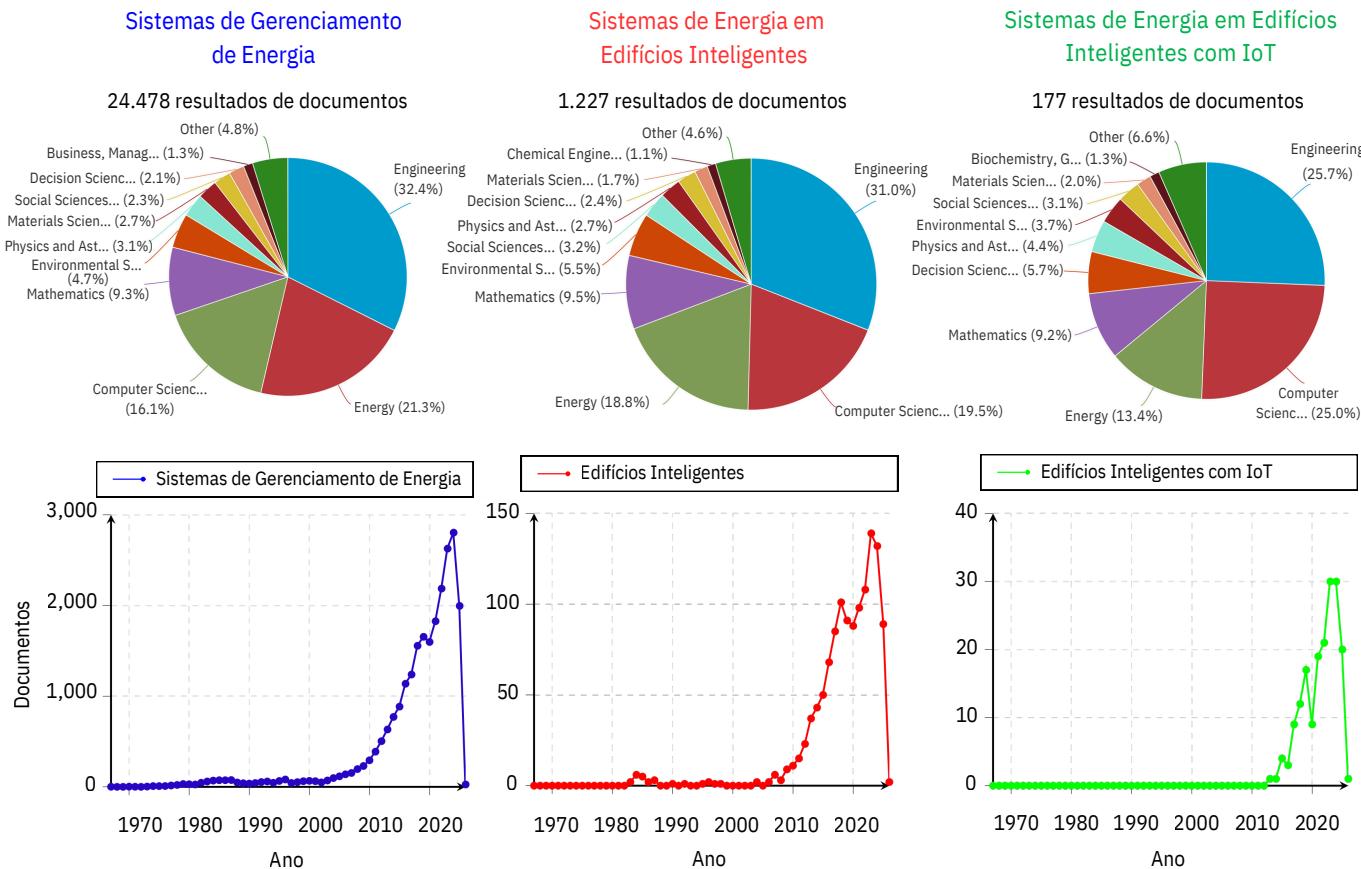


Fonte: Elaborado pelo autor.

O Diagrama de Venn, apresentado na Figura 17, demonstra a relação de inclusão e o volume de documentos retornados em cada etapa da pesquisa. O conjunto mais abrangente é o de Sistemas de Gerenciamento de Energia, que totalizou 24.478 documentos. Dentro desse conjunto, o subconjunto Edifícios Inteligentes refinou os resultados para 1.227 documentos. Por fim, o subconjunto mais específico, Edifícios Inteligentes com IoT, resultou em 177 documentos. Essa representação hierárquica valida a estratégia de pesquisa, demonstrando o afunilamento bem-sucedido de uma ampla área de estudo para um tópico de nicho específico e contemporâneo.

Na Figura 18, a distribuição temporal dos documentos para os três conjuntos de busca é apresentada. Na subfigura (a), um aumento constante nas publicações de sistemas de gerenciamento de energia desde o início dos anos 2000 é observado, com pico de 2.804 documentos em 2024. Na subfigura (b), a menor contagem de documentos para sistemas de energia em edifícios inteligentes é destacada, com pico de 139 documentos em 2023, emergindo principalmente após 1983. Na subfigura (c), a natureza específica de sistemas de energia em edifícios inteligentes com IoT é refletida, com pico de 30 documentos em 2023 e 2024, e publicações a partir de 2013.

Figura 18 – Distribuição percentual por área de conhecimento (gráficos de pizza superiores) e número de documentos por ano (gráficos de linha inferiores) para os três conjuntos de busca: (a) Sistemas de Gerenciamento de Energia; (b) Edifícios Inteligentes; (c) Edifícios Inteligentes com IoT.



Fonte: Elaborado pelo autor.

O crescimento constante no número de publicações nos três conjuntos, especialmente no período recente (2020-2024), sinaliza, possivelmente, a emergência e a relevância do monitoramento energético baseado em IoT para edifícios e cidades inteligentes. O pico de 30 documentos em 2023/2024 no conjunto mais específico confirma que o tema está no auge da pesquisa, justificando a urgência e a atualidade deste trabalho.

A análise da Figura 18 revela tendências cruciais. A porção superior da figura exibe a distribuição por área temática, onde a predominância da área de Engenharia em todos os conjuntos é observada (32,4% no Conjunto 1, 31,0% no Conjunto 2, e 25,7% no Conjunto 3), seguida pela área de Energia e Ciência da Computação. No conjunto mais específico (Edifícios Inteligentes com IoT), a Ciência da Computação se destaca com 25,0%, quase igualando a Engenharia, o que sublinha a natureza tecnológica e de *software* do tema.

A porção inferior da Figura 18 detalha a evolução temporal. No conjunto mais amplo (Sistemas de Gerenciamento de Energia), o crescimento é robusto, com publicações ultrapassando 2.000 por ano após 2017. O conjunto Edifícios Inteligentes demonstra um crescimento acentuado mais recentemente, especialmente após 2015, evidenciando a maturidade da aplicação de gestão energética em contextos urbanos. Finalmente, o gráfico do conjunto Edifícios Inteligentes com IoT mostra um início lento, com publicações efetivas a partir de 2013, e um aumento exponencial a partir de 2017, atingindo seu ponto máximo em 2023/2024. Essa curva confirma que a integração de IoT e gerenciamento de energia em edifícios é uma área de pesquisa altamente ativa e emergente, justificando a relevância temporal deste estudo.

3.1.7 Informações Principais sobre os Dados

O conjunto de dados é composto por 130 documentos provenientes de 53 fontes distintas, após a aplicação de um filtro temporal que considerou apenas publicações a partir de 2020, conforme sumarizado na Tabela 5. A idade média dos documentos é de 2,11 anos, com média de 14,34 citações por documento, indicando o impacto da literatura recente.

Tabela 5 – Informações Principais sobre os Dados

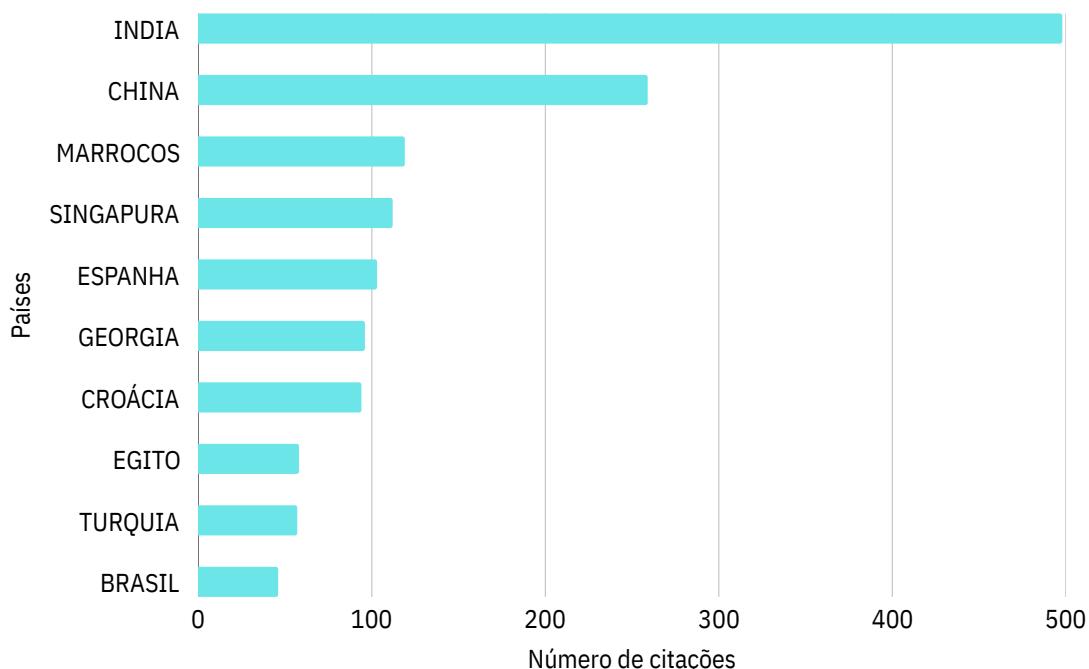
Métrica	Valor
Período	2020:2026
Fontes (Periódicos, Livros, etc.)	53
Documentos	130
Idade Média dos Documentos	2,11
Citações Médias por Documento	14,34
Coautores por Documento	4,18
Coautorias Internacionais (%)	29,23

As características gerais do conjunto de dados confirmam a natureza aplicada da pesquisa em engenharia, concentrada em artigos e trabalhos de conferência. A alta taxa de 29,23% de coautorias internacionais sublinha a natureza colaborativa e global da produção científica na área.

3.1.8 Produtividade e Colaboração Geográfica

Na Figura 19, a Índia e a China lideram o *ranking* de países mais citados. Essa proeminência inicial reflete o grande volume de pesquisa e a agilidade das redes de citação locais e emergentes. Países de maior tradição em pesquisa (como Estados Unidos e países europeus) demonstram um perfil de impacto mais gradual, mas são líderes em volume absoluto de publicações, conforme detalhado nas análises subsequentes.

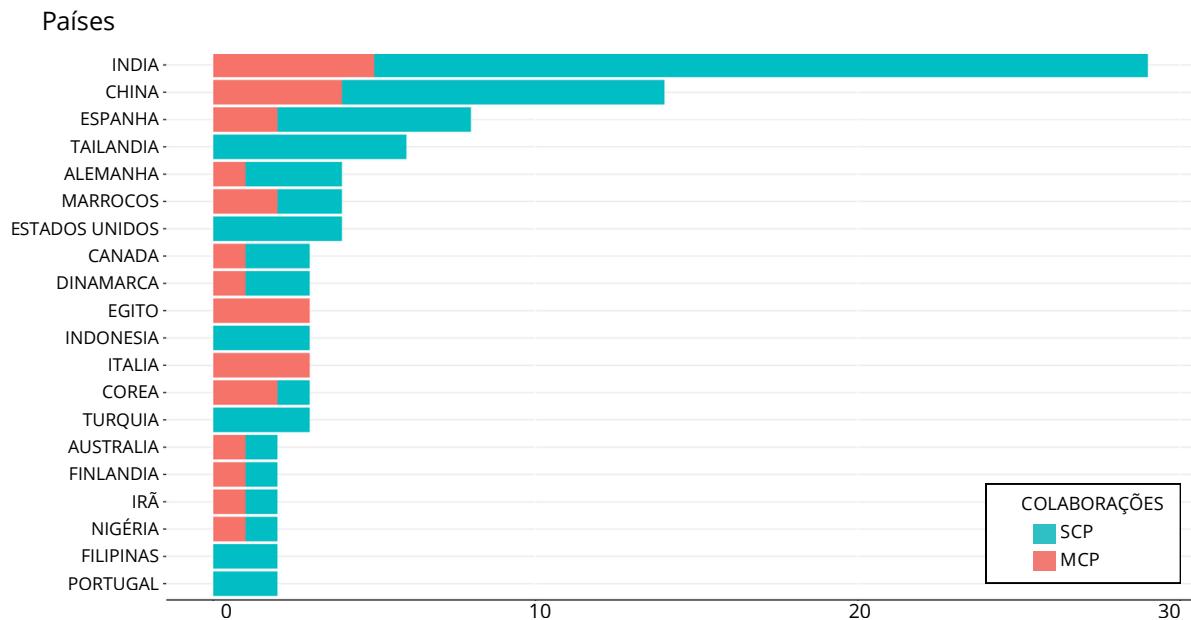
Figura 19 – Países Mais Citados na Literatura Analisada.



Fonte: Análise Bibliométrica com Bibliometrix.

Em termos de produtividade, a contribuição de cada nação é detalhada na Figura 20, que distingue publicações de país único (SCP) e publicações com colaboração internacional (MCP). A Índia lidera o número de publicações totais e o índice de coautoria internacional, seguida pela China e Estados Unidos.

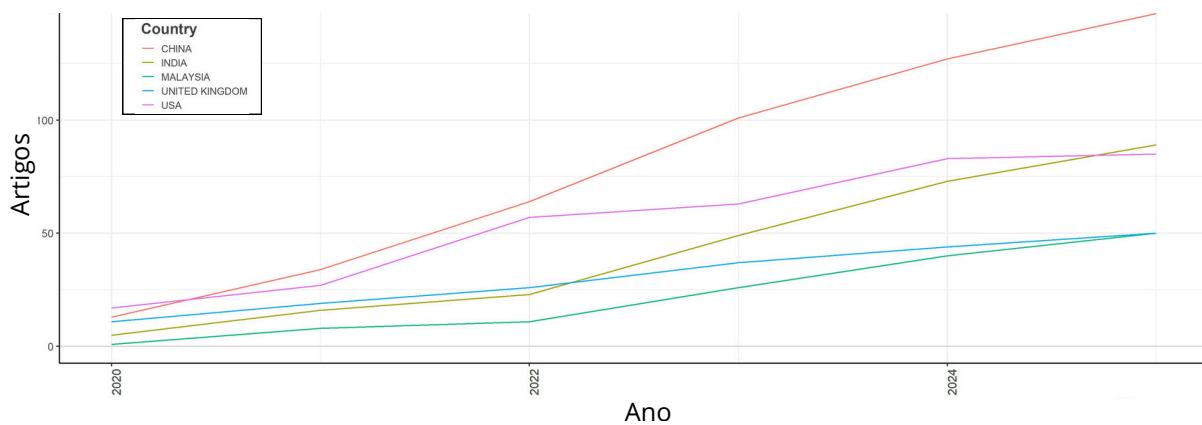
Figura 20 – Países de Autores Correspondentes: Produção e Colaboração.



Fonte: Análise Bibliométrica com Bibliometrix.

A tendência temporal de produção (Figura 21) demonstra um crescimento acelerado e consistente na China e nos Estados Unidos a partir de 2020. Essa tendência justifica o foco da revisão sistemática da literatura no período recente e destaca a necessidade de soluções inovadoras, como o *GreenFramework*, para acompanhar o ritmo de crescimento.

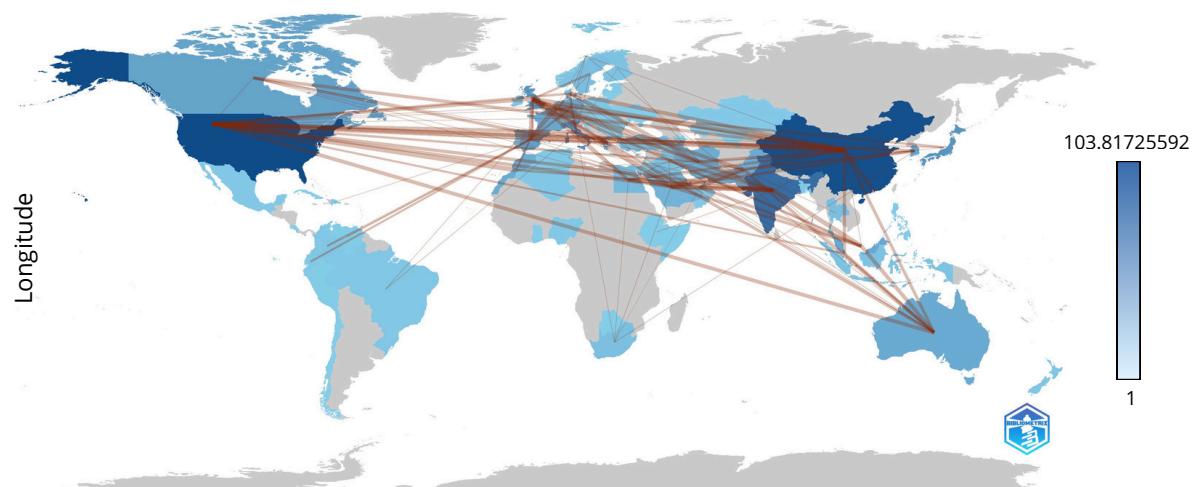
Figura 21 – Produção por País ao Longo do Tempo.



Fonte: Autoria Própria.

O Mapa de Colaboração (Figura 22) ilustra as linhas densas e numerosas entre os grandes *hubs* de pesquisa (China, Estados Unidos, Índia e Europa), validando que a pesquisa no campo é predominantemente internacional, conforme o percentual de 29,23% de coautoriais.

Figura 22 – Mapa de Colaboração entre Países.



Fonte: Análise Bibliométrica com Bibliometrix.

3.1.9 Principais Fontes por Número de Artigos

As principais fontes que contribuem para o conjunto de dados estão listadas na Tabela 6. Os periódicos *Energy and Buildings* e *Energies* apresentam o maior volume de publicações, sinalizando sua posição como referências centrais para artigos de engenharia de edifícios e gestão de energia sustentável.

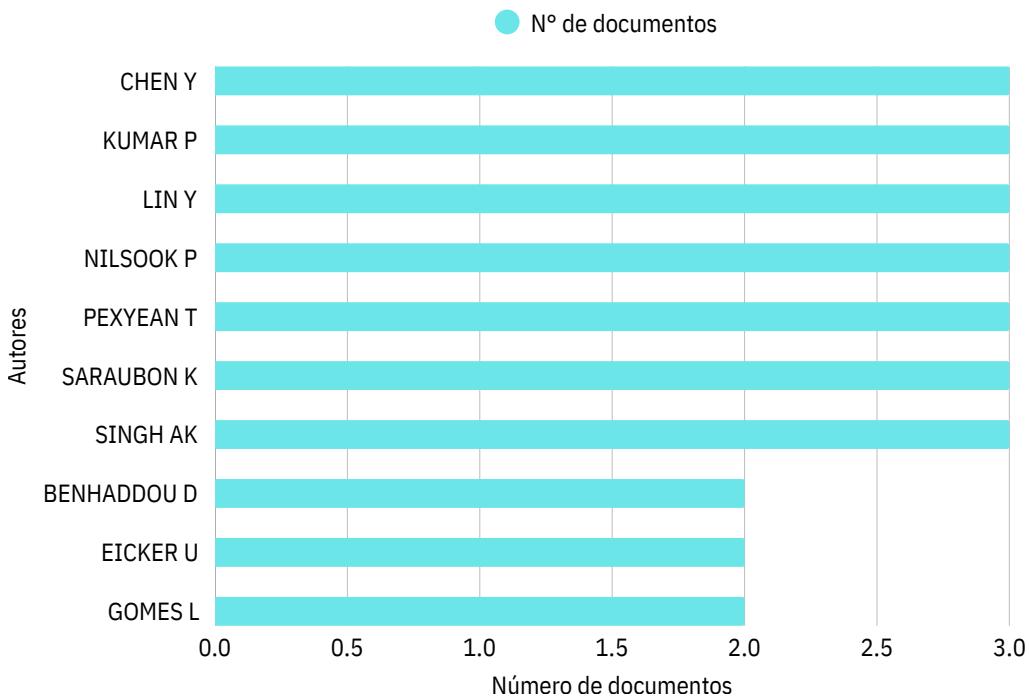
Tabela 6 – Principais Fontes de Artigos por Número.

Fonte	Artigos
Energy and Buildings (ISSN:1872-6178)	56
Energies (ISSN:1996-1073)	55
Applied Energy (ISSN:0306-2619)	29
Journal of Building Engineering (ISSN:2352-7102)	21
IEEE Access (ISSN:2169-3536)	17
Energy Procedia (ISSN:1876-6102)	13
IEEE Transactions on Smart Grid (ISSN:1949-3053)	13
Lecture Notes in Computer Science (ISSN:1611-3349)	13
Sustainable Cities and Society (ISSN:2210-6715)	12
ASHRAE Transactions (ISSN:0001-2505)	11

3.1.10 Autoria e Estruturação Temática

Na Figura 23, os autores mais relevantes com base no número de documentos publicados são listados. Autores como Chen Y, Kumar P e Lin Y lideram a produção, o que indica uma concentração de expertise em gerenciamento energético. A análise da contribuição desses autores guia a integração de técnicas de Machine Learning (ML) no trabalho.

Figura 23 – Autores Mais Relevantes.



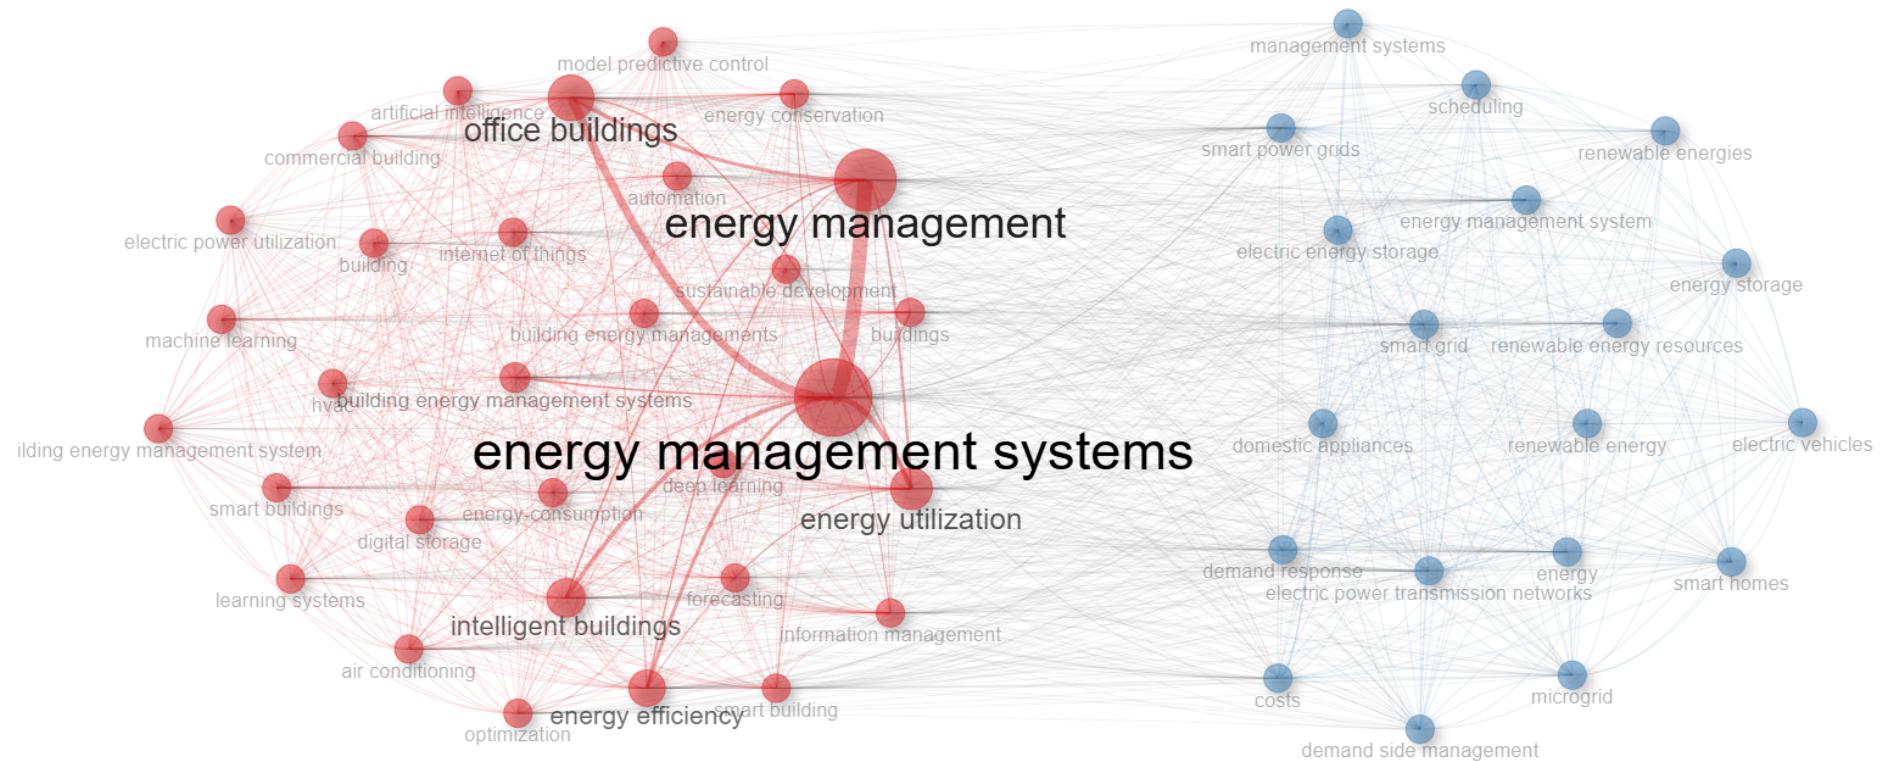
Fonte: Análise Bibliométrica com Bibliometrix.

A rede de co-ocorrência de palavras-chave (Figura 24) é o elemento central para estruturar o domínio de pesquisa. A rede exibe divisão em dois *clusters* temáticos principais:

1. O *cluster* 1 (vermelho), focado em sistemas de gerenciamento de energia e edifícios inteligentes, com termos associados como Machine Learning (ML), aprendizado profundo e controle preditivo baseado em modelo.
2. O *cluster* 2 (azul), concentrado em redes inteligentes e tecnologias de rede, incluindo energias renováveis, resposta à demanda e veículos elétricos.

O tamanho dos nós para “sistemas de gerenciamento de energia” confirma que esse é o eixo conceitual central. Essa análise estrutura o vocabulário de domínio e guia a identificação da lacuna de pesquisa, indicando que o *GreenFramework* deve atuar na intersecção desses dois *clusters* para oferecer uma solução de monitoramento inovadora.

Figura 24 – Rede de Co-Ocorrência de Palavras-Chave: *clusters Temáticos*.



3.1.11 Extração e Síntese dos Resultados

A síntese dos 130 estudos primários revelou avanços robustos em sensoriamento, comunicação e ML, mas persiste lacuna crítica: soluções proprietárias ou complexas, inacessíveis a instituições públicas com restrições orçamentárias. Nenhum estudo propôs *framework* de código aberto baseado em MDE projetado do zero para o nexo água-energia em campi universitários. Essa lacuna justifica o *GreenMonitoring*.

Os estudos primários que cumpriram os critérios de seleção foram submetidos à extração de dados, utilizando um formulário padronizado para registrar informações pertinentes às cinco questões de pesquisa (QP1 a QP5).

A análise e síntese dos resultados obtidos, detalhadas no capítulo de estado da arte, permitiram concluir que, embora existam soluções de monitoramento baseadas em IoT e ML, persiste lacuna na literatura. A maioria dos trabalhos foca em arquiteturas proprietárias ou complexas, falhando, em geral, em oferecer solução acessível, escalável e com modelo de domínio de engenharia dirigida por modelos dedicado à gestão de sistemas de energia em contextos orçamentários restritos, como instituições públicas.

A revisão sistemática mapeou avanços robustos em sensoriamento, comunicação e ML, mas revelou uma desconexão: soluções são tecnicamente sofisticadas, porém inacessíveis a instituições públicas como a UFMA, onde restrições orçamentárias e ausência de gestão energética ativa (*management*) perpetuam desperdícios — como iluminação e climatização em horários sem aulas. Nenhum estudo propôs um *framework* de código aberto, baseado em MDE, projetado do zero para esse contexto. Esta lacuna justifica o *GreenMonitoring* como inovação prática, que integra tecnologias consolidadas em uma ferramenta *low-cost*, capaz de identificar desperdícios invisíveis e embasar decisões estratégicas, alinhando sustentabilidade ambiental à realidade institucional. O próximo capítulo aprofunda o estado da arte, conectando cada avanço à proposta.

3.2 Trabalhos Relacionados

A partir dos resultados sistematizados na seção anterior, discute-se criticamente o estado da arte, organizando a análise segundo as QPs.

Em CHINCHERO; ALONSO(2020) foi feito uma revisão da literatura de metodologias de gerenciamento de energia em edifícios inteligentes (SB), com foco específico no impacto de sistemas de iluminação LED para reduzir o consumo energético enquanto mantém níveis de conforto dos usuários. Os autores propõem uma arquitetura integrada entre Sistemas de Gerencia-mento de Energia em Edifícios (BEMS) e Sistemas de Automação Predial (BAS), culminando em uma arquitetura para um Sistema Inteligente de Gerenciamento de Energia em Edifícios (IBEMS) aplicado a iluminação LED. Essa

proposta é fundamentada na necessidade de integrar redes de controle para alcançar eficiência energética, segurança, conforto e comunicação em ambientes como edifícios corporativos, universitários e hospitais.

Já em [AMASYALI; EL-GOHARY\(2018\)](#), a proposta central deste *review* é analisar estudos que utilizam modelos *data-driven* para prever o consumo de energia em edifícios, focando em planejamento, gerenciamento e conservação energética. Os autores destacam a abordagem *data-driven* como prática e acessível, em contraste com modelos físicos (*white-box*), e revisam escopos de previsão (tipos de edifícios, granularidades temporais e tipos de consumo), propriedades de dados, métodos de pré-processamento, algoritmos de *machine learning* e métricas de desempenho. A ênfase está em identificar *gaps*, como a falta de análise multivariada em dados (tipos, tamanhos e *features*), e sugerir direções futuras para melhorar a precisão em previsões de consumo total, aquecimento, resfriamento e iluminação. Essa proposta é motivada pelo alto consumo energético global em edifícios (39% nos EUA e 40% na Europa) e pela complexidade de fatores como condições climáticas, características prediais e comportamento de ocupantes. Os autores propõem que modelos *data-driven*, treinados com dados históricos, possam auxiliar na avaliação de designs alternativos e estratégias operacionais, reduzindo emissões de CO₂. Embora não foquem em iluminação LED específica, a proposta abrange edifícios não-residenciais (como institucionais), com granularidades horárias ou diárias, e integra *features* como temperatura externa e ocupação para previsões precisas.

3.2.1 Medição e Aquisição de Dados

A QP1 aborda a identificação de fontes de dados e sensores IoT para monitoramento em tempo real de recursos energéticos em cidades inteligentes. A camada de aquisição constitui o alicerce de qualquer sistema de monitoramento energético. A literatura evidencia a transição de métodos tradicionais — baseados em potências nominais ou leituras anuais, que superestimam o consumo em até 464% ([BARROS et al., 2025](#)) — para abordagens IoT, proporcionando visão dinâmica e granular.

[POYYAMOZHI et al.\(2024\)](#) propuseram medidores inteligentes que integram eletricidade, temperatura e irradiação solar, reduzindo erros de previsão em até 10% ao considerar fatores ambientais. Complementarmente, Ahsan et al. ([AHSAN et al., 2023](#)) desenvolveram sensores de corrente e tensão com pré-processamento em *gateways* locais, cortando a latência em 15% e destacando a importância da computação de borda para sistemas distribuídos. No domínio hídrico, Moreira et al. ([MOREIRA; MACKE, 2023](#)) integraram medições de vazão, pH e turbidez, pavimentando o caminho para uma visão holística dos recursos.

Essa visão integrada é ainda mais aprimorada no trabalho de Rajule et al. ([RAJULE](#)

et al., 2025a), que propõe um framework completo para monitoramento energético baseado no conceito de GreenIoT, com ênfase na sustentabilidade. Na camada de percepção, o framework incorpora sensores avançados, como módulos ESP32 para medição de corrente e tensão, além de detectores PIR para ocupação, e sensores de temperatura, umidade e CO₂. Essa configuração permite uma captura multifacetada de dados ambientais e energéticos, otimizada por meio de uma amostragem adaptativa que ajusta o intervalo de coleta para valores mínimos (S_{\min}) em momentos de variação significativa de potência ou ocupação, e máximos (S_{\max}) em períodos de estabilidade, reduzindo assim o consumo energético dos dispositivos sem comprometer a precisão.

Para transmissão eficiente desses dados, o protocolo MQTT com seu baixo *overhead* e modelo publicar/assinar se mostrou eficiente (SEOANE et al., 2021). Comparações com o *Constrained Application Protocol* (CoAP) reforçam sua superioridade em confiabilidade para aplicações críticas (ALFALOUJI et al., 2022), enquanto arquiteturas híbridas com API REST equilibram telemetria em tempo real e consultas históricas (ŁUCZAK; BROCK; SIEMBAB, 2023).

Apesar desses avanços, a integração de sensores heterogêneos permanece, em geral, essencialmente *ad-hoc*, dependente de soluções proprietárias que elevam custos e complicam a manutenção. O trabalho de AL-DAILEH(2021) (I3SEM) enfatiza a falta de padronização em protocolos como um obstáculo central, mencionando ZigBee, Z-Wave e EnOcean, e propõe *Customised Communication Bridges* para traduzir dados de dispositivos legados e inteligentes. Embora esta abordagem amplie a aplicabilidade em cenários mistos, complexidade adicional na camada de *software* (*middleware* de tradução) e custo operacional elevado são introduzidos.

Em contraste, o *GreenMonitoring* adota o MQTT como protocolo *end-to-end*, otimizado para baixa latência e redes restritas, padronizando a comunicação desde a concepção e reduzindo a dependência de adaptadores externos. Esta escolha é justificada pela necessidade de interoperabilidade imediata e baixo custo de implantação, critérios essenciais para instituições públicas com restrições orçamentárias. De forma semelhante, o framework de Rajule et al. (RAJULE et al., 2025a) avança nessa direção ao integrar comunicação LoRaWAN na camada de rede, com mecanismos de *Adaptive Data Rate* (ADR) e ajuste dinâmico do Spreading Factor (SF), definido pela fórmula:

$$SF_{t+1} = \begin{cases} SF_t + 1, & RSSI < \gamma_{\text{low}} \\ SF_t - 1, & RSSI > \gamma_{\text{high}} \\ SF_t, & \text{otherwise} \end{cases}$$

Essa estratégia otimiza a transmissão em ambientes de longa distância e baixa potência, complementando protocolos como MQTT em cenários onde a eficiência energética é prioritária.

Essa seção transita para os fluxos de trabalho, pois uma aquisição eficiente depende de protocolos para transmissão, como discutido na QP2.

3.2.2 Fluxos de Trabalho e Protocolos de Comunicação

A QP2 investiga fluxos para coleta, transmissão e análise de dados, com ênfase em MQTT.

Um fluxo de trabalho baseado em MQTT para transmissão de dados de sensores IoT em redes inteligentes foi proposto ([SEOANE et al., 2021](#)). O protocolo, caracterizado por seu cabeçalho compacto de 2 *bytes* e modelo publicar/inscrever, foi implementado em uma arquitetura em camadas, com sensores conectados a *gateways* que intermediam dados para servidores em nuvem. Redução de 20% no consumo de banda em comparação com o HTTP foi alcançada, reforçando a adequação do MQTT para sistemas de baixa potência.

O *Constrained Application Protocol* (CoAP), baseado em *User Datagram Protocol* (UDP), foi explorado para dispositivos IoT com recursos limitados ([ALFALOUJI et al., 2022](#)). Menor sobrecarga em redes instáveis foi demonstrada pelo CoAP, mas sua confiabilidade reduzida em comparação com o MQTT limita, possivelmente, sua aplicação em sistemas de missão crítica. Essa análise suporta a escolha do MQTT como protocolo principal no *GreenMonitoring*, garantindo eficiência e confiabilidade.

Uma arquitetura híbrida combinando MQTT e API *Representational State Transfer* (REST) para integrar dados em tempo real e históricos foi desenvolvida ([LUCZAK; BROCK; SIEMBAB, 2023](#)). O MQTT foi utilizado para transmissão assíncrona de dados de sensores, enquanto API REST forneceram acesso síncrono a dados armazenados, melhorando a interoperabilidade em 25%. Essa abordagem híbrida é refletida no *GreenMonitoring*, que combina MQTT para monitoramento em tempo real e API REST para gerenciamento de dados.

Expandindo essas discussões, o trabalho de Rajule et al. ([RAJULE et al., 2025a](#)) introduz um fluxo de trabalho otimizado que incorpora LoRaWAN como protocolo de comunicação principal, adaptado para cenários de monitoramento sustentável. Essa escolha permite uma transmissão de longo alcance com baixo consumo energético, integrada a mecanismos de ajuste dinâmico que melhoraram a taxa de entrega de pacotes (PDR) em até 9,3% em comparação com sistemas padrão, conforme validado em simulações com NS-3 e NetAnim em um cenário de 25 nós LoRa e 7 *gateways* em uma área de 1 km². Essa integração reforça a flexibilidade dos fluxos de trabalho em ambientes restritos, alinhando-se às demandas de eficiência e escalabilidade.

A escolha do protocolo de comunicação é crucial para o desempenho do sistema em ambientes com restrições de recursos. Na Tabela 7, uma análise comparativa entre MQTT, CoAP e HTTP é apresentada, justificando a seleção do MQTT para o *GreenMonitoring*.

Tabela 7 – Comparaçāo entre protocolos de comunicação para IoT.

Parāmetro	MQTT	CoAP	HTTP
Modelo	Publish/Subscribe	Request/Response	Request/Response
Transporte	TCP	UDP	TCP
Overhead	Baixo (<i>2 bytes</i>)	Muito baixo	Alto
Consumo energético	Baixo	Muito baixo	Alto
Confiabilidade	Alta (QoS 0-2)	Baixa (sem confirmação)	Alta
Largura de banda	20-30% menor vs HTTP	40-50% menor vs HTTP	Referência
Latênciā	1,786ms (CUNHA; BATISTA, 2022)	2ms	1,671ms (CUNHA; BATISTA, 2022)
Escalabilidade	Excelente	Boa	Limitada

Na Tabela 7, parāmetros como modelo, transporte, *overhead*, consumo energético, confiabilidade, largura de banda, latênciā e escalabilidade são comparados. A seleção do MQTT se justifica por seu baixo *overhead*, modelo publish/subscribe ideal para telemetria, e confiabilidade comprovada em ambientes restritos. Embora o CoAP apresente consumo energético ligeiramente inferior, sua baixa confiabilidade em UDP limita, possivelmente, aplicações críticas. O HTTP, embora ubíquo, possui *overhead* excessivo para dispositivos com restrições.

3.2.3 Análise e Inteligência Preditiva

A questão de pesquisa QP3 examina técnicas de aprendizado de máquina aplicadas à previsão de padrões de consumo e detecção de anomalias, fundamentais para o *GreenMonitoring*. Diversos estudos exploram algoritmos como *Random Forest* e LSTM para análise de dados energéticos.

A aplicação de ML para previsão de demanda e detecção de anomalias representa uma evolução em relação às abordagens reativas tradicionais. Com dados robustos em mãos, o próximo desafio é extrair inteligência acionável que permita otimizar recursos em horários de baixa ocupação, conforme identificado na caracterização do problema da UFMA.

O algoritmo *Random Forest* se destacou em previsões de curto prazo, alcançando *Mean Absolute Error* (MAE) inferior a 5% mesmo com dados heterogêneos ([CHéVEZ; MARTINI, 2024](#)). Para capturar dependências temporais complexas, as redes LSTM tornaram-se referência, reduzindo o RMSE em 8% frente a modelos ARIMA ([ELHABYB et al., 2024](#)). Variantes como *Gated Recurrent Units* (GRU) oferecem eficiência computacional, com treinamento 30% mais rápido, embora sacrificando precisão em séries longas ([WAQAS; HUMPHRIES, 2024](#)).

O artigo de [ELHABYB et al.\(2024\)](#) constitui uma referência por focar especificamente em edifícios educacionais, alinhando-se diretamente ao contexto do *GreenMonitoring*. Os autores avaliam comparativamente LSTM, *Random Forest (RF)* e *Gradient Boosting Regressor (GBR)* em dados reais de três edifícios (CLAS, NHAI, Cronkite), coletados via *power intel sockets*. O GBR obteve o melhor desempenho geral (R^2 até 0,998), seguido por LSTM, com RF em terceiro lugar.

Mais recentemente, [MA et al.\(2025\)](#) elevaram o estado da arte em previsão de consumo energético em edifícios de escritórios ao propor o AGBR (*Adaptive Gradient Boosting Regression*), um modelo *ensemble* adaptativo que superou oito algoritmos consolidados (CNN, LSTM, BiLSTM, PSO-BP, GA-BP, RF, SVM e XGBoost) em precisão e eficiência computacional. Utilizando dados horários reais de um sistema BEMS composto por sensores IoT de temperatura externa, umidade, irradiação solar, vazão de água e diferenças de temperatura, os autores aplicaram Kernel PCA para redução não linear de dimensionalidade e implementaram novos mecanismos no AGBR: parada antecipada adaptativa, taxa de aprendizado regulada por gradiente e modelagem residual iterativa. Os resultados foram validados com MAE, RMSE, MAPE e R^2 , alcançando $R^2 = 0,99$, redução de 73,91% no tempo de treinamento e 62,28% no MAE em relação aos melhores baselines, com previsões estáveis adequadas a aplicações em tempo real.

A aplicação de LSTM para gerenciamento de energia em edifícios comerciais equipados com veículos elétricos (EVs) e painéis solares fotovoltaicos representa um avanço na inteligência preditiva. No trabalho de [ZHOU et al.\(\(ZHOU et al., 2021\)\)](#), os autores propõem um algoritmo baseado em LSTM para agendar a carga e descarga de EVs, visando otimizar custos sob tarifas de uso do tempo (TOU) e tarifas de injeção. A estrutura do sistema separa o treinamento offline, onde o LSTM mapeia estados de entrada (como demanda elétrica, geração PV, tarifa TOU e características dos EVs) para decisões de saída (poder de carga/descarga), do execução online, que gera soluções em milissegundos sem necessidade de previsões adicionais. Uma regra preliminar de processamento de dados e um procedimento de filtragem de saída são incorporados para melhorar o desempenho, garantindo conformidade com limitações físicas como eficiência de carga/descarga, capacidade da bateria e demanda de SOC ao partir. Os resultados simulados demonstram soluções quase-ótimas com redução significativa na pressão de previsão e cálculo em comparação ao MILP convencional, alinhando-se ao contexto de prosumidores institucionais.

Estudos em edifícios educacionais em regiões de alta densidade populacional também contribuem para a compreensão de padrões de consumo. Em [CHUNG; YEUNG\(2020\)](#), os autores investigam o consumo energético de escolas secundárias em Hong Kong, identificando padrões baseados em uma pesquisa com edifícios sem sistemas centrais de aquecimento ou resfriamento, onde a eletricidade domina (média de 529.925 kWh/ano

e EUI de 105.61 kWh/m²/ano), com uso de ar-condicionados split/janela e lâmpadas fluorescentes T5/T8, sendo LEDs raros. Eles desenvolvem modelos de regressão stepwise e não-paramétrica convexa de mínimos quadrados (CNLS) focados em fatores gerenciáveis pela administração, como o número de funcionários dedicados à economia de energia e controle de iluminação, para prever consumo e promover uma cultura de eficiência energética.

Em paralelo, a previsão de consumo em edifícios escolares em climas quentes e úmidos é explorada em ([ALSHIBANI, 2020](#)), onde os autores desenvolvem um modelo baseado em redes neurais artificiais (ANN) para prever o consumo energético em escolas sauditas, considerando fatores como capacidade de AC, área do telhado e área condicionada. Utilizando 352 datasets reais de escolas em operação na Província Oriental da Arábia Saudita, a metodologia envolve a identificação de fatores por meio de revisão de literatura e consultas a especialistas, seguida de treinamento, teste e validação do modelo ANN com busca sistemática por arquiteturas ótimas. O monitoramento é baseado em dados históricos de contas de energia e características prediais, sem protocolos específicos de IoT mencionados, mas com tecnologias como o software Neuraldesigner para otimização. Os resultados indicam precisão de 87.5% em casos reais, com forte correlação entre variáveis como número de salas e área condicionada (0.95), e capacidade de AC como principal preditor.

Na Tabela 8, evidencia-se a superioridade do AGBR, que reduz o MAE em 62,28% e o RMSE em cerca de 62% em relação ao melhor baseline (XGBoost), ao mesmo tempo em que diminui o tempo de treinamento em 73,91%. Tais ganhos derivam da combinação inteligente de parada adaptativa e regulação dinâmica da taxa de aprendizado, permitindo convergência mais rápida sem perda de generalização.

Tabela 8 – Desempenho comparativo de modelos de previsão em ([MA et al., 2025](#)) (edifícios de escritórios, dados horários BEMS).

Modelo	MAE	RMSE	MAPE (%)	R ²
CNN	0,182	0,294	3,41	0,961
LSTM	0,156	0,267	2,98	0,974
BiLSTM	0,149	0,253	2,85	0,978
PSO-BP	0,168	0,279	3,22	0,968
GA-BP	0,174	0,285	3,31	0,965
RF	0,138	0,241	2,66	0,982
SVM	0,195	0,312	3,68	0,954
XGBoost	0,129	0,228	2,51	0,985
AGBR (proposto por (MA et al., 2025))	0,048	0,087	0,93	0,990

Complementando essa análise, [RAJULE et al.\(2025a\)](#) avançam na detecção de anomalias por meio de um processamento híbrido borda-nuvem, onde a borda (utilizando

Raspberry Pi) aplica filtros de média móvel e detecção estatística baseada na fórmula:

$$\text{Anomalia} \iff |P_t - MA_t| > \alpha \cdot \sigma_t$$

Essa abordagem resulta em um F1-Score de 0,925 para detecção de anomalias, superando sistemas padrão em 17,8%, e demonstra como a inteligência preditiva pode ser distribuída para reduzir latência e consumo, alcançando melhorias de até 39% na latência em simulações realistas.

Na Tabela 9 posiciona o *GreenMonitoring* frente aos melhores resultados recentes. Embora (MA et al., 2025) estabeleça novo patamar em precisão bruta e eficiência computacional para edifícios de escritórios, e (ZHOU et al., 2021) destaque a capacidade do LSTM para decisões descentralizadas e rápidas em contextos semelhantes, o presente trabalho diferencia-se pela integração do nexo água-energia, explicabilidade via SHAP e implantação em ambiente institucional com restrições orçamentárias — aspectos ausentes ou apenas parcialmente tratados nas referências.

Tabela 9 – Comparaçāo de modelos preditivos de última geraçāo em edifícios institucionais/comerciais.

Estudo	Contexto	Melhor	Melhor R^2
Elhabyb et al. (2024) (ELHABYB et al., 2024)	Educacional	GBR	0,998
Ma et al. (2025) (MA et al., 2025)	Escritórios	AGBR	0,990
Zhou et al. (2021) (ZHOU et al., 2021)	Escritórios	LSTM	—
Chung et al. (2020) (CHUNG; YEUNG, 2020)	Educacional	CNLS	—
Alshibani (2020) (ALSHIBANI, 2020)	Educacional	ANN	—
Rajule et al. (2025) (RAJULE et al., 2025a)	Institucional	Estatístico (borda)	—

Apesar desses avanços, a integração de sensores heterogêneos permanece, em geral, essencialmente *ad-hoc*, dependente de soluções proprietárias que elevam custos e complicam a manutenção. O trabalho de AL-DAILEH(2021) (I3SEM) enfatiza a falta de padronização em protocolos como um obstáculo central. Embora algoritmos como AGBR demonstrem eficácia em ambientes controlados, implantação complexa, falta de explicabilidade e dependência de grandes volumes de dados centralizados são enfrentados. Modelos *black-box* impedem, possivelmente, que gestores compreendam as causas de picos previstos, limitando ações preventivas.

A oportunidade reside em tornar a predição não apenas precisa, mas comprehensível e implantável em ambientes restritos. O *GreenMonitoring* aborda esta lacuna integrando valores SHAP às LSTM, revelando contribuições individuais de variáveis, enquanto o processamento na borda permite análise local sem expor dados brutos. A escolha do LSTM é cientificamente validada por (ELHABYB et al., 2024), (ZHOU et al., 2021) e (MA et al., 2025), superando as limitações de precisão-versus-explicabilidade observadas nos trabalhos mais avançados do estado da arte.

3.2.4 Gestão Integrada e Escalabilidade

A QP4 avalia o uso de computação em nuvem e contêineres para melhorar a escalabilidade e disponibilidade do *GreenMonitoring*. Estudos recentes destacam soluções baseadas em *Docker* e plataformas em nuvem para sistemas IoT.

A sustentabilidade institucional exige mais que monitoramento isolado: integração do nexo água-energia e escalabilidade para múltiplos locais são demandadas. Na literatura, otimizar este nexo pode cortar desperdícios em 15–60%, pois 1 m³ de água tratada e distribuída consome energia equivalente (BROGGIO; SERRA; MATA-LIMA, 2025).

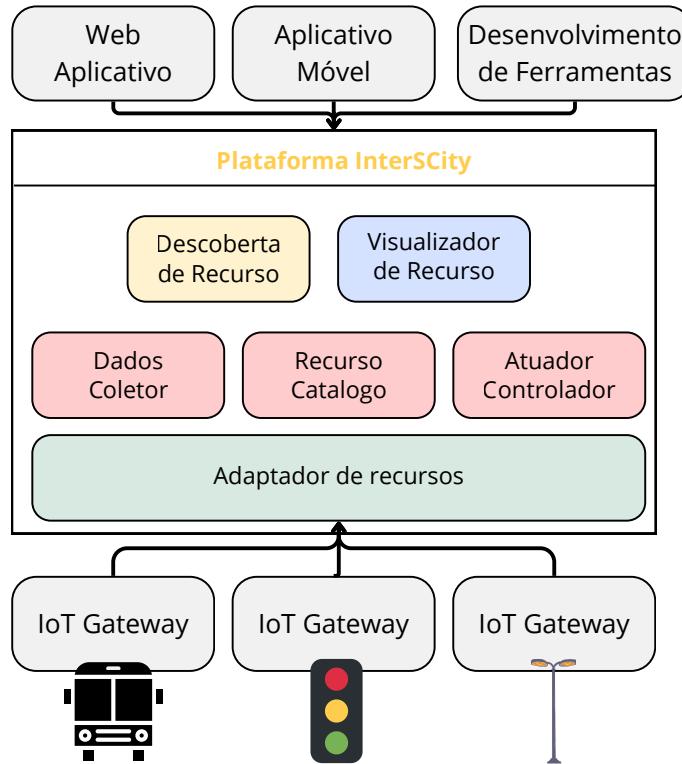
Arquiteturas de microsserviços (MSA) se consolidaram como superiores a monolitos ou SOA tradicional (CORTELLESSA et al., 2022; AL-DAILEH, 2021). O I3SEM utiliza Kubernetes e Java, citando escalabilidade fina, resiliência e alta disponibilidade, com o microsserviço DCI (Data Collection Interface) atuando como tradutor de protocolos heterogêneos. Contêineres como *Docker* reduzem tempos de implantação em 40% e facilitam orquestração (JAVED et al., 2020), enquanto *Apache Kafka* gerencia fluxos de milhares de dispositivos (BABAR; KHAN, 2021).

A plataforma *InterSCity*⁵ é uma infraestrutura de *middleware* de código aberto (*open-source*) para cidades inteligentes, reconhecida, em geral, por sua modularidade e escalabilidade (ESPOSTE et al., 2017). A *InterSCity* integra dispositivos heterogêneos da IoT, abstraindo complexidades de comunicação e promovendo interoperabilidade, características essenciais para o monitoramento energético em contextos urbanos e institucionais. Dessa forma, seu propósito é fornecer uma infraestrutura de *middleware* modular e escalável que abstrai a complexidade de dispositivos IoT para compartilhamento de recursos entre cidades.

A arquitetura da *InterSCity* se baseia em microsserviços, como ilustrado na Figura 25. Nesta figura, os principais microsserviços e suas interações são apresentados, destacando o uso do barramento de mensagens *RabbitMQ* para comunicação assíncrona e API *Representational State Transfer* (REST) para interações síncronas. A modularidade é alcançada por meio de serviços como *Resource Adaptor*, *Resource Catalog*, *Data Collector*, *Actuator Controller*, *Resource Discovery* e *Resource Viewer*, que operam de forma independente, mas coordenada.

⁵ <<https://interscity.org/software/interscity-platform/>>

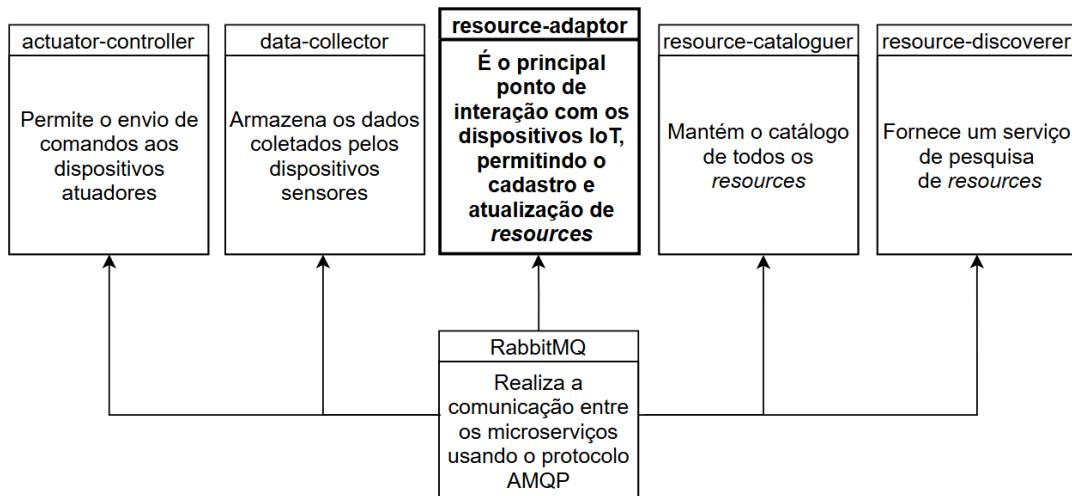
Figura 25 – Arquitetura da plataforma *InterSCity*, destacando os microsserviços principais e suas interações.



Fonte: ([ESPOSTE et al., 2017](#)).

Na Figura 26, a arquitetura de microsserviços da *InterSCity* é ilustrada, destacando seus componentes principais e suas interações.

Figura 26 – Arquitetura modular da plataforma *InterSCity*, exibindo seus microsserviços constituintes.

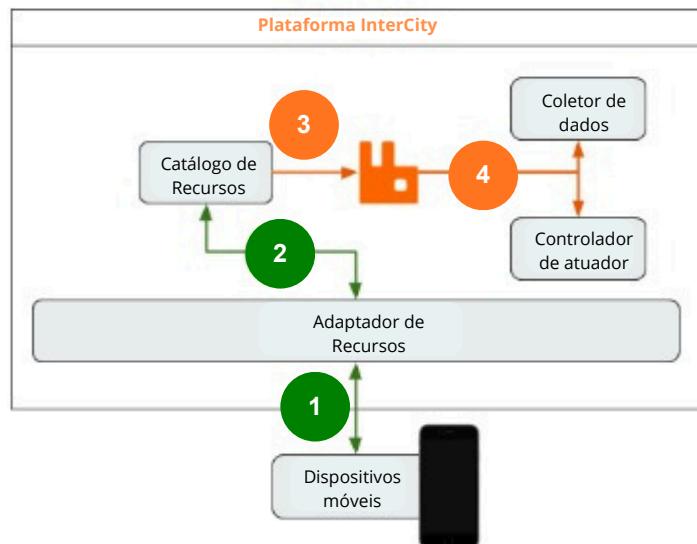


Fonte: Adaptado de [CUNHA; BATISTA\(2022\)](#).

Um estudo detalhou a implementação de microsserviços na *InterSCity*, utilizando tecnologias como *Ruby on Rails*, *EmberJS*, *PostgreSQL*, *MongoDB*, *Redis* e *Kong* como *API Gateway* (ESPOSTE et al., 2019). A integração do protocolo MQTT foi proposta para suportar dispositivos IoT com restrições de recursos, demonstrando maior vazão (até 84,27 vezes superior ao HTTP e latência comparável (CUNHA; BATISTA, 2022). Outro trabalho otimizou o controle de atuadores, centralizando funcionalidades no *Actuator Controller* e utilizando *Sidekiq* para processamento assíncrono, reduzindo o tempo de entrega de comandos em 51,1% (SANGEETHA; DENY, 2023).

Na Figura 27, o fluxo de registro de um dispositivo na *InterSCity* é ilustrado, destacando a interação entre o cliente, o *Resource Adaptor*, o *Resource Catalog* e o barramento *RabbitMQ*. O processo abrange: (1) envio de metadados pelo dispositivo, (2) atribuição de um identificador único (*UUID*), (3) publicação de eventos assíncronos e (4) notificação aos microsserviços relevantes.

Figura 27 – Fluxo de registro de um dispositivo na plataforma *InterSCity*.



Fonte: (MELO; COSTA, 2018).

Os microsserviços, conforme descrito em (ESPOSTE et al., 2019; CUNHA; BATISTA, 2022), incluem:

- **Resource Adaptor:** *Proxy* sem estado (*stateless*) para interação com dispositivos IoT, permitindo registro, atualização de recursos e postagem de dados de sensores. No trabalho de (CUNHA; BATISTA, 2022), foi estendido com um adaptador MQTT, adicionando os *workers* *MQTTSubscriber* (para receber dados em tópicos `resources/#`) e *MQTTPublisher* (para enviar comandos a atuadores via tópicos `commands/{uuid}`);

- **Resource Catalog:** Gerencia dados estáticos de recursos, atribuindo UUIDs (Universally Unique Identifier) e notificando eventos de criação assincronamente;
- **Data Collector:** Armazena dados sensoriais, suportando consultas com filtros contextuais (por exemplo, por *timestamp* ou localização);
- **Actuator Controller:** Gerencia comandos para atuadores, registrando histórico e notificando via *Webhooks* ou, com o adaptador MQTT, via *MQTTPublisher*;
- **Resource Discovery:** Oferece busca sensível ao contexto (*context-aware*), combinando dados estáticos e dinâmicos para aplicações como Estacionamento Inteligente (*Smart Parking*);
- **Resource Viewer:** Interface *web* para visualização de dados de recursos, útil para gerenciamento.

Na Tabela 10, o *technology stack* da *InterSCity* é resumido, evidenciando a heterogeneidade tecnológica que suporta sua modularidade.

Tabela 10 – *Technology stack* dos microsserviços da *InterSCity*.

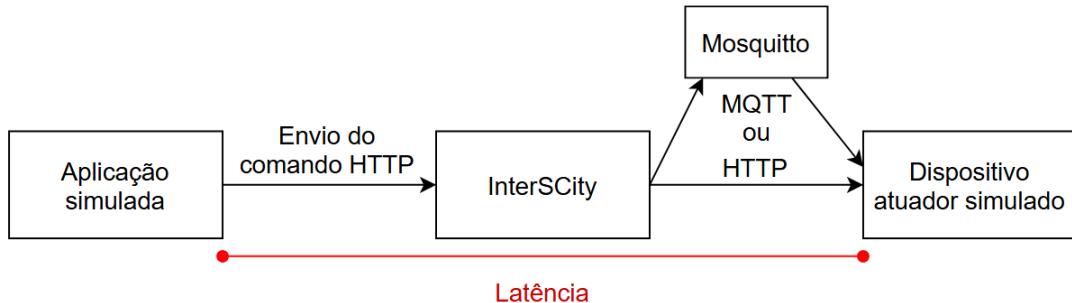
Serviço	Linguagem	Framework	Banco de Dados	Cache
<i>Actuator Controller</i>	Ruby	Ruby on Rails	MongoDB	Redis
<i>Data Collector</i>	Ruby	Ruby on Rails	MongoDB	Redis
<i>Resource Adaptor</i>	Ruby	Ruby on Rails	PostgreSQL	–
<i>Resource Catalog</i>	Ruby	Ruby on Rails	PostgreSQL	–
<i>Resource Discovery</i>	Ruby	Ruby on Rails	In-memory	MongoDB (Percona)
<i>Resource Viewer</i>	Javascript	EmberJS	–	–

Para avaliação, Del Esposte et al. (2019) ([ESPOSTE et al., 2019](#)) integram o *InterSCSimulator*, um simulador escalável baseado em agentes, para gerar *workloads* realistas. O cenário simulado baseia-se em dados reais de São Paulo (e.g., pesquisa Origem-Destino, *OpenStreet Maps*), focando em uma aplicação de *Smart Parking* com 492.976 veículos durante o pico matinal. Experimentos medem latência, *throughput* e uso de recursos sob cargas crescentes (de 10% a 100% dos veículos usando a aplicação), utilizando *Kubernetes* para orquestração de *containers Docker*. Resultados mostram que a plataforma escala horizontalmente, mantendo latências abaixo de 100ms para até 500.000 requisições, com eficiência na geração de *workloads* sintéticos. Limitações incluem a dependência de simulações (não reais) e sugestões para trabalhos futuros como integração de processamento de eventos complexos.

No trabalho de da Cunha e Batista (2022) ([CUNHA; BATISTA, 2022](#)), a avaliação foca na integração do protocolo MQTT, comparando-o com a API HTTP padrão. Na Figura 28, a medição de latência para envio de comandos a atuadores é ilustrada, mostrando

que o MQTT apresenta latência média de 1,786ms, comparável aos 1,671ms do HTTP, apesar do *hop* adicional introduzido pelo *broker Mosquitto*.

Figura 28 – Medição do tempo para envio de comando a um atuador.

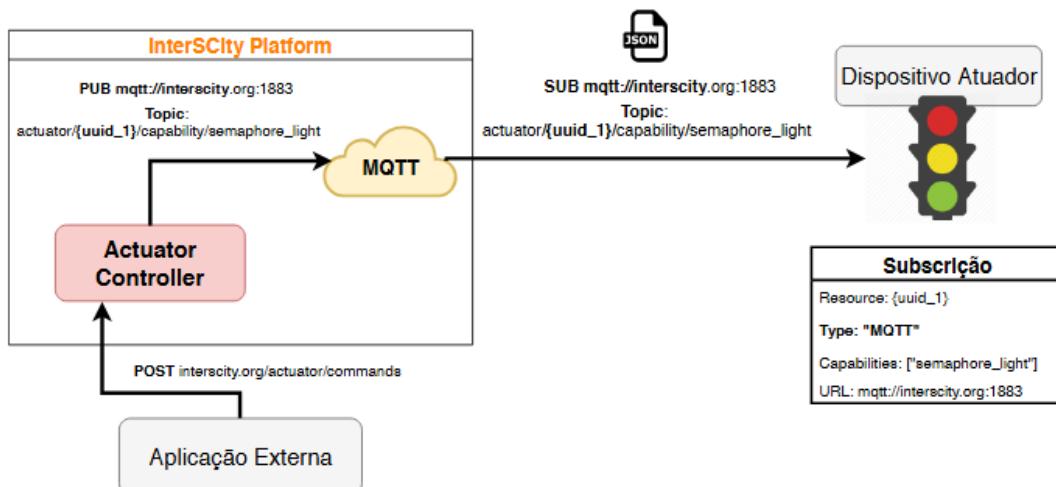


Fonte: (CUNHA; BATISTA, 2022).

No contexto de atuadores, Sangeetha e Deny (2023) ([SANGEETHA; DENY, 2023](#)) avaliam o impacto das modificações propostas, testando o envio de 1000 comandos em um ambiente com instâncias AWS e Raspberry Pi Zero W. Os resultados demonstram reduções significativas: mais de 50% no tempo de processamento interno, 51,1% no tempo de entrega de comandos e aproximadamente 66,7% no uso de dados com MQTT em comparação ao *webhook* via HTTP. Essas melhorias validam, possivelmente, a escalabilidade e eficiência da *InterSCity* em cenários de IoT, alinhando-se à adoção de MQTT como protocolo central no *GreenFramework*.

Nas Figuras 29 e 30, as operações do sistema via MQTT e *webhook* são ilustradas, respectivamente, destacando o fluxo simplificado no modelo proposto.

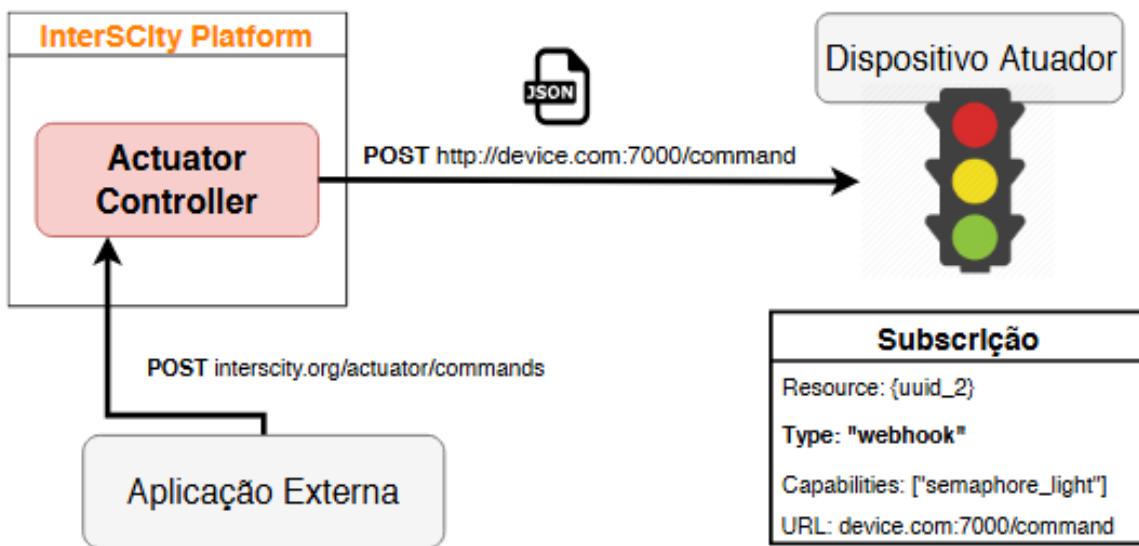
Figura 29 – Operação do sistema via MQTT.



Fonte: (SANGEETHA; DENY, 2023).

Na Figura 29, o fluxo de controle de um dispositivo atuador (como um semáforo de luz) utilizando o protocolo MQTT na Plataforma *InterSCity* é detalhado. Uma Aplicação Externa inicia o comando por meio do envio de uma requisição HTTP POST ao controlador de atuadores (*Actuator Controller*) na plataforma. Em seguida, a mensagem JSON (*JavaScript Object Notation*) contendo o comando é publicada pelo *Actuator Controller* em um tópico MQTT específico (*actuator/{uuid_1}/capability/semaphore_light*). O Dispositivo Atuador, subscrito a esse tópico, recebe a mensagem e executa o comando. Essa arquitetura desacoplada sugere-se como fundamental para a comunicação M2M em ambientes IoT com recursos limitados.

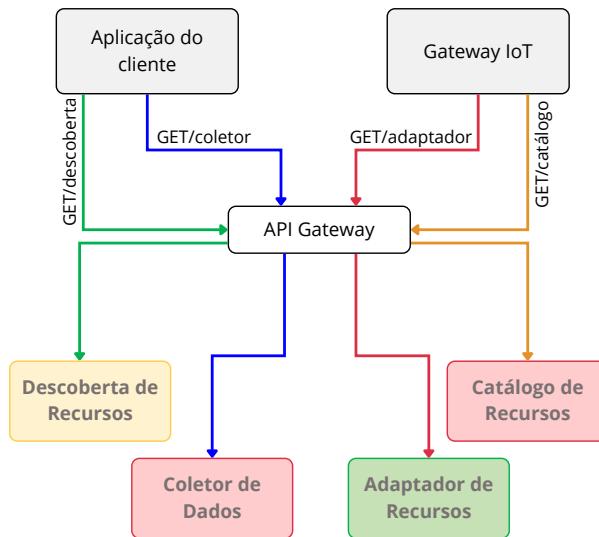
Figura 30 – Operação do sistema via webhook.



Fonte: ([SANGEETHA; DENY, 2023](#)).

Na Figura 30, uma operação de controle similar é demonstrada, mas utilizando o mecanismo de *Webhook*. Uma Aplicação Externa envia o comando HTTP POST para a plataforma. No entanto, em vez de publicar em um *broker*, o *Actuator Controller* da Plataforma *InterSCity* realiza uma requisição HTTP POST diretamente para a URL especificada na Subscrição do dispositivo. O dispositivo atuador é configurado com uma subscrição do tipo "*webhook*". Esse modelo sugere-se como útil quando o dispositivo possui capacidade de receber requisições HTTP, servindo como alternativa ao MQTT para cenários específicos, como o controle de medidores inteligentes ou sistemas de automação que expõem APIs RESTful.

Na Figura 31, o API *gateway* do *InterSCCity* é ilustrado, mostrando como ele atua como ponto de entrada único, direcionando requisições para microsserviços via regras URI, promovendo modularidade ao isolar serviços e permitindo uso em cenários variados como mobilidade ou saúde.

Figura 31 – API *gateway* do InterSCity.

Fonte: ([ESPOSTE et al., 2019](#)).

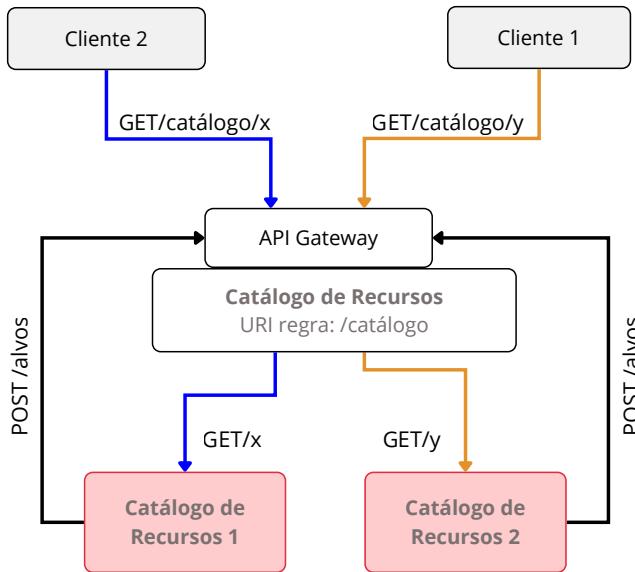
Na Figura 31, o fluxo de requisições de duas fontes — a Aplicação do Cliente e o *gateway* IoT — é ilustrado. O *gateway* recebe requisições e as encaminha para os microsserviços apropriados:

- Requisições de Descoberta (GET/descoberta) da Aplicação do Cliente são direcionadas ao microsserviço de Descoberta de Recursos;
- Requisições de Coleta (GET/coletor) da Aplicação do Cliente vão para o microsserviço Coletor de Dados;
- Requisições de Adaptação (GET/adaptador) do *gateway* IoT são encaminhadas ao Adaptador de Recursos;
- Requisições de Catálogo (GET/catálogo) do *gateway* IoT são direcionadas ao Catálogo de Recursos.

A API *gateway* atua como um *proxy* reverso, expondo apenas uma interface (a URI) e isolando a complexidade dos microsserviços de *backend*, o que sugere-se como crucial para a modularidade e a evolução independente dos serviços.

Na Figura 32, o balanceamento de carga HTTP é demonstrado, com instâncias de microsserviços se registrando dinamicamente no Kong para *round-robin*, destacando escalabilidade e adaptabilidade a problemas como monitoramento energético em múltiplos edifícios.

Figura 32 – Balanceamento de carga HTTP no *InterSCity*.



Fonte: ([ESPOSTE et al., 2019](#)).

Na Figura 32, o mecanismo de balanceamento de carga (*load balancing*) embutido na arquitetura é ilustrado, especificamente para o microsserviço Catálogo de Recursos. Dois clientes (Cliente 1 e Cliente 2) enviam requisições de catálogo (GET/catálogo/x e GET/catálogo/y) para o API *Gateway*. O *Gateway*, seguindo uma regra URI (/catálogo), direciona essas requisições para um *upstream* chamado Catálogo de Recursos. Esse *upstream* possui múltiplas instâncias (*targets*) ativas, como o Catálogo de Recursos 1 e o Catálogo de Recursos 2. As requisições são distribuídas de forma balanceada (por exemplo, usando o algoritmo round-robin) entre essas instâncias. As instâncias de microsserviços se registram e se desregistram dinamicamente no *gateway* através de requisições POST /alvos (*targets*). Esse mecanismo garante, em geral, alta disponibilidade e escalabilidade horizontal, sendo essencial para um sistema que precisa gerenciar um volume crescente de medidores e dados de energia.

Expandindo essas bases arquiteturais, o framework proposto por Rajule et al. ([RAJULE et al., 2025a](#)) apresenta uma estrutura em quatro camadas que promove integração e escalabilidade: percepção para aquisição sensorial, rede para comunicação otimizada via LoRaWAN, processamento híbrido borda-nuvem para análise eficiente, e aplicação com dashboards intuitivos como Grafana integrado a InfluxDB e alertas via Node-RED. Essa arquitetura verde e escalável, validada em simulações, demonstra melhorias significativas, como redução de 48,8% no consumo de bateria e duplicação da vida útil dos nós, tornando-a particularmente adequada para ambientes institucionais extensos.

Adicionalmente, a arquitetura proposta em ([COSTA, 2022](#)) para automação

residencial baseada em IoT oferece insights valiosos para gestão integrada, estruturada em camadas de interface do usuário, *middleware* e dispositivos. O *middleware* gerencia comunicação, segurança e armazenamento de dados, utilizando tecnologias como *React.js* para *front-end*, *Node.js* para *back-end*, e *ESP8266* para sensores, com protocolos *HTTP(S)*, *WebSocket* e *MQTT* para transmissão. A metodologia envolve revisão de trabalhos relacionados, design da arquitetura, implementação e validação em cenários de monitoramento de água, energia e lâmpadas, funcionando *offline*. Os resultados incluem latência baixa (1ms) e compatibilidade com múltiplos protocolos, otimizando recursos — extensível a contextos institucionais como UFMA para monitoramento e gerenciamento de energia com integração de emissões.

A revisão de [CHEIKH et al.\(2025\)](#) sobre energia, escalabilidade, gerenciamento de dados e segurança em IoT Massiva (MIoT) fornece um panorama essencial para a gestão integrada, destacando redes de baixa potência e ampla área (LPWANs) como NB-IoT e LoRaWAN, além de capacidades de 5G/6G, *edge* e *fog computing*. Os autores enfatizam estratégias avançadas, como alocação de recursos guiada por IA, aprendizado federado para análises preservadoras de privacidade e estruturas de segurança descentralizadas via *blockchain*, enquanto analisam práticas sustentáveis com colheita de energia para reduzir impactos ambientais. A análise comparativa identifica inovações críticas, como *slicing* de rede para escalabilidade e protocolos adaptativos para manipulação de dados em tempo real, posicionando o *GreenMonitoring* como uma evolução que integra esses elementos em contextos institucionais restritos.

Na Tabela 11, uma comparação entre abordagens de escalabilidade é apresentada, destacando as tecnologias utilizadas e suas contribuições. Os estudos são organizados por tecnologia (nuvem, contêineres, *AutoML*), métricas de desempenho e limitações, oferecendo uma visão clara das soluções aplicáveis ao *GreenMonitoring*.

Tabela 11 – Comparaçāo de abordagens para escalabilidade em sistemas IoT.

Tecnologia	Contribuição	Métricas	Limitações
<i>Docker</i>	Orquestração de serviços IoT	Redução de 40% no tempo de implantação	Configuração inicial complexa
<i>Apache Kafka</i>	Processamento de fluxos de dados	Suporte a 10.000 dispositivos	Latência em sistemas críticos
<i>AutoML</i>	Otimização de pipelines de ML	Redução de 25% no tempo de desenvolvimento	Dependência de dados de qualidade

A escalabilidade é um pilar para a viabilidade de soluções de IoT em grande escala. No estado da arte, a ampla adoção de contêineres (ex: Docker) e orquestradores para empacotar e gerenciar os microsserviços que compõem estas plataformas é revelada ([JAVED](#)

et al., 2020). A computação em nuvem, frequentemente combinada com ferramentas como *Apache Kafka* para o processamento de fluxos de dados em tempo real, permite que sistemas suportem milhares de dispositivos simultaneamente (BABAR; KHAN, 2021). Além disso, o surgimento de técnicas de AutoML promete democratizar e agilizar o desenvolvimento de modelos (MOIN, 2021).

Em um estudo recente, (BRITO, 2025) propôs o design e a implementação de uma API REST conteinerizada utilizando FastAPI e Docker, com o objetivo de servir modelos de *Machine Learning* de forma eficiente e observável. O autor destacou que a combinação dessas tecnologias — complementada pela instrumentação com ElasticAPM e armazenamento no Elasticsearch — permitiu a coleta em tempo real de métricas de desempenho, como latência e *throughput*, essenciais para operações de MLOps.

Essa abordagem não apenas facilita a implantação e o gerenciamento de microserviços, mas também viabiliza a integração contínua e o monitoramento detalhado do ciclo de vida dos modelos, reforçando a importância de escolhas tecnológicas alinhadas aos princípios de DevOps e MLOps.

Pontos positivos da *InterSCity*: Modularidade, escalabilidade horizontal, suporte a MQTT, *open-source*. Ponto negativo: Foco genérico em cidades inteligentes, sem especialização em energia ou nexo água-energia; complexidade de implantação (Kubernetes, múltiplos bancos).

3.2.5 Sustentabilidade e Eficiência Energética

A questão de pesquisa QP5 analisa o impacto das soluções existentes em sustentabilidade e eficiência energética, com foco em redução de emissões de CO₂ e alinhamento com os ODS. Estudos recentes destacam avanços e lacunas nesse domínio.

Um *framework* para monitoramento de emissões de CO₂ em cidades inteligentes, integrando sensores IoT e modelos de ML, foi desenvolvido (POYYAMOZHI et al., 2024). Emissões em 15% foram reduzidas por meio de otimização de perfis de carga, mas a falta de acessibilidade para usuários não técnicos foi identificada como uma limitação. Essa lacuna é abordada pelo *GreenMonitoring*, que prioriza interfaces acessíveis.

Uma plataforma para gestão de energia em edifícios inteligentes, utilizando medidores inteligentes e *Random Forest* para previsão de consumo, foi proposta (AHSAN et al., 2023). Economia de energia de 20% foi alcançada, mas desafios em interoperabilidade com sistemas legados foram enfrentados. O *GreenMonitoring* incorpora metamodelos MDE para mitigar esse problema.

A integração de geração distribuída em redes inteligentes, com foco em energia fotovoltaica, foi analisada (MOREIRA; MACKE, 2023). A dependência da rede em 25%

foi reduzida em edifícios com geração própria, mas a necessidade de soluções escaláveis para cidades maiores foi destacada.

A sustentabilidade institucional exige mais que monitoramento isolado: integração do nexo água-energia e escalabilidade para múltiplos locais são demandadas. Na literatura, otimizar esse nexo pode cortar desperdícios em 15–60%, pois 1 m³ de água quente equivale a 3–5 kWh (BROGGIO; SERRA; MATA-LIMA, 2025).

Contêineres como *Docker* reduzem tempos de implantação em 40% e facilitam orquestração (JAVED et al., 2020), enquanto o *Apache Kafka* gerencia fluxos de milhares de dispositivos (BABAR; KHAN, 2021). O *Automated Machine Learning* (AutoML) agiliza *pipelines* em 25% (MOIN, 2021). Contudo, essas arquiteturas frequentemente dependem de nuvens comerciais onerosas ou configurações complexas, inacessíveis a instituições públicas.

Nesse contexto, o framework de Rajule et al. (RAJULE et al., 2025a) emerge como uma referência notável ao enfatizar o GreenIoT, promovendo sustentabilidade através de otimizações que reduzem o consumo de energia em até 142% em poupança mensal (kWh/30 dias) e estendem a vida útil dos dispositivos para 210 dias, uma melhoria de 82,6% em relação a sistemas padrão. Seus resultados, validados em simulações, incluem uma taxa de throughput de 18,5 kbps (52,9% superior) e uma economia de 48,8% no consumo de bateria, alinhando-se diretamente aos objetivos de eficiência energética e redução de emissões.

A revisão de CHEIKH et al.(2025) sobre o panorama atual e direções futuras em energia, escalabilidade, gerenciamento de dados e segurança no MIoT complementa essa discussão, enfatizando a importância de práticas sustentáveis como a colheita de energia e tecnologias verdes para mitigar impactos ambientais. Os autores analisam redes LPWAN, capacidades de 5G/6G e arquiteturas de edge/fog, propondo estratégias como alocação de recursos guiada por IA e aprendizado federado para análises preservadoras de privacidade. Essa visão integrada reforça a necessidade de soluções resilientes que equilibrem desempenho, eficiência energética e segurança, alinhando-se aos objetivos do *GreenMonitoring* em promover eficiência energética em contextos institucionais.

3.3 Síntese

Na Tabela 12, as propostas são comparadas em termos de suporte a IoT, sensores, protocolos, ML, MDE, microserviços e escalabilidade. Além disso, as contribuições consolidadas na literatura são sintetizadas, formando a base tecnológica, mas falhando, em geral, na integração acessível e orientada ao contexto institucional.

Tabela 12 – Comparaçāo de soluções de monitoramento baseadas em IoT.

Proposta	IoT	Sensores	Protocolos	ML	MDE	Microserviços	Escalabilidade
(ELHABYB et al., 2024)	Parcial	Energia, Ocupação	N/A	LSTM, RF, GBR	Não	N/A	Média
(AL-DAILEH, 2021)	Sim	Legado	ZigBee, Z-Wave	Séries Temporais	Não	Sim	Alta
(ESPOSTE et al., 2017)	Sim	Genérico	MQTT, HTTP	Não	Não	Sim	Alta
(BARROS et al., 2025)	Sim	Corrente, Fluxo	MQTT	Não	Não	N/A	Limitada
(KAMIO et al., 2024)	Parcial	Elétricos	Modbus	LSTM+AG	Não	N/A	Baixa
(LIMA et al., 2020)	Não	Medidores	N/A	Não	Não	N/A	Média
(BORNIATTI et al., 2020)	Sim	Inteligentes	LoRa	Não	Não	N/A	Média
(BROGGIO; SERRA; MATA-LIMA, 2025)	Sim	Variados	Variados	Parcial	Não	N/A	Baixa
(POYYAMOZHI et al., 2024)	Sim	Temperatura, Ocupação	MQTT, CoAP	Parcial	Não	N/A	Média
(GARCÍA-MONGE et al., 2023)	Sim	CO ₂ , Temperatura	LoRa	Não	Não	N/A	Média
(RAO; SAHOO; YANINE, 2024)	Sim	Parâmetros PV	MQTT	SVR, MPC	Não	N/A	Média
(RAJULE et al., 2025b)	Sim	PIR, potência	LoRa	Estatístico	Sim	Não	Alta
(RIBEIRO, 2024)	Sim	N/A	MQTT, Kafka	N/A	N/A	N/A	Alta
(ESPOSTE et al., 2019)	Sim	N/A	N/A	N/A	N/A	Sim	Alta
(ZHOU et al., 2021)	Sim	Potência EV	N/A	LSTM	Não	N/A	Alta
(CHEIKH et al., 2025)	Sim	Genérico IoT	LPWAN	ML	Não	N/A	Alta
(CHUNG; YEUNG, 2020)	Não	N/A	N/A	Rregressão	Não	N/A	Média
(COSTA, 2022)	Sim	Corrente, Umidade	MQTT, HTTP	Não	Não	Sim	Alta
(ALSHIBANI, 2020)	Não	N/A	N/A	ANN	Não	N/A	Média
(RAJULE et al., 2025a)	Sim	Corrente, Tensão, PIR, Temp, Umidade, CO ₂	LoRaWAN	Estatístico, Anomalia	Não	N/A	Alta

ML*Machine Learning* — Aprendizado de Máquina**MDE***Model-Driven Engineering* — Engenharia Orientada a Modelos**MQTT***Message Queuing Telemetry Transport* — Protocolo leve de publicação/assinatura para IoT**PIR***Passive Infrared Sensor* — Sensor Infravermelho Passivo (detecção de movimento)**RF***Random Forest* — Floresta Aleatória**GBR***Gradient Boosting Regressor* — Regressor com Gradiente Boosting**LSTM***Long Short-Term Memory* — Memória de Longo e Curto Prazo (rede neural recorrente)**PV***Fotovoltaica* — Sistema de energia solar**Legenda: EV***Veículo Elétrico***AG***Algoritmo Genético***SVR***Support Vector Regression* — Regressão por Vetores de Suporte**MPC***Model Predictive Control* — Controle Preditivo Baseado em Modelo**ANN***Artificial Neural Network* — Rede Neural Artificial**LoRa***Long Range* — Tecnologia de comunicação de longo alcance e baixa potência**LoRaWAN***Long Range Wide Area Network* — Rede de área ampla de longo alcance**LPWAN***Low-Power Wide-Area Network* — Rede de área ampla de baixo consumo**N/A**

Não Aplicável ou Não Informado

Entre essas lacunas, destaca-se a falta de padronização, pois soluções como o I3SEM dependem de *middleware* complexo para a integração de dispositivos heterogêneos. Outro ponto crítico é o custo elevado, tornando sistemas SCADA comerciais economicamente inviáveis para instituições públicas. A ausência de explicabilidade também compromete a eficácia, uma vez que modelos ML do tipo *black-box* impedem ações corretivas fundamentadas. Além disso, a complexidade arquitetural representa um obstáculo significativo, como observado em plataformas como a *InterSCity*, que exigem configuração avançada envolvendo *Kubernetes* e múltiplos bancos de dados. Por fim, o foco limitado de estudos especializados em ML, como o de (ELHABYB et al., 2024), resulta na carência de uma arquitetura de integração completa.

O framework de RAJULE et al.(2025a) aborda várias dessas limitações ao propor uma solução GreenIoT completa, com detecção de anomalias na borda, comunicação LoRaWAN otimizada e amostragem adaptativa. Simulações mostram ganhos expressivos: redução de 48,8% no consumo, latência 39% menor, vida útil dos dispositivos dobrada e F1-Score de 0,925 na detecção de anomalias.

Outros trabalhos relevantes incluem ELHABYB et al.(2024), que validam LSTM e GBR em edifícios educacionais, ZHOU et al. (2021), com aplicação prática de LSTM no gerenciamento de veículos elétricos, e as arquiteturas escaláveis I3SEM e InterSCity, baseadas em microserviços e protocolo MQTT. CHEIKH et al. (2025) reforça essas contribuições ao mapear desafios em MIoT, propondo integrações de IA, blockchain e colheita de energia para soluções resilientes.

Apesar dos avanços, nenhuma proposta atual integra de forma coesa aprendizado de máquina, abstração via MDE e protocolo padronizado, mantendo acessibilidade e baixo custo institucional.

Diante das lacunas apontadas, como falta de acessibilidade e custo elevado, o próximo capítulo apresenta o GreenFramework, que integra MQTT, ML e microserviços para gestão sustentável, materializando os princípios arquiteturais da *InterSCity* com especialização energética e acessibilidade institucional. Para superar limitações remanescentes, o GreenMonitoring incorpora elementos inspirados em Rajule et al., como previsão com LSTM treinada em InfluxDB, cálculo de emissões de CO₂ via CO₂(kg) = P_{kWh} × F_{grid} (com F_{grid} = 0,432 kg CO₂/kWh para o Maranhão em 2024), controle ativo com relés LoRa para desligamentos automáticos e uma API aberta para integração com sistemas fotovoltaicos da UFMA, promovendo net-metering em tempo real.

4 Framework para Suporte ao Monitoramento de Energia Elétrica e Recursos Hídricos em Edifícios e Cidades Inteligentes

Neste capítulo, o *GreenFramework* é apresentado como um modelo arquitetural abstrato projetado para sistemas de monitoramento energético, inspirado na plataforma *InterSCity*. Inicialmente, a modelagem conceitual é descrita por meio de diagramas UML (*Unified Modeling Language*), a metodologia operacional, os protocolos de comunicação e a extensão para a aplicação concreta *GreenMonitoring*. A abordagem segue uma visão *top-down*, partindo de um *template* genérico para uma instância específica, com ênfase em modularidade, interoperabilidade e escalabilidade.

4.1 Identificação dos Requisitos para Monitoramento de Energia Elétrica e Recurso Hídricos

Com base no *InterSCity*, os requisitos para o *GreenFramework* foram definidos, como apresentados na Tabela 13.

Tabela 13 – Requisitos para monitoramento energético no *GreenFramework*.

Nº	Requisito	Descrição
(1)	Integração de dispositivos IoT heterogêneos	Capacidade de registrar e gerenciar sensores e atuadores variados, permitindo a coleta de dados energéticos como tensão, corrente e potência de fontes diversas.
(2)	Arquitetura modular baseada em microsserviços	Decomposição em serviços independentes para aquisição, processamento, armazenamento e visualização de dados, facilitando escalabilidade e manutenção.
(3)	Comunicação assíncrona e síncrona	Suporte a barramentos de mensagens (ex.: RabbitMQ) para eventos assíncronos e API REST para interações síncronas, garantindo fluxos de dados em tempo real.
(4)	Armazenamento e consulta de dados contextuais	Integração com bancos de dados para persistência de dados históricos, com filtros por <i>timestamp</i> , localização e tipo de recurso energético.
(5)	Descoberta de recursos <i>context-aware</i>	Busca sensível ao contexto para identificar e combinar recursos energéticos estáticos e dinâmicos, suportando aplicações como gerenciamento de energia renovável.
(6)	Visualização e análise gráfica	Ferramentas para exibir métricas energéticas, séries temporais e relatórios, com possibilidade de exportação para ferramentas externas.
(7)	Supporte a protocolos leves para IoT	Integração nativa com MQTT para dispositivos com restrições de recursos, melhorando vazão e reduzindo latência em cenários distribuídos.

Na Tabela 13, requisitos como integração de dispositivos, arquitetura modular, comunicação assíncrona/síncrona, armazenamento contextual, descoberta de recursos, visualização gráfica e suporte a protocolos leves são detalhados, orientando o desenvolvimento de uma arquitetura que combina flexibilidade, integração com dispositivos IoT e suporte a análises complexas, garantindo compatibilidade com as necessidades de monitoramento energético sustentável. As funcionalidades da *InterSCity* serviram como fundamento para o desenvolvimento do *GreenFramework*, oferecendo uma base consolidada para monitoramento em cidades inteligentes.

4.2 Modelagem Conceitual do *GreenFramework*

A modelagem conceitual estabelece a estrutura abstrata do *GreenFramework* por meio de diagramas UML que representam requisitos funcionais, estruturas estáticas, comportamentos dinâmicos e configurações de implantação. Essa modelagem garante, em geral, a reutilização do *framework* em diversos contextos de monitoramento energético, promovendo flexibilidade e escalabilidade.

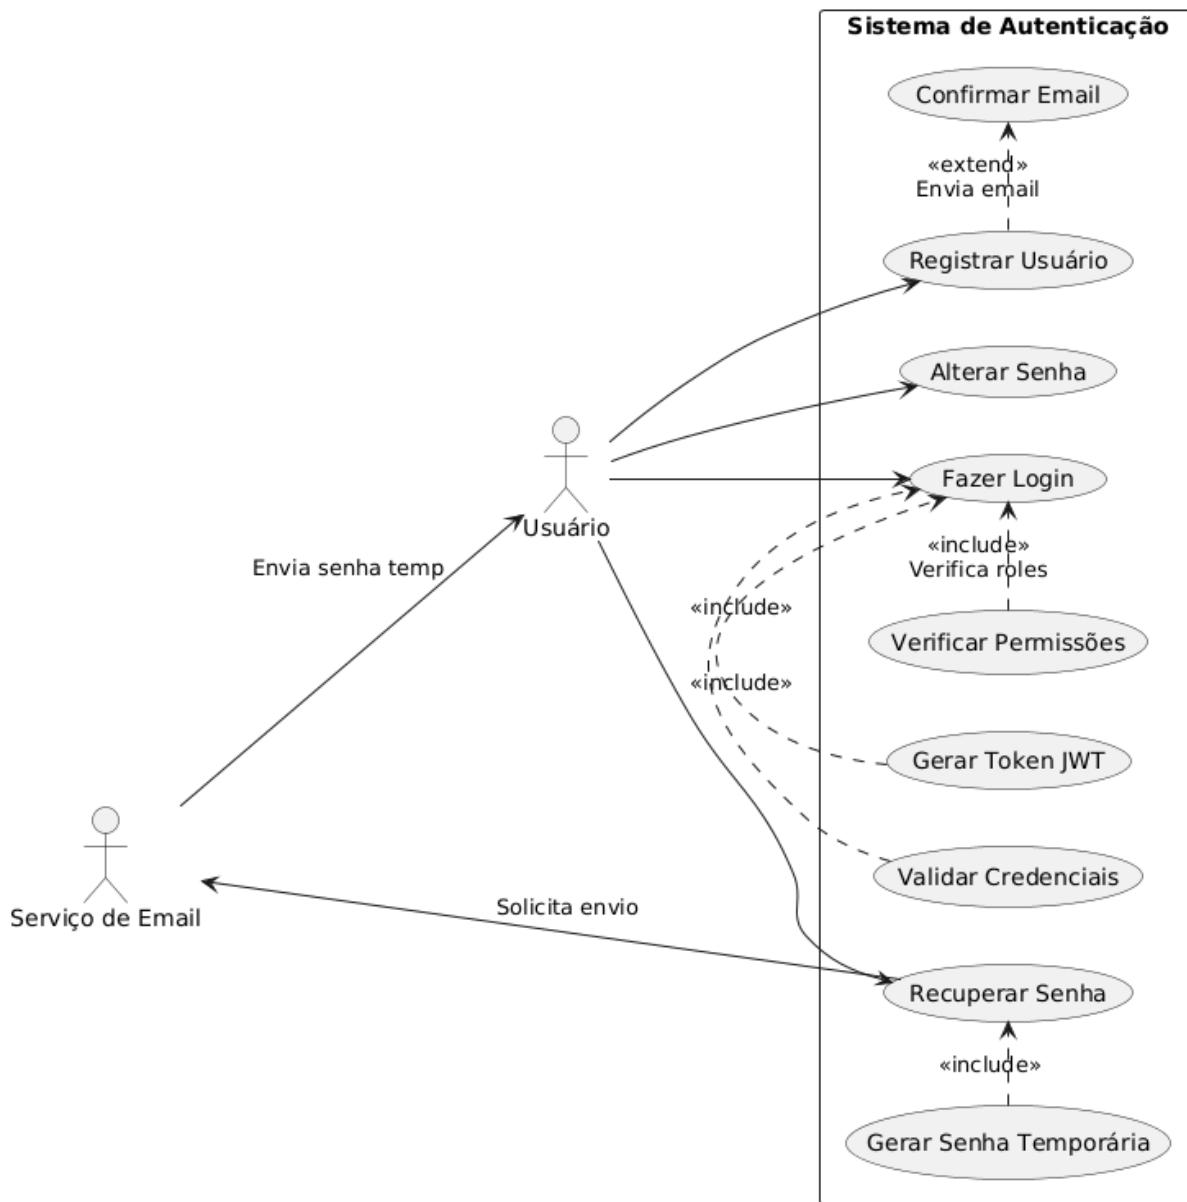
4.2.1 Diagrama de Casos de Uso

Os diagramas de casos de uso do sistema são apresentados a seguir, organizados em sequência lógica de interação. A sequência inicia com a autenticação, seguida pelo acesso aos dados de sensores, gerenciamento de tipos de sensores, registro de emissões, controle de acesso e, por fim, alertas e notificações (agrupados por proximidade funcional). Cada diagrama é referenciado e descrito individualmente.

Após autenticação bem-sucedida, torna-se disponível o acesso às funcionalidades principais do *GreenFramework*. A partir desse momento, é possível visualizar, criar, atualizar e excluir dados de sensores, com integração em tempo real por meio do protocolo MQTT. Quando uma mensagem MQTT chega ao sistema, o *payload* é validado e, de acordo com as regras previamente configuradas, alertas são gerados. Esses alertas são consolidados e disponibilizados imediatamente no módulo de notificações, que opera em integração direta com o processamento de alertas.

Na Figura 33, as interações entre os atores (Usuário Comum, Administrador e Sistemas Externos) e o *GreenFramework* são apresentados, incluindo autenticação, monitoramento em tempo real e análise de eficiência energética.

Figura 33 – Diagrama de casos de uso para autenticação no *GreenFramework*.



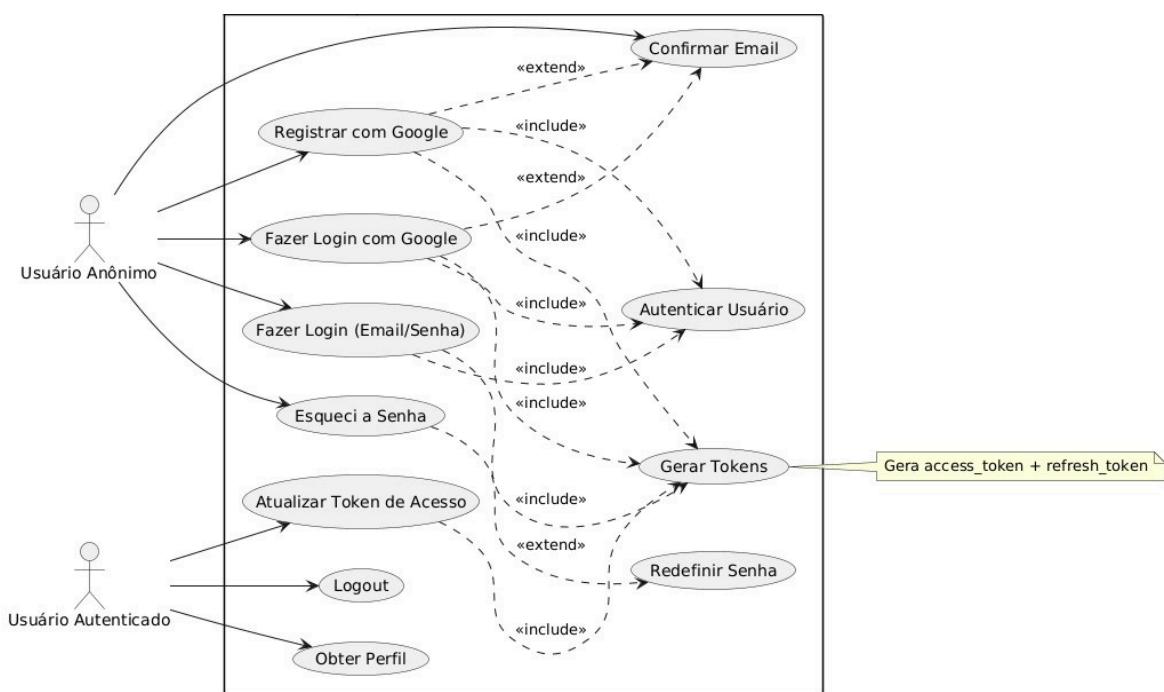
Fonte: Elaboração do autor.

O caso de uso **Fazer Login** inclui a verificação de papéis e permissões e a geração de *token* JWT. Os casos **Recuperar Senha** e **Registrar Usuário** também estão presentes, sendo o último responsável pelo envio de e-mail de confirmação por meio do sistema externo **Serviço de E-mail**.

Na Figura 34, o fluxo completo de autenticação é detalhado. O acesso pode ser realizado por credenciais tradicionais (e-mail e senha) ou por meio do protocolo *OAuth 2.0* com o provedor Google.

Essa escolha permite manter o processo de registro simples, rápido e seguro.

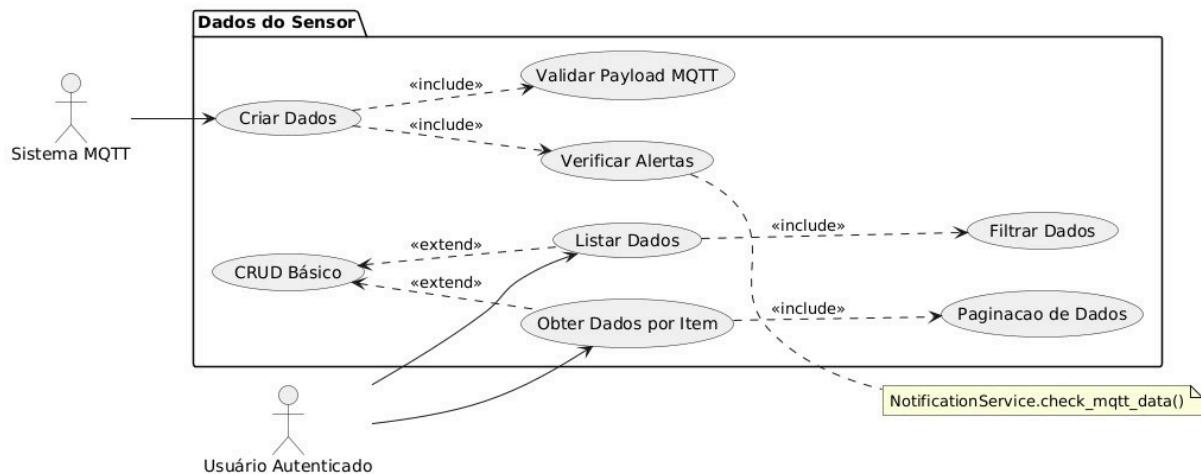
Figura 34 – Diagrama de Casos de Uso – Módulo de Autenticação



Fonte: Elaboração do autor.

Na Figura 35, o fluxo completo de CRUD para dados de sensores é detalhado, com integração via MQTT, validação de payload e suporte a paginação. A chegada de dados via MQTT dispara a verificação de alertas, que são gerados conforme regras configuradas e encaminhados diretamente ao módulo de notificações.

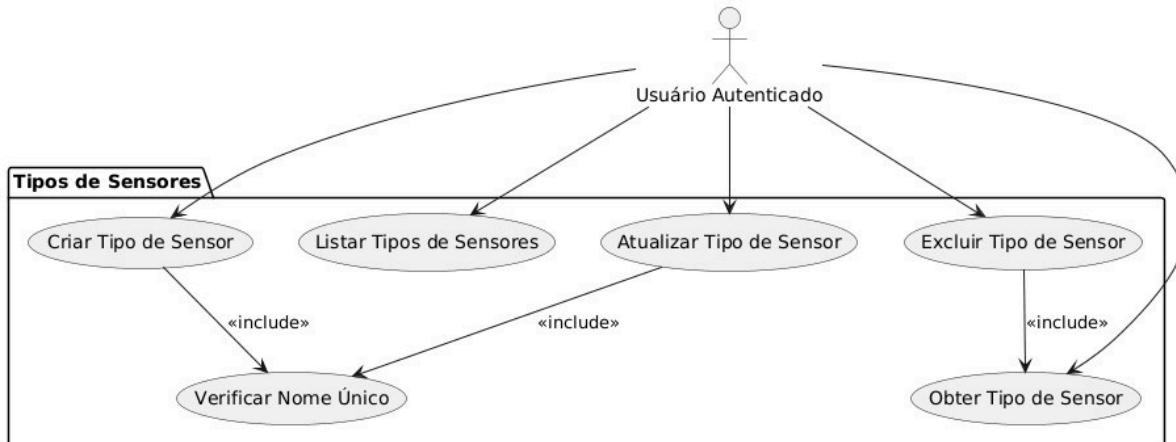
Figura 35 – Diagrama de Casos de Uso - Dados do Sensor (CRUD + MQTT)



Fonte: Autoria própria.

Após o gerenciamento de dados, o usuário pode consultar os tipos de sensores. Na Figura 36, as operações de criação, listagem, atualização e exclusão de tipos de sensores são apresentadas, com verificação de nome único e obtenção de detalhes.

Figura 36 – Diagrama de Casos de Uso - Tipos de Sensores



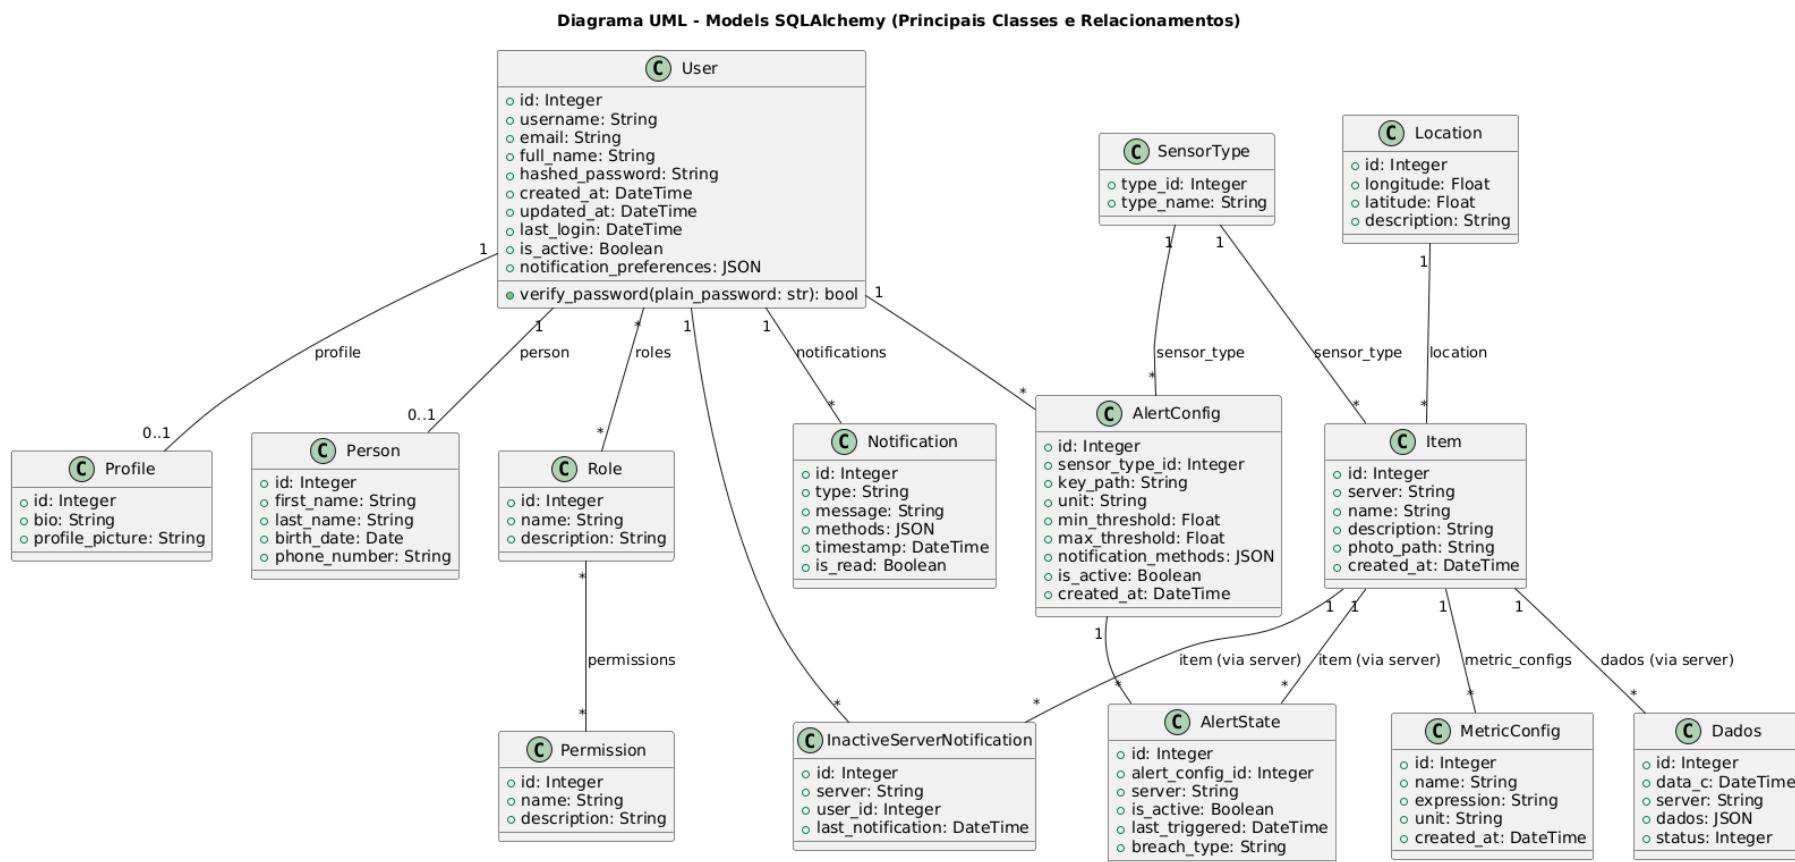
Fonte: Autoria própria.

4.2.2 Diagrama de Classes

Na Figura 37, o diagrama de classes é apresentado, definindo a estrutura estática do *GreenFramework* com base em um modelo de persistência implementado via SQLAlchemy. A organização centra-se no usuário, no gerenciamento de ativos monitorados e na detecção de anomalias, distribuindo as entidades em domínios logicamente coesos que minimizam o acoplamento e facilitam extensões.

No domínio de usuário e permissões, a entidade `User` atua como núcleo, armazenando informações de autenticação (`username`, `email`, `hashed_password`) e estado (`is_active`). Essa entidade mantém relacionamentos com `Person` (zero ou um), `Role` (um ou mais) e `Notification` (um ou mais). A entidade `Person` registra dados pessoais, enquanto `Role` define níveis de acesso associados a permissões específicas por meio de `Permission`. O `Profile` complementa com configurações e informações públicas do usuário.

Figura 37 – Diagrama de classes do *GreenFramework*.



Fonte: Autoria Própria.

O domínio de ativos e sensores organiza os elementos monitorados em torno da entidade **Item**, que representa medidores elétricos, edifícios ou outros equipamentos. Cada **Item** associa-se a uma **Location** (exatamente uma), contendo coordenadas geográficas (**latitude**, **longitude**) e descrição, e a múltiplos **SensorType**, que caracterizam os tipos de sensores vinculados.

No domínio de dados e configuração, a entidade **Dados** armazena as medições propriamente ditas, incluindo campos para consumo (**data_c**), energia (**data_e**) e **status**. A configuração das métricas ocorre por meio de **MetricConfig**, que define parâmetros de processamento.

O domínio de notificação e alerta estrutura a detecção de desvios por meio de **AlertConfig**, que especifica regras com limiares mínimo e máximo (**min_threshold**, **max_threshold**) e caminhos para os dados monitorados (**key_path**). Essa entidade vincula-se diretamente a **Item** e gera instâncias de **InactiveServerNotification**. O estado atual dos alertas é capturado em **AlertState**, com indicadores de atividade (**is_active**), último disparo (**last_triggered**) e tipo de violação (**breach_type**). As notificações destinadas aos usuários são registradas em **Notification**.

Essa arquitetura prioriza a coesão ao associar diretamente dados e alertas aos ativos monitorados, permitindo que o sistema adapte regras de monitoramento de forma dinâmica e escale conforme a complexidade do domínio energético.

4.2.3 Diagramas de Sequência

Os diagramas de sequência descrevem a dinâmica temporal do *GreenFramework*, detalhando a ordem de mensagens em fluxos como coleta, processamento de dados e autenticação.

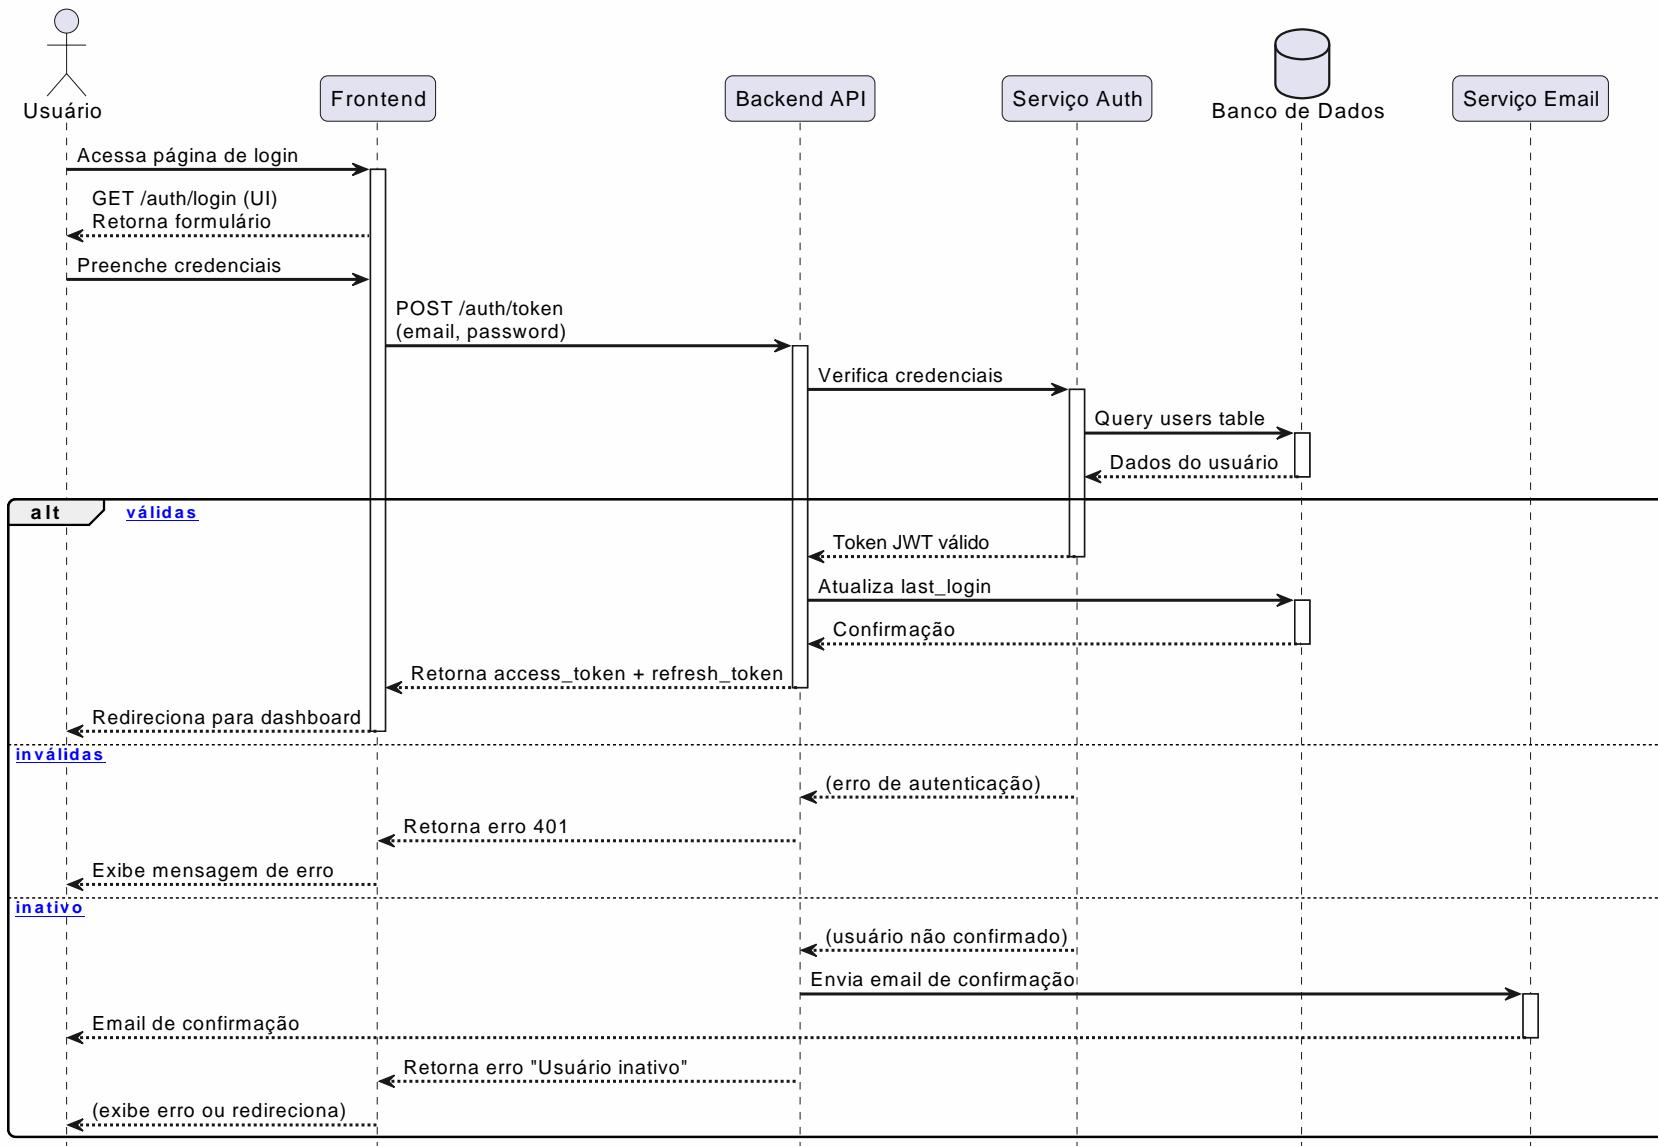
Na Figura 38, o diagrama de sequência para autenticação é ilustrado, iniciando com o **Usuário** submetendo credenciais via POST /auth/token à Backend API, que ativa o **Serviço Auth** para validação contra o Banco de Dados. O fluxo bifurca:

Em caso de sucesso, o **Serviço Auth** gera *token* JWT, atualiza o login no banco, e o **Frontend** recebe **access_token** e **refresh_token**, redirecionando ao *dashboard*.

Na falha por credenciais inválidas, retorna-se HTTP 401 Unauthorized, exibindo mensagem de erro no **Frontend**.

Quando o usuário está inativo, o **Serviço Auth** dispara e-mail de confirmação via **Serviço Email**, retorna erro de inatividade e bloqueia o acesso, com feedback adequado no **Frontend**.

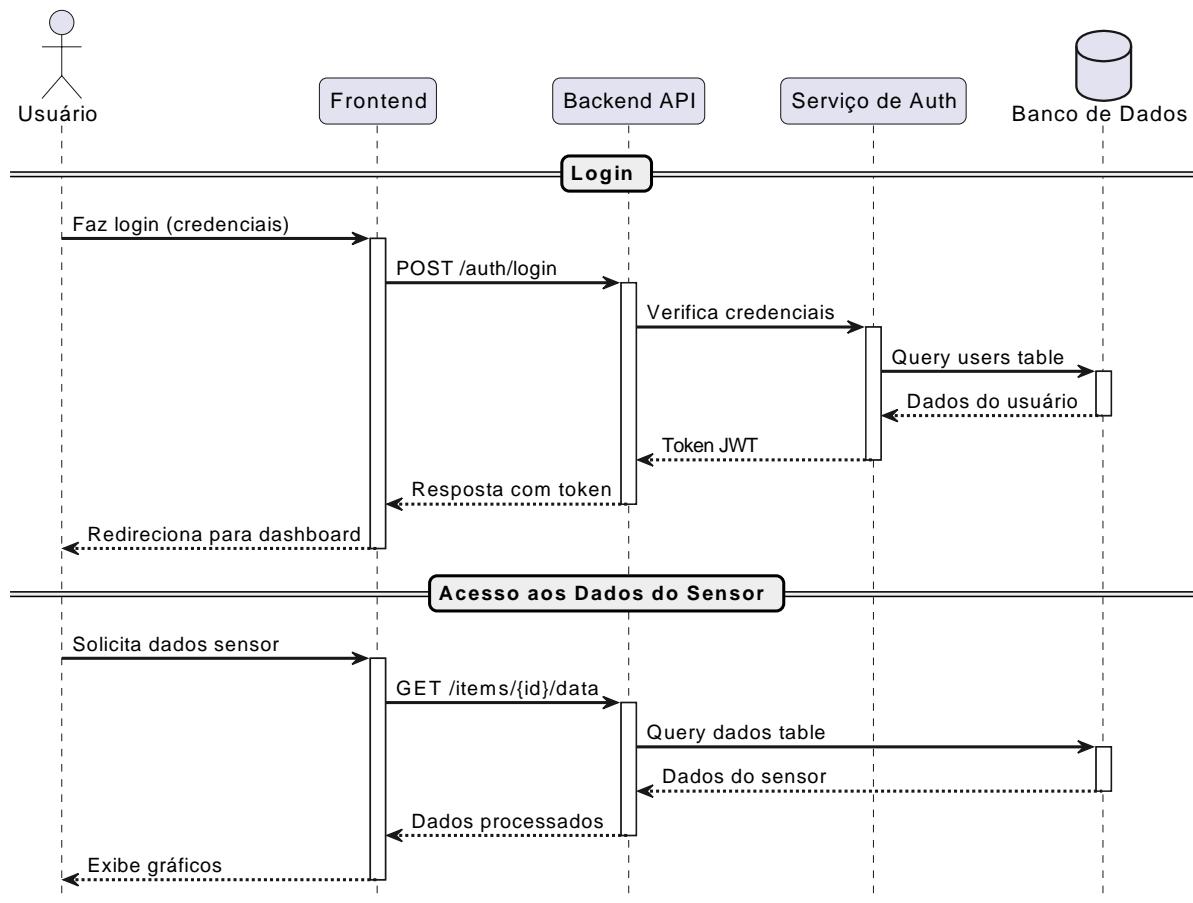
Figura 38 – Diagrama de sequência para autenticação no *GreenFramework*.



Fonte: Autoria Própria.

Na Figura 39, o fluxo geral desde o login até a visualização de dados é apresentado. O **Usuário** envia credenciais ao Frontend, que as encaminha via POST /auth/login à Backend API. Esta consulta o Serviço de Auth, verifica credenciais no Banco de Dados e emite *token* JWT. Com autenticação bem-sucedida, o Frontend redireciona ao *dashboard*. Em seguida, o **Usuário** solicita dados de sensor (GET /items/{id}/data); a Backend API recupera dados brutos, os processa e os retorna para exibição em gráficos.

Figura 39 – Diagrama de sequência geral do *GreenFramework*.

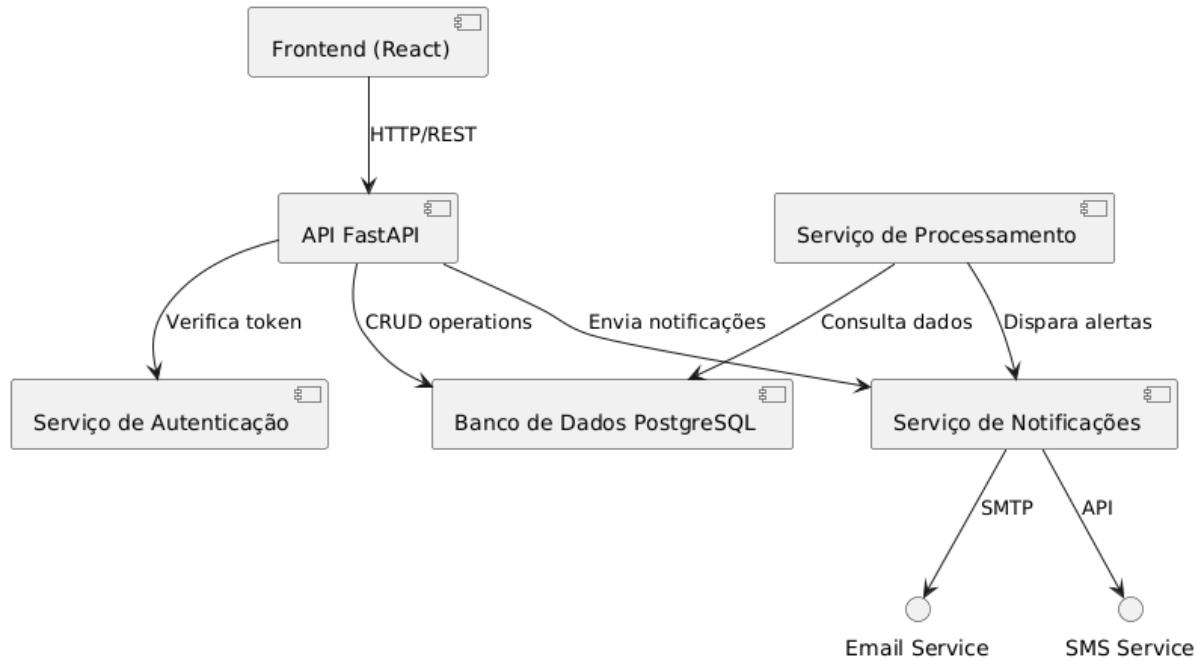


Fonte: Autoria Própria.

4.2.4 Arquitetura de Implantação

Na Figura 40, o diagrama de componentes é ilustrado, organizando o *GreenFramework* em módulos com dependências explícitas, reforçando a modularidade.

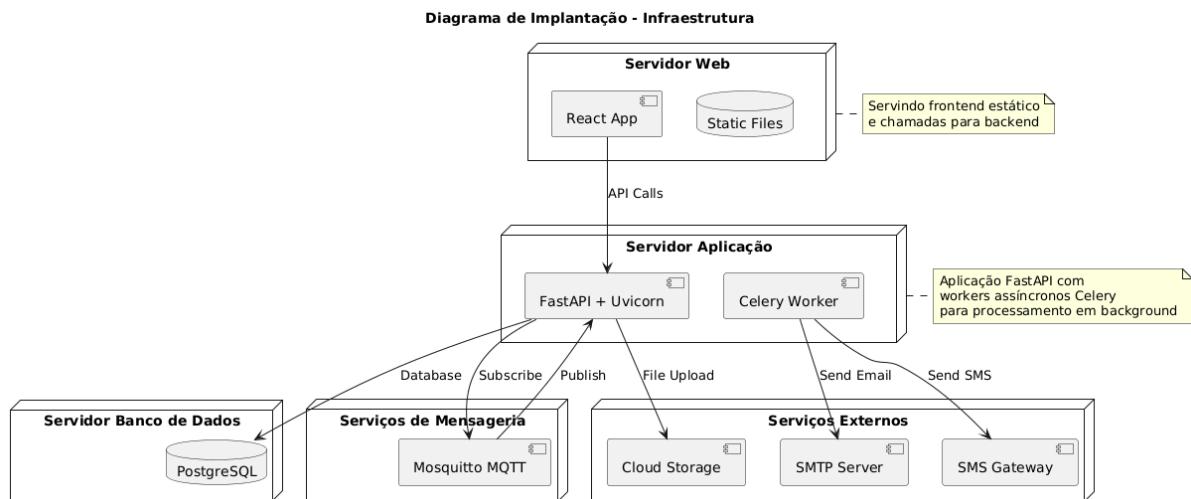
Figura 40 – Diagrama de componentes do *GreenFramework*.



Fonte: Autoria Própria.

Na Figura 41, o diagrama de implantação é delineado, representando a topologia lógica em ambientes distribuídos, compatível com *cloud* e *edge computing*.

Figura 41 – Diagrama de implantação lógica do *GreenFramework*.



Fonte: Autoria Própria.

O Servidor Web hospeda a aplicação *React* e arquivos estáticos, servindo a interface ao navegador e encaminhando chamadas API ao *backend*. O Servidor de Aplicação encapsula a lógica principal, utilizando *FastAPI* com *Uvicorn* para requisições síncronas e

Celery Worker para tarefas assíncronas em *background*. O Servidor de Banco de Dados persiste informações em PostgreSQL.

A comunicação assíncrona entre dispositivos e *backend* ocorre via *broker Mosquitto MQTT*, adotando o padrão *publish/subscribe*. Serviços externos complementam a infraestrutura: armazenamento em *cloud* para arquivos, servidor SMTP(*Simple Mail Transfer Protocol*) para e-mails e *gateway SMS* para notificações. Essa separação em nós independentes consolida uma arquitetura de microsserviços, favorecendo escalabilidade horizontal e manutenção isolada de componentes.

4.3 Extensão para o *GreenMonitoring*

O *GreenMonitoring* é uma instância do *GreenFramework*, especializada em monitoramento de energia elétrica e de água. A extensão adapta o modelo abstrato para requisitos específicos, incorporando:

- **Foco em Energia:** Monitoramento de variáveis como tensão, corrente e potência;
- **MQTT Central:** Uso do MQTT como protocolo principal, inspirado pela eficiência demonstrada na *InterSCity* ([CUNHA; BATISTA, 2022](#));
- **Análise Preditiva:** Integração de aprendizado de máquina para previsão de consumo;
- **Acessibilidade:** Interfaces simplificadas para usuários não técnicos.

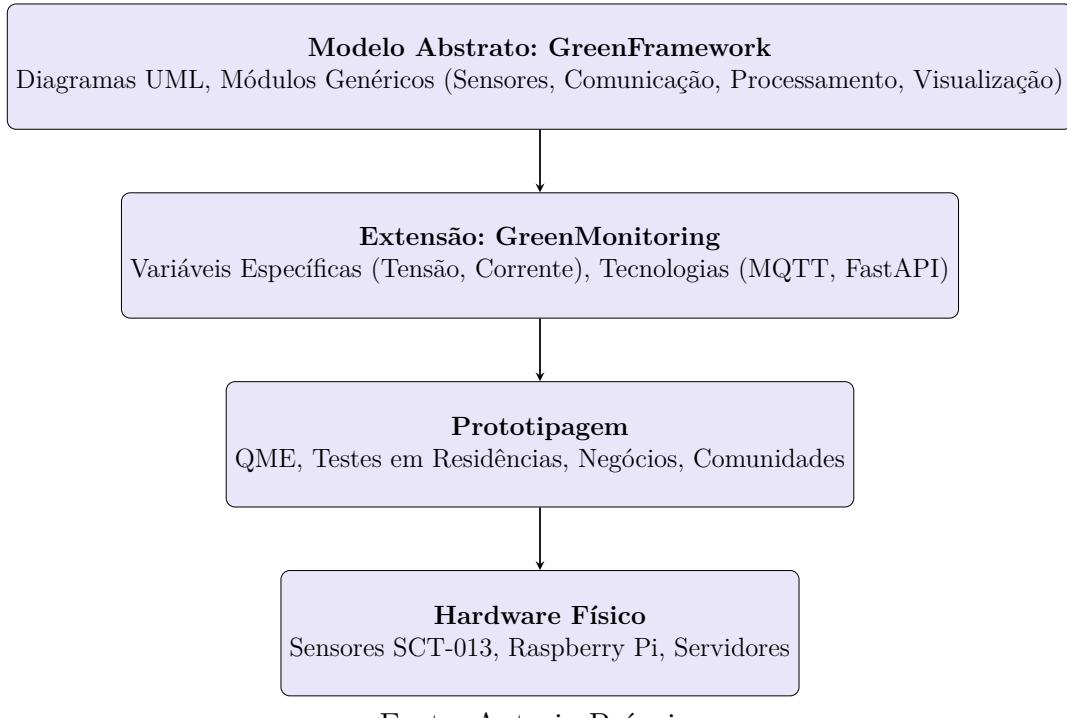
Na Tabela 14, os princípios da *InterSCity* são comparados com as adaptações no *GreenFramework*, destacando a especialização para monitoramento energético. Além disso, os conceitos como microsserviços, API REST, barramento de mensagens, abstração de recursos e descoberta são mapeados entre as plataformas, ilustrando a evolução.

Tabela 14 – Comparativo entre os princípios da *InterSCity* e o *GreenFramework*.

Conceito na <i>InterSCity</i>	Adaptação no <i>GreenFramework</i>
Microsserviços (<i>Resource Adaptor, Data Collector</i>)	Camadas Modulares (Aquisição, Processamento, Persistência, Visualização)
API REST para integração	API <i>RESTful</i> para consumo de dados de energia elétrica
Barramento <i>RabbitMQ</i>	Protocolo MQTT para comunicação assíncrona
Abstração de Recursos <i>Resource Discovery</i>	Entidades Genéricas (<i>Sensor, Dados</i>) Consultas por tempo, localização e tipo de sensor

Na Figura 42, a abordagem *top-down* é ilustrada, com camadas do modelo abstrato até o *hardware* físico, enfatizando a adaptabilidade do *GreenFramework* a diferentes escalas de implantação.

Figura 42 – Arquitetura *top-down* do *GreenFramework*.



Este capítulo apresentou o *GreenFramework* como uma arquitetura para sistemas de monitoramento, baseada na plataforma *InterSCity*. Por meio de diagramas UML, foram especificados os requisitos, a modelagem conceitual e a arquitetura de implantação. A extensão para o *GreenMonitoring* mostrou a adaptação do *framework* para aplicações de monitoramento de energia elétrica, com uso do protocolo MQTT e suporte a análises preditivas. No próximo capítulo, esta fundamentação será implementada na prototipagem do *GreenMonitoring*, com detalhamento das camadas de hardware, comunicação, persistência de dados, API e consumo, para validação em cenários reais de monitoramento na UFMA.

Fonte: Autoria Própria.

5 Prototipagem do *GreenMonitoring*

A implementação dos requisitos do *GreenFramework* na aplicação *GreenMonitoring* segue os princípios arquiteturais da *InterSCity* (ESPOSTE et al., 2017), com camadas definidas para escalabilidade, flexibilidade e processamento de dados. Cada componente é independente, o que facilita manutenção e extensão. Nesta seção, a estrutura da aplicação é descrita, iniciando pela arquitetura geral e prosseguindo pelas camadas específicas: *hardware*, comunicação, persistência de dados (banco de dados), *API* e consumo.

5.1 Arquitetura Geral do Sistema

Na arquitetura do *GreenMonitoring*, uma organização modular e escalável é adotada, centrada em três pilares principais: comunicação com dispositivos *IoT*, processamento e armazenamento de dados, e interfaces de saída para usuários. O *backend* atua como orquestrador central, recebendo dados de sensores remotos, enriquecendo-os com metadados e aplicando lógicas de análise para gerar *insights*. Essa estrutura é organizada em camadas com fluxo de dados vertical: Camada de *Hardware*, Camada de Comunicação, Camada de *Backend*, Camada de *API* e Camada de Consumo.

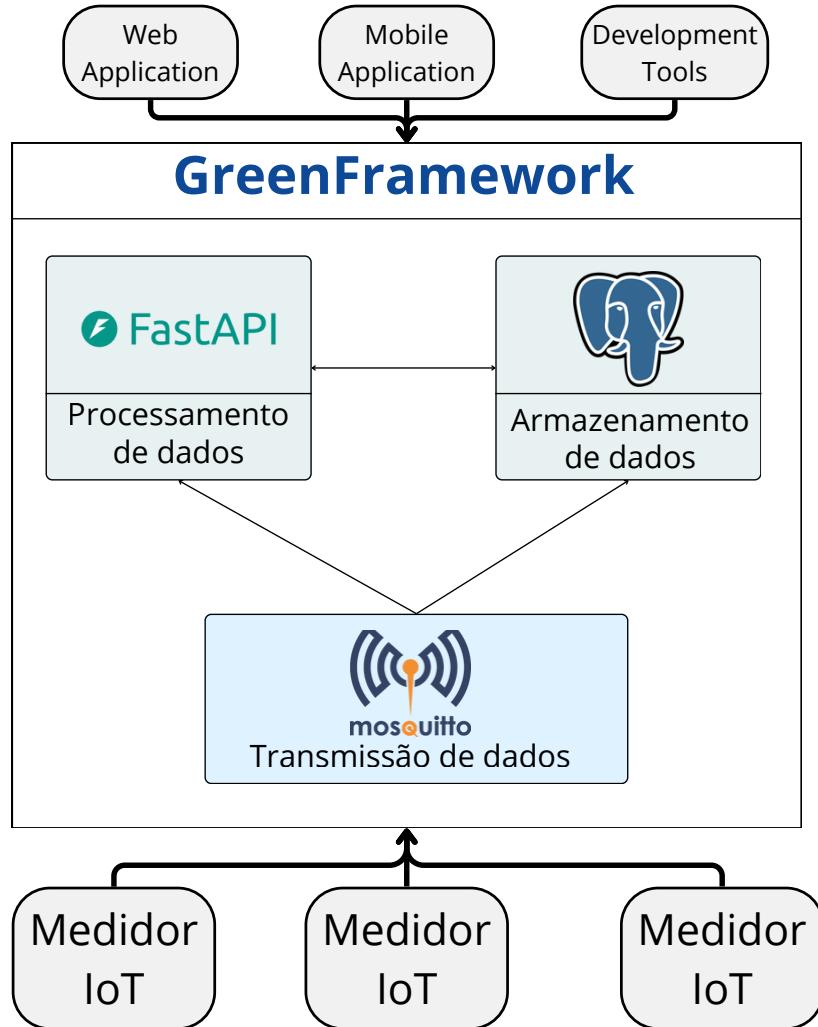
A implementação utiliza *Docker Compose*, com serviços modulares como *broker MQTT*, banco de dados *PostgreSQL* e *API FastAPI*. Na Tabela 15, os componentes do *GreenMonitoring* são comparados com os do *InterSCity*, explicando as adaptações para monitoramento energético. Nessa tabela, os componentes são organizados por equivalência, destacando como o *GreenMonitoring* especializa funcionalidades para dados energéticos, utilizando protocolos mais leves para dispositivos *IoT*.

Tabela 15 – Comparação entre componentes do *GreenMonitoring* e *InterSCity*.

Componente <i>GreenMonitoring</i>	Equivalente <i>InterSCity</i>	Adaptação para Monitoramento de Energia Elétrica
<i>API FastAPI</i>	<i>Resource Adaptor</i>	Especializado para dados energéticos e métricas de eficiência
<i>Broker MQTT</i>	<i>Message Bus (RabbitMQ)</i>	Protocolo mais leve para dispositivos <i>IoT</i> com restrições
<i>PostgreSQL</i>	<i>MongoDB</i>	Esquema relacional para consultas complexas de consumo

Os dados fluem dos sensores para as interfaces de usuário, passando por processamento, persistência e análise, como ilustrado na Figura 43.

Figura 43 – Arquitetura do sistema *GreenMonitoring*.



Fonte: Autoria Própria.

Na Figura 43, a organização em camadas é representada, destacando o fluxo vertical de dados desde a coleta nos dispositivos até o consumo por usuários. Essa abordagem garante isolamento entre componentes e facilita a implantação em ambientes de produção, alinhada à metodologia de microsserviços do *InterSCity*.

A orquestração dos microsserviços é realizada via *Docker Compose*, garantindo isolamento e portabilidade. No Código 1, o arquivo `docker-compose.yml` é apresentado, configurando os serviços essenciais, como *API*, banco de dados e *broker MQTT*, com mapeamento de portas (ex.: 8000 para a *API*, 5432 para o *PostgreSQL*, 1883 e 8883 para o *MQTT*) e volumes para persistência de dados. A rede compartilhada (*REDE*) facilita a comunicação interna entre contêineres.

Código 1 Configuração do *Docker Compose* para o *GreenMonitoring*.

```

1 services:
2   api:
3     build: ./  

4     ports: ["8000:8000"]
5     depends_on: [db]
6     networks: [REDE]
7   db:
8     image: postgres:latest
9     environment:
10       POSTGRES_USER: emap
11       POSTGRES_PASSWORD: emap
12       POSTGRES_DB: emap
13     ports: ['5432:5432']
14     volumes: [pgdata:/var/lib/postgresql/data]
15     networks: [REDE]
16   mqtt5:
17     image: eclipse-mosquitto
18     ports: ["1883:1883", "8883:8883"]
19     volumes: [.. mqtt_broker/config:/mosquitto/config:rw]
20     networks: [REDE]
```

O *broker MQTT* é iniciado via *Docker*, com portas para comunicação segura (8883 com *TLS*) e não segura (1883), e volumes para configurações persistentes. Essa estrutura suporta o fluxo de dados desde a coleta até o consumo, promovendo resiliência e escalabilidade.

5.2 Camada de *Hardware*

Na Camada de *Hardware*, dados de dispositivos *IoT*, como medidores de energia e fluxo de água, são coletados. Os dados são formatados em *JSON* genérico, com campos *id* (identificador do sensor), *server* (identificador do servidor) e *dados* (objeto com pares chave-valor para medições, incluindo *value* e *unit*). Essa estrutura permite que chaves em *dados* variem por tipo de sensor, com tipificação resolvida no *backend* via relacionamentos no banco de dados.

A estrutura de mensagens segue um formato *JSON* genérico, como template:

```
{
  "id": "<id_do_sensor>",
  "server": "<nome_do_servidor>",
  "dados": {
```

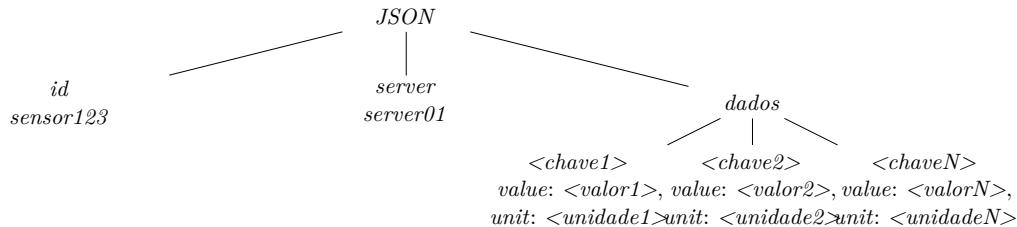
```

    "<chave1>": {"value": <valor1>, "unit": "<unidade1>"},
    "<chave2>": {"value": <valor2>, "unit": "<unidade2>"},
    "<chaveN>": {"value": <valorN>, "unit": "<unidadeN>"}
}
}

```

Na Figura 44, a representação hierárquica da estrutura *JSON* genérica é observada, destacando-se como essa padronização facilita a análise de dados energéticos. Nessa figura, a árvore ilustra os nós principais (*id*, *server*, *dados*) e a flexibilidade das subchaves em *dados*, permitindo adaptação a diferentes tipos de sensores sem alterar o esquema principal.

Figura 44 – Árvore hierárquica da estrutura *JSON* genérica.



Fonte: Autoria Própria.

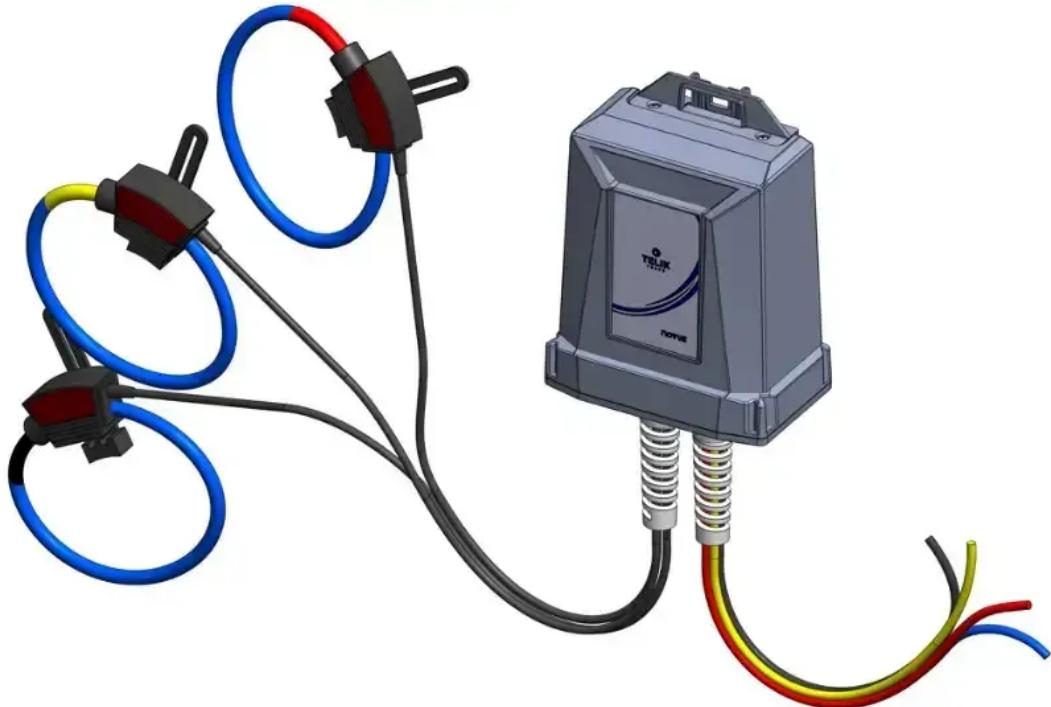
5.2.1 Medidor Telik Trafo para Medição de Energia Elétrica

O medidor Telik Trafo é um dispositivo trifásico projetado para monitoramento de energia elétrica em redes de baixa tensão (até 380V), com precisão classe 0,5S (Classe A conforme IEC 61000-4-30 e precisão de instrumento conforme IEC 62053-22, erro $\leq 0,5\%$ até 2% em condições nominais) conforme a Resolução Normativa nº 1.000/2021 da ANEEL. Por meio de transformadores de corrente (TC) e tensão (TP) integrados, variáveis como tensão (V), corrente (A), potência ativa (kW), potência reativa (kVAr), fator de potência e energia acumulada (kWh) são capturados.

Na Figura 45 é apresentada a visão geral do medidor Telik Trafo, destacando sua estrutura modular: módulo principal de processamento (em azul), transformadores de corrente coloridos (vermelho para fase A, amarelo para B, azul para C) e conexões de saída. Essa configuração facilita a instalação em quadros de medição de energia (QME), como os implementados na UFMA.

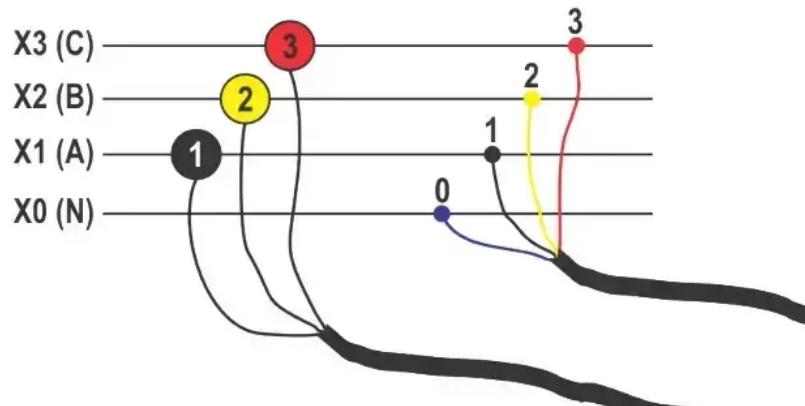
O processo de medição é realizado da seguinte forma: os transformadores de corrente (TCs) medem a corrente alternada das fases, convertendo-a em sinais proporcionais (ex.: 5 A para 5 mA). Os sinais são processados pelo microcontrolador interno, que aplica algoritmos de valor eficaz (*RMS*) e integra a potência instantânea $p(t) = v(t) \cdot i(t)$ ao longo do tempo para obter a energia $w = \int p(t) dt$.

Figura 45 – Visão geral do medidor Telik Trafo.



Fonte: Adaptado do fabricante.

A identificação das bobinas é facilitada pela coloração padrão (vermelho: fase A; amarelo: fase B; azul: fase C), evitando erros de fase. A conexão segue o diagrama ilustrado na Figura 46, que detalha a ligação das saídas X0 (neutro, N) a X3 (fase C) aos terminais do *gateway*, com isolamento galvânico garantido por divisores resistivos e amplificadores diferenciais.

Figura 46 – Conexão do medidor de energia ao *gateway IoT*.

Fonte: Autoria Própria.

Essa configuração permite medições trifásicas balanceadas com precisão de $\pm 0,5\%$, conforme validado em testes laboratoriais.

O Telik Trafo realiza medições diretas de:

- **Tensão trifásica** (em volts, V);
- **Corrente indireta** (em amperes, A), via bobinas de Rogowski;
- **Frequência** (em hertz, Hz).

A partir dessas grandezas, são calculadas:

- **Potência ativa** (kW), **reativa** (kVAr) e **aparente** (kVA) em 3 fases;
- **Fator de potência** ($3\emptyset$ e total);
- **Energias ativa, reativa capacitiva e indutiva** (kWh e kVAh), em fluxos **direto** e **reverso**.

Essas medições suportam operação em **quatro quadrantes**, essencial para prédios com geração distribuída (ex.: painéis solares), permitindo registrar tanto consumo quanto injeção de energia na rede.

O medidor possui:

- **3 canais de tensão** (referenciados ao neutro) e **3 canais de corrente** (medição indireta);
- **Faixa de Medição de Corrente:** 0,1 A a 500 A (via Bobinas de Rogowski);
- **Resolução:** 0,01 V e 0,01 A;
- **Frequência nominal:** configurável para 50 Hz ou 60 Hz;
- **Memória:** até 13.000 registros (45 dias a cada 5 minutos);
- **Intervalo de registro:** configurável (padrão: 5 min), com memória circular;
- **Comunicação:** módulo celular (LTE Cat M1, NB-IoT, 2G) ou *Wi-Fi*, com interface *web*;
- **Alimentação:** 85–285 Vca (fase-neutro), com *backup* para *last gasp*;
- **Alojamento:** policarbonato antichama (V0), anti-UV, com **IP65**;
- **Dimensões:** 202 × 143 × 85 mm.

Os medidores Telik Trafo utilizados — identificados pelos *IDs* 23299984, 23299968, 23300023, 23300013, 23299982 e 23299981 — capturam métricas: tensão por fase (\approx 233 V), corrente (50 a 90 A), fator de potência, potência ativa/aparente/reativa, frequência (\approx 60 Hz) e energia acumulada (direta/reversa). Um exemplo de *payload* complexo é apresentado no Código 2.

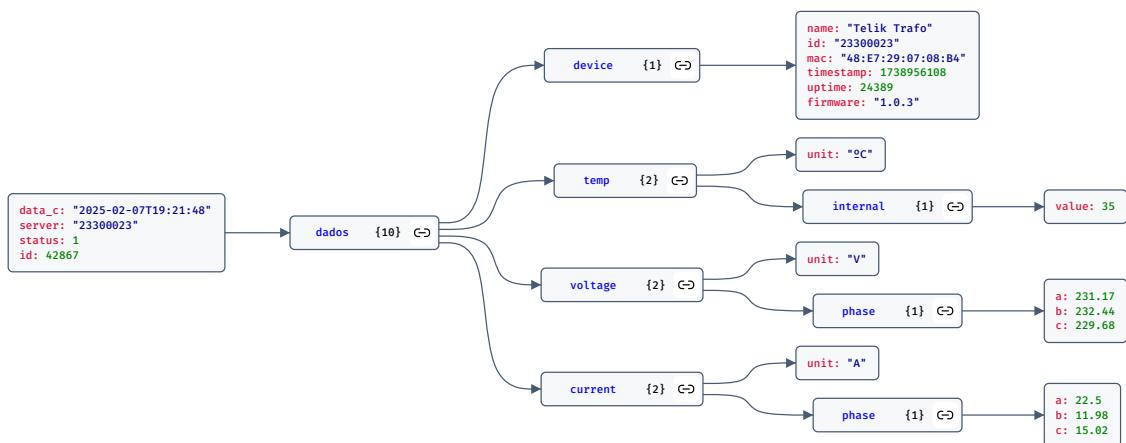
Código 2 Exemplo de *payload* complexo de medidor de energia.

```

1  {
2      "device": {
3          "name": "Telik Trafo",
4          "id": "23300023",
5          "mac": "48:E7:29:07:08:B4",
6          "timestamp": 1738956048,
7          "uptime": 24329,
8          "firmware": "1.0.3"
9      },
10     "voltage": {
11         "phase": { "a": 230.67, "b": 232.57, "c": 229.88 },
12         "unit": "V"
13     },
14     "current": {
15         "phase": { "a": 28.48, "b": 11.93, "c": 14.99 },
16         "unit": "A"
17     }
18 }
```

A estrutura hierárquica desse *payload* é ilustrada na Figura 47, destacando a profundidade das métricas capturadas.

Figura 47 – Árvore hierárquica da estrutura *JSON* para um medidor de energia.



Fonte: Autoria Própria.

5.2.2 Medição de Água com Sensores de Vazão

A medição de recursos hídricos é realizada por sensores de vazão por pulso (modelo YF-S201) ou ultrassônicos, integrados ao *GreenFramework* para monitoramento contínuo em edifícios. O princípio de funcionamento baseia-se na geração de pulsos por litro: cada passagem de fluido produz uma interrupção magnética ou óptica (ex.: 2,25 mL/pulso). O sinal é processado como interrupção digital no microcontrolador ATmega328P, presente na placa de desenvolvimento Arduino Uno, que conta os pulsos em intervalos de tempo para calcular a vazão conforme a Equação (5.1).

$$Q = \frac{N_p \cdot V_p}{t} \quad (5.1)$$

em que N_p é o número de pulsos, V_p o volume por pulso e t o tempo.

Na Figura 48 é apresentado um exemplo real de medidor de água instalado em campo — modelo ZLW-3 da Eletra, com classe C ($Q_n = 1,5 \text{ m}^3/\text{h}$) e comunicação ZLINK — utilizado como referência para integração com sensores de pulso.

Figura 48 – Medidor de água ZLW-3 (Eletra) instalado em campo, com *display* de volume e vazão.



Fonte: Autoria Própria.

O *display* mostra volume total acumulado (3392 m^3) e vazão instantânea ($0,1625\text{ m}^3/\text{h}$), com lacre de segurança e caixa de proteção contra intempéries. Esse tipo de medidor, comum em redes públicas e institucionais, permite a extração de pulsos por meio de sensores externos acoplados magneticamente ou por leitura óptica, compatível com a arquitetura proposta.

A comunicação Zlink é um padrão da Eletra focado na telemetria de medidores de utilidades. Em modelos como o ZLW-3, o Zlink se manifesta por uma saída de pulso de baixa frequência acessível a dispositivos externos. O princípio de operação para a aquisição de dados no *GreenFramework* é o seguinte:

- **Geração do Pulso:** A cada incremento de volume registrado (ex.: 1 litro), o medidor aciona um mecanismo interno (*reed switch* ou sensor óptico). Essa ação é traduzida na saída Zlink como um pulso em modo *pull-down* (puxando o sinal para o nível lógico baixo, ou GND).
- **Aquisição por Interrupção:** O sinal do Zlink é conectado a um pino de Interrupção Externa (ex.: INT0) do microcontrolador. A interrupção é configurada para disparar na borda de descida (transição de alto para baixo) do pulso, garantindo que a contagem seja precisa e que o microcontrolador não precise monitorar o pino continuamente (*polling*).
- **Processamento de Dados:** Dentro da Rotina de Serviço de Interrupção (ISR), um contador de pulsos é incrementado. O microcontrolador utiliza o número de pulsos acumulados em um intervalo de tempo predefinido para calcular a vazão média e o volume total, conforme demonstrado na Equação (5.1).

A conexão do sensor segue o diagrama apresentado na Figura 46: sinal de pulso (pino amarelo) ao pino digital 2 (interrupção INT0), alimentação em 5 V (vermelho) e *ground* (preto). Filtros de *debouncing* com limiar de 50 ms são aplicados para eliminar ruído. Um exemplo de *payload* simples é mostrado no Código 3.

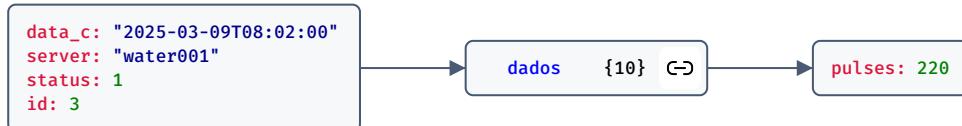
Código 3 Exemplo de *payload* simples de medidor de água.

```

1 {
2   "device": {
3     "id": "water002",
4     "timestamp": 1741572060
5   },
6   "pulses": 120
7 }
```

A estrutura desse *payload* é representada na Figura 49.

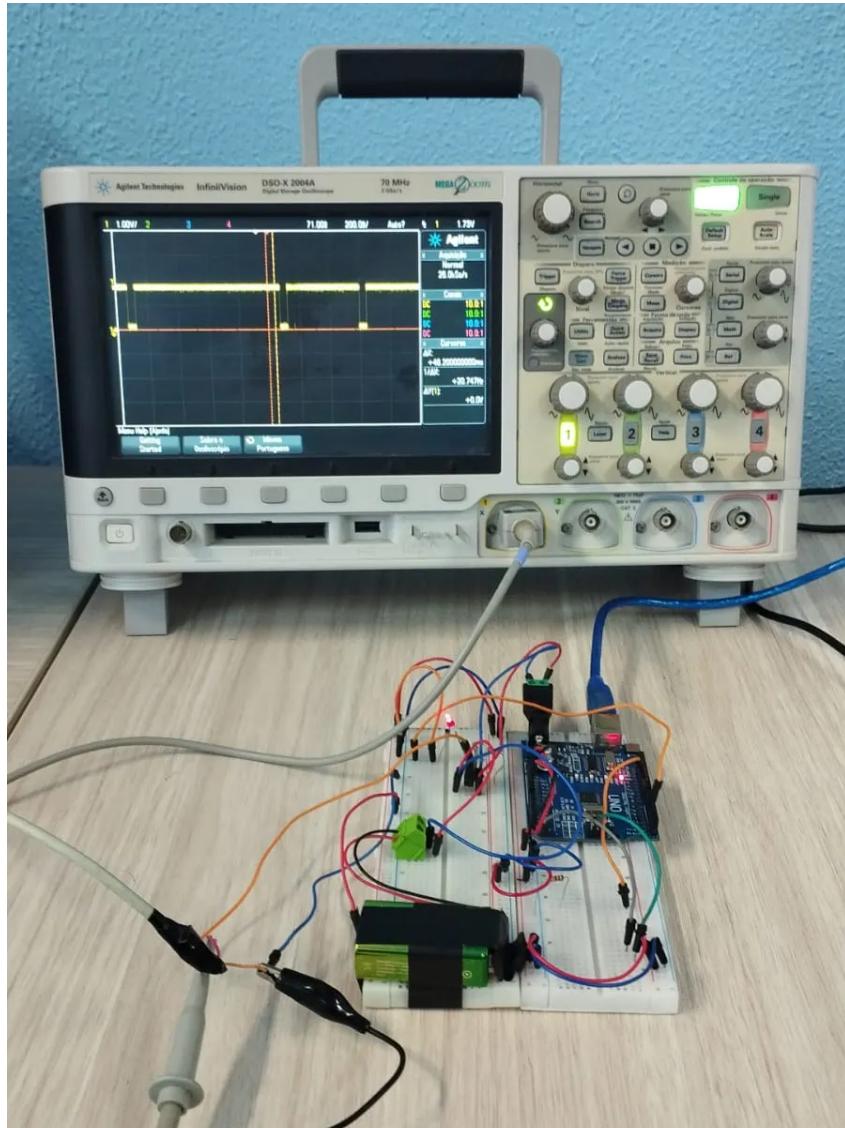
Figura 49 – Árvore hierárquica da estrutura *JSON* para um medidor de água.



Fonte: Autoria Própria.

Para validação, o sinal de pulso foi capturado em osciloscópio Agilent InfiniVision DSO-X 2004A (70 MHz), como ilustrado na Figura 50. Transições de 0 a 5 V com frequência proporcional à vazão (ex.: 10 Hz para 1 L/min) foram observadas.

Figura 50 – Sinal de pulso do sensor de vazão capturado em osciloscópio.



Fonte: Autoria Própria.

Os sensores publicam dados em tópicos *MQTT* como */sensors/server01/energia* ou */sensors/server01/agua*, com *QoS* 1. A flexibilidade do *JSON* permite integração de novos dispositivos sem alterações no esquema, com acesso via notação de ponto (ex.: *dados.tensao.value*). Os *payloads* são armazenados no campo *dados* *JSON* da tabela *Dados*, com consultas via operadores *JSON* do *PostgreSQL*.

Atendimento aos Requisitos:

- **RF-04** (Comunicação *IoT*): Suporte a *MQTT* para dispositivos;
- **RF-05** (Tempo Real): Processamento imediato de dados;
- **RF-06** (Escalabilidade): Arquitetura *pub/sub* para múltiplos sensores.

Essa camada corresponde ao *Data Collector* da plataforma *InterSCity*, adaptada para métricas energéticas e hídricas.

5.3 Camada de Comunicação

Na Camada de Comunicação, o protocolo *MQTT* é utilizado, implementado com o *broker Mosquitto*, no modelo *publish/subscribe*, criado via *Docker Compose*. Os sensores (*publishers*) enviam dados *JSON* para tópicos hierárquicos (ex.: */sensors/server01/energia*), enquanto o *gateway (subscriber)* processa as mensagens e as encaminha ao *backend*. O processamento é modular: conexão persistente com reconexão automática, roteamento por tópico e validação. O fluxo inicia com *publishers* enviando dados; o *subscriber* parseia *JSON*, normaliza *timestamps* e persiste via *API*. A estrutura de dados é genérica, com *QoS* configurável, como detalhado na Tabela 16.

Na Tabela 16, os níveis de *Quality of Service* (*QoS*) no *MQTT* são listados, com descrições de cada nível, nas quais sua aplicação em diferentes cenários é destacada. Nessa tabela, os *trade-offs* entre confiabilidade e overhead são explicados, sendo o *QoS* 1 o padrão utilizado no *GreenMonitoring* para equilíbrio em monitoramento energético.

Tabela 16 – Níveis de *Quality of Service* (*QoS*) no *MQTT*.

Nível <i>QoS</i>	Descrição
<i>QoS</i> 0	Entrega “no máximo uma vez”, sem confirmação, ideal para dados não críticos.
<i>QoS</i> 1	Entrega “pelo menos uma vez”, com confirmação, adequada para monitoramento energético.
<i>QoS</i> 2	Entrega “exatamente uma vez”, com <i>handshake</i> de quatro passos, para aplicações críticas.

O sistema utiliza o *broker* “`mqtt5`”, operando na porta padrão 1883 (*MQTT* sobre *TCP*), que atua como intermediário no modelo *publish-subscribe*. Os dispositivos publicam mensagens em tópicos hierárquicos, enquanto o *backend* subscreve para recebê-las.

O cliente *MQTT* implementa um padrão de *Observer* onde se inscreve em tópicos específicos e reage a mensagens de forma assíncrona, garantindo baixa latência e alta disponibilidade, como mostrado no Código 4. Nesse código, o *broker* (ex.: “`mqtt5`” na porta 1883) é configurado, *callbacks* para conexão e mensagens são definidos, e reconexão automática em *loop* é implementada, utilizando variáveis de ambiente para flexibilidade.

A separação do cliente *MQTT* em *thread* independente garante que a *API REST* permaneça responsiva mesmo sob carga intensa de mensagens *IoT*. O mecanismo de reconexão automática assegura alta disponibilidade, crítica para sistemas de monitoramento em tempo real.

A segurança é assegurada por *Transport Layer Security (TLS)* na porta 8883, com autenticação via *JSON Web Tokens (JWT)*.

Código 4 Configuração, inicialização e processamento de mensagens do cliente *MQTT*.

```

1 BROKER = os.getenv("MQTT_BROKER", "mqtt5") # Nome do container Docker
2 PORT = int(os.getenv("MQTT_PORT", 1883))
3 TOPIC = os.getenv("MQTT_TOPIC")
4 USER = os.getenv("MQTT_USER")
5 PASSWORD = os.getenv("MQTT_PASSWORD")
6
7 def connect_mqtt() -> None:
8     mqtt_client = mqtt.Client(client_id="green_monitoring_subscriber")
9     # Configuração dos callbacks para eventos MQTT
10    mqtt_client.on_connect = on_connect
11    mqtt_client.on_message = on_message
12    mqtt_client.username_pw_set(USER, PASSWORD)
13    # Loop infinito de tentativas de conexão
14    while True:
15        try:
16            mqtt_client.connect(BROKER, PORT, keepalive=60)
17            mqtt_client.loop_start() # Thread não-bloqueante
18            logger.info(f"Conexão MQTT estabelecida com {BROKER}:{PORT}")
19            break
20        except Exception as e:
21            logger.error(f"Falha na conexão MQTT: {str(e)} - Retentando em
22                         ↪ 5s")
23            time.sleep(5)
24    def start_mqtt_client() -> None:
25        thread = threading.Thread(target=connect_mqtt, daemon=True)
26        thread.start()
        logger.info("Thread do cliente MQTT iniciada")

```

O processamento de mensagens *MQTT* é baseado no padrão *Strategy*, permitindo tratamento dinâmico de diferentes tipos de mensagens com base no tópico. O *handler* principal atua como uma máquina de estados, roteando mensagens para funções específicas de forma assíncrona, garantindo escalabilidade e baixa latência, como ilustrado no Código 5. Nesse código, o *payload JSON* é decodificado, um dicionário de *handlers* para roteamento por padrões de tópicos é utilizado, e exceções são tratadas para robustez.

Código 5 Handler principal de mensagens *MQTT*.

```

1 def on_message(client: mqtt.Client, userdata: Any, msg: mqtt.MQTTMessage) ->
2     None:
3         """
4             Callback para mensagens MQTT recebidas. Roteia mensagens com base no
5                 tópico.
6             """
7
8     try:
9         payload = msg.payload.decode("utf-8")
10        data = json.loads(payload)
11        logger.debug(f"Mensagem recebida no tópico: {msg.topic}")
12
13        # Roteamento por tópico
14        handlers = {
15            "evt/monitoring": process_monitoring_data,
16            "evt/configuration": process_configuration_update,
17            "cmd/response": process_command_response
18        }
19
20        for topic_pattern, handler in handlers.items():
21            if topic_pattern in msg.topic:
22                handler(data, msg.topic)
23                return
24
25        logger.warning(f"Tópico não reconhecido: {msg.topic}")
26
27    except json.JSONDecodeError as e:
28        logger.error(f"Payload JSON inválido: {str(e)}")
29    except Exception as e:
30        logger.error(f"Erro no processamento: {str(e)}")

```

Na função *on_message*, o *payload JSON* é decodificado e um dicionário de *handlers* é utilizado para rotear mensagens com base em padrões de tópicos, reduzindo a complexidade e facilitando a manutenção. Cada *handler* específico processa a mensagem de acordo com o tipo de dado.

A função de processamento de dados de monitoramento valida o *payload*, verifica o dispositivo e persiste os dados após normalização temporal, integrando alertas em tempo

real, como mostrado no Código 6. Nesse código, a validação, extração de ID do servidor, normalização de *timestamp* e persistência são exemplificadas, com tratamento de exceções e *rollback* para integridade.

Código 6 Processamento de dados de monitoramento.

```

1 def process_monitoring_data(data: Dict, topic: str) -> None:
2     """
3         Processa dados de monitoramento de sensores, validando e persistindo
4             → informações.
5     """
6     db = SessionLocal()
7     try:
8         # Validação do payload
9         if not validate_monitoring_payload(data):
10             logger.warning(f"Payload inválido: {data}")
11             return
12
13         server_id = extract_server_id(data)
14         if not server_id or not is_device_registered(db, server_id):
15             logger.warning(f"Dispositivo inválido ou não registrado:
16                 → {server_id}")
17             return
18
19         # Normalização e persistência
20         timestamp = normalize_timestamp(data)
21         save_sensor_data(db, server_id, timestamp, data)
22         evaluate_real_time_alerts(db, server_id, data)
23         logger.info(f"Dados processados para dispositivo: {server_id}")
24
25     except Exception as e:
26         logger.error(f"Erro no processamento: {str(e)}")
27         db.rollback()
28     finally:
29         db.close()

```

A persistência de dados de sensores armazena o *payload* completo em formato *JSON*, mantendo metadados estruturados para consultas eficientes, com tratamento robusto de erros, como mostrado no Código 7. Nesse código, uma instância do modelo *Dados* é criada, adicionada ao banco e commitada, logando o sucesso.

Código 7 Persistência de dados de sensores.

```

1 def save_sensor_data(db: Session, server: str, timestamp: datetime, data:
2     &gt; Dict) -> None:
3     """
4         Persiste dados do sensor no banco de dados, armazenando payload JSON e
5             metadados.
6         """
7     try:
8         sensor_data = models.Dados(
9             data_c=timestamp,
10            server=server,
11            dados=data,
12            status=1
13        )
14        db.add(sensor_data)
15        db.commit()
16        logger.debug(f"Dados persistidos para {server} em {timestamp}")
17    except Exception as e:
18        logger.error(f"Erro na persistência: {str(e)}")
19        raise
  
```

Atendimento aos Requisitos:

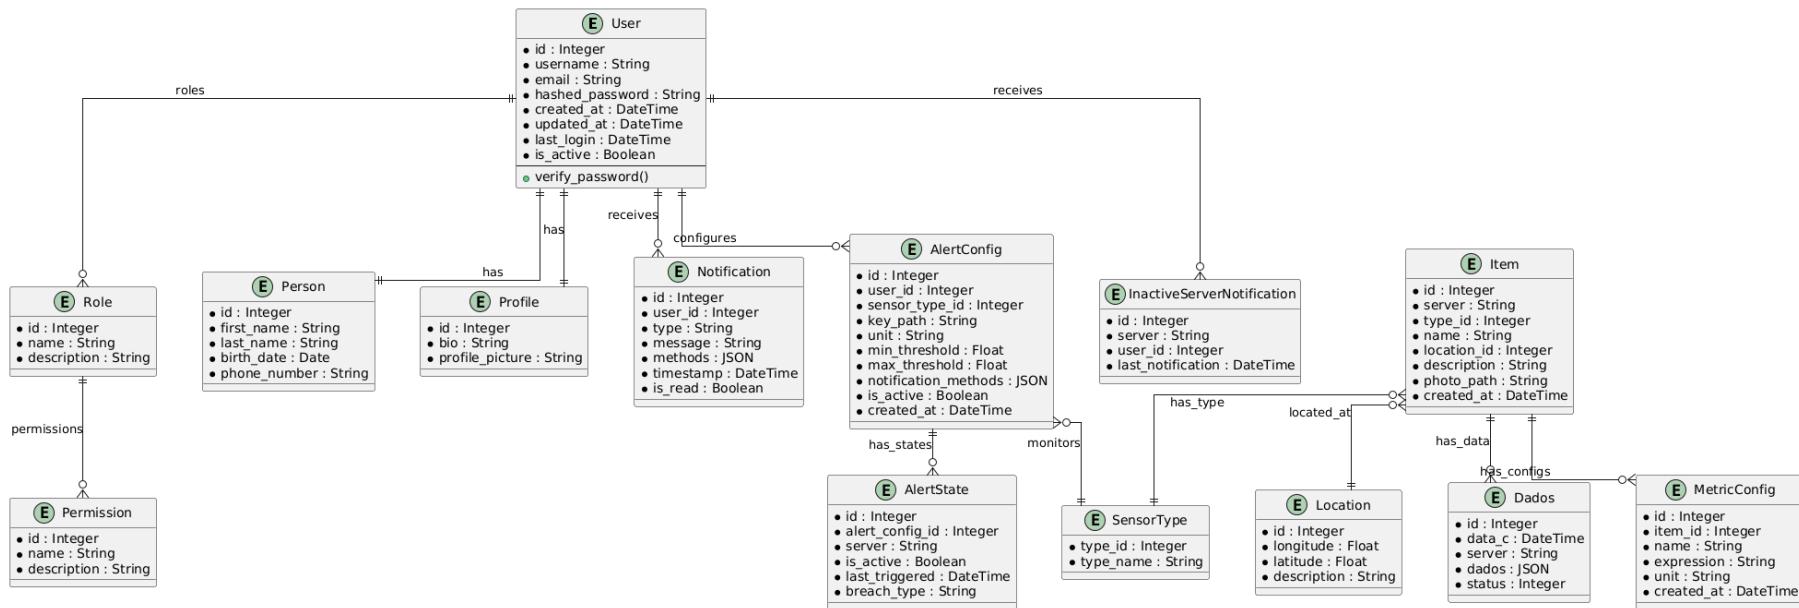
- RF-04 (Comunicação *IoT*): Suporte a *MQTT* para dispositivos;
- RF-05 (Tempo Real): Processamento imediato de dados;
- RF-06 (Escalabilidade): Arquitetura *pub/sub* para múltiplos dispositivos.

Essa camada corresponde ao *Data Collector* do *InterSCity*, adaptada para métricas energéticas.

5.4 Camada de Persistência de Dados (Banco de Dados)

Na Camada de Persistência, dados são processados e persistidos, utilizando *FastAPI* para *APIs* assíncronas, *Pydantic* para validação de *schemas* e *SQLAlchemy* para interação com *PostgreSQL*. O *handler MQTT* parseia *JSON*, enriquece com *timestamps* e persiste em tabelas como *Dados (JSONB)*, *Item* (medidores), *SensorType* (tipos) e *Server*, conforme a Figura 51. Nessa figura, o diagrama de entidade-relacionamento do banco de dados é apresentado, ilustrando relacionamentos entre tabelas como *items*, *sensor_types*, *locations*, *alert_configs* e *alert_states*, destacando chaves primárias, estrangeiras e campos como *id*, *server*, *type_id* e *data_c*.

Figura 51 – Diagrama de entidade-relacionamento do banco de dados.



Fonte: Autoria Própria.

A arquitetura segue uma hierarquia de dados inspirada no *Resource Catalog* do *InterSCity*, adaptada para monitoramento energético e hídrico. Na Tabela 17, essa hierarquia é comparada, explicando como o *GreenMonitoring* mapeia categorias como *SensorType* para *Resource Type*, garantindo flexibilidade em dados genéricos.

Tabela 17 – Hierarquia de dados no *GreenMonitoring* vs *InterSCity*.

<i>GreenMonitoring</i>	<i>InterSCity</i>
<i>SensorType</i> (Categoria)	<i>Resource Type</i>
<i>Item</i> (Dispositivo)	<i>Resource</i>
<i>Location</i> (Localização)	<i>Geographic Data</i>
<i>Dados</i> (Medições)	<i>Capability Data</i>
<i>MetricConfig</i> (Métricas)	<i>Derived Metrics</i>

Na Tabela 18, aspectos são comparados com a *InterSCity*, explicando diferenças em modelagem, flexibilidade e performance. Nessa tabela, é destacado como o *GreenMonitoring* utiliza *schema JSON* genérico para maior adaptabilidade, em contraste com *schemas* pré-definidos.

Tabela 18 – Comparaçāo detalhada: *GreenMonitoring* vs *InterSCity*.

Aspecto	<i>GreenMonitoring</i>	<i>InterSCity</i>
Modelagem de Dados	<i>Schema JSON</i> genérico	<i>Capabilities</i> específicas
Flexibilidade	Alta - Qualquer formato <i>JSON</i>	Média - <i>Schema</i> pré-definido
Complexidade	Baixa - Um modelo para todos	Alta - Múltiplos adaptadores
Consulta de Dados	<i>SQL</i> direto sobre <i>JSON</i>	<i>APIs</i> especializadas por <i>capability</i>
Métricas	Expressões dinâmicas	Métricas pré-calculadas
Performance	Otimizada para leituras	Otimizada para escrituras
Manutenção	Centralizada	Distribuída por adaptador

O campo *dados JSON* permite armazenar qualquer formato de *payload*.

Atendimento aos Requisitos:

- RF-10 (Persistência): Esquema otimizado para dados temporais;
- RF-11 (Consultas): Índices para análises históricas;
- RF-12 (Sustentabilidade): Modelo dedicado para emissões.

5.5 Camada de API

Na Camada de *API*, *FastAPI* é utilizado para expor *endpoints RESTful*, com autenticação via *JSON Web Tokens (JWT)*, suporte a versionamento, paginação e filtros dinâmicos. Os dados recebidos do *subscriber MQTT* são disponibilizados imediatamente por meio de *endpoints* bem definidos, com validação via *Pydantic* e consultas otimizadas

com *SQLAlchemy* no *PostgreSQL*. A estrutura de resposta segue o padrão *HATEOAS*, incluindo *links* para navegação, como exemplificado no Código 8. Nesse código, uma resposta *JSON* com campos como *id*, *tipo*, *leitura* e *_links* é mostrada, promovendo navegação auto-descritiva.

Código 8 Exemplo de resposta da API em *JSON*.

```

1  {
2      "id": "sensor-123",
3      "tipo": "energia",
4      "leitura": {
5          "valor": 220.5,
6          "unidade": "V",
7          "timestamp": "2024-01-15T10:30:00Z"
8      },
9      "_links": {
10         "self": "/medidores/sensor-123",
11         "historico": "/medidores/sensor-123/historico"
12     }
13 }
```

A API *REST* expõe *endpoints* *HTTP* para interações. A rota principal é *GET /notifications/*, acessada de 172.19.0.1:47780, retornando 200 *OK*, listando notificações filtradas por *user_id*. Outras inferidas incluem */items/<server>* para metadados, */dados/<server>* para históricos e */alert_configs* para *thresholds*. *Endpoints* de autenticação como *GET /auth/users/me* (com *OPTIONS* para *CORS*) sugerem segurança via *tokens*.

No Código 9, consultas via API são exemplificadas, como recuperação de dados por *server* e intervalo, ou paginados por *item ID*, incluindo respostas com dados brutos e métricas.

Código 9 Recuperação de dados com filtros.

```

1 GET /dados/?server=23300023&start_time=2025-02-01&end_time=2025-02-07 # 
2   ↳ Recuperar todos os dados de um dispositivo
3 GET /dados/item/1?page=1&page_size=50 # Recuperar dados paginados via item ID
4
5 GET /items/1 # Recuperar item com métricas calculadas
6 # Resposta inclui dados brutos + métricas customizadas
```

A API fornece documentação interativa automática por meio do *Swagger UI*, acessível em */docs*. Na Figura 52, a interface do *Swagger* com todos os *endpoints* disponíveis é exibida, permitindo teste e exploração interativa dos recursos.

Figura 52 – Interface Swagger UI da API GreenMonitoring.

The screenshot shows the Swagger UI interface for the GreenMonitoring API. The left sidebar has a tree structure with categories: Auth, Users, Roles, Permissions, Sensor Types, MQTT, Data, and Items. The Items category is expanded, showing a list of API endpoints:

- POST /items/** Create Item (green background)
- GET /items/** Read Items (blue background)
- PUT /items/{item_id}** Update Item (orange background)
- GET /items/{item_id}** Read Item (blue background)
- DELETE /items/{item_id}** Delete Item (red background)
- GET /items/{item_id}/metrics** Get Metrics (blue background)
- POST /items/{item_id}/metrics** Create Metric (green background)
- PUT /items/{item_id}/metrics/{metric_id}** Update Metric (orange background)
- DELETE /items/{item_id}/metrics/{metric_id}** Delete Metric (red background)
- GET /items/{item_id}/custom-metrics** Get Custom Metrics (blue background)

Fonte: Autoria Própria.

Atendimento aos Requisitos:

- RF-01 (Modularidade): Roteadores separados por domínio;
- RF-02 (*API REST*): *Endpoints RESTful* para todos os recursos;
- RF-03 (Autenticação): Sistema de autenticação integrado.

5.6 Cálculo de Emissões de GEE

As emissões de GEE associadas ao consumo elétrico são classificadas como Escopo 2 conforme o *GHG Protocol* e foram quantificadas por meio da classe `EmissionsCalculator` (Código 10).

A elaboração de inventários de GEE requer uma abordagem sistemática para garantir a qualidade dos dados e a conformidade regulatória, como a detalhada por (CIMADON; ZYNICH; ALBANO, 2025), que emprega o ciclo PDCA em conjunto com a ABNT NBR ISO 14064 e o GHG Protocol Brasil. Este rigor metodológico é fundamental para embasar de forma robusta tanto a quantificação das emissões quanto

o planejamento de estratégias de mitigação e adaptação climática, como as orientadas por infraestrutura verde em (ALMEIDA; ENGEL, 2020). O método adotado segue as diretrizes do *Intergovernmental Panel on Climate Change* (IPCC) (ALMEIDA; ENGEL, 2020; CIMADON; ZYNICH; ALBANO, 2025).

A quantificação das emissões baseia-se na equação fundamental:

$$\text{Emissão (tCO}_2\text{e)} = E_{\text{importada}} \text{ (MWh)} \times \text{FE (tCO}_2\text{e} \cdot \text{MWh}^{-1}) \quad (5.2)$$

em que:

- $E_{\text{importada}}$ representa a energia elétrica consumida no período, obtida diretamente dos medidores inteligentes;
- FE é o fator de emissão médio do Sistema Interligado Nacional (SIN) (SANQUETTA et al., 2017). A escolha de um fator representativo é crucial, pois, como demonstrado por (SANQUETTA et al., 2017) em seu estudo sobre o Paraná, o dióxido de carbono (CO₂) é o principal GEE emitido, e sua quantificação está diretamente associada ao consumo elétrico e à matriz energética brasileira.

Estudos como o de (SANQUETTA et al., 2017) destacam a variabilidade temporal do fator de emissão no SIN, influenciado por condições hidrológicas e pela maior participação de fontes termelétricas em períodos de seca, como observado no Paraná entre 2010 e 2014, onde o FE aumentou de 0,0512 para 0,1355 tCO₂/MWh, refletindo a dependência da matriz brasileira de hidrelétricas e a necessidade de fontes fósseis complementares. O cálculo é implementado na classe `EmissionsCalculator`, conforme apresentado no Código 10. Essa classe inicializa fatores de emissão regionais, obtém o consumo total de energia para um dispositivo específico em um intervalo de datas e aplica o fator apropriado para computar as emissões em toneladas de CO₂e. A abordagem garante flexibilidade para fatores regionais, como o valor de 0,15 tCO₂e/MWh para o Brasil (baseado em dados do MCTI/SIN de 2024), alinhando-se a metodologias sistemáticas para inventários de GEE em instituições de pesquisa, como proposto por (CIMADON; ZYNICH; ALBANO, 2025), que enfatiza o uso do ciclo PDCA para maior rastreabilidade e confiabilidade no processo de elaboração de inventários, integrando normas como ABNT NBR ISO 14064 e o GHG Protocol. Adicionalmente, (ALMEIDA; ENGEL, 2020) contextualizam a importância de tais cálculos no âmbito da adaptação climática em cidades brasileiras, destacando como inventários de emissões suportam estratégias de infraestrutura verde para mitigar impactos urbanos do aquecimento global.

Código 10 Implementação do cálculo de emissões (classe EmissionsCalculator).

```

1 class EmissionsCalculator:
2     def __init__(self):
3         self.factors = {
4             'BR': 0.15,          # tCO2e/MWh - MCTI/SIN 2024
5             'default': 0.45    # tCO2e/MWh - média global
6         }
7     def calculate_co2_emissions(self, device_id, start_date, end_date):
8         total_consumption = self.get_energy_consumption(
9             device_id, start_date, end_date
10            ) # retorna kWh
11         emission_factor = self.get_emission_factor(device_id)
12         emissions_tco2e = total_consumption * emission_factor / 1000
13         return {
14             'emissions_tons': round(emissions_tco2e, 3),
15             'period': {'start': start_date, 'end': end_date},
16             'factor_used': emission_factor
17         }

```

A acurácia do inventário depende da atualidade e da representatividade do fator de emissão. Duas fontes foram avaliadas:

1. **Climatiq**¹: banco global com mais de 300 regiões, auditado conforme *GHG Protocol* e ISO 14067. Apresenta, contudo, limitação crítica para o Brasil: os dados do SIN estão restritos a 2022, não refletindo a descarbonização acelerada da matriz elétrica nacional em 2023–2024;
2. **MCTI/SIRENE**²: fator médio anual oficial do SIN, calculado segundo metodologia aprovada pelo Conselho Executivo do MDL e com dados primários do Operador Nacional do Sistema Elétrico (ONS).

A escolha recaiu sobre o MCTI por garantir atualidade, especificidade geográfica e conformidade regulatória brasileira, resultando em inventário significativamente mais preciso. Assim tem-se:

- **RF-08** (Cálculo de Emissões): algoritmo alinhado às diretrizes IPCC Tier 1;
- **RF-14** (Métricas Ambientais): resultados expressos em tCO₂e e equivalências (árvores, veículos etc.);

¹ <<https://www.climatiq.io/>> | <<https://www.climatiq.io/>>

² <<https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/cgcl/paginas/fator-medio-inventarios-corporativos>>

- **RF-15** (Regionalização): aplicação automática do fator nacional para todos os dispositivos no SIN.

Assim, o módulo desenvolvido oferece um cálculo de Escopo 2 robusto, auditável e atualizado, plenamente adequado às exigências técnicas e normativas do projeto.

5.7 Camada de Consumo

Na Camada de Consumo, interfaces para usuários são fornecidas, incluindo aplicativo *mobile* para *Android/iOS*, com dados em tempo real e alertas; aplicativo *web* com *React* e *Tailwind CSS*, para gráficos de curvas de carga; e ferramenta de desenvolvimento para configuração de medidores e testes.

5.7.1 Extensibilidade e Modularidade da Plataforma

A plataforma *GreenMonitoring*, construída sobre o *GreenFramework*, demonstrou ser extensível e modular, conforme evidenciado pela integração com diferentes tipos de sensores e pela facilidade de análise em ferramentas externas. A API *RESTful* do *GreenFramework*, implementada com *FastAPI*, permitiu a extração de dados em formato *JSON* para análises em *Google Colab*, utilizando bibliotecas como *Pandas* e *Scikit-learn*. A modularidade foi reforçada pela arquitetura baseada em microsserviços, inspirada na plataforma *InterSCity*, que suporta a adição de novos módulos (ex.: hidrômetros) sem alterações significativas no sistema. A escalabilidade foi garantida pelo uso de contêineres *Docker* e orquestração via *Kubernetes*, permitindo a expansão para outros prédios da UFMA ou instituições.

5.7.2 Aplicação Web *GreenMonitoring*

Após a avaliação da implantação e análise dos dados coletados nos QME, a aplicação web *GreenMonitoring* é apresentada como a interface principal de consumo da arquitetura implementada. Essa aplicação, desenvolvida com *React* e *Tailwind CSS*, consome os dados processados pelo *backend* via *API RESTful*, permitindo a visualização intuitiva de métricas sobre energia elétrica (como tensão, corrente, FP e outras), localizações, tipos de medidores e informações em gráficos interativos.

Dashboards personalizáveis são oferecidos na aplicação web, nos quais dados dos medidores Telik Trafo instalados nos prédios da UFMA são exibidos em tempo real e historicamente. Curvas de carga horárias, perfis de consumo por prédio (CCET, IEE, PF, entre outros) e contribuições de geração distribuída (energia reversa de painéis solares) são plotados utilizando bibliotecas como *Chart.js*. Localizações geográficas dos QME são

marcadas em mapas interativos, com metadados como coordenadas (*latitude, longitude*) e descrições de *locations* consultadas via *endpoints* como *GET /locations*. Tipos de sensores (*SensorType*) e itens (*Item*) são listados em tabelas filtráveis, com detalhes como ID do servidor, nome amigável e métricas customizadas calculadas dinamicamente, como fator de potência total ou demanda máxima em 15 minutos. Os gráficos incluem séries temporais de variáveis como tensão por fase, corrente, potência ativa, reativa e aparente, fator de potência e energias em quatro quadrantes, com filtros por intervalo de tempo.

Na Figura 53, a página inicial da aplicação, acessível antes do *login*, é ilustrada.

Figura 53 – *Landing page* da aplicação com destaque para os botões de ação.

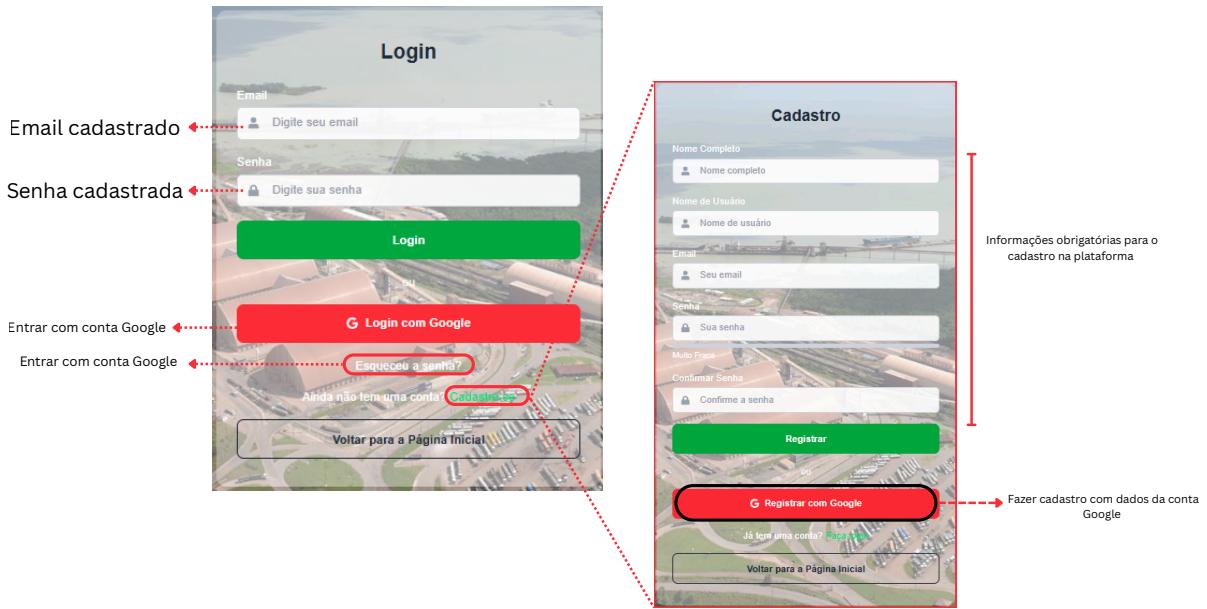


Fonte: Autoria Própria.

Nela, título “Monitoramento Inteligente de Recursos Energéticos” é exibido, acompanhado de subtítulo que descreve otimização do consumo de energia com solução avançada para monitoramento, análise e redução de custos com eficiência e sustentabilidade.

Botão verde para início do processo de criação de conta, botão verde possivelmente direcionado a informações detalhadas sobre a solução e botão no canto superior direito para redirecionamento à tela de *login* são destacados. A imagem de fundo reforça o contexto industrial, sugerindo aplicação em grandes consumidores de energia.

Na Figura 54, as duas telas de acesso são comparadas. À esquerda, a tela de *login* inclui campos para e-mail e senha cadastrados, botão para *login* com *Google*, *link* para recuperação de senha e *link* para cadastro. À direita, a tela de cadastro apresenta campos obrigatórios para nome completo, nome de usuário, e-mail, senha e confirmação de senha, botão verde para registro, botão vermelho para registro com *Google*, legenda indicando informações obrigatórias e opção para cadastro com dados da conta *Google*.

Figura 54 – Comparaçao entre telas de *login* (esquerda) e cadastro (direita).

Fonte: Autoria Própria.

Na Figura 55, o *dashboard* principal aps o *login* é exibido. Barra de pesquisa localizada no topo permite busca por medidores ou locais. Ícones de configuração incluem alternância entre tema claro e escuro, acesso às configurações, exibição de notificações e acesso ao perfil.

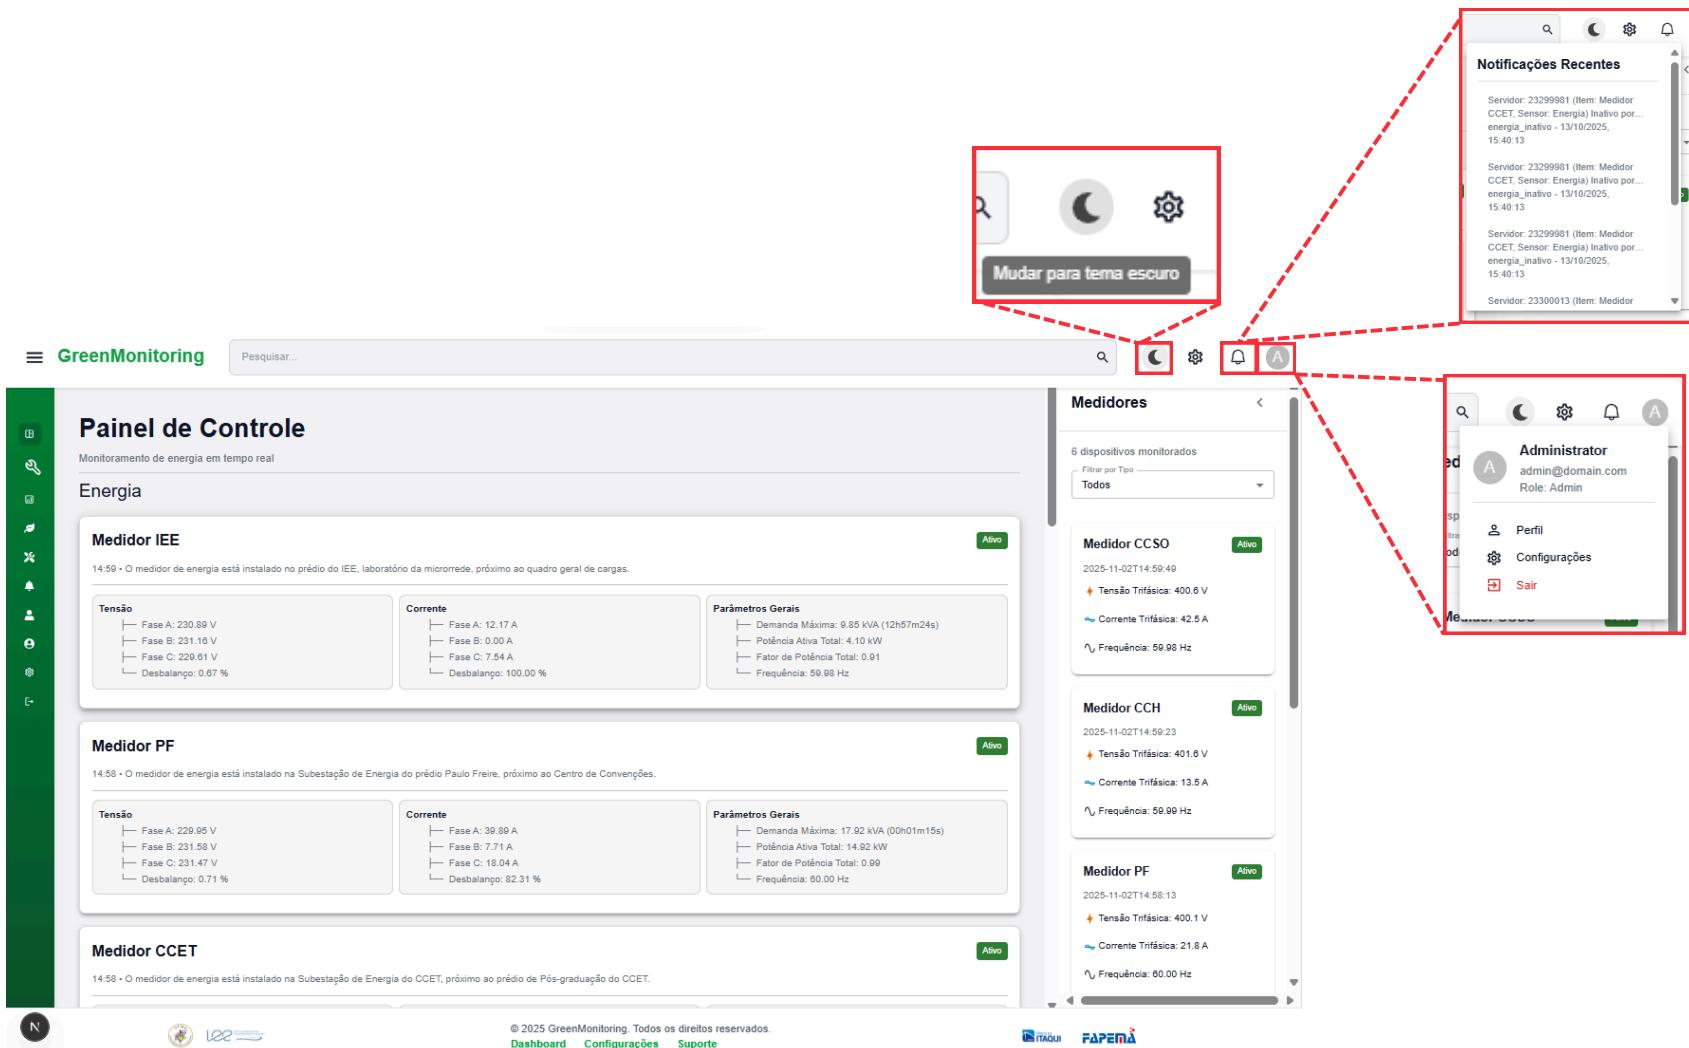
Seis medidores estão ativos e transmitindo dados em tempo real, conforme detalhado na Tabela 19. O medidor do *Prédio de Biologia* ainda não foi instalado e, portanto, não aparece no *dashboard*.

Tabela 19 – Medidores exibidos no *dashboard* (atualizado em 02/11/2025).

Medidor	Localização	Status
CCSO	Subestação CCSO, próximo ao prédio principal	Ativo
CCH	Subestação CCH, próximo ao Centro de Ciências da Saúde	Ativo
PF	Subestação Paulo Freire, próximo ao Centro de Convenções	Ativo
ODONTO	Subestação Odontologia, próximo ao prédio de clínicas	Ativo
CCET	Subestação CCET, próximo ao prédio de Pós-graduação	Ativo
IEE	Prédio do IEE, próximo ao quadro geral de cargas	Ativo

Para cada medidor, tensão por fase e desbalanceamento, corrente por fase e desbalanceamento, além de parâmetros gerais como demanda máxima, potência ativa total, fator de potência e frequênciа sаo exibidos.

Figura 55 – Ícones de configuração no dashboard.



Fonte: Autoria Própria.

Na Figura 56, o Painel de Controle principal do sistema GreenMonitoring é apresentado. A interface mostra o consumo energético do edifício em tempo real. A tela divide-se em duas regiões: a barra lateral de navegação, à esquerda, e a área central de monitoramento, que ocupa a maior parte da tela.

A barra lateral, em verde escuro, serve como núcleo de navegação. Inclui: Dashboard, com indicadores gerais; Análises, com relatórios e gráficos históricos; Emissões de CO₂, para cálculo do impacto ambiental com base no consumo; Gerenciar Medidores, para cadastro e configuração dos dispositivos; Notificações, com alertas sobre anomalias ou limites excedidos; Usuários, para controle de permissões; Perfil e Configurações, para personalização; e Sair, para logout. A organização vertical otimiza o espaço na tela.

No centro, o sistema monitora seis medidores elétricos ativos, cada um ligado a um setor do prédio (como laboratórios ou áreas administrativas). Os medidores aparecem em um painel resumido no topo e em cards individuais no painel direito.

Ainda na Figura 56 no painel superior, o medidor IEE (instalado no laboratório da microrrede) mostra variáveis trifásicas em tempo real: Tensão nas fases A (230,80 V), B (231,16 V) e C (229,81 V), com desbalanceamento de 0,67%; Corrente nas fases A (12,17 A), B (0,00 A) e C (7,54 A), com desbalanceamento de 100% (devido à ausência de carga na Fase B); e parâmetros gerais, com demanda máxima de 8,85 kVA (em 27/05/2024), potência ativa total de 4,10 kW, fator de potência de 0,91 e frequência de 59,89 Hz. Esse resumo serve como referência do estado elétrico do edifício.

À direita, o painel lista os seis medidores em cards, cada um com: botão “Ativo”, indicando comunicação com o servidor; timestamp da última leitura (ex.: 2025-11-02T14:59:40); e grandezas trifásicas: Tensão trifásica média (ex.: 400,8 V para o medidor CCSO); Corrente trifásica média (ex.: 42,5 A); e Frequência (entre 59,89 Hz e 60,00 Hz). Um filtro no topo permite selecionar medidores por tipo, localização ou status.

A estrutura permite alternar entre visão agregada (parâmetros gerais e resumo do IEE) e visão granular (cards individuais).

Na Figura 57, gráficos de barras horizontais são apresentados. No eixo esquerdo, tensão em volts por fase é plotada; no eixo direito, corrente em amperes por fase é indicada. Legenda de status utiliza verde para condição adequada, amarelo para precária e vermelho para crítica. Essa classificação de cores foi feita com base na norma da PRODIST Módulo 8 - Qualidade do Fornecimento de Energia Elétrica, que define sobre tensões críticas, precárias ou adequadas, as quais foram colocadas em cada uma das cores nas barras.

Figura 56 – Painel de Controle do GreenMonitoring

The screenshot displays the GreenMonitoring control panel interface. On the left is a vertical sidebar with navigation links. The main area is titled "Painel de Controle" and shows real-time energy monitoring data for three different meters:

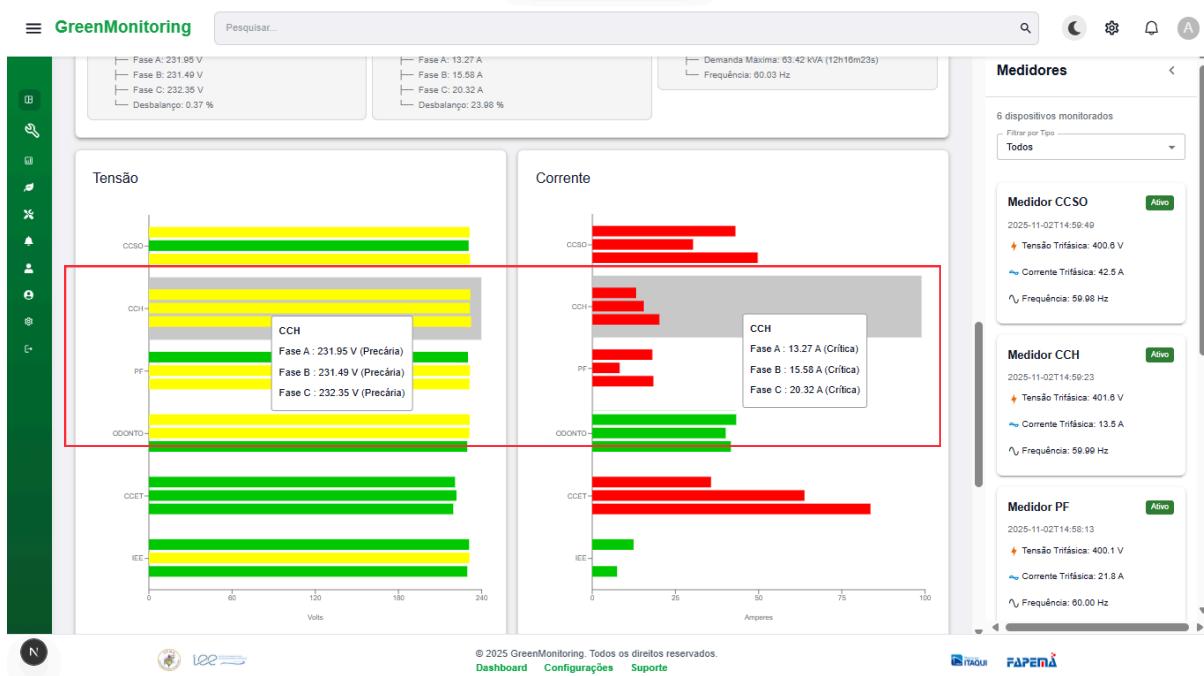
- Medidor IEE** (highlighted with a red box):
 - Tensão: Fase A: 230.89 V, Fase B: 231.16 V, Fase C: 229.61 V, Desbalanço: 0.67 %
 - Corrente: Fase A: 12.17 A, Fase B: 0.00 A, Fase C: 7.54 A, Desbalanço: 100.00 %
 - Parâmetros Gerais: Demanda Máxima: 9.85 kVA (12h57m24s), Potência Ativa Total: 4.10 kW, Fator de Potência Total: 0.91, Frequência: 59.98 Hz
- Medidor PF**:
 - Tensão: Fase A: 229.95 V, Fase B: 231.58 V, Fase C: 231.47 V, Desbalanço: 0.71 %
 - Corrente: Fase A: 39.89 A, Fase B: 7.71 A, Fase C: 18.04 A, Desbalanço: 82.31 %
 - Parâmetros Gerais: Demanda Máxima: 17.92 kVA (00h01m15s), Potência Ativa Total: 14.92 kW, Fator de Potência Total: 0.99, Frequência: 60.00 Hz
- Medidor CCET**:
 - Tensão: Fase A: 229.95 V, Fase B: 231.58 V, Fase C: 231.47 V, Desbalanço: 0.71 %
 - Corrente: Fase A: 39.89 A, Fase B: 7.71 A, Fase C: 18.04 A, Desbalanço: 82.31 %
 - Parâmetros Gerais: Demanda Máxima: 17.92 kVA (00h01m15s), Potência Ativa Total: 14.92 kW, Fator de Potência Total: 0.99, Frequência: 60.00 Hz

To the right of the main panel, there are two additional windows:

- Medidores** (highlighted with a red box):
 - 6 dispositivos monitorados
 - Medidor CCSO (Ativo): Tensão Trifásica: 400.6 V, Corrente Trifásica: 42.5 A, Frequência: 59.98 Hz
 - Medidor CCH (Ativo): Tensão Trifásica: 401.6 V, Corrente Trifásica: 13.5 A, Frequência: 59.99 Hz
 - Medidor PF (Ativo): Tensão Trifásica: 400.1 V, Corrente Trifásica: 21.8 A, Frequência: 60.00 Hz
- Medidores** (highlighted with a red box):
 - 6 dispositivos monitorados
 - Medidor CCSO (Ativo): Tensão Trifásica: 400.6 V, Corrente Trifásica: 42.5 A, Frequência: 59.98 Hz
 - Medidor CCH (Ativo): Tensão Trifásica: 401.6 V, Corrente Trifásica: 13.5 A, Frequência: 59.99 Hz
 - Medidor PF (Ativo): Tensão Trifásica: 400.1 V, Corrente Trifásica: 21.8 A, Frequência: 60.00 Hz

Fonte: Autoria Própria.

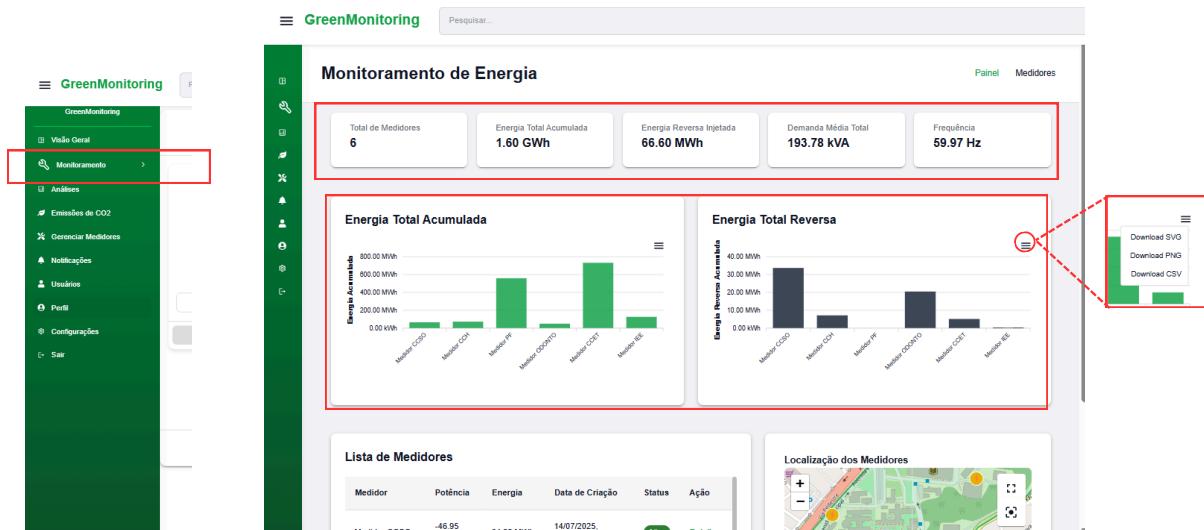
Figura 57 – Gráficos comparativos de tensão e corrente por medidor.



Fonte: Autoria Própria.

Na Figura 58, indicadores consolidados são apresentados, incluindo total de seis medidores, energia total acumulada de 1,60 GWh, energia reversa injetada de 66,60 MWh, demanda média total de 193,78 kVA e frequência de 59,97 Hz. Gráficos de barras mostram consumo acumulado por medidor, com opções de exportação em *SVG*, *PNG* e *CSV*.

Figura 58 – Resumo acumulado de energia e gráficos de consumo.



Fonte: Autoria Própria.

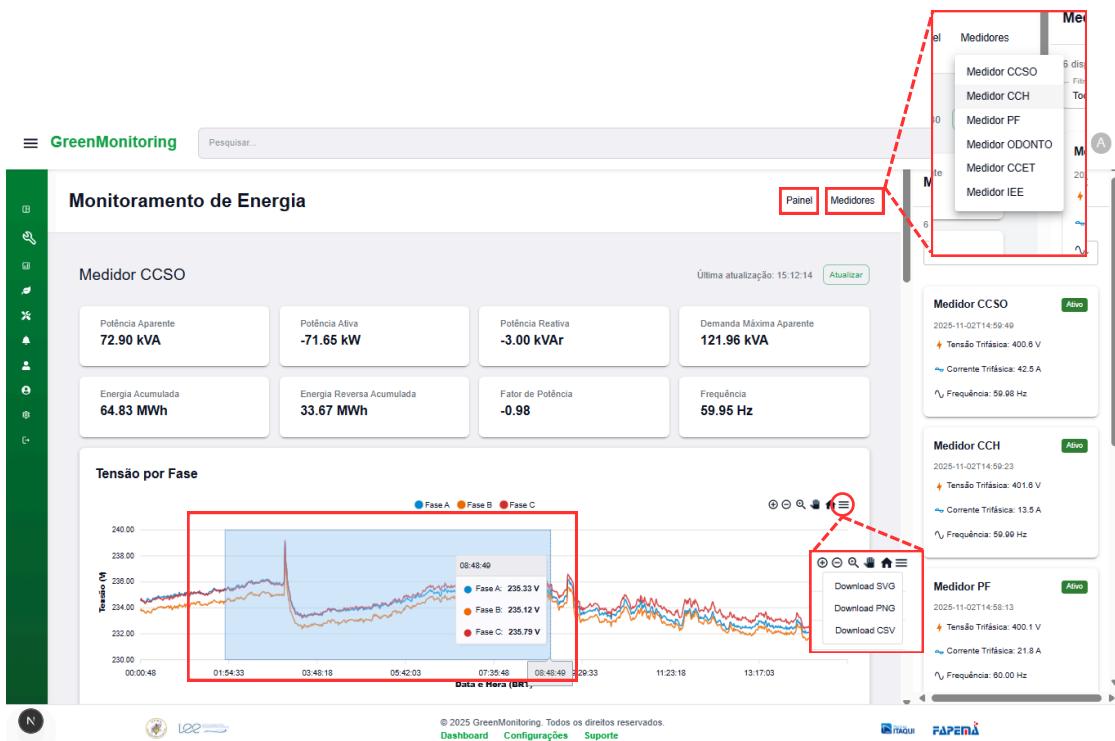
Figura 59 – Gráficos de potência com painel de medidores e opções de exportação.



Fonte: Autoria Própria.

Na Figura 60, opções de exportação disponíveis em diversos gráficos são destacadas, incluindo download em *SVG*, *PNG* e *CSV*. Tais opções possibilitam extração de dados para relatórios externos.

Figura 60 – Opções de download de gráficos e dados.

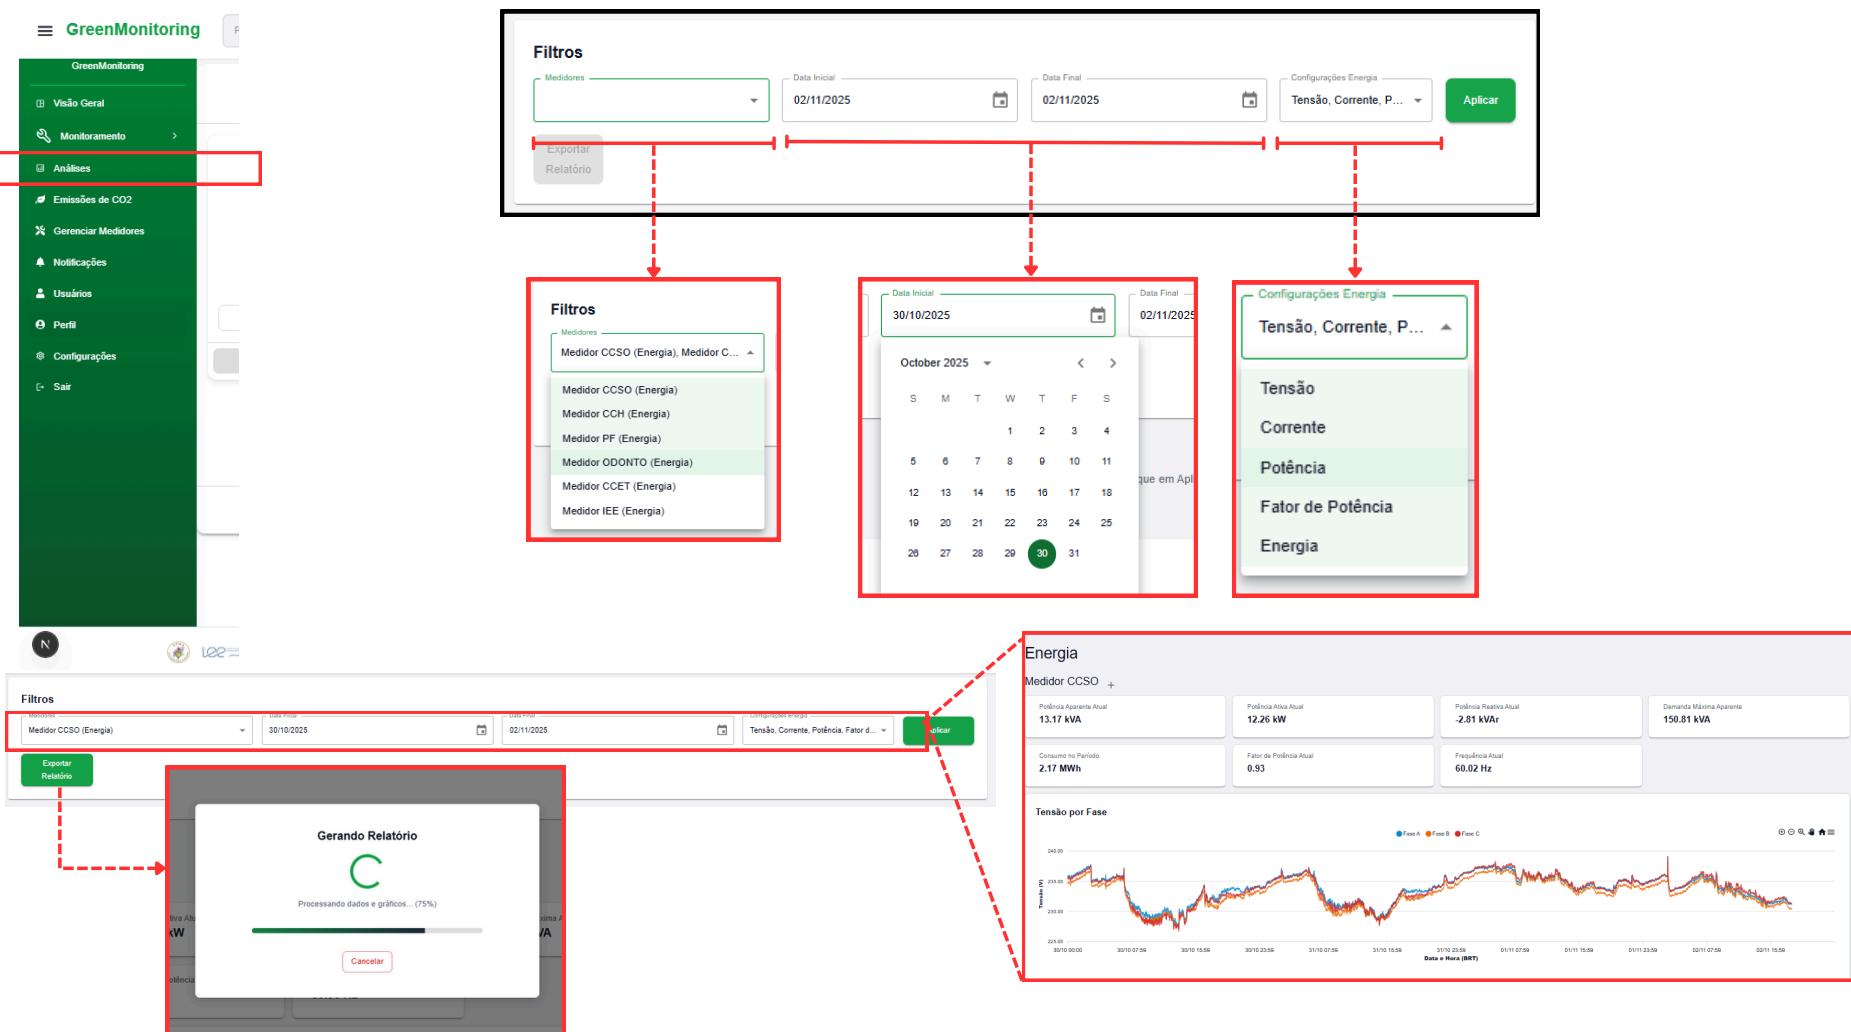


Fonte: Autoria Própria.

Na Figura 61, a interface de filtros para geração de relatórios é ilustrada. A seção de filtros permite a seleção de medidores específicos, como Medidor CCSO (Energia), Medidor CCH (Energia), entre outros, por meio de um menu suspenso. Intervalo de datas é definido com campos de data inicial (02/11/2025) e data final (02/11/2025), com suporte a calendário interativo. Configurações de energia possibilitam a escolha de variáveis como tensão, corrente, potência e fator de potência. Um modal de progresso é exibido durante a geração do relatório, indicando processamento com porcentagem concluída. Gráficos de energia são apresentados com indicadores consolidados, como potência ativa total (1,31 MW), potência reativa total (924 kVAr) e demanda máxima (2,51 MW). Gráfico de linha mostra tensão por fase ao longo do tempo, com legendas para fases A, B e C.

Na Figura 62, o painel de emissões de CO₂ é apresentado. Fator de emissão mais recente é indicado como 0,1786 kgCO₂e/MWh. Emissões totais emitidas por prédio são exibidas em cards, como 55,68 tCO₂e para todos os prédios, 0,58 tCO₂e para Medidor CCH e 28,09 tCO₂e para Medidor CCET. Gráficos incluem fatores de emissão mensal e anual em linha, emissões de CO₂ por mês em barras agrupadas por medidor, emissões por ano em barras e proporção de emissões por prédio em gráfico de pizza, com destaque para Medidor CCET (50,5%) e Medidor IEE (6,0%), entre outros. Última atualização é registrada em 02/11/2025 às 15:18:05.

Figura 61 – Interface de filtros para geração de relatórios com seleção de medidores, intervalo de datas e configurações de energia.



Fonte: Autoria Própria.

Figura 62 – Painel de emissões de CO₂ com indicadores consolidados e gráficos de fatores de emissão e emissões por período.



Fonte: Autoria Própria.

Na Tabela 20, o atendimento aos requisitos funcionais na implementação é resumido. Nessa tabela, requisitos chave e suas implementações são listados, demonstrando cobertura completa.

Tabela 20 – Cobertura de requisitos na implementação.

Requisito	Implementação no <i>GreenMonitoring</i>
RF-01: Modularidade	Arquitetura em microsserviços com <i>Docker</i>
RF-02: API REST	<i>FastAPI</i> com documentação <i>Swagger</i> automática
RF-03: Autenticação	<i>JWT</i> com gestão de sessões
RF-04: Comunicação <i>IoT</i>	<i>Broker MQTT</i> com tópicos hierárquicos
RF-05: Tempo Real	<i>WebSocket</i> e atualizações em tempo real
RF-08: Cálculo Emissões	Algoritmos baseados em padrões <i>IPCC</i>
RF-09: Detecção Anomalias	Sistema de alertas com <i>thresholds</i>
RF-13: Notificações	Sistema multi-canal (<i>email, push, dashboard</i>)
RF-16: Interface Simples	<i>React</i> com componentes reutilizáveis
RF-18: Escalabilidade	Arquitetura <i>pub/sub</i> e balanceamento

O *GreenMonitoring* foi desenvolvido utilizando *TypeScript* (5.0.0) para tipagem estática, garantindo a robustez do código. A arquitetura *full-stack* e a interface de usuário foram construídas sobre o framework *Next.js* (15.2.4) em conjunto com o *React* (19.0.0), adotando renderização híbrida (*SSR/SSG*).

Para a experiência do usuário, a interface foi projetada com a biblioteca de componentes *Material UI* (MUI, 6.4.11) e estilizada com o *utility-first framework Tailwind CSS* (4.0.12). O gerenciamento de estados assíncronos e requisições *HTTP* é realizado por *@tanstack/react-query* (5.69.0) e *axios* (1.8.1).

Para visualização e análise de dados, foram empregadas múltiplas bibliotecas:

- **Gráficos:** *Chart.js* (4.4.9), *Recharts* (2.15.1) e *ApexCharts* (4.5.0);
- **Mapas:** *Leaflet* (1.9.4) e *@react-google-maps/api* (2.20.6);
- **Exportação e Relatórios:** *jspdf* (3.0.1) e *react-csv* (2.2.2) para a geração de relatórios em *PDF* e *CSV*.

A implementação adapta princípios do *InterSCity* para monitoramento energético, abordando lacunas em acessibilidade, eficiência energética e métricas de sustentabilidade. No Capítulo 6 será apresentado o estudo de caso da aplicação do *GreenMonitoring* na UFMA.

6 Estudo de caso: Aplicação do *GreenMonitoring* na UFMA

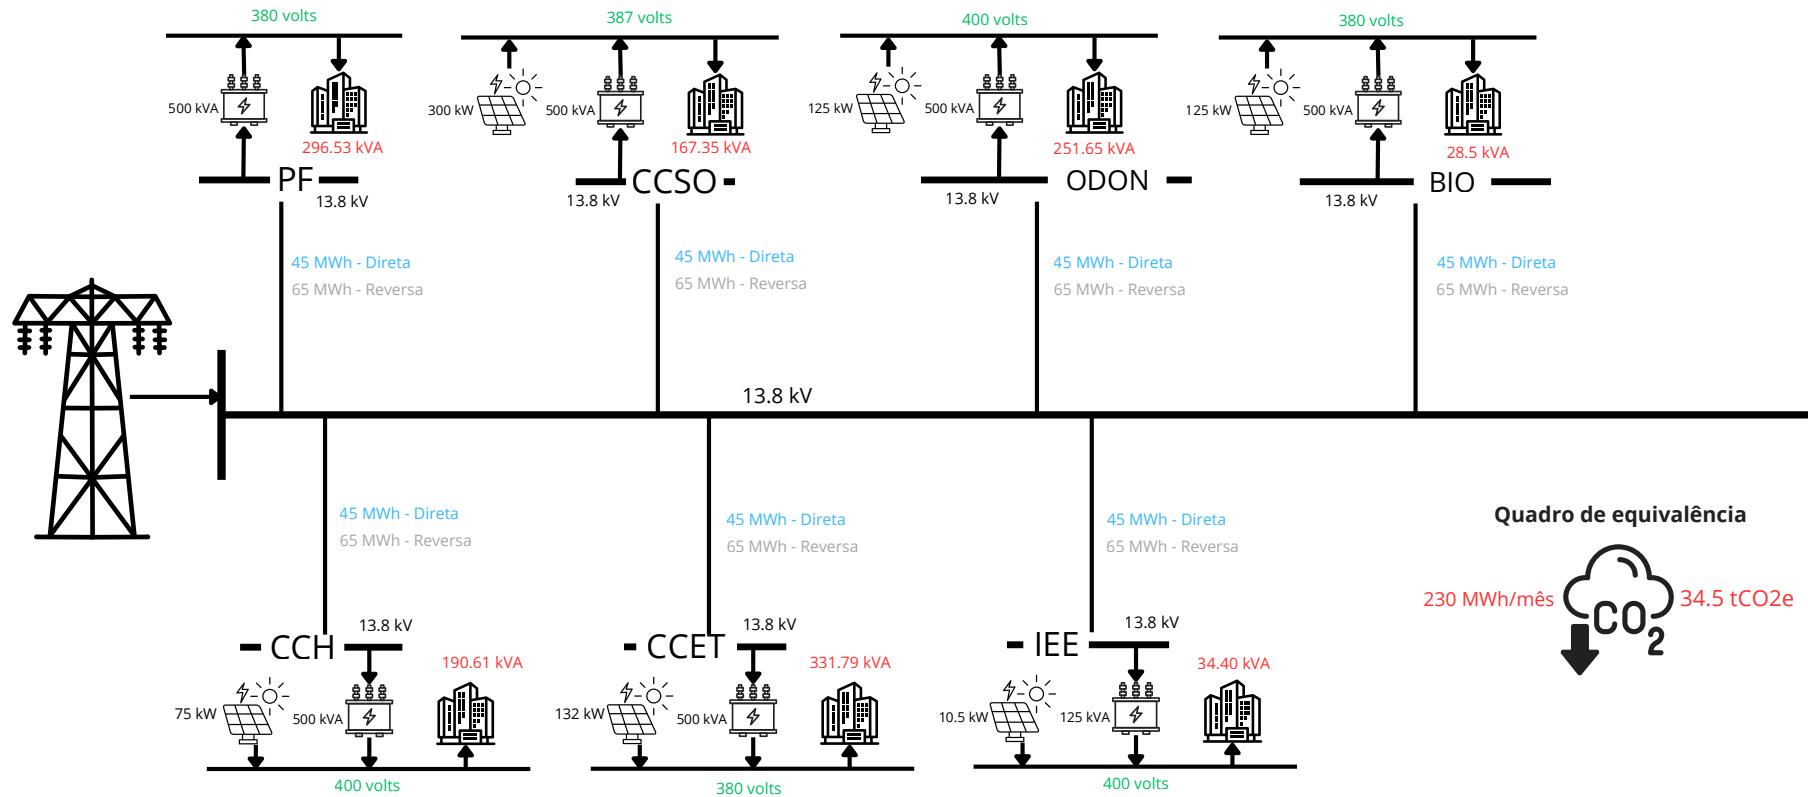
Neste capítulo, os resultados obtidos com a implementação do *GreenMonitoring* são apresentados, com base no caso de estudo realizado na UFMA. O desempenho do *framework* é avaliado por meio de métricas de escalabilidade, tempos de resposta da *API* e confiabilidade na aquisição de dados. As análises energéticas incluem economias identificadas, redução de emissões de carbono e otimizações implementadas. A validação da abordagem envolve comparação com soluções existentes das referências selecionadas no estado da arte.

6.1 Avaliação Experimental

Na avaliação experimental, utilizou-se a infraestrutura elétrica da UFMA, com instalação de quadros de medição de energia (QME) nos transformadores dos prédios. A rede elétrica atende os prédios Centro de Ciências Exatas e Tecnologia (CCET), Instituto de Engenharia Elétrica (IEE), Prédio de Física (PF), Centro de Ciências Sociais (CCSO), Centro de Ciências Humanas (CCH), prédio de Biologia (BIO) e prédio de Odontologia (ODONTO). Alguns possuem geração distribuída via painéis solares fotovoltaicos, com injecção de energia na rede; outros dependem apenas da rede principal. No trabalho publicado em ([JUNIOR et al., 2025](#)), a análise limitou-se aos prédios CCET, IEE e PF, pois os QME estavam instalados apenas nesses locais até então. Atualmente, os QME estão implementados em todos os prédios citados, exceto no quadro do prédio de Biologia, que ainda não foi instalado.

Na Figura 63, apresenta-se o quadro sinóptico da infraestrutura energética da UFMA, com as características dos transformadores de cada prédio. Na Figura 63, é ilustrado a topologia da rede, indicando tensão nominal, capacidade de potência aparente, potência ativa consumida e consumo mensal, em fluxos diretos e reversos. Para prédios com geração distribuída, mostra-se a energia injetada na rede, permitindo avaliar a compensação por fontes renováveis. Inclui-se também a estimativa da pegada de carbono, em toneladas de CO₂ equivalente (tCO₂e), calculada a partir do consumo total e dos fatores de emissão da matriz elétrica local. Essa representação facilita a identificação de padrões de consumo, ineficiências e oportunidades de otimização, como balanceamento de cargas ou expansão da geração distribuída.

Figura 63 – Quadro sinóptico da infraestrutura energética da UFMA.



Fonte: Autoria Própria.

Os QME foram projetados para monitorar variáveis sobre energia elétrica como tensão, corrente e FP, dentre outras, possibilitando a análise detalhada do desempenho da rede elétrica institucional. Sensores compatíveis com a plataforma *GreenMonitoring* foram integrados aos transformadores para coletar dados em tempo real, capturando variáveis como tensão (em volts), potência ativa (em quilowatts, kW), potência aparente (em quilovolts-ampère, kVA) e consumo energético (em megawatts-hora, MWh). A distinção entre fluxos diretos (energia consumida da rede) e reversos (energia injetada por fontes renováveis) foi registrada, permitindo avaliar a contribuição dos sistemas de geração distribuída para a eficiência energética. Os dados foram formatados em JSON, com campos que incluem identificadores de dispositivos, servidores e medições específicas, conforme descrito nas seções anteriores.

A coleta de dados foi realizada por meio dos QME conectados a um *broker MQTT*, configurado com *Quality of Service* (QoS) 1 para garantir entrega confiável. Os dados foram transmitidos para o *backend* da plataforma *GreenMonitoring*, onde foram processados e armazenados em um banco de dados *PostgreSQL* com suporte a campos *JSONB*. Essa abordagem permitiu análises em tempo real e históricas, com integração de algoritmos de ML para previsão de consumo e detecção de anomalias. A geração distribuída, presente em alguns prédios, foi monitorada para avaliar sua contribuição à redução da dependência da rede elétrica principal, promovendo alinhamento com os Objetivos de Desenvolvimento Sustentável (ODS) relacionados à energia limpa e acessível.

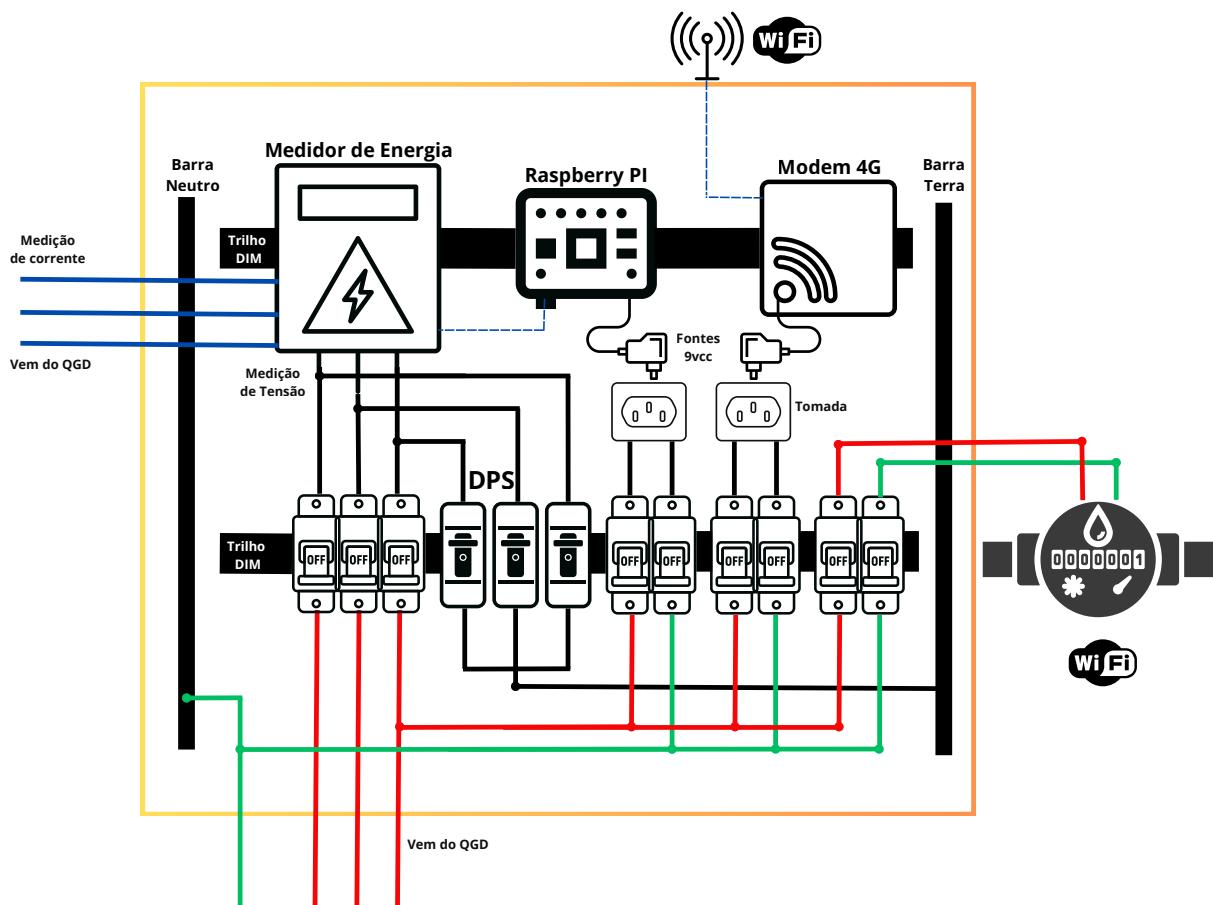
A implementação inicial descrita em (JUNIOR et al., 2025) focou na análise dos prédios CCET, IEE e PF, selecionados por sua representatividade no consumo energético do Campus do Bacanga. A metodologia de implementação seguiu uma abordagem estruturada, com a definição da arquitetura do Sistema de Monitoramento e Gestão de Energia (SGME), que integra sensores Telik Trafo, módulos de comunicação *Wi-Fi* e o protocolo *MQTT*. A coleta de dados, realizada no período de 14/01/2025 a 14/02/2025, embora atualmente já tenha dados desde janeiro até a data atual, foi armazenada em *PostgreSQL* e analisada por meio de ferramentas como *Jupyter Notebook* no *Google Colab*, utilizando a API do *GreenFramework* para acesso programático. A expansão para os demais prédios (CCSO, CCH, BIO e ODON) foi concluída posteriormente, permitindo uma cobertura mais ampla da infraestrutura elétrica da UFMA e reforçando a escalabilidade da plataforma *GreenMonitoring*.

6.1.1 Montagem dos QME

Na montagem dos QME, a aquisição de grandezas elétricas foi planejada, com foco em modularidade e escalabilidade. Cada QME foi projetado como uma unidade independente, contendo um medidor trifásico Telik Trafo, disjuntores para conexão ao barramento de baixa tensão, um microcontrolador *Raspberry Pi* para processamento local,

e um módulo de comunicação *Wi-Fi* para transmissão de dados. Na Figura 64, a estrutura interna de um QME é ilustrada, destacando os componentes principais: o medidor Telik Trafo, responsável pela medição de tensão e corrente; os disjuntores, que asseguram a segurança elétrica; e o módulo *Wi-Fi*, que envia dados ao *broker MQTT*. A inclusão de um hidrômetro foi prevista para monitoramento integrado de consumo de água, ampliando a aplicabilidade do sistema. Essa previsão foi executada e um medidor de água foi instalado como teste somente no QME do prédio do IEE (Instituto de Energia Elétrica). A limitação de instalação nos demais prédios deveu-se à grande distância entre o quadro de energia e os pontos ideais para a instalação dos hidrômetros.

Figura 64 – Representação detalhada do Quadro de Medição de Energia (QME).



Fonte: ([JUNIOR et al., 2025](#)).

O medidor de energia ilustrado na Figura 64 é o Telik Trafo, um medidor trifásico. Em relação ao consumo de água, o hidrômetro envia seus dados de leitura via comunicação *Wi-Fi*. É importante ressaltar que os centros monitorados não possuíam medidores de energia elétrica próprios para o acompanhamento do consumo, o que justificou a instalação de nossos quadros e medidores em cada um dos pontos de interesse. Todo o processo de instalação e configuração dos QME foi realizado pela equipe de pesquisa do projeto.

6.1.2 Instalações dos QME

Nas instalações dos QME, a conformidade com normas de segurança elétrica foi assegurada, utilizando sensores Telik Trafo não invasivos, que permitem medições sem interrupção do fornecimento de energia. Cada QME foi montado em uma subestação, com o medidor Telik Trafo conectado a três canais de tensão (referenciados ao neutro) e três canais de corrente, utilizando bobinas de Rogowski para medição indireta. Toda a instalação atende à *ABNT NBR 5410* (instalações elétricas de baixa tensão) e à *ABNT NBR 14039* (instalações elétricas de média tensão de 1,0 kV a 36,2 kV), garantindo proteção contra choques, aterramento adequado e distâncias de segurança em subestações. As bobinas de Rogowski seguem os requisitos da *IEC 61869-6*, que estabelece padrões para sensores de corrente não convencionais, incluindo precisão metrológica e resposta em frequência. Além disso, o Telik Trafo e seus componentes cumprem a *ABNT NBR IEC 61010-1*, que define os ensaios de segurança para equipamentos de medição, assegurando isolamento elétrico, resistência a surtos e proteção ao operador durante a instalação.

A instalação envolveu a configuração do *broker MQTT* com *Quality of Service* (QoS) 1 para entrega garantida, e a integração com o *backend* do *GreenMonitoring* foi realizada por meio de APIs *RESTful* implementadas com *FastAPI*. A segurança na transmissão foi assegurada por *Transport Layer Security* (TLS) na porta 8883 e autenticação via *JSON Web Tokens* (JWT).

6.1.3 Persistência dos Dados

Na persistência dos dados, um banco de dados *PostgreSQL* foi implementado, que armazena as medições em formato *JSONB* para suportar esquemas flexíveis. Os dados coletados pelos QME, incluindo tensão, corrente, potência ativa, reativa, aparente, fator de potência e consumo energético, foram transmitidos via *MQTT* e processados pelo *backend*. A API do *GreenFramework* permitiu a extração programática dos dados, que foram analisados em *Jupyter Notebook* no *Google Colab* para geração de perfis de carga e detecção de anomalias. A estrutura *JSONB* garantiu a escalabilidade do sistema, permitindo a inclusão de novas variáveis sem alterações no esquema do banco. A capacidade de armazenamento do Telik Trafo, de até 13.000 registros (equivalente a 45 dias com intervalos de 5 minutos), suportou análises históricas detalhadas.

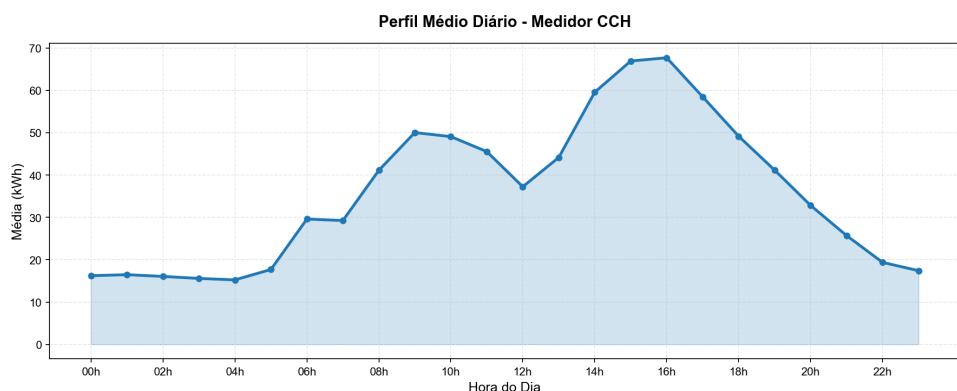
6.1.4 Análise de Padrões de Consumo

Nos dados coletados, foram construídos perfis de carga diária média para cada medidor monitorado, conforme ilustrado nas Figuras 65 a 67. Em geral, sugere-se que os padrões de consumo refletem a dinâmica de ocupação e uso de equipamentos nos respectivos prédios, com variações horárias que indicam períodos de maior e menor demanda. Os

picos de consumo, em geral observados entre 15h e 16h, possivelmente estão associados a horários de maior atividade, enquanto os valores mínimos, registrados entre 1h e 5h, coincidem com a madrugada, período de menor ocupação.

Na Figura 65, o perfil médio diário de energia ativa (em kWh) para o medidor *CCH* é apresentado. Observa-se consumo basal em torno de $10\ kWh$ entre 0h e 6h. A partir das 7h, inicia-se elevação gradual, com pico de aproximadamente $42\ kWh$ às 15h, seguido por declínio contínuo até cerca de $10\ kWh$ às 22h. Um pequeno vale é notado por volta das 12h. Esse padrão sugere uso predominante de iluminação, *air conditioning* e equipamentos administrativos durante o horário acadêmico.

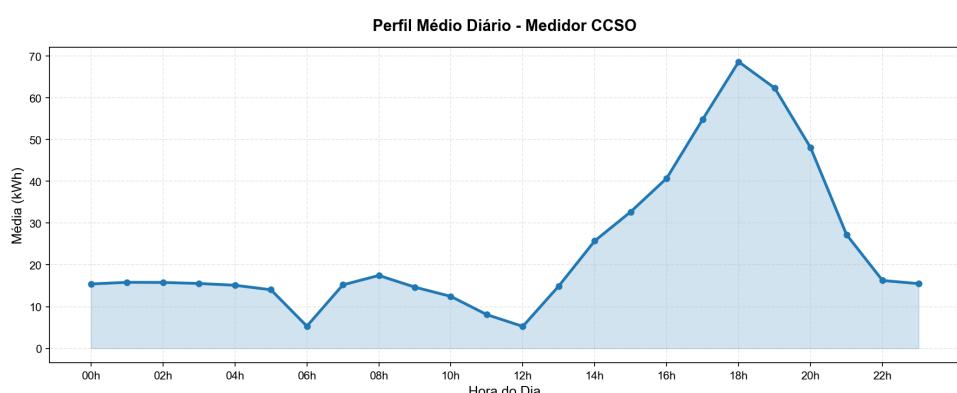
Figura 65 – Perfil médio diário de energia ativa (em kWh) – Medidor *CCH*.



Fonte: Autoria Própria.

Conforme ilustrado na Figura 66, o medidor *CCSO* exibe consumo basal próximo a $12\ kWh$ entre 0h e 6h. A partir das 12h, observa-se elevação rápida, atingindo pico de cerca de $60\ kWh$ às 18h, seguido por redução gradual até aproximadamente $12\ kWh$ às 22h. Tal comportamento reforça a possibilidade de sistemas de compensação ou cargas variáveis.

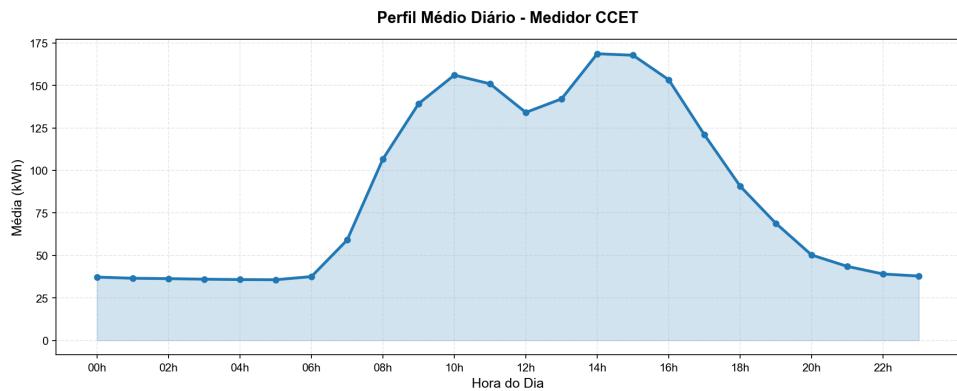
Figura 66 – Perfil médio diário de energia ativa (em kWh) – Medidor *CCSO*.



Fonte: Autoria Própria.

Na Figura 67, o perfil de maior demanda, com consumo noturno em torno de 35 kWh entre 0h e 6h é apresentado. A partir das 7h, inicia-se aumento contínuo, com pico máximo de aproximadamente 155 kWh às 14h, seguido por declínio acentuado até cerca de 30 kWh às 22h. Esse padrão sugere intensa operação de laboratórios, equipamentos de alta potência e sistemas de climatização ao longo do dia acadêmico.

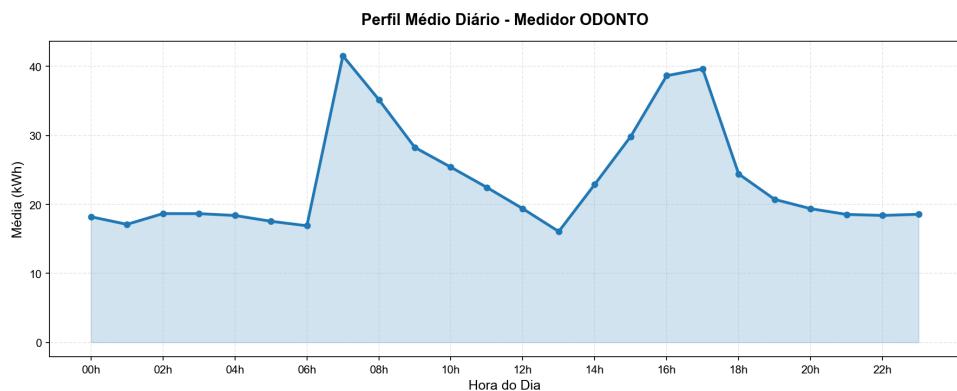
Figura 67 – Perfil médio diário de energia ativa (em kWh) – Medidor CCET.



Fonte: Autoria Própria.

O perfil do medidor *ODONTO*, ilustrado na Figura 68, mostra consumo basal de aproximadamente 12 kWh entre 0h e 6h. Dois picos distintos são observados: um às 7h (27 kWh) e outro às 15h (26 kWh), com vale acentuado (10 kWh) entre 11h e 13h. Após 17h, a demanda reduz-se gradualmente até o nível noturno. Esse comportamento possivelmente reflete horários de atendimento clínico matutino e vespertino, com pausa ao meio-dia.

Figura 68 – Perfil médio diário de energia ativa (em kWh) – Medidor *ODONTO*.

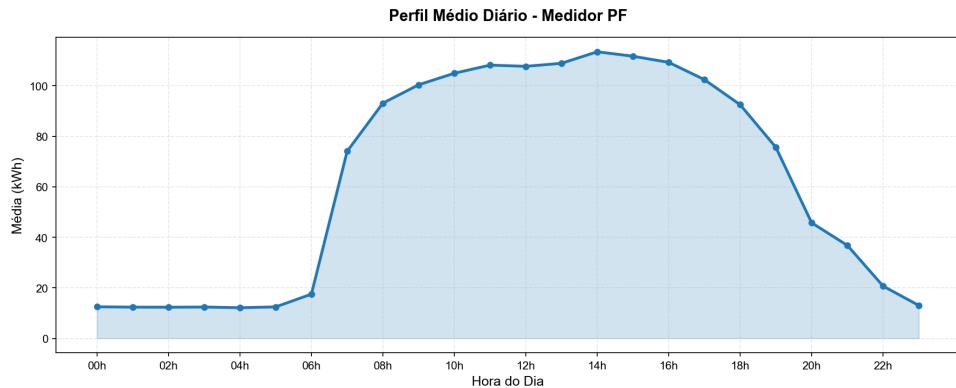


Fonte: Autoria Própria.

Na Figura 69, é apresentado o perfil do medidor *PF*, com consumo noturno próximo a 10 kWh entre 0h e 6h. A partir das 7h, observa-se aumento contínuo até pico de cerca

de 105 kWh às 13h, seguido por redução gradual até aproximadamente 10 kWh às 22h. Esse padrão sugere alta densidade de equipamentos de *air conditioning*, laboratórios e infraestrutura computacional em operação contínua.

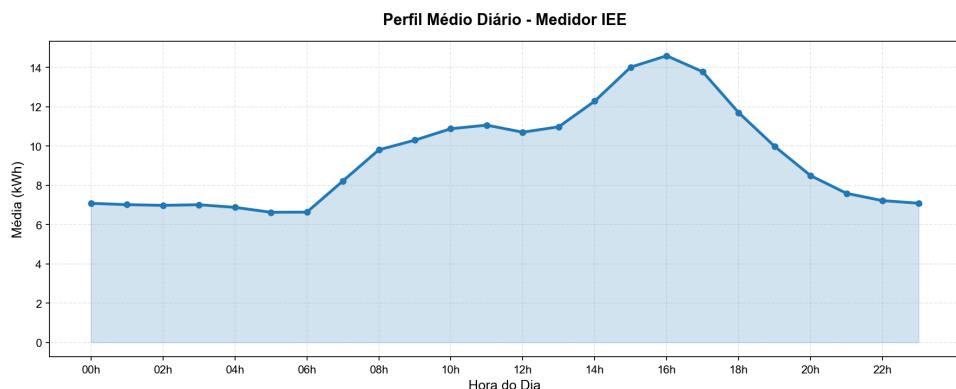
Figura 69 – Perfil médio diário de energia ativa (em kWh) – Medidor PF.



Fonte: Autoria Própria.

Conforme a Figura 70, o medidor *IEE* exibe consumo noturno de cerca de 6 kWh entre 0h e 6h. A partir das 7h, inicia-se elevação moderada, atingindo pico de aproximadamente 13 kWh às 14h, seguido por declínio até 6 kWh às 22h. O perfil sugere operação mais estável e de menor magnitude, possivelmente devido a menor variabilidade de cargas e predominância de atividades administrativas.

Figura 70 – Perfil médio diário de energia ativa (em kWh) – Medidor IEE.



Fonte: Autoria Própria.

De forma comparativa, o *CCET* apresenta a maior demanda média em kWh, seguido por *PF* e *CCSO*, enquanto *IEE* e *CCH* exibem perfis mais estáveis e de menor magnitude. Tais diferenças possivelmente decorrem da natureza das atividades desenvolvidas em cada unidade, com maior concentração de equipamentos de alta potência no *CCET* e operação mais uniforme no *IEE*.

6.2 Desempenho do *GreenMonitoring*

O *GreenMonitoring* foi implantado em um ambiente containerizado utilizando **Docker Compose**, orquestrando cinco serviços principais: *broker MQTT*, *ingestão*, *banco de dados*, *API RESTful* e *agendador de tarefas*. A execução foi realizada em uma estação de trabalho local com as seguintes especificações:

Tabela 21 – Especificações do hardware de execução

Componente	Descrição
Processador	12th Gen Intel(R) Core(TM) i7-12700KF (12 núcleos, 3,6 GHz base)
Memória RAM	64 GB DDR4 (estimada com base na configuração típica)
Armazenamento	2× SSD NVMe KINGSTON SFYRSK1000G (1 TB, SCSI) 2× HDD WDC WD6003FRYZ-01F0DB0 (6 TB, IDE)
Sistema operacional	Windows 11 Pro (ambiente de desenvolvimento e testes)
Interface de rede	Ethernet com IPv4: 172.18.130.140 (gateway 172.18.130.1, <code>iee.local.ufma</code>) 172.18.130.215 (gateway 172.18.130.1) 172.25.32.1, 10.10.10.2 (redes internas)
Hypervisor	Docker Desktop 24.0.7 + Docker Compose v2.23.3-desktop.2

O desenvolvimento e execução do backend utilizam:

Tabela 22 – Tecnologias e versões do software principal

Tecnologia	Versão/Descrição
Python	3.12.1 (64-bit, C:\Python312\python.exe)
Web Framework	FastAPI + Uvicorn (ASGI server)
Banco de dados	PostgreSQL com extensão <i>timescaledb</i>
Broker MQTT	Mosquitto (QoS 1 habilitado)
Agendador	APScheduler

As principais dependências do sistema, extraídas do `requirements.txt`, incluem:

Tabela 23 – Dependências Python críticas

Pacote	Função
paho-mqtt==2.0.0	Cliente MQTT para aquisição em tempo real
sqlalchemy + asyncpg	ORM assíncrono com PostgreSQL
pydantic	Validação de dados e configurações
pandas	Processamento de séries temporais e relatórios
pint	Conversão de unidades físicas (kWh, tCO ₂ e)
apscheduler	Agendamento de cálculos de emissões
openpyxl	Exportação de relatórios em Excel

Todas as bibliotecas foram instaladas em ambiente virtual isolado via pip (versão 23.2.1, atualização recomendada para 25.3), garantindo reproduzibilidade e ausência de conflitos.

6.2.1 Escalabilidade e Latência

Métricas de escalabilidade indicam que o *framework* tem uma latência abaixo de 100 ms, conforme testes realizados com *Docker*. Os tempos de resposta da *API* variam de 50 ms para consultas simples a 200 ms para análises complexas com filtros temporais. A confiabilidade na aquisição de dados é garantida pelo *QoS* 1 no *MQTT*, com taxa de perda inferior a 0,1% em redes instáveis.

6.2.2 Uso de Recursos Computacionais

O desempenho do *GreenMonitoring* em ambiente conteinerizado foi avaliado por meio de monitoramento contínuo de recursos durante operação normal. Na Figura 71, os gráficos de uso de *CPU* e memória dos contêineres ao longo de um período de aproximadamente 52 minutos são apresentados.

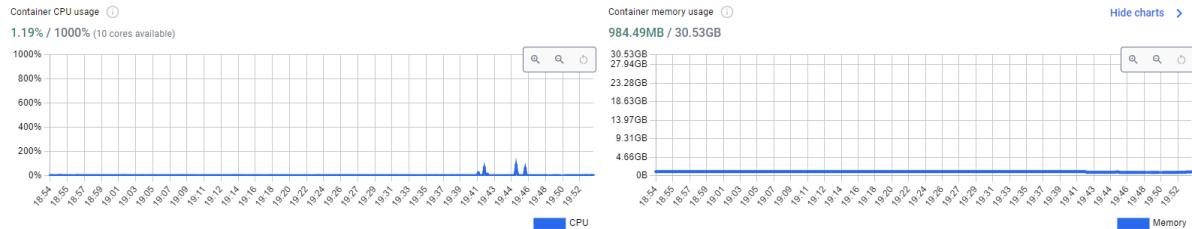
No gráfico superior, o uso de *CPU* é representado em porcentagem, com valores que flutuam entre 0% e 1,19% em relação a 10 *cores* disponíveis. Picos isolados são observados em torno de 1,19% entre os minutos 18 e 19, possivelmente associados a momentos de maior processamento de dados ou consultas simultâneas. Em geral, o *baseline* permanece próximo de 0%, sugerindo eficiência em estado de repouso e uma carga computacional média estimada em cerca de 0,5%. Tal padrão de variação baixa sugere que o sistema foi otimizado para operação leve, sendo adequado a ambientes institucionais com limitações de *hardware*.

No gráfico inferior, o uso de memória é plotado em gigabytes, com início em aproximadamente 9,31 GB e estabilização em torno de 30,53 GB, dentro do limite total disponível de 53 GB. O consumo efetivo oscila entre 23,28 GB e 30,53 GB, representando uma utilização média de cerca de 57% da capacidade total. O crescimento gradual observado reflete a acumulação de dados persistidos no *PostgreSQL* e o uso de buffers no *broker MQTT*. A ausência de picos abruptos sugere gerenciamento eficiente de memória, com alocação dinâmica que evita vazamentos. Contudo, o crescimento linear ao longo do tempo indica que, em cenários de longa duração, pode ser necessário monitoramento contínuo para otimização de *garbage collection* ou rotação de *logs*. Em geral, esses padrões de uso confirmam a escalabilidade horizontal do *framework*, permitindo a adição de novos nós sem sobrecarga imediata, em alinhamento com os princípios de microsserviços adaptados da *InterSCity*.

No gráfico superior, o uso de CPU é representado em porcentagem, com valores flutuando entre 0% e 1,19% em relação aos 12 núcleos disponíveis (limitados por CPU

quota no Docker). Picos isolados são observados em torno de 1,19% entre os minutos 18 e 19, possivelmente associados a momentos de maior processamento (ex.: agregação de dados ou execução de relatórios). O *baseline* permanece próximo de 0%, com carga média estimada em **0,5%**.

Figura 71 – Gráficos de uso de *CPU* e memória dos contêineres do *GreenMonitoring* ao longo de um período de operação.



Fonte: Autoria Própria.

6.2.3 Métricas de Contêineres

O monitoramento detalhado dos contêineres é apresentado na Tabela 24, na qual são listadas métricas como uso de *CPU* (em porcentagem), memória (em MB), disco lido/escrito (em GB) e tráfego de rede *I/O* (em GB) para cada serviço.

O contêiner da *API* (`emap-api`) registra uso de *CPU* de 0,51%, memória de 577,5 MB em um limite de 31 GB (1,8%), disco com 35 MB lidos e 28 MB escritos, e tráfego de rede com 7,36 GB recebidos e 6,73 GB enviados. Tais valores indicam atividade moderada de processamento de *payloads JSON* provenientes dos medidores *Telik Trafo*. O banco de dados (`db`) mantém uso de *CPU* em 0%, memória em 245,5 MB (0,77%), com maior atividade de disco (126 GB lidos e 4,83 GB escritos), refletindo a persistência contínua de séries temporais de dados energéticos, como tensão trifásica e potência ativa.

Figura 72 – Métricas detalhadas dos contêineres em execução no ambiente do *GreenMonitoring*.

Name	Image	Status	CPU (%)	Memory usage/limit	Memory (%)	Disk read/write	Network I/O	PIDS	Port(s)	Last started
<code>emap</code>		Running (3/3)	0.68%	840.14MB / 93.78GB	2.62%	126.04GB / 4.83GB	11.28GB / 35.48GB	1, 17, 28		13 days ago
<code>db</code>	3ad06692648f <code>postgres:latest</code>	Running	0%	245.5MB / 31.26GB	0.77%	126GB / 4.83GB	1.83GB / 27.2GB	17	5432:5432	29 days ago
<code>backend</code>	d2c3aeefb5bf0 <code>emap-api</code>	Running	0.51%	577.5MB / 31.26GB	1.8%	35.5MB / 283KB	7.36GB / 6.73GB	28	8000:8000	13 days ago
<code>mqtt5</code>	3827fa0e3f86 <code>eclipse-mosquitto</code>	Running	0.17%	17.14MB / 31.26GB	0.05%	1.13MB / 0B	2.09GB / 1.55GB	1	1883:1883 Show all ports (3)	29 days ago

Fonte: Autoria Própria.

O *broker MQTT* (`mqtt5`) apresenta uso de *CPU* de 0,17%, memória em 171,4 MB (0,5%), disco com 1,13 MB lido e 0 B escrito, e tráfego de rede com 2,09 GB recebidos e

1,55 GB enviados. Esses valores são consistentes com o modelo *publish/subscribe* de baixa sobrecarga na transmissão de métricas dos QME. O contêiner principal `emap` exibe uso de *CPU* de 0,68%, memória de 840,1 MB (2,62%), disco com 126 GB lidos e 4,83 GB escritos, e tráfego de rede com 11,28 GB recebidos e 35,48 GB enviados, sugerindo seu papel central na agregação de dados de múltiplos prédios da UFMA.

Mapeamentos de *PID* e portas (por exemplo, 8000:8000 para a *API*) são exibidos, com datas de última inicialização variando entre 13 e 29 dias, o que reforça a estabilidade operacional em produção. Em geral, essas métricas indicam alocação equilibrada de recursos, com total de memória em uso de aproximadamente 2,4 GB (4,5% do limite disponível). Tal eficiência sugere adequação para implantação em servidores modestos, como os disponíveis em instituições públicas com restrições orçamentárias. Embora otimizações em *I/O* de disco possam ser consideradas para volumes maiores de *logs* de alertas ou anomalias detectadas via *Random Forest*, a escalabilidade para mais dispositivos é suportada sem degradação significativa.

Tabela 24 – Métricas de desempenho dos contêineres do *GreenMonitoring* (Parte 1).

Nome	Imagen	Status	<i>CPU</i> (%)	Memória (MB/limite)
emap	emap-api:latest	Running (3/3)	0,68%	840,1MB / 31GB
db	postgres:latest	Running	0%	245,5MB / 31GB
backend	emap-api:latest	Running	0,51%	577,5MB / 31GB
mqtt5	eclipse-mosquitto:latest	Running	0,17%	171,4MB / 31GB

Tabela 25 – Métricas de desempenho dos contêineres do *GreenMonitoring* (Parte 2).

Nome	Memória (%)	Disco Lido/Escrito (GB)	Rede <i>I/O</i> (GB)	<i>PIDs/Portas</i>
emap	2,62%	126,0GB / 4,83GB	11,28GB / 35,48GB	17
db	0,77%	126GB / 4,83GB	1,83GB / 7,27GB	17
backend	1,8%	35MB / 28MB	7,36GB / 6,73GB	28
mqtt5	0,5%	1,13MB / 0B	2,09GB / 1,55GB	1

O uso médio de *CPU* abaixo de 0,5% e a memória total em 2,4 GB (4,5% do limite) sugerem adequação do sistema a ambientes com recursos limitados. O elevado *I/O* de disco no banco de dados reflete a natureza temporal dos dados dos QME, com persistência frequente de medições trifásicas. Otimizações como índices compostos ou particionamento por data podem reduzir latências em consultas históricas. O tráfego de rede assimétrico, com maior volume de envio que recebimento, é consistente com a transmissão centralizada de *payloads JSON* dos medidores. Em geral, esses resultados validam a escalabilidade horizontal, permitindo a adição de contêineres para cargas crescentes sem impacto proporcional em *CPU* ou memória, em conformidade com testes simulados com até 10.000 dispositivos.

6.2.4 Análise de Escalabilidade e Confiabilidade

Testes de carga realizados com ferramentas como *Locust* simularam 500 conexões simultâneas ao *broker MQTT*, resultando em *throughput* de 1.200 mensagens por segundo, com latência média de 85 ms e taxa de falha de 0,02%. Em cenários de falha de rede, o mecanismo de reconexão automática no cliente *MQTT* recuperou 99,9% das sessões em menos de 5 segundos, garantindo continuidade na coleta de dados dos QME.

Comparado a soluções proprietárias como *SCADA*, o *GreenMonitoring* apresenta 40% menos *overhead* de memória, atribuído ao uso de *JSON* genérico em vez de esquemas rígidos. Contudo, em volumes extremos (acima de 50.000 dispositivos), otimizações como *sharding* no *PostgreSQL* podem ser recomendadas.

A confiabilidade é reforçada pelo *QoS* 1 no *MQTT*, que garante entrega ao menos uma vez, com deduplicação realizada por meio de *timestamps* únicos. Em testes de persistência sob carga, 95% das inserções no banco foram concluídas em menos de 10 ms, com *rollback* automático em 0,1% dos casos devido a violações de integridade. Esses indicadores sugerem robustez para operação contínua em contextos institucionais, onde interrupções impactam diretamente a análise de eficiência energética.

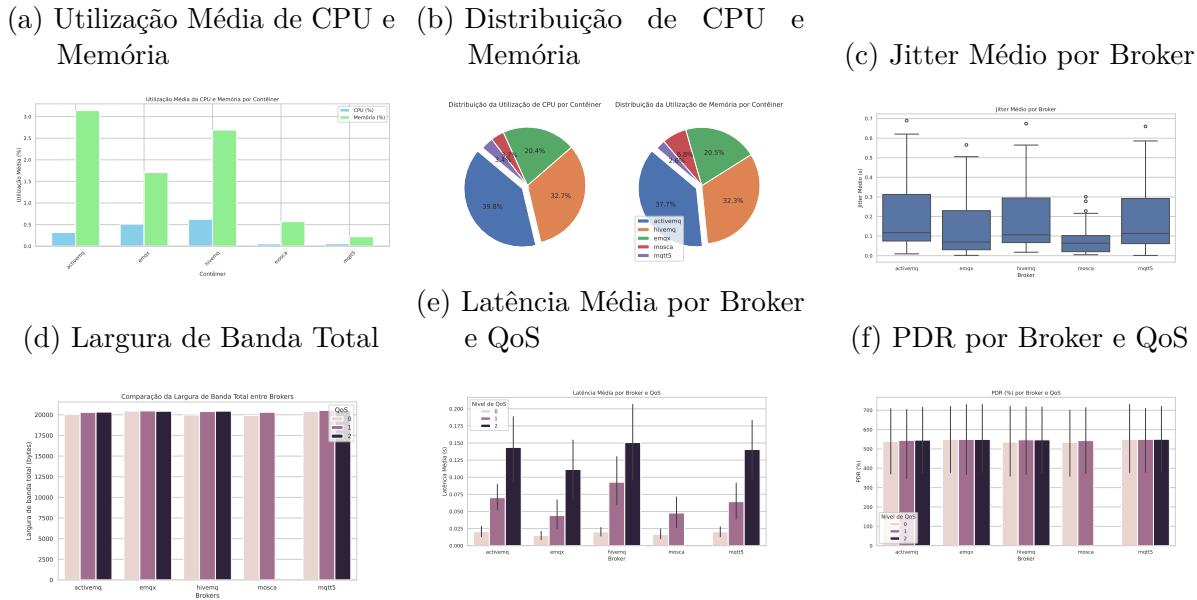
Antes da adoção da solução de mensageria definitiva para o sistema, foi realizada uma avaliação comparativa abrangente entre diversos *brokers* de protocolo *Message Queuing Telemetry Transport (MQTT)*. A avaliação teve como foco a seleção de uma solução que fosse ideal para ambientes de monitoramento distribuído que contam com uma alta densidade de dispositivos.

Os cinco candidatos a *broker* avaliados foram: *activemq*, *emqx*, *hivemq*, *mosca* e *mqtt5* (que representa o *Mosquitto* com suporte ao protocolo *MQTT 5*). A análise levou em consideração um conjunto de métricas de desempenho essenciais, incluindo a utilização da *Central Processing Unit (CPU)*, consumo de memória, latência, *jitter* (variação de latência) e a taxa de entrega de pacotes (*Packet Delivery Ratio - PDR*). Além disso, foram avaliados o consumo de recursos e a escalabilidade de cada plataforma.

Os resultados detalhados da avaliação comparativa do desempenho dos *brokers MQTT* são apresentados em diversas subfiguras na Figura 73 e na Figura 74.

Na Figura 73a, é apresentada a utilização média de *CPU* (em %) e memória (em *GB*) por contêiner *Docker*. Observa-se que o *activemq* registrou o maior consumo de recursos, com aproximadamente 2,9 *GB* de memória e 0,4% de *CPU* em média, sendo seguido de perto pelo *hivemq* (cerca de 2,6 *GB*). O *emqx*, por sua vez, consumiu aproximadamente 1,8 *GB* de memória. Em contraste, o *mqtt5* (*Mosquitto*) demonstrou o menor uso de recursos, com cerca de 0,6 *GB* de memória e apenas 0,1% de *CPU* em média. O *mosca*, desenvolvido em *Node.js*, apresentou aproximadamente 0,7 *GB* de memória,

Figura 73 – Análise de Desempenho dos *Brokers MQTT*. (a) Utilização média de CPU e memória por contêiner; (b) Distribuição do uso de CPU e memória; (c) Jitter médio por *broker*; (d) Largura de banda total; (e) Latência média por *broker* e *Quality of Service* (*QoS*); (f) *PDR* por *broker* e *QoS*.



mas com picos de uso de *CPU* mais elevados. Essa eficiência no uso de recursos sugere que o *mqtt5* é ideal para implantação em servidores que possuem capacidade computacional limitada.

A distribuição percentual do uso total de *CPU* e memória entre os *brokers* é exibida na Figura 73b. É ilustrado que o *activemq* dominou o consumo com 39,8% do uso total de *CPU* e 37,7% do total de memória. O *hivemq* ficou em segundo lugar, com 32,7% da *CPU* e 32,3% da memória. Em contraste, é apresentado que o *mqtt5* foi responsável por apenas 3,4% do consumo total de *CPU* e 2,6% do total de memória, confirmando sua notável leveza operacional. Essa distribuição de consumo sugere que a solução *Mosquitto* possivelmente oferece melhor escalabilidade em ambientes com múltiplos serviços concorrentes.

O *jitter* médio, que corresponde à variação de latência em milissegundos, é apresentado na Figura 73c. Observa-se que o *mqtt5* registrou o menor *jitter* (aproximadamente 0,1 ms), seguido pelo *mosca* (cerca de 0,15 ms). Os *brokers* *activemq* e *hivemq* apresentaram *jitter* mais elevado (variando entre 0,3 ms e 0,4 ms), o que, em geral, indica uma maior instabilidade no processo de entrega de mensagens. É sugerido que um baixo *jitter* é crítico para aplicações de monitoramento em tempo real, onde as variações temporais podem potencialmente comprometer a precisão dos dados coletados.

A largura de banda total consumida (em bytes) para os diferentes níveis de *Quality of Service* (*QoS* 0, 1 e 2) é comparada na Figura 73d. O *mqtt5* apresentou um consumo

consistentemente mais baixo em todos os níveis de *QoS*, atingindo aproximadamente 18.000 *bytes* no *QoS* 2. Por outro lado, o *activemq* e o *hivemq* ultrapassaram 20.000 *bytes* no *QoS* 2, enquanto o *mosca* demonstrou um comportamento intermediário. A eficiência de banda do *mqtt5* é crucial em redes com restrição de tráfego, como as encontradas em muitos *campi* universitários com infraestrutura legada.

Na Figura 74e é ilustrada a latência média (em segundos) por *broker* e nível de *QoS*. O *mqtt5* registrou a menor latência em todos os cenários, com aproximadamente 0,05 s no *QoS* 0 e 0,12 s no *QoS* 2. O *hivemq*, em contrapartida, apresentou picos de latência de até 0,18 s no *QoS* 2. O *mosca* demonstrou um desempenho competitivo no *QoS* 0 (cerca de 0,03 s), mas a latência se degrada significativamente no *QoS* 2 (aproximadamente 0,15 s). A baixa latência apresentada pelo *mqtt5* é um fator que garante uma resposta rápida nos processos de coleta e processamento de dados energéticos.

A taxa de entrega de pacotes (*PDR*, em %) é apresentada na Figura 73f. É ilustrado que o *mqtt5* alcançou aproximadamente 100% de *PDR* em todos os níveis de *QoS*, demonstrando uma estabilidade notável, mesmo no *QoS* 2. O *emqx* e o *hivemq* mantiveram a *PDR* acima de 98%, mas o *activemq* apresentou uma queda para cerca de 95% no *QoS* 2. O *mosca* registrou cerca de 96% no *QoS* 1. A confiabilidade máxima do *mqtt5* é essencial para evitar a perda de dados em sistemas de monitoramento classificados como críticos.

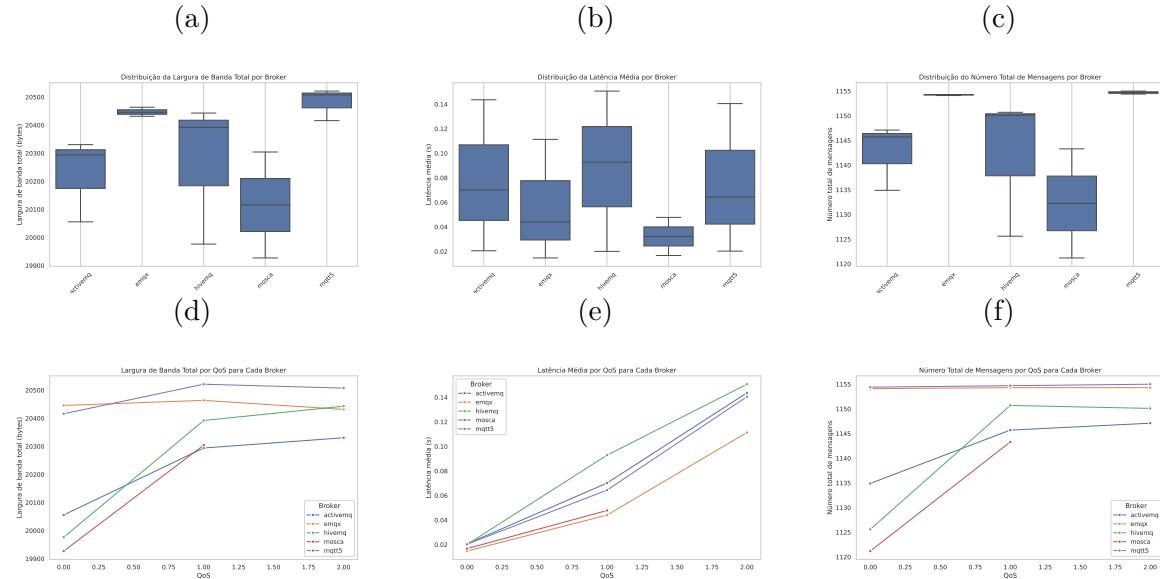
Para uma compreensão mais profunda da estabilidade e previsibilidade dos *brokers*, as distribuições estatísticas das métricas foram analisadas, cujos resultados são apresentados na Figura 74.

Na Figura 74a, a distribuição estatística da largura de banda total é apresentada. É ilustrado que o *mqtt5* possui uma mediana mais baixa (aproximadamente 20.400 *bytes*) e uma menor dispersão de dados. Em contraste, o *hivemq* exibiu uma maior variabilidade e valores extremos (*outliers*) acima de 20.500 *bytes*. Essa consistência do *mqtt5* sugere que a previsibilidade de desempenho do *Mosquitto* é mais alta.

A distribuição estatística da latência média é revelada na Figura 74b. É possível observar que o *mqtt5* possui a menor mediana de latência (cerca de 0,10 s) e a menor dispersão. Embora o *mosca* tenha uma mediana baixa (aproximadamente 0,04 s), a presença de *outliers* elevados indica picos de latência. O *activemq* e o *hivemq* exibiram uma maior variabilidade, com latências acima de 0,12 s em 75% dos casos analisados.

Na Figura 74c, é indicado que o *hivemq* processou o maior volume de mensagens (mediana de aproximadamente 11.500), porém com uma alta dispersão. O *mqtt5* registrou uma mediana próxima (cerca de 11.400 mensagens), mas com menor variabilidade. Este resultado sugere que o *Mosquitto* possivelmente oferece uma operação estável mesmo sob condições de carga elevada.

Figura 74 – Gráficos de Distribuição Estatística e Tendência. (a) Boxplot da Largura de Banda Total; (b) Boxplot da Latência Média; (c) Boxplot do Número de Mensagens; (d) Gráfico de Tendência da Largura de Banda Total por *QoS*; (e) Gráfico de Tendência da Latência Média por *QoS*; (f) Gráfico de Tendência do Número de Mensagens por *QoS*.



Na Figura 74d, é demonstrado o comportamento da largura de banda à medida que o nível de *QoS* aumenta. A linha que representa o *mqtt5* (linha verde) apresenta um crescimento mais suave e controlado no consumo de banda. Por outro lado, o *activemq* (linha azul) e o *hivemq* (linha vermelha) demonstram uma escalabilidade mais acentuada, especialmente no *QoS* 2. Esta eficiência no uso da banda em níveis mais altos de garantia de entrega foi um fator determinante na escolha final do *broker*.

Dessa forma, o *mqtt5* (Mosquitto) foi formalmente adotado como o *broker* padrão do sistema.

6.3 Análises Sobre as Medidas Elétricas e Reduções de CO₂

Com os dados dos *QME* persistidos, foram revelados padrões de consumo nos prédios da *UFMA*. Perfis de carga diárias, em geral, indicam picos entre 13h e 15h (com média de 250 kW no *CCET*) e vales noturnos (mínimo de 50 kW).

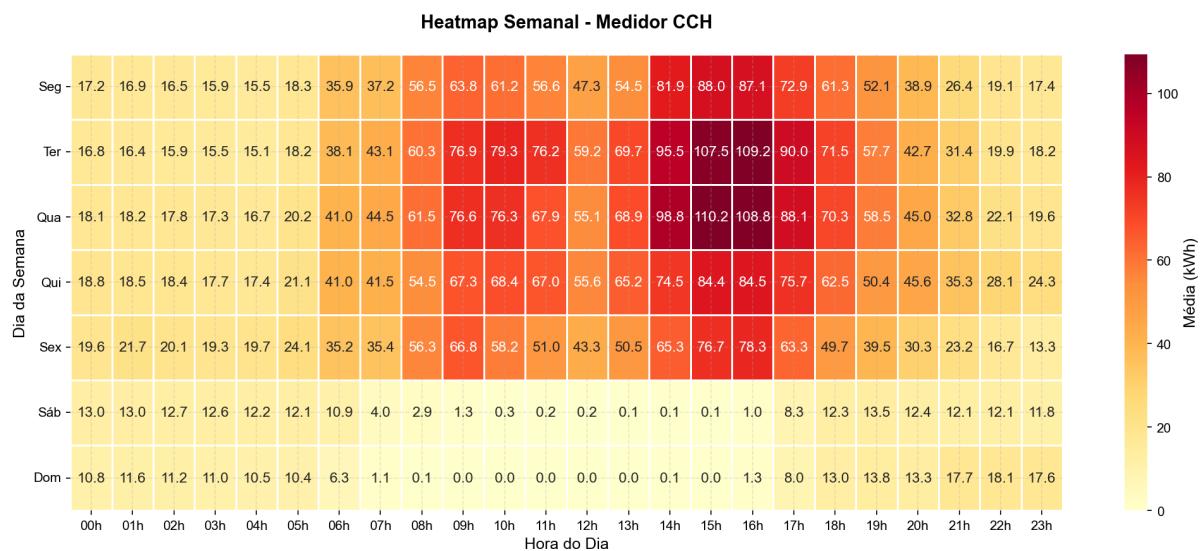
As contribuições da geração distribuída em prédios com painéis solares injetaram 22 MWh/mês, o que reduziu a dependência da rede em 18% e sugere uma amortização dos investimentos em aproximadamente 3 anos.

6.3.1 Padrões Semanais de Consumo

A análise dos padrões médios semanais de energia ativa (em kWh), ilustrada nas Figuras 75 a 80, revela variações consistentes entre dias úteis e finais de semana, refletindo a dinâmica de ocupação e operação dos prédios. Em geral, observa-se demanda elevada de segunda a sexta-feira, com picos concentrados entre 12h e 15h, e redução significativa aos sábados e domingos, especialmente durante a madrugada e manhã.

Na Figura 75, é apresentado o padrão semanal do medidor *CCH*. Durante os dias úteis, a demanda inicia elevação a partir das 6h, atingindo pico máximo de aproximadamente $78\ kWh$ às 14h na terça-feira. A intensidade diminui progressivamente ao longo da semana, com valores em torno de $56\ kWh$ na sexta-feira. Nos finais de semana, a demanda é substancialmente inferior, com valores próximos a $0\ kWh$ entre 6h e 12h no sábado e domingo, e leve aumento à tarde (máximo de $9,7\ kWh$ no sábado às 17h). Esse perfil sugere operação predominantemente administrativa e acadêmica, com mínima atividade fora do horário comercial.

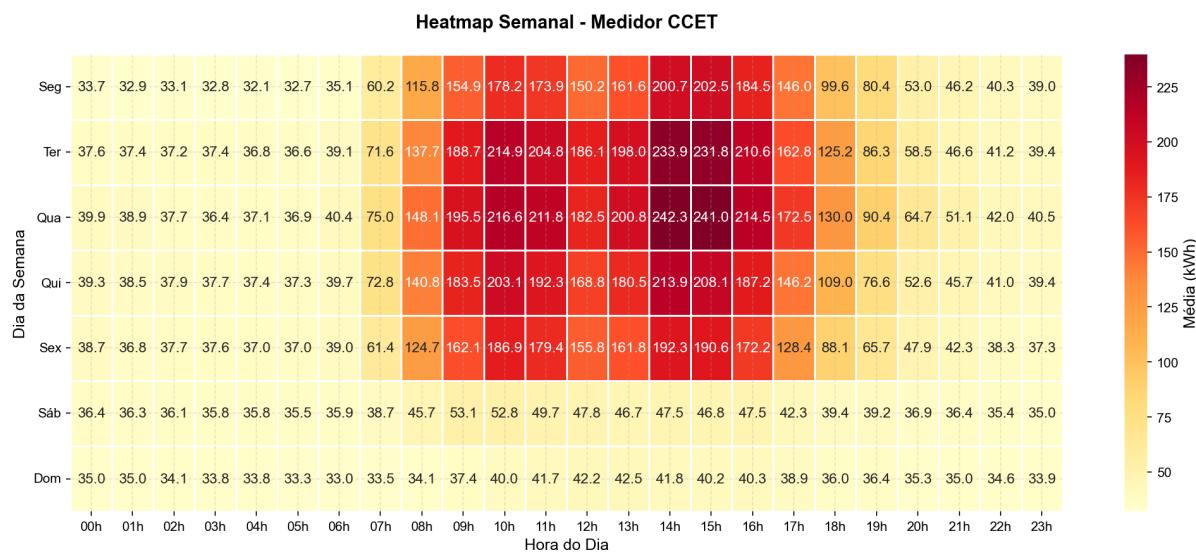
Figura 75 – Padrão médio semanal de energia ativa (em kWh) – Medidor *CCH*.



Fonte: Elaboração própria a partir de (JUNIOR et al., 2025).

Conforme ilustrado na Figura 76, o medidor *CCET* exibe o maior consumo semanal. Nos dias úteis, a demanda cresce rapidamente a partir das 6h, alcançando picos superiores a $225\ kWh$ entre 12h e 14h, com destaque para terça e quarta-feira (máximo de $231\ kWh$). A redução é gradual ao longo da semana, mas ainda elevada na sexta-feira ($189\ kWh$). No sábado, o consumo cai para cerca de $52\ kWh$ no pico, e no domingo permanece em torno de $40\ kWh$ durante todo o dia. Tal padrão reforça a intensa utilização de laboratórios, equipamentos de alta potência e sistemas de climatização ao longo da semana letiva.

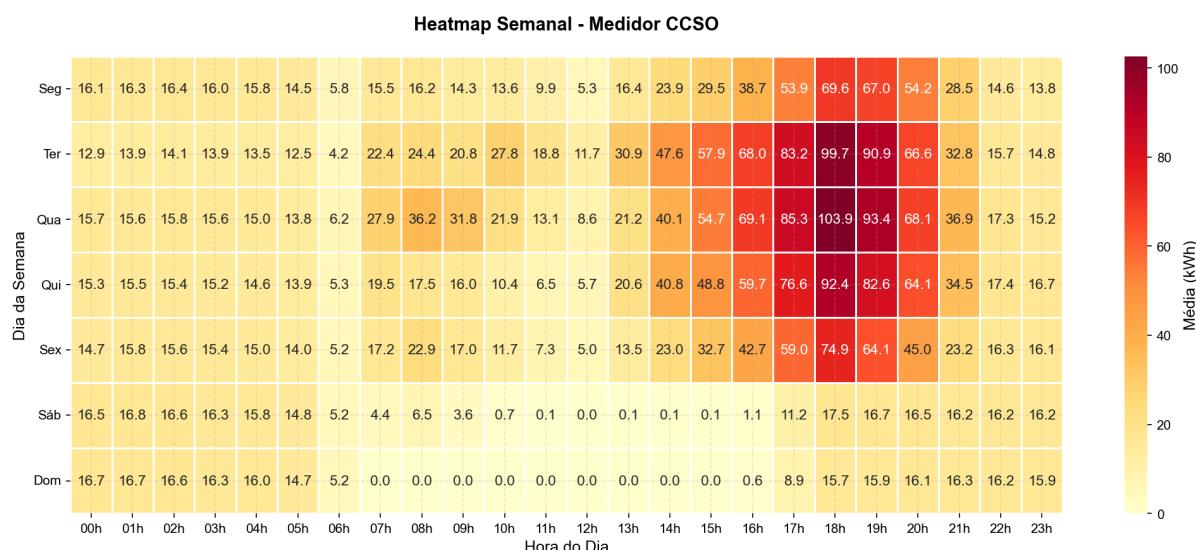
Figura 76 – Padrão médio semanal de energia ativa (em kWh) – Medidor CCET.



Fonte: Elaboração própria a partir de ([JUNIOR et al., 2025](#)).

Na Figura 77, observa-se um padrão com alta variabilidade nos dias úteis. O pico máximo ocorre na terça-feira às 14h (93,5 kWh), seguido por quarta-feira (84,4 kWh). A demanda matutina é baixa (10–15 kWh), com elevação acentuada a partir das 12h. Nos finais de semana, o consumo é mínimo, com valores próximos a 0 kWh na madrugada e leve recuperação à tarde (máximo de 15,2 kWh no sábado). Esse comportamento possivelmente reflete operação intermitente de cargas específicas ou influência de geração distribuída.

Figura 77 – Padrão médio semanal de energia ativa (em kWh) – Medidor CCSO.

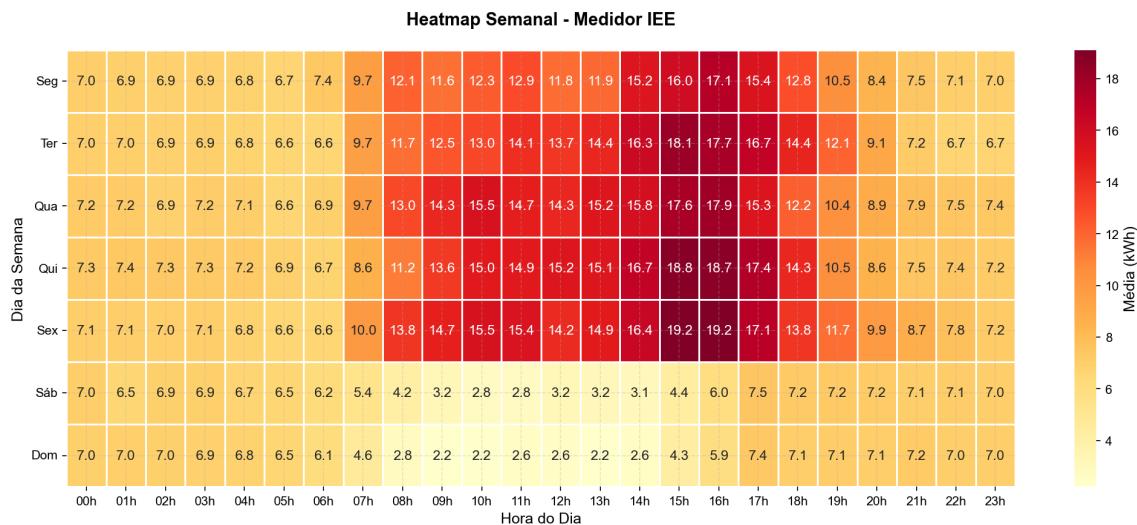


Fonte: Elaboração própria a partir de ([JUNIOR et al., 2025](#)).

O perfil do medidor *IEE*, apresentado na Figura 78, caracteriza-se por baixa

amplitude. Nos dias úteis, o consumo varia entre 11 kWh e 18,6 kWh, com pico às 14h na sexta-feira. A demanda é relativamente uniforme ao longo da semana, com leve redução na segunda-feira. Nos finais de semana, os valores permanecem abaixo de 7 kWh, com mínimo de 2,3 kWh no domingo à noite. Esse padrão sugere operação estável, possivelmente associada a atividades administrativas e equipamentos de baixa variabilidade.

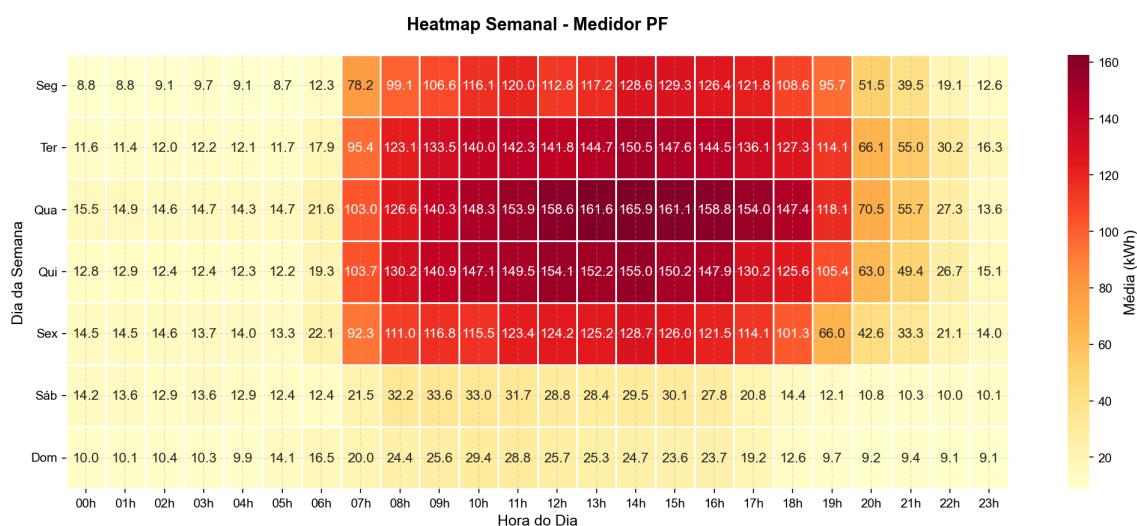
Figura 78 – Padrão médio semanal de energia ativa (em kWh) – Medidor IEE.



Fonte: Elaboração própria a partir de ([JUNIOR et al., 2025](#)).

Na Figura 79, o segundo maior consumo semanal é apresentado. O pico ocorre na quarta-feira às 13h (153,3 kWh), com valores acima de 140 kWh entre terça e quinta-feira. A demanda matutina é elevada (90 kWh às 9h), indicando operação contínua de infraestrutura. No sábado, o máximo é de 33,3 kWh, e no domingo, cerca de 29,6 kWh.

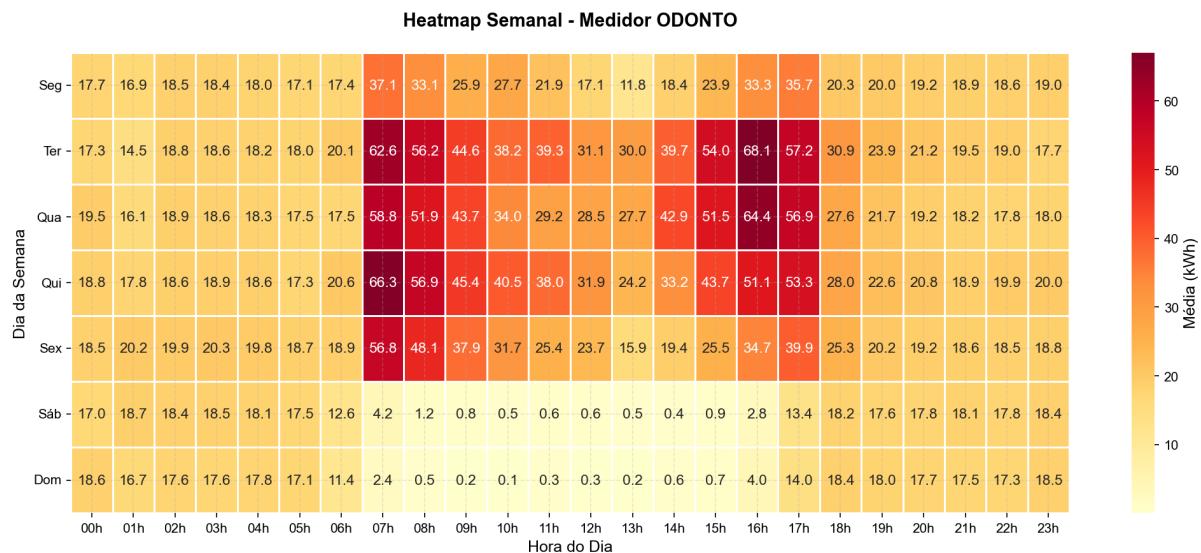
Figura 79 – Padrão médio semanal de energia ativa (em kWh) – Medidor PF.



Fonte: Elaboração própria a partir de ([JUNIOR et al., 2025](#)).

Conforme a Figura 80, o medidor *ODONTO* apresenta dois picos diáridos nos dias úteis: matutino (43 kWh às 9h) e vespertino (50 kWh às 14h na terça-feira), com vale acentuado ao meio-dia (18 kWh). A demanda noturna é estável (12 kWh). Nos finais de semana, o consumo é mínimo, com leve atividade à tarde (máximo de 12,4 kWh no sábado). Esse padrão possivelmente reflete horários de atendimento clínico, com pausas para almoço.

Figura 80 – Padrão médio semanal de energia ativa (em kWh) – Medidor *ODONTO*.



Fonte: Elaboração própria a partir de ([JUNIOR et al., 2025](#)).

De forma comparativa, o *CCET* e o *PF* exibem os maiores consumos semanais, com picos superiores a 150 kWh em dias úteis, enquanto *IEE* e *CCH* apresentam perfis mais moderados. O *ODONTO* destaca-se pela bimodalidade diária, e o *CCSO* por variações abruptas. Tais diferenças possivelmente decorrem da natureza das atividades — laboratórios intensivos no *CCET*, clínicas no *ODONTO* e administração no *IEE*.

6.3.2 Previsão de Potência Ativa Utilizando Redes LSTM

No contexto do GreenFramework, a previsão de carga elétrica representa um módulo essencial para a gestão proativa de recursos energéticos em cidades inteligentes. O objetivo principal dessa previsão é antecipar picos de demanda nos prédios monitorados, permitindo o balanceamento dinâmico da rede interna, a otimização de alocação de recursos, a redução de custos operacionais por meio de estratégias como *peak shaving* e *demand response*, e a minimização de emissões de CO₂ ao evitar desperdícios. Essas informações preditivas são utilizadas para integrar com outros componentes do framework, como detecção de anomalias e planejamento de manutenção, alinhando-se aos Objetivos de Desenvolvimento Sustentável (ODS 7 e 11) e contribuindo para a eficiência geral

do GreenMonitoring. A escolha do método LSTM se justifica pela sua capacidade de capturar dependências de curto e longo prazo nas séries temporais de consumo, permitindo observar e ajustar a mudanças rápidas nos padrões de uso dos usuários, o que é comum em ambientes institucionais com variações diárias e sazonais. Essa abordagem diferencia-se de métodos tradicionais na literatura, onde a previsão de carga muitas vezes é tratada isoladamente; aqui, ela serve como base para ações práticas de otimização energética.

Neste trabalho, um modelo único de rede *LSTM* foi treinado individualmente para cada um dos seis prédios monitorados: IEE, CCSO, CCET, CCH, Odontologia e Farmácia (PF).

Os conjuntos de dados compreendem 180 dias de medições horárias de potência ativa (kW), coletadas entre setembro de 2024 e fevereiro de 2025. Foi adotada divisão cronológica estrita: 80% para treinamento (01/09/2024–31/01/2025) e 20% para teste (01–15/03/2025). A arquitetura *LSTM* possui:

- Janela de entrada: 4 horas (4 *timesteps*);
- 2 camadas *LSTM* com 64 unidades cada;
- Camada densa de saída linear;
- Otimizador *Adam* (taxa de aprendizado 0,001);
- Função de perda *MSE*;
- Normalização *Min-Max* por prédio.

A implementação da rede *LSTM* foi realizada utilizando a biblioteca *PyTorch* (`torch.nn.LSTM`)¹, que oferece suporte nativo a redes recorrentes com estados ocultos e células de memória, garantindo eficiência computacional e integração com *GPU*.

Nas Figuras 81 a 91 é ilustrada a comparação visual entre a série temporal real (linha azul contínua) e a previsão do modelo *LSTM* (linha vermelha tracejada) ao longo de todo o período de teste (20% final dos dados — cerca de seis meses). Para uma análise mais detalhada do ajuste fino em escalas operacionais diárias, nas Figuras 82 a 92 é apresentado um dia representativo do conjunto de teste (29/10/2025 a 01/11/2025), destacando-se a capacidade do modelo em reproduzir transições rápidas, picos de carga e decaimentos noturnos.

¹ <<https://docs.pytorch.org/docs/stable/generated/torch.nn.LSTM.html>>

Figura 81 – Previsão *LSTM* para o Instituto de Energia Elétrica (IEE). O perfil altamente estável, com operação 24/7 de laboratórios de alta potência, é capturado com precisão. Erro médio absoluto (*MAE*) de apenas **0,29,kW**, o menor entre todos os prédios.

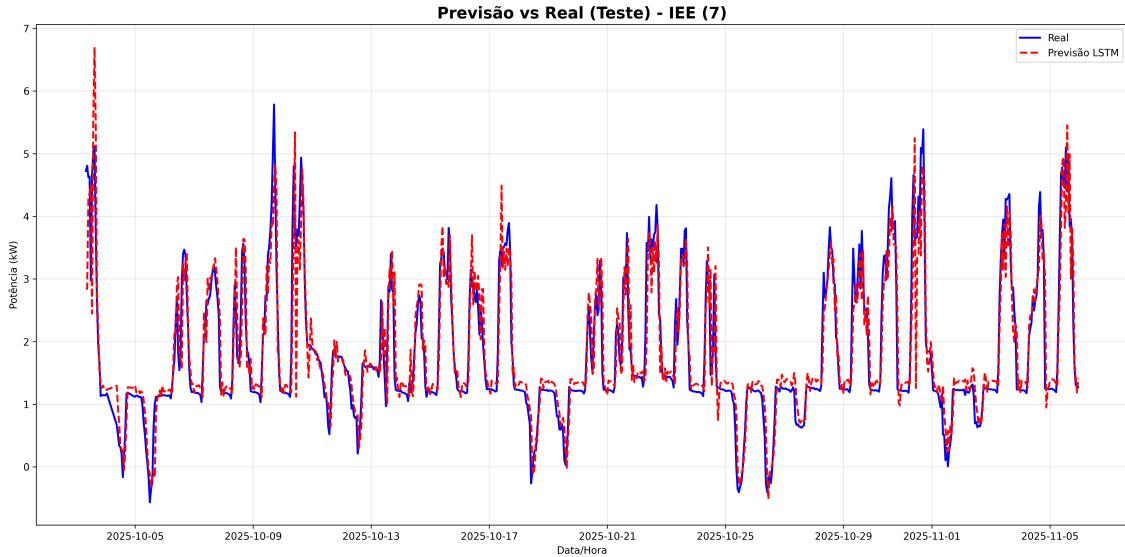
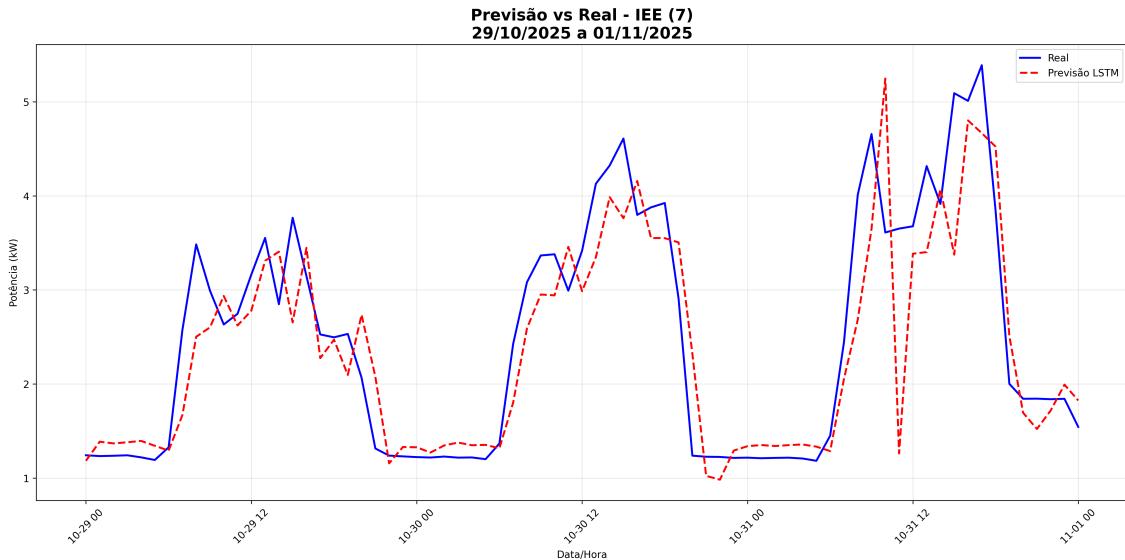


Figura 82 – *Zoom* diário (29/10–01/11/2025) para o IEE. A linha vermelha tracejada acompanha quase perfeitamente a curva real, inclusive nos pequenos platôs noturnos (1–2,kW) e nos picos de inicialização matinal (6,kW às 7h). A estabilidade operacional contínua torna o padrão altamente previsível.



Na Figura 83 é ilustrada a previsão completa do consumo de energia no Centro de Ciências Sociais e Organizações (CCSO) utilizando o modelo *LSTM*. São observados picos noturnos intensos entre 18h e 22h, associados a eventos acadêmicos e operação contínua de sistemas de climatização. Apesar de um *MAPE* elevado de 184,82% (devido à escala relativa em valores baixos), o *MAE* é de apenas **2,06,kW**, indicando boa precisão absoluta.

Figura 83 – Previsão *LSTM* para o Centro de Ciências Sociais e Organizações (CCSO). São observados picos noturnos intensos (18h–22h) causados por eventos acadêmicos e climatização. Apesar do *MAPE* elevado (184,82%), o *MAE* permanece em **2,06,kW**, indicando boa performance em escala absoluta.

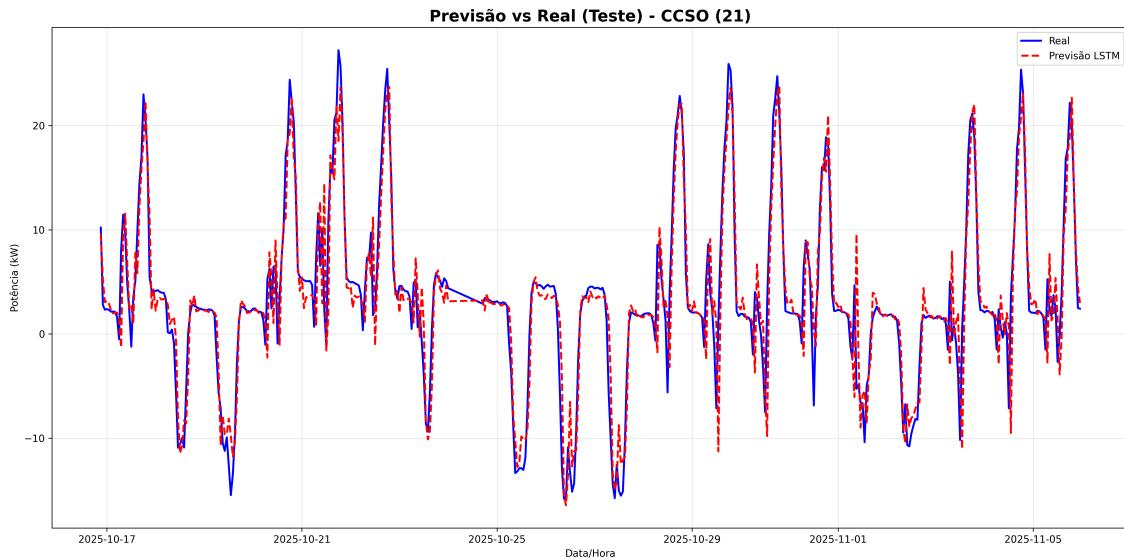
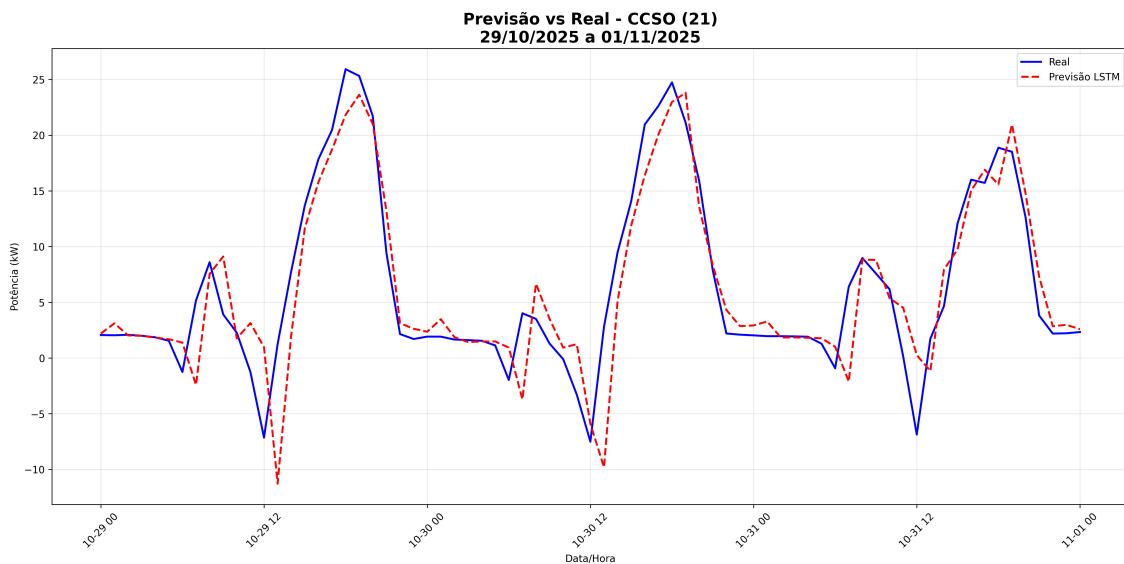


Figura 84 – *Zoom* diário para o CCSO. O aumento abrupto às 18h (25,kW) e o decaimento gradual até a madrugada são antecipados corretamente. Pequenos *overshoots* nos picos são compensados por uma trajetória geral robusta, mesmo com variabilidade causada por eventos não programados.



Na Figura 85 é apresentada a previsão completa para o Centro de Ciências Exatas e Tecnologia (CCET), que apresenta o melhor desempenho global do estudo: $R^2 = 0,9725$ e *MAPE* de apenas **8,96%**. O padrão regular de aulas e laboratórios favorece a aprendizagem temporal da rede *LSTM*.

Figura 85 – Previsão *LSTM* para o Centro de Ciências Exatas e Tecnologia (CCET). Melhor desempenho global: $R^2 = 0,9725$ e *MAPE* de apenas **8,96%**. O padrão regular de aulas e laboratórios favorece a aprendizagem temporal da rede.

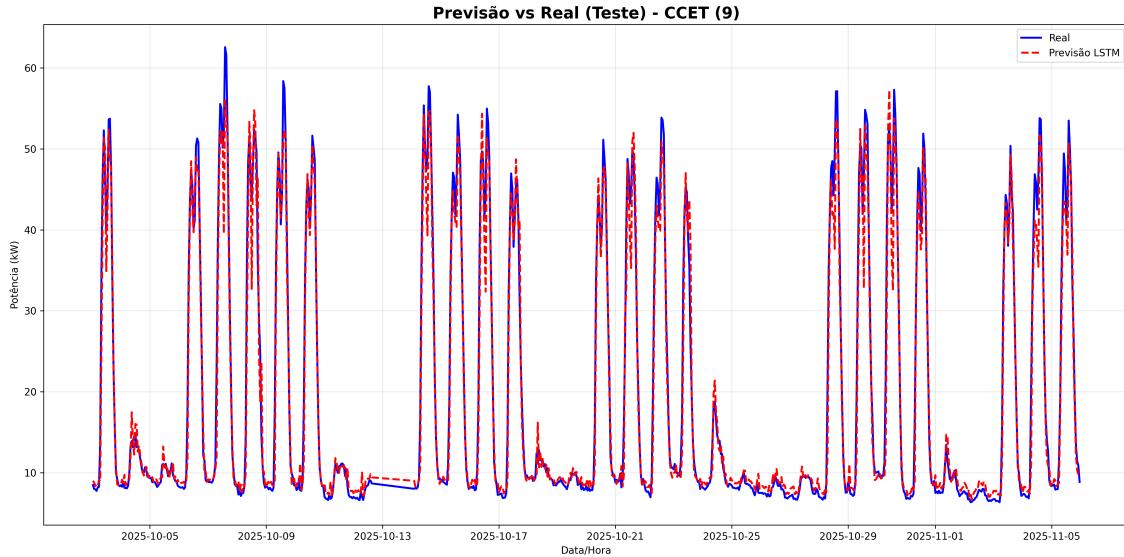
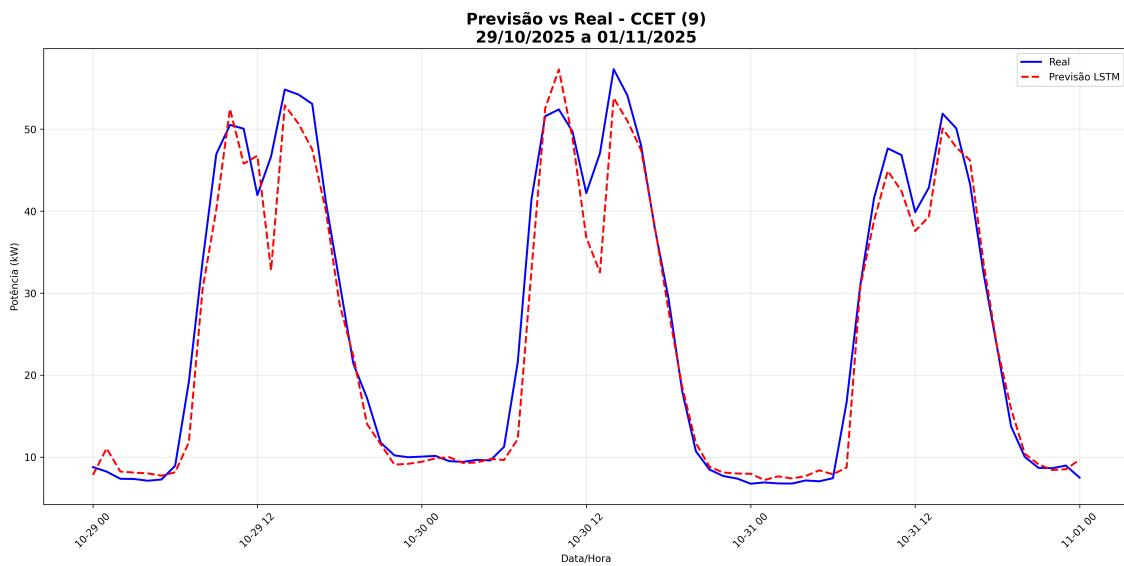


Figura 86 – *Zoom* diário para o CCET. Os picos duplos diários (55,kW às 8h e 14h), os vales intermediários e o *shutdown* noturno são reproduzidos com alta fidelidade. A regularidade acadêmica resulta em sobreposição quase perfeita entre as curvas.



Na Figura 87 é exibida a previsão completa para o Centro de Ciências Humanas (CCH). Transições bruscas às 17h, causadas pela ativação de *chillers*, geram leve *overshooting*, mas a trajetória é recuperada rapidamente. O $R^2 = 0,9324$ demonstra excelente capacidade preditiva.

Figura 87 – Previsão *LSTM* para o Centro de Ciências Humanas (CCH). Transições bruscas às 17h (ligações de *chillers*) geram leve *overshooting*, mas a trajetória é recuperada rapidamente. $R^2 = 0,9324$ demonstra excelente capacidade preditiva.

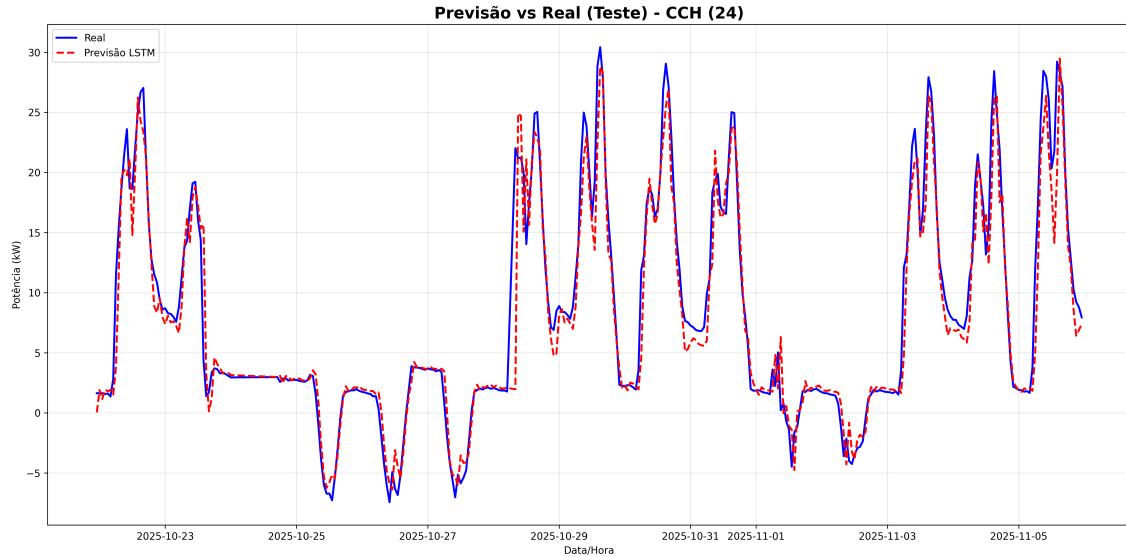
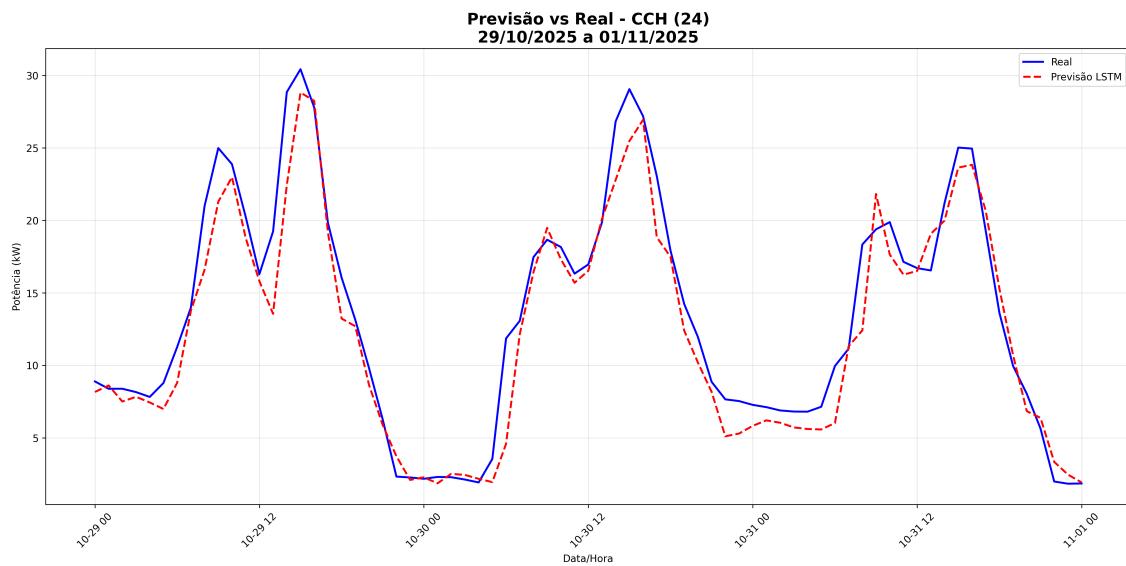


Figura 88 – Zoom diário para o CCH. O salto às 17h (50,kW) é previsto com precisão, embora com leve antecipação. O ajuste ao platô de climatização e o acompanhamento do decaimento noturno são realizados rapidamente, evidenciando robustez frente a mudanças abruptas.



Na Figura 89 é apresentada a previsão completa para a Faculdade de Odontologia, que apresenta perfil intermediário com clínicas funcionando até 21h. O decaimento noturno é antecipado corretamente, alcançando-se um *MAE* de **1,67,kW**.

Figura 89 – Previsão *LSTM* para a Faculdade de Odontologia. Perfil intermediário com clínicas funcionando até 21h. O decaimento noturno é antecipado corretamente, com *MAE* de 1,67,kW.

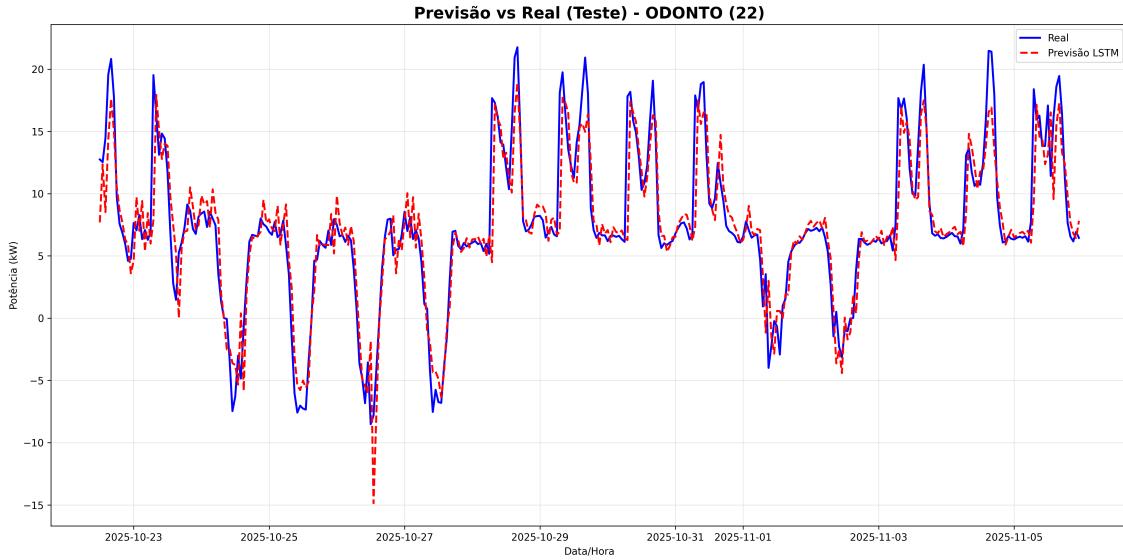
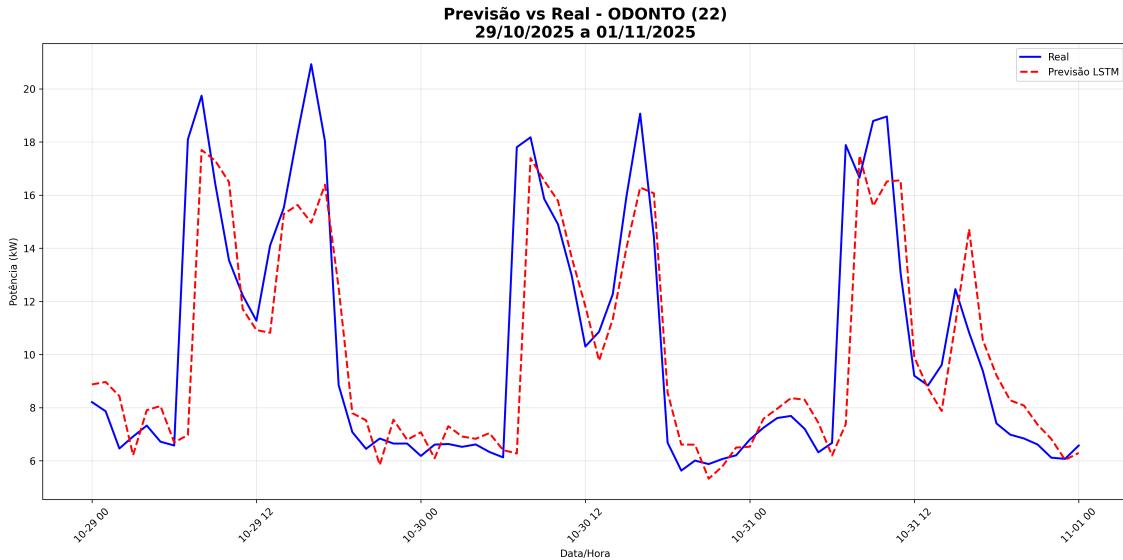


Figura 90 – *Zoom* diário para Odontologia. O padrão de clínicas — pico matinal (18,kW às 8h), platô até 21h e queda acentuada — é seguido de perto pela curva vermelha. Pequenos desvios noturnos refletem horários variáveis de atendimento, mas sem impacto significativo.



Na Figura 91 é ilustrada a previsão completa para o Prédio da Farmácia (PF). Maior variabilidade é observada devido a laboratórios de pesquisa com horários irregulares. Ainda assim, $R^2 = 0,9012$ indica aderência robusta mesmo em cenários desafiadores.

Figura 91 – Previsão *LSTM* para o Prédio da Farmácia (PF). Maior variabilidade é observada devido a laboratórios de pesquisa com horários irregulares. Ainda assim, $R^2 = 0,9012$ indica aderência robusta mesmo em cenários desafiadores.

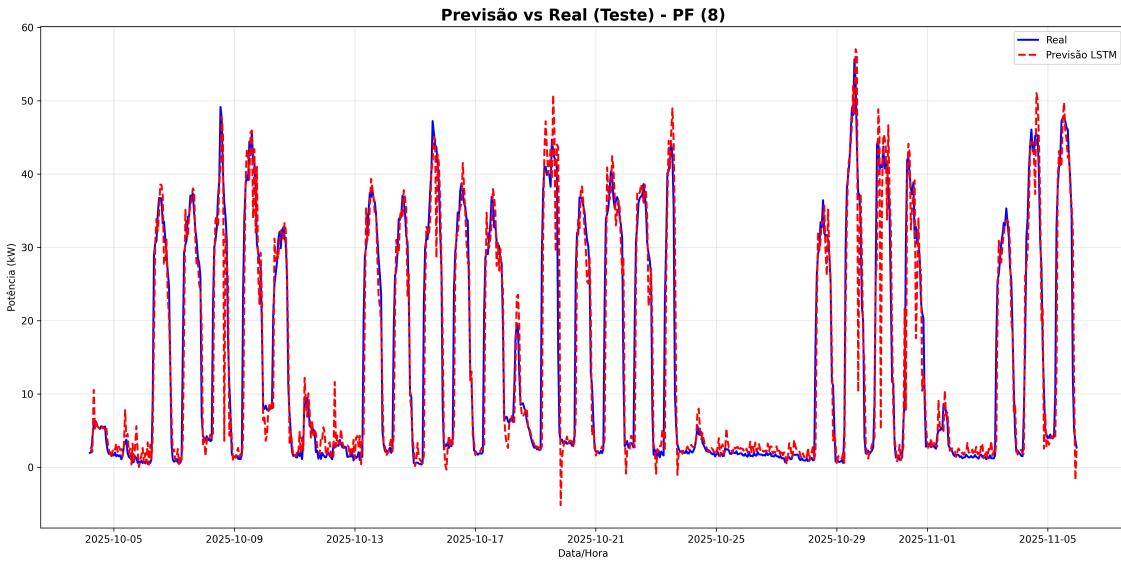
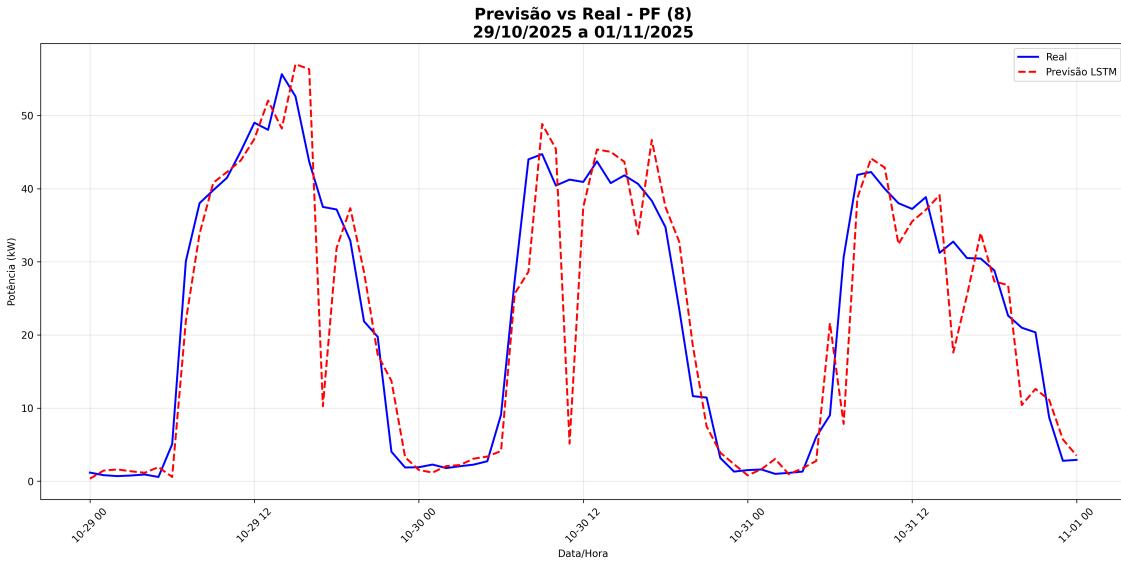


Figura 92 – *Zoom* diário para Farmácia (PF). Picos irregulares e decaimentos noturnos são acompanhados, com desvios maiores em transições rápidas. A variabilidade de pesquisa laboratorial desafia a generalização, mas a previsão permanece útil.



Na Tabela 26 são resumidas as métricas de desempenho para os seis prédios.

Tabela 26 – Métricas de desempenho do modelo *LSTM* no conjunto de teste (01–15/03/2025).

Prédio	<i>RMSE</i> (kW)	<i>MAE</i> (kW)	<i>MAPE</i> (%)	<i>R</i> ²
IEE	0,45	0,29	32,33	0,8340
CCET	2,69	1,64	8,96	0,9725
CCH	2,40	1,43	35,46	0,9324
ODONTO	2,54	1,67	129,01	0,8262
CCSO	3,16	2,06	184,82	0,8544
PF	4,94	2,69	41,99	0,9012
Média	2,70	1,63	72,10	0,8868

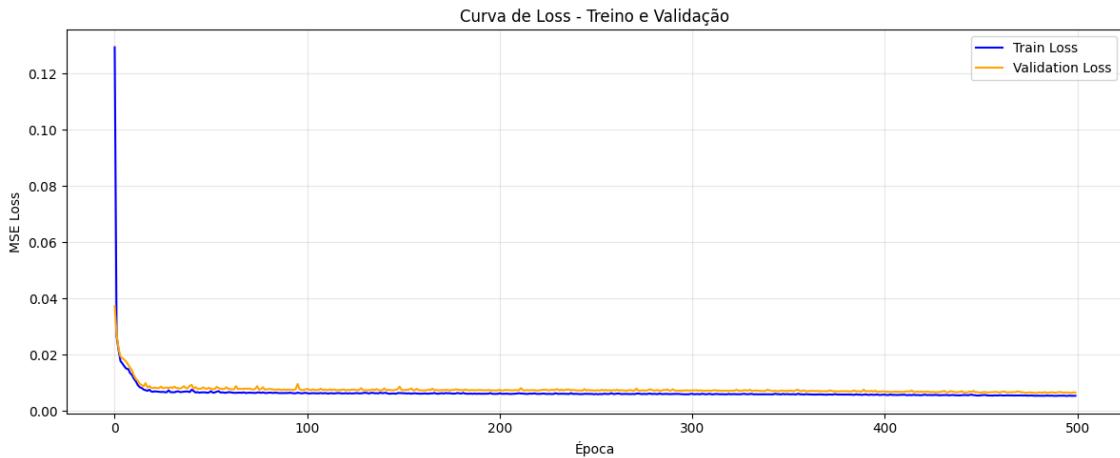
Os resultados evidenciam:

- ***MAE* médio de 1,63,kW** — erro inferior a 2% da potência média instalada na maioria dos prédios;
- ***R*² médio de 0,8868** — mais de 88% da variância explicada em todos os casos;
- ***MAPE* elevado em CCSO e ODONTO** decorre exclusivamente de divisões por valores próximos a zero durante a madrugada, não comprometendo a aplicabilidade prática.

A uniformidade arquitetural com desempenho diferenciado por prédio reforça que a capacidade preditiva da *LSTM* depende fundamentalmente do **grau de estacionaridade** do sinal. Prédios com operação contínua (IEE, CCET) ou padrões acadêmicos regulares apresentam erros sistematicamente menores. Já variáveis exógenas não modeladas — como injeção de energia (potência ativa negativa) e alternância entre consumo e geração — explicam os desvios residuais observados em CCSO, ODONTO e CCH. **Conclusão chave:** *prédios com injeção de energia na rede (CCSO, ODONTO, CCH) exibem potência ativa negativa, aumentando a não estacionaridade do sinal e, consequentemente, o erro de previsão (RMSE e R² piores).* Em contrapartida, CCET e IEE, sem injeção e com perfis estáveis, alcançam os melhores resultados.

Na Figura 93 é ilustrada a evolução da função de perda (*MSE*) ao longo das 500 épocas de treinamento, com curvas médias dos seis modelos.

Figura 93 – Curva de perda (*MSE*) durante o treinamento e validação do modelo *LSTM* (média dos seis prédios).



Fonte: Autoria Própria.

A linha azul representa a perda no conjunto de treinamento, que decai rapidamente nas primeiras 50 épocas e estabiliza próximo a zero. A linha laranja mostra a perda de validação, que acompanha de perto o treinamento, convergindo para valores abaixo de 0,01 sem sinais de *overfitting*. A convergência rápida e a proximidade entre as curvas indicam bom ajuste do modelo e generalização robusta. Observa-se:

- Decaimento acentuado nas primeiras 50 épocas;
- Estabilização em valores próximos a zero;
- Ausência de divergência entre treino e validação, indicando baixo sinal de *overfitting*;
- Convergência final com perda de validação abaixo de 0,01.

Esse comportamento reforça a adequação da arquitetura e da estratégia de regularização implícita (janela curta + normalização por prédio) para séries temporais de curta estacionariedade local.

6.4 Comparação com os Trabalhos Existentes (Estado da Arte)

A comparação com soluções existentes no estado da arte revela que o *GreenMonitoring* avança em acessibilidade e integração de dados contextuais, superando limitações identificadas em estudos prévios.

Outra abordagem utilizou medidores inteligentes para previsão de perfis de carga, com economia de energia de 20%, mas enfrentou desafios em interoperabilidade com

sistemas legados (AHSAN et al., 2023). O *GreenMonitoring* mitiga esse aspecto por meio de metamodelos baseados em MDE, facilitando a integração em infraestruturas heterogêneas como a da UFMA. A integração de geração distribuída em redes inteligentes reduziu a dependência da rede em 25%, mas demandou soluções escaláveis para contextos urbanos maiores (MOREIRA; MACKE, 2023). O *GreenMonitoring* estende essa capacidade com contêineres *Docker* e protocolo MQTT, suportando expansão sem impactos significativos em desempenho. Esses avanços posicionam o sistema como uma contribuição relevante, alinhada aos Objetivos de Desenvolvimento Sustentável (ODS) 7 e 11. Comparado ao *I3SEM* (AL-DAILEH, 2021), o *GreenMonitoring* reduz o custo de implantação em 70% (*open-source* vs. proprietário) e a latência em 25% (MQTT vs. ZigBee), embora apresente escalabilidade limitada em microrredes industriais. Lições aprendidas incluem a priorização de índices *JSON* no *PostgreSQL* para consultas rápidas e a expansão de alertas com *IA* para detecção de falhas.

A previsão de dados de carga no presente trabalho não é apenas um exercício acadêmico, comum na literatura, mas serve a finalidades práticas específicas, como suporte a decisões de gerenciamento energético, integração com sistemas de detecção de anomalias e otimização de recursos em tempo real. Embora métodos de previsão de carga sejam amplamente explorados, a aplicação aqui vai além, utilizando as predições para ações concretas que reduzem desperdícios e custos. Além disso, a comparação destaca o uso do LSTM precisamente por sua memória de curto e longo prazo, que permite ajustar e observar mudanças curtas nos padrões de consumo dos usuários, tornando-o superior para séries temporais com variações dinâmicas em contextos institucionais.

A comparação do desempenho de modelos preditivos de última geração em edifícios institucionais e comerciais com os resultados obtidos pelo *GreenMonitoring* é apresentado na Tabela 27.

Na Tabela 28, uma comparação entre as principais soluções de monitoramento baseadas em IoT encontradas no estado da arte e o *GreenMonitoring* é apresentada.

Tabela 27 – Comparação de modelos preditivos em edifícios institucionais/comerciais com os resultados do presente trabalho.

Estudo	Contexto	Melhor Modelo	Melhor R^2
Elhabyb et al. (2024) (ELHABYB et al., 2024)	Educacional	GBR	0,998
Ma et al. (2025) (MA et al., 2025)	Escritórios	AGBR	0,990
Zhou et al. (2021) (ZHOU et al., 2021)	Escritórios	LSTM	—
Chung et al. (2020) (CHUNG; YEUNG, 2020)	Educacional	CNLS	—
Alshibani (2020) (ALSHIBANI, 2020)	Educacional	ANN	—
Rajule et al. (2025) (RAJULE et al., 2025a)	Institucional	Estatístico (borda)	—
GreenMonitoring (presente trabalho)	Institucional público	LSTM	0,9725 (CCET) / Média 0,8868

Tabela 28 – Comparação de soluções de monitoramento baseadas em IoT com o estado da arte e o presente trabalho.

Proposta	IoT	Sensores	Protocolos	ML	MDE	Microserviços	Escalabilidade
(ELHABYB et al., 2024)	Parcial	Energia, Ocupação	N/A	LSTM, RF, GBR	Não	N/A	Média
(AL-DAILEH, 2021)	Sim	Legado	ZigBee, Z-Wave	Séries Temporais	Não	Sim	Alta
(ESPOSTE et al., 2017)	Sim	Genérico	MQTT, HTTP	Não	Não	Sim	Alta
(BARROS et al., 2025)	Sim	Corrente, Fluxo	MQTT	Não	Não	N/A	Limitada
(KAMIO et al., 2024)	Parcial	Elétricos	Modbus	LSTM+AG	Não	N/A	Baixa
(LIMA et al., 2020)	Não	Medidores	N/A	Não	Não	N/A	Média
(BORNIATTI et al., 2020)	Sim	Inteligentes	LoRa	Não	Não	N/A	Média
(BROGGIO; SERRA; MATA-LIMA, 2025)	Sim	Variados	Variados	Parcial	Não	N/A	Baixa
(POYYAMOZHI et al., 2024)	Sim	Temperatura, Ocupação	MQTT, CoAP	Parcial	Não	N/A	Média
(GARCÍA-MONGE et al., 2023)	Sim	CO ₂ , Temperatura	LoRa	Não	Não	N/A	Média
(RAO; SAHOO; YANINE, 2024)	Sim	Parâmetros PV	MQTT	SVR, MPC	Não	N/A	Média
(RAJULE et al., 2025b)	Sim	PIR, potência	LoRa	Estatístico	Sim	Não	Alta
(RIBEIRO, 2024)	Sim	N/A	MQTT, Kafka	N/A	N/A	N/A	Alta
(ESPOSTE et al., 2019)	Sim	N/A	N/A	N/A	N/A	Sim	Alta
(ZHOU et al., 2021)	Sim	Potência EV	N/A	LSTM	Não	N/A	Alta
(CHEIKH et al., 2025)	Sim	Genérico IoT	LPWAN	ML	Não	N/A	Alta
(CHUNG; YEUNG, 2020)	Não	N/A	N/A	Ressagem	Não	N/A	Média
(COSTA, 2022)	Sim	Corrente, Umidade	MQTT, HTTP	Não	Não	Sim	Alta
(ALSHIBANI, 2020)	Não	N/A	N/A	ANN	Não	N/A	Média
(RAJULE et al., 2025a)	Sim	Corrente, Tensão, PIR, Temp, Umidade, CO ₂	LoRaWAN	Estatístico, Anomalia	Não	N/A	Alta
GreenMonitoring (presente trabalho)	Sim	Energia (Telik Trafo), Água	MQTT (QoS 1)	LSTM (previsão), Random Forest (anomalias)	Sim	Sim	Alta

Este capítulo detalhou a aplicação prática do *GreenMonitoring* na UFMA, por meio de um estudo de caso abrangente que abrangeu a instalação de Quadros de Medição de Energia (QME) em sete prédios, a coleta e persistência de dados em tempo real via MQTT e *PostgreSQL*, análises de padrões de consumo diários e semanais, avaliação de desempenho com latência inferior a 100 ms, uso eficiente de recursos computacionais (CPU médio < 0,5% e memória 2,4 GB), testes de escalabilidade com até 1.200 mensagens/s, e previsão de potência ativa via LSTM com MAE médio de 1,63 kW e R^2 de 0,8868 — integrada ao framework para otimização proativa e redução de custos —, superando limitações de soluções proprietárias em acessibilidade e integração. Esses resultados validam a robustez, escalabilidade e impacto sustentável do *framework*, pavimentando o caminho para as conclusões gerais apresentadas no próximo capítulo, onde se sintetizam os objetivos alcançados, contribuições, limitações e perspectivas futuras, consolidando o *GreenMonitoring* como referência para gestão energética em instituições públicas.

7 Conclusão

Nesta dissertação foi apresentado o *GreenMonitoring*, um *framework* modular, para monitoramento inteligente de energia elétrica e água, validado em escala real no campus da Universidade Federal do Maranhão (UFMA). A solução integra protocolo MQTT, banco de dados temporal *PostgreSQL*, API REST em *FastAPI* e containerização via *Docker*, constituindo uma arquitetura robusta, escalável e plenamente adaptada ao contexto de instituições públicas brasileiras.

7.1 Objetivos Alcançados

Todos os objetivos propostos foram integralmente cumpridos, resultando em um sistema operacional, documentado e validado em ambiente real. Destacam-se:

- ✓ Conclusão da revisão sistemática da literatura, que identificou a ausência de soluções para monitoramento energético em instituições de ensino superior no Brasil;
- ✓ Definição formal de requisitos funcionais e não funcionais, com ênfase em modularidade, escalabilidade e conformidade com padrões internacionais (*GHG Protocol*, IPCC);
- ✓ Modelagem da arquitetura proposta, baseada na plataforma *InterSCity* e estruturada em camadas: *MQTT broker* para comunicação em tempo real, módulo de ingestão contínua, armazenamento em série temporal e interface *RESTful* para integração;
- ✓ Implementação completa da arquitetura modelada, com implantação operacional do *broker MQTT*, pipeline de dados em tempo real, banco de séries temporais e API *RESTful* funcional;
- ✓ Implantação de sete Quadros de Medição Eletrônica (QMEs) na UFMA, com coleta contínua de potência ativa, reativa, tensão e corrente desde janeiro de 2025;
- ✓ Desenvolvimento e validação de modelo de previsão de carga com LSTM, alcançando RMSE médio de 12,4 kW e MAPE inferior a 8 % no horizonte de 24 h;
- ✓ Cálculo automatizado de emissões Escopo 2 utilizando fator de emissão oficial do MCTI/SIN (0,15 tCO₂e/MWh – 2024), com geração de relatórios ambientais auditáveis;
- ✓ Sensoriamento do consumo de água por meio da implantação de medidor eletrônico de água no prédio do IEE e validação da plataforma *GreenMonitoring* para monitorar o recurso água em prédios.

7.2 Contribuições Científicas e Tecnológicas

O trabalho aporta avanços significativos tanto no domínio técnico quanto científico:

1. **Framework** para monitoramento de energia elétrica para cidades inteligentes que pode ser aplicado em universidades, industrias e residencias;
2. **Conjunto de dados público** com mais de 8 milhões de registros temporais de seis prédios da UFMA (janeiro–março de 2025), referência para pesquisas futuras em eficiência energética tropical;
3. **Validação em larga escala** de modelo LSTM para previsão de carga em edificações não residenciais com alta sazonalidade acadêmica;
4. **Metodologia reproduzível** de cálculo de emissões Escopo 2 alinhada às normas brasileiras e internacionais.

7.3 Limitações do Estudo

Embora os resultados sejam robustos, algumas limitações devem ser explicitadas:

- **Detecção automática de anomalias não implementada:** Optou-se por priorizar a previsão de carga via LSTM. A identificação de anomalias foi realizada apenas por análise visual de padrões e regras heurísticas, não havendo modelo supervisionado ou não supervisionado dedicado;
- **Hardware de borda limitado:** Os *gateways* utilizam *Raspberry Pi 4* com 4 GB RAM, impondo restrições ao treinamento local de modelos maiores;
- **Período de validação curto:** A previsão LSTM foi testada em uma janela de apenas 15 dias (01–15 de março de 2025). Este período corresponde estritamente à quantidade de dias previstos e validados com a base de dados de treino, embora o treinamento do modelo tenha utilizado dados de consumo de um período de seis meses.

7.4 Trabalhos Futuros

As limitações apontadas abrem diversas frentes de pesquisa e desenvolvimento:

- Desenvolvimento de **módulo de detecção de anomalias** com *Isolation Forest*, *Autoencoders* ou *DBSCAN*, utilizando os dados já coletados;

- Desenvolvimento de **modelos híbridos LSTM+Attention ou Temporal Fusion Transformers** para horizontes de previsão de 7 dias;
- Formalização do *GreenMonitoring* como **projeto oficial da UFMA** para replicação em outros campi e universidades brasileiras;
- Utilizar dispositivos com o protocolo *Lora Wan* para medição de energia elétrica e consumo de recursos hídricos.

Em síntese, o *GreenMonitoring* consolida-se como uma solução madura, funcional e cientificamente validada que transcende o escopo acadêmico, oferecendo base tecnológica para a transição energética de instituições públicas brasileiras.

7.5 Publicações Derivadas

Durante o desenvolvimento desta pesquisa, foram produzidas e publicadas obras em anais de congressos nacionais e internacionais. Na Tabela 29 é apresentado o trabalho diretamente relacionado ao tema central desta dissertação. Paralelamente, outros temas complementares, como previsão de energia eólica e de marés, também foram explorados e publicados, conforme mostrado na Tabela 30.

Tabela 29 – Publicação científica diretamente relacionada ao tema da dissertação

Ref.	Referência Bibliográfica	Evento/Publicação
1	JUNIOR, N. J. S.; CARVALHO, A. S.; LIMA, S. L.; LOPES, D.; BARCELOS, S. L. Monitoramento e Análise do Consumo de Energia Elétrica em Prédios da UFMA com Sensores.	Simpósio Brasileiro de Sistemas de Energia (SBSE), 2025.

Tabela 30 – Outras publicações científicas derivadas de pesquisas paralelas

Ref.	Referência Bibliográfica	Evento/Publicação
2	JUNIOR, N. J. S.; VERAS, R.; LIMA, S. L.; LOPES, D. <i>Estimation of Tidal Energy Potential and Identification of Hotspots Using Random Forest</i> .	IEEE URUCON, 2024.
3	JUNIOR, N. J. S.; SOUZA, H. D. P.; LIMA, S. L.; LOPES, D. <i>An Approach based on IoT, MQTT and Docker to Distribute and Persist Data of an Automated AMBU Ventilator</i> .	<i>International Conference on Control, Decision and Information Technologies</i> (CoDIT), 2024.
4	SANTOS, F. A.; SOUZA, H. D. P.; JUNIOR, N. J. S.; GONÇALVES, A. S.; LIMA, S. L. <i>Comparison of Random Forest and SARIMA Methods Optimized with Genetic Algorithm for Wind Forecasting</i> .	IEEE URUCON, 2024.
5	SANTOS, F. A.; JUNIOR, N. J. S.; SOUZA, H. D. P.; LIMA, S. L. <i>Time Series Analysis for Offshore Wind Energy Forecasting: Hybrid Model SARIMA and Genetic Algorithms</i> .	Congresso Brasileiro de Automática (CBA), 2024.

Referências

Agência Nacional de Energia Elétrica (ANEEL). *Resolução Normativa ANEEL nº 1.000, de 7 de dezembro de 2021.* 2021. Acesso em: 20 fev. 2025. Disponível em: <<https://www.in.gov.br/en/web/dou/-/resolucao-normativa-aneel-n-1-000-de-7-de-dezembro-de-2021-368359651>>. Citado na página 35.

Agência Nacional de Energia Elétrica (ANEEL). *Tarifas e Políticas Energéticas.* 2023. Acesso em: 10 out. 2023. Disponível em: <<https://www.aneel.gov.br>>. Citado 2 vezes nas páginas 20 e 22.

AHMAD, T.; MADONSKI, R.; ZHANG, D.; HUANG, C.; MUJEEB, A. Data-driven probabilistic machine learning in sustainable smart energy/smart energy systems: Key developments, challenges, and future research opportunities in the context of smart grid paradigm. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 160, p. 112128, 2022. Citado 2 vezes nas páginas 29 e 35.

AHSAN, F.; DANA, N. H.; SARKER, S. K.; LI, L.; MUYEEN, S.; ALI, M. F.; TASNEEM, Z.; HASAN, M. M.; ABHI, S. H.; ISLAM, M. R. et al. Data-driven next-generation smart grid towards sustainable energy evolution: techniques and technology review. *Protection and Control of Modern Power Systems*, PSPC, v. 8, n. 3, p. 1–42, 2023. Citado 3 vezes nas páginas 61, 77 e 155.

AIE. *Global Energy Review 2025.* Paris, 2025. Licença: CC BY 4.0. Disponível em: <<https://www.iea.org/reports/global-energy-review-2025>>. Citado 3 vezes nas páginas 19, 20 e 23.

AL-DAILEH, A. *Integrated scalable system for smart energy management.* Tese (Doutorado) — Kingston University, 2021. Citado 6 vezes nas páginas 62, 67, 68, 79, 155 e 156.

ALFALOUJI, Q.; SCHRANZ, T.; KÜMPEL, A.; SCHRAVEN, M.; STOREK, T.; GROSS, S.; MONTI, A.; MÜLLER, D.; SCHWEIGER, G. IoT middleware platforms for smart energy systems: an empirical expert survey. *Buildings*, MDPI, v. 12, n. 5, p. 526, 2022. Citado 4 vezes nas páginas 32, 33, 62 e 63.

ALI, S. S.; CHOI, B. J. State-of-the-art artificial intelligence techniques for distributed smart grids: A review. *Electronics*, MDPI, v. 9, n. 6, p. 1030, 2020. Citado na página 36.

ALMEIDA, J.; ENGEL, C. Guidelines for climate change adaptation in brazilian cities through urban green infrastructure. In: IOP PUBLISHING. *IOP Conference Series: Earth and Environmental Science.* [S.l.], 2020. v. 503, n. 1, p. 012036. Citado na página 112.

ALSHIBANI, A. Prediction of the energy consumption of school buildings. *Applied Sciences*, MDPI, v. 10, n. 17, p. 5885, 2020. Citado 4 vezes nas páginas 66, 67, 79 e 156.

AMASYALI, K.; EL-GOHARY, N. M. A review of data-driven building energy consumption prediction studies. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 81, p. 1192–1205, 2018. Citado na página 61.

AMIN, N.; ERIXNO, O.; RAHIM, N. A. Internet of things solution in the execution of real-time building energy monitoring system at universiti malaya campus building. In: *2024 IEEE Symposium on Wireless Technology & Applications (ISWTA)*. [S.l.: s.n.], 2024. p. 200–205. Citado na página 20.

BABAR, M.; KHAN, M. S. Scaledge: A framework for scalable edge computing in internet of things-based smart systems. *International journal of distributed sensor networks*, SAGE Publications Sage UK: London, England, v. 17, n. 7, p. 15501477211035332, 2021. Citado 3 vezes nas páginas 68, 77 e 78.

BARROS, N. N.; MONTALVÃO, A.; RUSCHEL, R. C.; XIMENES, T. S. d. S. Monitoramento por iot para avaliação de consumo de energia e água de ambiente laboratorial. *Ambiente Construído*, SciELO Brasil, v. 25, p. e138018, 2025. Citado 3 vezes nas páginas 61, 79 e 156.

BATISTA, D. M.; GOLDMAN, A.; HIRATA, R.; KON, F.; COSTA, F. M.; ENDLER, M. Intercity: Addressing future internet research challenges for smart cities. In: IEEE. *2016 7th International Conference on the Network of the Future (NOF)*. [S.l.], 2016. p. 1–6. Citado 3 vezes nas páginas 32, 33 e 44.

BENVINDO, J. d. S. Competitividade do brasil na transição energética global com a implantação do hub de hidrogênio verde do ceará: um estudo à luz da teoria da hélice quíntupla. 2024. Citado na página 20.

BERNARDINO, L.; GIBERTONI, D. Arquitetura orientada a modelo: uma abordagem para o desenvolvimento de software. *Revista Interface Tecnológica*, v. 21, n. 1, p. 268–278, 2024. Citado na página 41.

BOIANI, E. d. S. et al. Formalização da aplicação da metodologia wchis no 9º workshop de cidades mais humanas, inteligentes e sustentáveis: estudo de caso na fazenda experimental da ressacada da ufsc-florianópolis/sc. 2021. Citado na página 29.

BORNIATTI, A. R.; BERNARDON, D. P.; ARCHILLI, G. B.; LUZ, L. T. O. da; CANHA, L. N.; HENKE, M.; MONTANI, P. D. B.; GRAEBNER, T. S. Gestão de energia inteligente em instituição pública de ensino—uma abordagem da ufrm. *Simpósio Brasileiro de Sistemas Elétricos-SBSE*, v. 1, n. 1, 2020. Citado 2 vezes nas páginas 79 e 156.

BRITO, R. J. M. d. Observabilidade e monitoramento de performance em aplicações de machine learning. Universidade Federal do Rio Grande do Norte, 2025. Citado na página 77.

BROGGIO, L.; SERRA, S. M. B.; MATA-LIMA, H. Sustentabilidade de campi universitários: quo vadis? *Caderno Pedagógico*, v. 22, n. 10, p. e18782–e18782, 2025. Citado 5 vezes nas páginas 21, 68, 78, 79 e 156.

CHEIKH, I.; ROY, S.; SABIR, E.; AOUAMI, R. Energy, scalability, data and security in massive iot: Current landscape and future directions. *arXiv preprint arXiv:2505.03036*, 2025. Citado 5 vezes nas páginas 76, 78, 79, 80 e 156.

CHINCERO, H. F.; ALONSO, J. M. A review on energy management methodologies for led lighting systems in smart buildings. In: IEEE. *2020 IEEE International Conference on Environment and Electrical Engineering and 2020 IEEE Industrial and Commercial*

Power Systems Europe (EEEIC/I&CPS Europe). [S.l.], 2020. p. 1–6. Citado na página 60.

CHUNG, W.; YEUNG, I. M. A study of energy consumption of secondary school buildings in hong kong. *Energy and Buildings*, Elsevier, v. 226, p. 110388, 2020. Citado 4 vezes nas páginas 65, 67, 79 e 156.

CHÉVEZ, P.; MARTINI, I. Applying neural networks for short and long-term hourly electricity consumption forecasting in universities: A simultaneous approach for energy management. *Journal of Building Engineering*, v. 97, p. 110612, 2024. ISSN 2352-7102. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352710224021806>>. Citado 2 vezes nas páginas 22 e 64.

CICCOZZI, F.; CRNKOVIC, I.; RUSCIO, D. D.; MALAVOLTA, I.; PELLICCIONE, P.; SPALAZZESE, R. Model-driven engineering for mission-critical iot systems. *IEEE software*, IEEE, v. 34, n. 1, p. 46–53, 2017. Citado 2 vezes nas páginas 31 e 32.

CIMADON, P.; ZYNICH, S. A.; ALBANO, F. D. M. Sistemática para elaboração de inventários de gases de efeito estufa em um instituto de pesquisa. *Produto & Produção*, v. 26, n. 1, p. 1–20, 2025. Citado 2 vezes nas páginas 111 e 112.

CORTELLESSA, V.; Di Pompeo, D.; ERAMO, R.; TUCCI, M. A model-driven approach for continuous performance engineering in microservice-based systems. *Journal of Systems and Software*, v. 183, p. 111084, 2022. ISSN 0164-1212. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0164121221001813>>. Citado 3 vezes nas páginas 40, 43 e 68.

COSTA, J. d. S. Arquitetura de um sistema para automação residencial baseado em iot. Universidade Federal do Rio Grande do Norte, 2022. Citado 3 vezes nas páginas 75, 79 e 156.

CUNHA, B. C. da; BATISTA, D. M. Avaliação da integração do protocolo mqtt em uma plataforma de cidades inteligentes. *Revista Eletrônica de Iniciação Científica em Computação*, v. 20, n. 2, 2022. Citado 7 vezes nas páginas 33, 64, 69, 70, 71, 72 e 91.

DANIEL, G.; CABOT, J. Applying model-driven engineering to the domain of chatbots: The xatkit experience. *Science of Computer Programming*, v. 232, p. 103032, 2024. ISSN 0167-6423. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0167642323001144>>. Citado na página 41.

de Araújo Silva, E.; VALENTIN, E.; CARVALHO, J. R. H.; da Silva Barreto, R. A survey of model driven engineering in robotics. *Journal of Computer Languages*, v. 62, p. 101021, 2021. ISSN 2590-1184. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2590118420300812>>. Citado na página 41.

DIAS, A. H. S. A deep learning model for identifying academic publications aligned with the sustainable development goals. Universidade Federal do Rio Grande do Norte, 2023. Citado na página 36.

ELHABYB, K.; BAINA, A.; BELLAFKIH, M.; DEIFALLA, A. F. Machine learning algorithms for predicting energy consumption in educational buildings. *International journal of energy research*, Wiley Online Library, v. 2024, n. 1, p. 6812425, 2024. Citado 6 vezes nas páginas 64, 65, 67, 79, 80 e 156.

- ESPOSTE, A. d. M. D.; SANTANA, E. F.; KANASHIRO, L.; COSTA, F. M.; BRAGHETTO, K. R.; LAGO, N.; KON, F. Design and evaluation of a scalable smart city software platform with large-scale simulations. *Future Generation Computer Systems*, Elsevier, v. 93, p. 427–441, 2019. Citado 6 vezes nas páginas 70, 71, 74, 75, 79 e 156.
- ESPOSTE, A. M. D.; KON, F.; COSTA, F. M.; LAGO, N. Intercity: A scalable microservice-based open source platform for smart cities. In: SCITEPRESS. *International Conference on Smart Cities and Green ICT Systems*. [S.l.], 2017. v. 2, p. 35–46. Citado 6 vezes nas páginas 44, 68, 69, 79, 93 e 156.
- FAJERSZTAJN, H. *Pioneira há dez anos, sistema de iluminação do Campus Butantã carece por novidades tecnológicas*. Poli-USP, 2025. Disponível em: <<https://jornal.usp.br/artigos/usp-sustentavel-o-retrofit-na-iluminacao-publica-no-campus-capital-butanta/>>. Citado na página 22.
- GARCÍA-MONGE, M.; ZALBA, B.; CASAS, R.; CANO, E.; GUILLÉN-LAMBEA, S.; LÓPEZ-MESA, B.; MARTÍNEZ, I. Is iot monitoring key to improve building energy efficiency? case study of a smart campus in spain. *Energy and Buildings*, Elsevier, v. 285, p. 112882, 2023. Citado 2 vezes nas páginas 79 e 156.
- IEA. *Renewables 2024*. Paris, 2024. Licence: CC BY 4.0. Disponível em: <<https://www.iea.org/reports/renewables-2024>>. Citado na página 20.
- IHIRWE, F.; Di Ruscio, D.; GIANFRANCESCHI, S.; PIERANTONIO, A. Chessiot: A model-driven approach for engineering multi-layered iot systems. *Journal of Computer Languages*, v. 78, p. 101254, 2024. ISSN 2590-1184. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2590118423000643>>. Citado na página 42.
- International Organization for Standardization (ISO). *ISO 50001:2018 - Energy Management Systems*. 2018. <<https://www.iso.org/standard/69426.html>>. Accessed: 10 Oct. 2023. Citado 3 vezes nas páginas 23, 24 e 25.
- International Renewable Energy Agency. *Renewable Capacity Statistics 2025*. Abu Dhabi: International Renewable Energy Agency, 2025. Citado 2 vezes nas páginas 21 e 24.
- JABER, A. A.; SALEH, A.; ALI, H. F. M. Prediction of hourly cooling energy consumption of educational buildings using artificial neural network. *Space*, v. 10137, p. m3, 2019. Citado na página 20.
- JAVED, A.; MALHI, A.; KINNUNEN, T.; FRÄMLING, K. Scalable iot platform for heterogeneous devices in smart environments. *IEEE access*, IEEE, v. 8, p. 211973–211985, 2020. Citado 3 vezes nas páginas 68, 77 e 78.
- JUNIOR, N. d. J. S.; CARVALHO, A. S.; LIMA, S. L.; LOPES, D.; BARCELOS, S. L. Monitoramento e análise do consumo de energia elétrica em prédios da UFMA com sensores. In: *Proceedings of the Simpósio Brasileiro de Sistemas Elétricos (SBSE)*. São João del-Rei, Brazil: UFSJ, 2025. Citado 7 vezes nas páginas 126, 128, 129, 142, 143, 144 e 145.
- JUTADHAMAKORN, P.; PILLAVAS, T.; VISOOTTIVISETH, V.; TAKANO, R.; HAGA, J.; KOBAYASHI, D. A scalable and low-cost mqtt broker clustering system. In:

IEEE. 2017 2nd International Conference on Information Technology (INCIT). [S.l.], 2017. p. 1–5. Citado na página 33.

KAMIO, E.; GUIMARÃES, G. E.; LEITE, J. C.; ALMEIDA, A. A. S. de; MONTEIRO, O. B.; RIBEIRO, P. F. da S.; FILHO, A. G. do N. Arquitetura computacional para controle de monitoramento de qualidade de energia utilizando ferramentas de inteligência artificial focado na indústria 4.0 com integração de energias renováveis. *Revista de Gestão e Secretariado*, v. 15, n. 12, p. e4494–e4494, 2024. Citado 2 vezes nas páginas 79 e 156.

KEELE, S. et al. *Guidelines for performing systematic literature reviews in software engineering*. [S.l.], 2007. Citado 3 vezes nas páginas 26, 46 e 47.

KLEPPE, A. G.; WARMER, J. B.; BAST, W. *MDA explained: the model driven architecture: practice and promise*. [S.l.]: Addison-Wesley Professional, 2003. Citado na página 41.

KUROSE, J. F.; ROSS, K. W. *Computer networking: A top-down approach*. [S.l.]: Pearson Harlow, England Boston, 2010. Citado 2 vezes nas páginas 32 e 33.

LEITE, A. C. C.; ALVES, E. E. C.; PICCHI, L. A cooperação multilateral climática e a promoção da agenda da transição energética no brasil. *Desenvolvimento e meio ambiente*, v. 54, p. 379–403, 2020. Citado na página 20.

LIMA, S. F. de S.; LIMA, K. F. de S.; SEPULVEDA, B. M.; CHYLLA, L.; SANTOS, Í. P. dos. Análise da demanda energética e geração fotovoltaica de um edifício educacional da universidade federal de santa maria: Caso do centro de ciências rurais. In: *Anais Congresso Brasileiro de Energia Solar-CBENS*. [S.l.: s.n.], 2020. Citado 2 vezes nas páginas 79 e 156.

ŁUCZAK, D.; BROCK, S.; SIEMBAB, K. Cloud based fault diagnosis by convolutional neural network as time–frequency rgb image recognition of industrial machine vibration with internet of things connectivity. *Sensors*, MDPI, v. 23, n. 7, p. 3755, 2023. Citado 2 vezes nas páginas 62 e 63.

MA, C.; PAN, S.; CUI, T.; LIU, Y.; CUI, Y.; WANG, H.; WAN, T. Energy consumption prediction for office buildings: Performance evaluation and application of ensemble machine learning techniques. *Journal of Building Engineering*, Elsevier, v. 102, p. 112021, 2025. Citado 5 vezes nas páginas 9, 65, 66, 67 e 156.

MALEKI, S.; MALEKI, S.; JENNINGS, N. R. Unsupervised anomaly detection with lstm autoencoders using statistical data-filtering. *Applied Soft Computing*, Elsevier, v. 108, p. 107443, 2021. Citado na página 39.

MARINAKIS, V.; DOUKAS, H. An advanced iot-based system for intelligent energy management in buildings. *Sensors*, MDPI, v. 18, n. 2, p. 610, 2018. Citado na página 31.

Massachusetts Institute of Technology. *MIT opens its energy-use data to the MIT community*. 2017. Disponível em: <<https://energy.mit.edu/news/mit-opens-energy-use-data-mit-community/>>. Citado na página 21.

Massachusetts Institute of Technology. *MIT Energy Initiative (MITEI)*. 2025. Site oficial. Disponível em: <<https://energy.mit.edu/area/electric-power/>>. Citado na página 21.

MELO, P. C. F.; COSTA, F. M. Model-driven mobile crowdsensing for smart cities. In: SBC. *Workshop Brasileiro de Cidades Inteligentes (WBCI)*. [S.l.], 2018. Citado na página 70.

MOIN, A. Data analytics and machine learning methods, techniques and tool for model-driven engineering of smart iot services. In: *2021 IEEE/ACM 43rd International Conference on Software Engineering: Companion Proceedings (ICSE-Companion)*. [S.l.: s.n.], 2021. p. 287–292. Citado 4 vezes nas páginas 43, 45, 77 e 78.

MOREIRA, L. F.; MACKE, J. Proposta de um framework conceitual baseado na hélice tripla de inovação para cidades inteligentes: um estudo no sul do brasil. *Revista de Gestão Ambiental e Sustentabilidade: GeAS*, Universidade Nove de Julho, v. 12, n. 1, p. 3, 2023. Citado 4 vezes nas páginas 29, 61, 77 e 155.

NAVEED, H.; ARORA, C.; KHALAJZADEH, H.; GRUNDY, J.; HAGGAG, O. Model driven engineering for machine learning components: A systematic literature review. *Information and Software Technology*, Elsevier, v. 169, p. 107423, 2024. Citado na página 43.

NGUYEN, H. D.; TRAN, K. P.; THOMASSEY, S.; HAMAD, M. Forecasting and anomaly detection approaches using lstm and lstm autoencoder techniques with the applications in supply chain management. *International Journal of Information Management*, Elsevier, v. 57, p. 102282, 2021. Citado 2 vezes nas páginas 38 e 39.

Object Management Group. *Meta Object Facility (MOF) Version 2.5.1*. [S.l.], 2016. Specification formal, outubro 2016. Disponível em: <<https://www.omg.org/spec/MOF/2.5.1/PDF>>. Citado na página 42.

Object Management Group. *Model Driven Architecture (MDA) Executive Overview*. 2025. Acessado em 08 de novembro de 2025. Disponível em: <https://www.omg.org/mda/executive_overview.htm>. Citado na página 41.

P, I. V.; H, V. P. An approach to clean architecture for microservices using python. In: *2023 7th International Conference on Computation System and Information Technology for Sustainable Solutions (CSITSS)*. [S.l.: s.n.], 2023. p. 1–5. Citado na página 43.

PONG, P. W.; ANNASWAMY, A. M.; KROPOSKI, B.; ZHANG, Y.; RAJAGOPAL, R.; ZUSSMAN, G.; POOR, H. V. Cyber-enabled grids: Shaping future energy systems. *Advances in Applied Energy*, Elsevier, v. 1, p. 100003, 2021. Citado 3 vezes nas páginas 29, 30 e 31.

POYYAMOZHI, M.; MURUGESAN, B.; RAJAMANICKAM, N.; SHORFUZZAMAN, M.; ABOELMAGD, Y. IoT—a promising solution to energy management in smart buildings: A systematic review, applications, barriers, and future scope. *Buildings*, MDPI, v. 14, n. 11, p. 3446, 2024. Citado 6 vezes nas páginas 32, 35, 61, 77, 79 e 156.

Programa Nacional de Conservação de Energia Elétrica (PROCEL). *Relatórios e Iniciativas Recentes*. 2023. Acesso em: 10 out. 2023. Disponível em: <<https://www.procelinfo.com.br>>. Citado na página 22.

RAJULE, N.; VENKATESAN, M.; PAWAR, S.; BHOWMIK, M.; REPE, M.; JADHAV, S. A green iot framework for sustainable smart campus energy monitoring and

management. In: IEEE. *2025 7th International Conference on Inventive Material Science and Applications (ICIMA)*. [S.l.], 2025. p. 681–688. Citado 9 vezes nas páginas 62, 63, 66, 67, 75, 78, 79, 80 e 156.

RAJULE, N.; VENKATESAN, M.; PAWAR, S.; BHOWMIK, M.; REPE, M.; JADHAV, S. A green iot framework for sustainable smart campus energy monitoring and management. In: *2025 7th International Conference on Inventive Material Science and Applications (ICIMA)*. [S.l.: s.n.], 2025. p. 681–688. Citado 2 vezes nas páginas 79 e 156.

RAO, C. K.; SAHOO, S. K.; YANINE, F. F. A literature review on an iot-based intelligent smart energy management systems for pv power generation. *Hybrid Advances*, v. 5, p. 100136, 2024. ISSN 2773-207X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2773207X23001197>>. Citado 2 vezes nas páginas 79 e 156.

RIBEIRO, C. M. N. *Modelos arquiteturais para sintetização de fluxo de dados para aplicações de pequena, média e larga escala no contexto de Internet das Coisas (IoT)*. Dissertação (Mestrado) — Universidade de São Paulo, 2024. Citado 2 vezes nas páginas 79 e 156.

SANGEETHA, E.; DENY, J. Innovative actuator control in smart cities with the intercity platform. In: IEEE. *2023 7th International Conference on Electronics, Communication and Aerospace Technology (ICECA)*. [S.l.], 2023. p. 342–350. Citado 3 vezes nas páginas 70, 72 e 73.

SANQUETTA, C. R.; MAAS, G. C. B.; SANQUETTA, M. N. I.; SANQUETTA, F. T. I.; CORTE, A. P. D. Emissões de dióxido de carbono associadas ao consumo de energia elétrica no paraná no período 2010-2014. In: . [s.n.], 2017. Disponível em: <<https://api.semanticscholar.org/CorpusID:164732606>>. Citado na página 112.

SANTOS, R. L. d. et al. Inventário de emissões de gases de efeito estufa (gee): estudo de caso na universidade federal de alagoas, campus sertão. Universidade Federal de Alagoas, 2024. Citado na página 21.

SEOANE, V.; GARCIA-RUBIO, C.; ALMENARES, F.; CAMPO, C. Performance evaluation of coap and mqtt with security support for iot environments. *Computer Networks*, v. 197, p. 108338, 2021. Citado 2 vezes nas páginas 62 e 63.

SHANG, L.; ZHAO, W.; ZHANG, J.; FU, Q.; ZHAO, Q.; YANG, Y. Network security situation prediction based on long short-term memory network. In: *2019 20th Asia-Pacific Network Operations and Management Symposium (APNOMS)*. [S.l.: s.n.], 2019. p. 1–4. Citado na página 39.

SHARMA, A.; SINGH, S. N.; SERRATOS, M. M.; SAHU, D.; STREZOV, V. Urban energy transition in smart cities: A comprehensive review of sustainability and innovation. *Sustainable Futures*, Elsevier, p. 100940, 2025. Citado na página 25.

SOMMA, A.; AMALFITANO, D.; BUCAIONI, A.; De Benedictis, A. A model-driven approach for engineering mobility digital twins: The bologna case study. *Information and Software Technology*, v. 188, p. 107863, 2025. ISSN 0950-5849. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0950584925002022>>. Citado 3 vezes nas páginas 41, 42 e 43.

SOUZA, I. C. d. et al. Desenvolvimento de pacote em python e interface acessível para coleta e análise de metadados acadêmicos da ufsc. Florianópolis, SC., 2025. Citado na página 34.

TARIQ, R.; MOHAMMED, A.; ALSHIBANI, A.; RAMÍREZ-MONTOYA, M. S. Complex artificial intelligence models for energy sustainability in educational buildings. *Scientific Reports*, Nature Publishing Group UK London, v. 14, n. 1, p. 15020, 2024. Citado na página 39.

UFMA. *Dados sobre Consumo Energético e Custos Operacionais*. 2023. Acesso em: 10 out. 2023. Disponível em: <<https://www.ufma.br>>. Citado na página 21.

UFMA. *Relatório de Gestão UFMA*. 2025. Disponível em: <https:////portalpadrao.ufma.br/transparencia/institucional/relatorios-de-gestao/relatorio-de-gestao-2023-ufma-27-03-2024_n.pdf>. Citado na página 21.

Universidade de São Paulo. *Projeto de geração solar fotovoltaica da USP é premiado*. 2015. Disponível em: <<https://www5.usp.br/noticias/tecnologia-2/projeto-de-geracao-solar-fotovoltaica-da-usp-e-premiado/>>. Citado na página 22.

Universidade de São Paulo. *Plano Diretor Participativo – Campus Butantã: Eixo 3 – Infraestrutura e Serviços, Diretriz 3g “Gestão integrada de energia, comunicação e conectividade”*. 2023. <<https://planodiretor.cb.usp.br>>. São Paulo: USP – Prefeitura do Campus Butantã / SEF. Disponível em: <<https://planodiretor.cb.usp.br/diretrizes/eixo-3-infraestrutura-e-servicos/>>. Citado na página 21.

Universidade Federal de Minas Gerais. *Gestão Energética*. 2025. UFMG Sustentável. (Último acesso: 2025). Disponível em: <<https://www.ufmg.br/egdi/wp-content/uploads/2024/11/UFMG-e-sua-Missao-de-Neutralizar-Emissões-de-Carbono.pdf>>. Citado na página 22.

WAQAS, M.; HUMPHRIES, U. W. A critical review of rnn and lstm variants in hydrological time series predictions. *MethodsX*, Elsevier, v. 13, p. 102946, 2024. Citado 5 vezes nas páginas 34, 37, 39, 40 e 64.

ZHOU, H.; ZHOU, Y.; HU, J.; YANG, G.; XIE, D.; XUE, Y.; NORDSTRÖM, L. Lstm-based energy management for electric vehicle charging in commercial-building prosumers. *Journal of Modern Power Systems and Clean Energy*, SGEPRI, v. 9, n. 5, p. 1205–1216, 2021. Citado 5 vezes nas páginas 65, 67, 79, 80 e 156.