



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS DE QUIXADÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO
MESTRADO ACADÊMICO EM COMPUTAÇÃO

ROBERT DE ALMEIDA CABRAL

SISTEMA IOT DE BAIXO CONSUMO PARA DETECÇÃO DE VAZAMENTOS DE
ÁGUA BASEADO EM LORAWAN E FIWARE: DESENVOLVIMENTO E AVALIAÇÃO
EXPERIMENTAL

QUIXADÁ

2026

ROBERT DE ALMEIDA CABRAL

SISTEMA IOT DE BAIXO CONSUMO PARA DETECÇÃO DE VAZAMENTOS DE ÁGUA
BASEADO EM LORAWAN E FIWARE: DESENVOLVIMENTO E AVALIAÇÃO
EXPERIMENTAL

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

Orientador: Prof. Dr. Paulo Armando Cavalcante Aguiar

Coorientador: Prof. Dr. Francisco Helder Candido dos Santos Filho

QUIXADÁ

2026

ROBERT DE ALMEIDA CABRAL

SISTEMA IOT DE BAIXO CONSUMO PARA DETECÇÃO DE VAZAMENTOS DE ÁGUA
BASEADO EM LORAWAN E FIWARE: DESENVOLVIMENTO E AVALIAÇÃO
EXPERIMENTAL

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

Aprovada em: 07 de Maio de 2026

BANCA EXAMINADORA

Prof. Dr. Paulo Armando Cavalcante
Aguilar (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Francisco Helder Candido dos Santos
Filho (Coorientador)
Universidade Federal do Ceará (UFC)

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

Prof. Dr. Michel Sales Bonfim
Universidade Federal do Ceará (UFC)

Prof. Dr. Reinaldo Fontes Cavalcante
Instituto Federal do Ceará (IFCE)

Á Deus,

Aos meus pais, Rosângela e Roberto.

AGRADECIMENTOS

Agradeço primeiramente a Deus por me dar forças todos os dias.

Agradeço meus pais Rosângela e Roberto por todo apoio, carinho e amor que fez com que eu me tornasse quem sou hoje, muito obrigado. A minha irmã Ana Roberta e meu irmão Roberto Filho que sempre estiveram do meu lado, motivando e me inspirando ser uma pessoa ainda melhor. Aos meus sobrinhos Eric e Luan que encham o nosso coração de amor e alegria.

Aos meus avós, em especial minhas avós Hosana e Valderez, por todo o cuidado e carinho que sempre tiveram comigo. Aos meus tios, em especial meu tio Antônio, que contribuiu muito com meu crescimento.

Aos meus amigos Juliana, Willame, Ana Ingrid, Segundo, Bruna e Andson por toda parceria, momentos, apoio e brincadeiras. Ao Heitor por deixar nossos dias mais leves.

Ao meu orientador, Professor Paulo Armando e coorientador Professor Hélder pelas orientações e colaboração. Ao meu amigo Abdul pelas conversas e cooperação.

Aos professores da Universidade Federal do Ceará, Campus Quixadá, que contribuíram para minha formação. Muito obrigado por todo aprendizado repassado.

À minha companheira Gabriela que sempre esteve ao meu lado, me ajudando, aconselhando e compartilhando momentos maravilhosos. Muito obrigado por todo carinho, suporte e amor.

E a todas as outras pessoas que não foram aqui citadas, mas contribuíram de alguma forma para o desenvolvimento desse trabalho.

“Em algum lugar, algo incrível está esperando
para ser descoberto.”

(Carl Sagan)

RESUMO

No contexto da gestão inteligente de recursos hídricos, sistemas baseados em Internet das Coisas (IoT) têm se mostrado promissores para o monitoramento do consumo de água e a detecção de vazamentos. No entanto, dispositivos de campo com autonomia energética elevada ainda representam um desafio, principalmente em soluções de baixo custo e larga escala. Neste trabalho, propõe-se uma arquitetura IoT completa, escalável e energeticamente eficiente para monitoramento de hidrômetros e detecção automática de vazamentos residenciais, integrando hardware, firmware, comunicação e processamento em nuvem. O protótipo foi desenvolvido com foco em eficiência energética, utilizando o microcontrolador STM32L031F6P6 e o transceptor SX1262, operando majoritariamente em modos de baixo consumo, com alimentação por bateria LiPo e suporte a *energy harvesting*.

Os pulsos provenientes do hidrômetro são coletados pelo nó IoT e transmitidos via protocolo LoRaWAN. A comunicação com a nuvem ocorre por meio do *The Things Network* (TTN) e integração à infraestrutura FIWARE. O sistema é hospedado em um ambiente AWS, onde os modelos são executados de forma contínua e automatizada, recebendo dados diretamente da base FIWARE e disponibilizando inferências em tempo real por meio de uma API integrada.

Na camada inteligente, são aplicadas técnicas de aprendizado de máquina não supervisionado e análise espectral para identificação de anomalias e microvazamentos. O modelo *Elliptic Envelope* é utilizado para detecção de vazamentos anômalos em séries temporais, enquanto a *Short-Time Fourier Transform* (STFT) permite reconhecer padrões cíclicos de baixo fluxo associados a microvazamentos. Os experimentos demonstraram elevada precisão na detecção de anomalias, com *FI-score* médio de 0,88 e consumo médio inferior a 1 mW, resultando em autonomia do protótipo superior a 130 dias sem recarga.

Palavras-chave: internet das coisas; LoRaWAN; FIWARE; vazamentos de água; aprendizado de máquina; análise espectral; detecção de anomalias; eficiência energética.

ABSTRACT

In the context of intelligent water resource management, Internet of Things (IoT) systems have shown great potential for monitoring water consumption and detecting leaks. However, achieving high energy autonomy in field devices remains a challenge, especially for low-cost and large-scale solutions. This work proposes a complete, scalable, and energy-efficient IoT architecture for smart water metering and automatic residential leak detection, integrating hardware, firmware, communication, and cloud-based processing. The prototype was designed with a strong focus on energy efficiency, using the STM32L031F6P6 microcontroller and the SX1262 transceiver, operating mainly in low-power modes and powered by a LiPo battery with *energy harvesting* support.

Water meter pulses are collected by the IoT node and transmitted via the LoRaWAN protocol. Cloud communication is established through *The Things Network* (TTN) and integrated into the FIWARE infrastructure. The system is hosted in an AWS environment, where the analytical models are continuously and automatically executed, receiving data directly from the FIWARE database and providing real-time inferences through an integrated API.

In the intelligent layer, unsupervised machine learning and spectral analysis techniques are applied to identify anomalies and microleaks. The *Elliptic Envelope* model is used for detecting anomalous leak events in time series data, while the *Short-Time Fourier Transform* (STFT) enables the recognition of cyclic low-flow patterns associated with microleaks. Experimental results demonstrated high accuracy in anomaly detection, with an average *F1-score* of 0.88 and average power consumption below 1 mW, resulting in prototype autonomy exceeding 130 days without recharging.

Keywords: internet of things; LoRaWAN; FIWARE; water leaks; machine learning; spectral analysis; anomaly detection; energy efficiency.

LISTA DE FIGURAS

Figura 1 – Ilustração dos tipos de vazamentos.	21
Figura 2 – Síntese das ações para o controle de perdas aparentes.	23
Figura 3 – Exemplo de casa inteligente baseada em IoT.	26
Figura 4 – Projeção global do número de dispositivos IoT conectados até 2030.	27
Figura 5 – Fluxo típico de dados em uma arquitetura <i>LoRa Wide Area Network</i> (LoRaWAN), desde o dispositivo sensor até a aplicação.	31
Figura 6 – Exemplo de arquitetura simplificada com FIWARE	33
Figura 7 – Técnicas de eficiência energética em IoT.	35
Figura 8 – Exemplo gráfico do Elliptic Envelope.	38
Figura 9 – Sinal no domínio do tempo, evidenciando uma variação progressiva da frequência ao longo do tempo.	40
Figura 10 – Representação tempo-frequência obtida pela <i>Short-Time Fourier Transform</i> (STFT). Observa-se que as componentes de frequência variam ao longo do tempo, conforme mostrado no espectrograma.	40
Figura 11 – Ecossistema Internet das Coisas (IoT) proposto para monitoramento e detecção de vazamentos, integrando hardware, rede LoRaWAN, FIWARE, FastAPI e análise inteligente.	47
Figura 12 – Placa do protótipo: vista superior e inferior.	48
Figura 13 – Fluxograma do funcionamento do firmware, indicando as três interrupções principais que despertam o microcontrolador do modo <i>STOP</i>	50
Figura 14 – Montagem experimental para medição do consumo energético do protótipo.	51
Figura 15 – Gateway LoRaWAN implementado com Raspberry Pi 4 e Elecrow LR1302.	55
Figura 16 – Exemplo de pacote recebido e decodificado na <i>The Things Network</i> (TTN), posteriormente encaminhado à infraestrutura FIWARE	56
Figura 17 – Fluxo de integração entre nó IoT, <i>TTN</i> , <i>fiware-connector</i> e infraestrutura FIWARE na AWS.	57
Figura 18 – Execução do <i>fiware-connector</i> durante o recebimento e repasse de dados da <i>TTN</i> para o FIWARE.	59
Figura 19 – Arquitetura geral da camada de aplicação.	60
Figura 20 – Interface principal do <i>frontend</i> web, com visualização temporal e alertas de anomalias.	63

Figura 21 – Exemplo de execução do modelo Elliptic Envelope.	65
Figura 22 – Elliptic Envelope com DBSCAN.	67
Figura 23 – Exemplo de microvazamento no gráfico.	69
Figura 24 – Exemplo de microvazamento detectado por análise espectral.	70
Figura 25 – Configuração do período de análise de microvazamentos na interface do sistema.	71
Figura 26 – Remoção automática de dias com consumo real detectado nos logs do sistema.	72
Figura 27 – Picos fundamentais identificados no espectro médio de consumo noturno.	73
Figura 28 – Protótipo instalado no ponto principal de medição da residência.	76
Figura 29 – Perfil de consumo energético do protótipo com transceptor SX1262 executando o firmware <i>bare-metal</i> e Arduino.	80
Figura 30 – Ampliação do perfil de potência no primeiro minuto de operação, evidenciando picos de interrupção e oscilações periódicas.	81
Figura 31 – Comparativo de consumo energético entre diferentes versões do sistema.	82
Figura 32 – Detecção de vazamentos pelo modelo <i>Elliptic Envelope</i> no <i>dataset</i> da dissertação.	89
Figura 33 – Ampliação de um vazamento leve mostrando oscilações detectadas parcialmente.	89
Figura 34 – Frequências fundamentais detectadas pela análise espectral de microvazamentos.	94
Figura 35 – Magnitude espectral e picos fundamentais identificados com base no Δ_{mag}	95
Figura 36 – Espectrograma da série temporal mostrando a estabilidade das componentes espectrais ao longo dos dias.	96
Figura 37 – Análise espectral dos <i>datasets</i> de (Kulikovas; Packevičius, 2023) e (Mauro <i>et al.</i> , 2019), sem indícios de microvazamentos.	98
Figura 38 – Interface do sistema <i>Smart Water Monitor</i> mostrando a atualização automática do status de microvazamento.	99

LISTA DE TABELAS

Tabela 1 – Comparação entre trabalhos relacionados	46
Tabela 2 – Limiar de tensão e comportamento energético do protótipo do sistema. . . .	49
Tabela 3 – Valores dos hiperparâmetros utilizados.	67
Tabela 4 – Hiperparâmetros da análise espectral para detecção de microvazamentos. . .	75
Tabela 5 – Comparativo geral de consumo energético entre as quatro abordagens avaliadas.	78
Tabela 6 – Consumo médio por modo de operação nas quatro abordagens avaliadas. . .	79
Tabela 7 – Desempenho comparativo entre <i>Isolation Forest</i> e <i>Elliptic Envelope</i> nos experimentos de (Cabral <i>et al.</i> , 2025a).	86
Tabela 8 – Métricas de desempenho do modelo <i>Elliptic Envelope</i> nos quatro conjuntos de dados analisados.	87
Tabela 9 – Desempenho do <i>Elliptic Envelope</i> por tipo de vazamento (métrica <i>Recall</i>). . .	88
Tabela 10 – Estatísticas descritivas dos <i>datasets</i> analisados.	90
Tabela 11 – Tempo de treinamento e inferência do modelo <i>Elliptic Envelope</i> em diferentes <i>datasets</i>	91
Tabela 12 – Custo de fabricação do protótipo IoT.	118

LISTA DE ABREVIATURAS E SIGLAS

LoRaWAN	<i>LoRa Wide Area Network</i>
STFT	<i>Short-Time Fourier Transform</i>
IoT	Internet das Coisas
TTN	<i>The Things Network</i>
ONU	Organização das Nações Unidas
LoRa	<i>Long Range</i>
LiPo	<i>Lithium Polymer</i>
ANA	Agência Nacional de Águas e Saneamento Básico
RFID	<i>Radio Frequency Identification</i>
RIS	Superfícies Inteligentes Reconfiguráveis
ISM	<i>Industrial, Scientific and Medical</i>
SF	<i>Spreading Factor</i>
BW	<i>Bandwidth</i>
ED	<i>End Device</i>
GW	<i>Gateway</i>
NS	Servidor de rede
AS	Servidor de aplicação
IP	<i>Internet Protocol</i>
GE	Habilitadores Genéricos (<i>Generic Enablers</i>)
NGSI	<i>Next Generation Service Interfaces</i>
ML	<i>Machine Learning</i>
RF	<i>Radio Frequency</i>
ADR	<i>Adaptative Data Rate</i>
LMIC	LoRaMAC-in-C
ABP	<i>Activation by Personalization</i>
HAT	<i>Hardware Attached on Top</i>
AWS	<i>Amazon Web Services</i>
DBSCAN	<i>Density-Based Spatial Clustering of Applications with Noise</i>

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos	18
1.1.1	<i>Objetivos específicos</i>	18
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	Perdas de Água e o Contexto Brasileiro	20
2.1.1	<i>Classificação dos Vazamentos</i>	21
2.1.2	<i>Micromedição no Controle de Perdas</i>	22
2.2	Internet das Coisas (IoT)	24
2.2.1	<i>Arquitetura da Internet das Coisas</i>	25
2.2.2	<i>Panorama Atual do Mercado de IoT</i>	27
2.2.3	<i>Desafios da Internet das Coisas</i>	28
2.2.4	<i>IoT Aplicada ao Saneamento</i>	29
2.3	Tecnologia LoRaWAN	30
2.3.1	<i>LoRa e LoRaWAN</i>	30
2.3.2	<i>Arquitetura LoRaWAN</i>	30
2.4	Plataforma FIWARE	32
2.5	Consumo Energético em Sistemas Embarcados	34
2.6	Técnicas de <i>Energy Harvesting</i> para IoT	35
2.7	Deteção de Anomalias e Aprendizado de Máquina Não Supervisionado	37
2.8	Análise Espectral e a Short-Time Fourier Transform (STFT)	39
2.9	Métricas de Avaliação	41
2.9.1	<i>Métricas de Desempenho dos Modelos de Aprendizado de Máquina</i>	41
2.9.2	<i>Métricas de Eficiência Energética</i>	43
3	TRABALHOS RELACIONADOS	44
4	METODOLOGIA	47
4.1	Protótipo do sistema	48
4.1.1	<i>Gerenciamento de energia</i>	48
4.1.2	<i>Processamento e firmware</i>	49
4.1.3	<i>Testes de Consumo Energético</i>	50
4.1.4	<i>Comunicação LoRa</i>	53

4.2	Gateway LoRaWAN e Servidor de Rede LoRaWAN	54
4.2.1	<i>Servidor de rede LoRaWAN</i>	55
4.3	Integração com o Framework FIWARE	57
4.3.1	<i>Orion Context Broker</i>	57
4.3.2	<i>QuantumLeap</i>	58
4.3.3	<i>CrateDB</i>	58
4.3.4	<i>FIWARE Connector</i>	59
4.4	Aplicação	60
4.4.1	<i>Backend Analítico</i>	60
4.4.2	<i>Frontend Web</i>	62
5	CAMADA ANALÍTICA	64
5.1	Detecção de Vazamentos por Aprendizado de Máquina	65
5.1.1	<i>Agrupamento temporal de anomalias com DBSCAN</i>	66
5.1.2	<i>Hiperparâmetros</i>	67
5.2	Detecção de Microvazamentos por Análise espectral	68
5.2.1	<i>Pré-processamento dos dados para detecção de microvazamentos</i>	71
5.2.2	<i>Critério de detecção de picos espectrais (Δmag)</i>	72
5.2.3	<i>Hiperparâmetros</i>	74
6	RESULTADOS E DISCUSSÃO	76
6.1	Resultados de Consumo Energético	77
6.1.1	<i>Análise estatística do consumo</i>	78
6.1.2	<i>Consumo por modo de operação</i>	79
6.1.3	<i>Comparação gráfica e interpretação dos resultados</i>	80
6.1.4	<i>Síntese dos resultados</i>	82
6.2	Energy Harvesting e Autonomia Operacional	83
6.3	Viabilidade Econômica do Sistema	84
6.4	Resultados da Aplicação de Aprendizado de Máquina	85
6.4.1	<i>Desempenho geral do modelo</i>	86
6.4.2	<i>Análise por tipo de vazamento</i>	87
6.4.3	<i>Análise visual dos resultados</i>	88
6.4.4	<i>Influência das características dos datasets</i>	90
6.4.5	<i>Desempenho Computacional do Modelo</i>	91

6.4.6	<i>Síntese dos resultados</i>	92
6.5	Resultados da Detecção de Microvazamentos	93
6.5.1	<i>Identificação das Frequências Fundamentais</i>	93
6.5.2	<i>Análise Espectral e Score de Detecção</i>	95
6.5.3	<i>Distribuição Temporal das Frequências</i>	96
6.5.4	<i>Comparação com Outros Conjuntos de Dados</i>	97
6.5.5	<i>Validação no Sistema Integrado</i>	98
6.5.6	<i>Síntese dos resultados</i>	100
6.6	Síntese Integrada dos Resultados	101
7	CONCLUSÕES E TRABALHOS FUTUROS	102
7.1	Considerações Finais	102
7.2	Trabalhos Futuros	103
	REFERÊNCIAS	105
	APÊNDICES	113
	APÊNDICE A–DOCKERFILE UTILIZADO NA INTEGRAÇÃO DO MIDDLEWARE COM O FIWARE	113
	APÊNDICE B–CÓDIGO UTILIZADO NA DECODIFICAÇÃO DE PAYLOAD NA TTN	117
	APÊNDICE C–DETALHAMENTO DOS CUSTOS DE FABRICAÇÃO DO NÓ IOT	118

1 INTRODUÇÃO

A crescente preocupação com a sustentabilidade e a segurança hídrica tem colocado a gestão dos recursos hídricos como uma prioridade estratégica global. A Organização das Nações Unidas (ONU) ressalta a importância de assegurar a disponibilidade e a gestão sustentável da água para todos, reforçando a urgência de iniciativas que combatam o desperdício e promovam o uso eficiente dos recursos naturais (Organização das Nações Unidas, 2023). No Brasil, esse desafio é agravado pelas elevadas taxas de perdas na distribuição de água tratada. Segundo o Instituto Trata Brasil, aproximadamente 37,78% da água distribuída se perde antes de chegar às residências, um volume suficiente para abastecer toda a população do Nordeste por um ano (Instituto Trata Brasil, 2024). Entre os fatores que contribuem para esse cenário estão a degradação da infraestrutura, falhas nos sistemas de medição e a ocorrência de vazamentos, configurando uma situação em que escassez e desperdício coexistem de forma crítica (ANA, 2024).

As consequências dessas perdas são amplas. Do ponto de vista ambiental, aumentam a pressão sobre os mananciais e elevam o consumo energético nos processos de captação e tratamento (Magalhães, 2017). Sob a ótica econômica, a Portaria nº 490/2024 da Agência Nacional de Águas e Saneamento Básico (ANA) estima que reduzir as perdas para 25% poderia gerar um ganho líquido de R\$ 20,4 bilhões até 2034, consolidando o controle de perdas como uma estratégia fundamental para a resiliência climática e a eficiência operacional (Ministério do Desenvolvimento Regional, 2021; ANA, 2024).

Nesse contexto, soluções baseadas em IoT, aliadas a técnicas de aprendizado de máquina, têm se mostrado altamente promissoras para o monitoramento do consumo e a detecção de vazamentos, devido à capacidade do IoT de realizar coleta contínua de dados e comunicação remota em larga escala, e à habilidade dos algoritmos de aprendizado de máquina em identificar padrões anômalos (ITU, 2021). Entre as tecnologias disponíveis, o LoRaWAN, protocolo que utiliza *Long Range* (LoRa) e se destaca pela comunicação de longo alcance com baixo consumo energético, tornando-se uma escolha adequada para aplicações residenciais e urbanas (FELINTO FILHO, 2023). Entretanto, a literatura ainda apresenta limitações: muitos trabalhos dependem de dados rotulados para empregar modelos supervisionados (Mauro *et al.*, 2019; Guezouli *et al.*, 2024), enquanto outros não consideram o impacto do software embarcado na autonomia dos dispositivos (Migabo *et al.*, 2021; Ayatullah *et al.*, 2023).

Outro fator relevante é que a eficiência energética em sistemas IoT não é determinada

apenas pelo hardware, mas também pelas estratégias de software, que influenciam diretamente a autonomia dos dispositivos em campo (Cabral *et al.*, 2025b). Esse aspecto é particularmente crítico em aplicações de monitoramento hídrico, nas quais os nós sensores devem permanecer operando por longos períodos sem intervenção manual. Sem um gerenciamento eficiente de energia, a bateria pode ser rapidamente drenada, comprometendo a continuidade da coleta de dados e a confiabilidade do sistema. Estudos anteriores mostraram que diferentes arquiteturas, como Arduino e FreeRTOS apresentam desempenhos significativamente distintos em termos de consumo energético e previsibilidade temporal.

Considerando esses desafios, esta dissertação propõe um sistema IoT de baixo custo, escalável e energeticamente eficiente para detecção de vazamentos residenciais, utilizando técnicas de detecção de anomalias e análise espectral de dados, fundamentado em uma arquitetura modular que abrange desde a coleta de dados até a análise inteligente na nuvem.

O sistema proposto integra hardware, firmware, rede e processamento de dados, formando um fluxo completo de telemetria hídrica. O nó IoT foi construído com o microcontrolador STM32L031F6P6, o transceptor SX1262 e um circuito de leitura de pulsos conectado a um hidrômetro ultrassônico. O dispositivo é alimentado por uma bateria *Lithium Polymer* (LiPo) com recarga por *energy harvesting*. O firmware implementado controla diretamente os modos de energia do microcontrolador, reduzindo o consumo médio e aumentando a autonomia.

Os dados de consumo são transmitidos via LoRaWAN para um gateway baseado no módulo LR1302, conectado a uma Raspberry Pi, e encaminhados à nuvem por meio da TTN. O processamento e a persistência dos dados ocorrem na infraestrutura FIWARE, utilizando os componentes Orion Context Broker e QuantumLeap, com armazenamento temporal em CrateDB. Essa arquitetura viabiliza o monitoramento contínuo, distribuído e de baixo custo operacional.

A camada analítica incorpora dois eixos complementares: (i) o modelo *Elliptic Envelope*, validado experimentalmente em (Cabral *et al.*, 2025a) no KDMiLe 2025, aplicado à detecção de vazamentos anômalos em séries temporais; e (ii) o método de análise espectral, voltado à detecção de microvazamentos contínuos e de baixa intensidade. Essas abordagens foram integradas ao sistema, compondo uma estrutura capaz de identificar tanto vazamentos evidentes quanto perdas sutis, ampliando a capacidade diagnóstica da solução.

O presente trabalho também gerou como resultado, o artigo apresentado no SEMISH 2025 (Cabral *et al.*, 2025b), que comparou o desempenho energético de diferentes arquiteturas de firmware. Nesta dissertação, o sistema é consolidado em sua versão final, incorporando o

firmware *bare-metal*, a arquitetura FIWARE e a comunicação completa via LoRaWAN, sendo validado quanto à conectividade, consumo energético e eficácia na detecção de vazamentos.

1.1 Objetivos

O objetivo geral desta dissertação é propor e validar um sistema IoT de baixo custo, escalável e energeticamente eficiente para detecção de vazamentos de água em ambientes residenciais, integrando comunicação LoRa, processamento distribuído com a plataforma FIWARE e mecanismos de detecção inteligente baseados em aprendizado de máquina não supervisionada e análise espectral.

1.1.1 Objetivos específicos

- Projetar e implementar o nó IoT com microcontrolador STM32L031F6P6, transceptor SX1262 e circuito de leitura de pulsos, com firmware *bare-metal* otimizado para baixo consumo.
- Avaliar o consumo energético e a autonomia do nó, quantificando o impacto das estratégias de economia de energia e do firmware utilizado.
- Comparar o desempenho energético entre diferentes abordagens de firmware (Arduino e *bare-metal*) e entre o novo protótipo projetado e o modelo utilizado em (Cabral *et al.*, 2025b), a fim de confrontar diferentes combinações de hardware e software executando a mesma tarefa.
- Implantar o gateway LoRaWAN (LR1302 + Raspberry Pi) e validar a comunicação com a rede pública TTN.
- Integrar o middleware com a infraestrutura FIWARE (Orion, QuantumLeap e CrateDB) para coleta e armazenamento temporal dos dados.
- Validar a detecção de vazamentos e microvazamentos utilizando as abordagens *Elliptic Envelope* e $STFT + \Delta mag$, respectivamente.
- Validar o modelo de aprendizado de máquina e a detecção de microvazamentos com métricas supervisionadas, avaliando *precision*, *recall* e *F1-score* sobre os dados coletados pelo sistema IoT.
- Analisar a viabilidade técnica e econômica do sistema, demonstrando seu potencial de replicação em larga escala.

Este trabalho está organizado da seguinte forma: o Capítulo 2 apresenta os conceitos fundamentais utilizados ao longo do estudo; o Capítulo 3 discute os trabalhos relacionados ao tema proposto; o Capítulo 4 detalha a metodologia adotada e a organização da proposta. O Capítulo 5 apresenta o detalhamento da camada analítica do sistema. O Capítulo 6 apresenta os resultados obtidos nos experimentos iniciais; por fim, o Capítulo 7 traz as considerações finais e as perspectivas para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os principais conceitos, dados e abordagens técnicas que fundamentam o desenvolvimento deste trabalho. São discutidos o panorama das perdas de água no Brasil, a classificação dos vazamentos, a importância da micromedição no controle de perdas aparentes, os princípios da IoT aplicados ao saneamento, a comunicação por LoRaWAN, a plataforma FIWARE, o consumo energético em sistemas embarcados, estratégias de *energy harvesting*, técnicas de detecção de anomalias em aprendizado de máquina não supervisionado, análise espectral na detecção de microvazamentos e a definição das métricas utilizadas.

2.1 Perdas de Água e o Contexto Brasileiro

O cenário brasileiro de perdas de água tratada permanece crítico e desafiador, tanto sob a ótica da sustentabilidade hídrica quanto da eficiência operacional dos serviços de saneamento (Instituto Trata Brasil, 2024). Em 2024, o país foi impactado por uma conjuntura marcada por eventos climáticos extremos, como estiagens prolongadas e enchentes severas que agravaram a pressão sobre os sistemas de abastecimento em diversas regiões. Segundo a Agência Nacional de Águas e Saneamento Básico (ANA), esses eventos tornaram ainda mais evidente a vulnerabilidade das redes de distribuição e a necessidade de modernização urgente dos serviços (ANA, 2024).

De acordo com o (Instituto Trata Brasil, 2024), o índice médio de perdas na distribuição atingiu 37,78% em 2023, valor que representa mais de 7 mil piscinas olímpicas de água desperdiçadas por dia. Em mais da metade dos municípios brasileiros, as perdas superam 40%, com destaque para as regiões Norte e Nordeste, onde se concentram os piores indicadores. O Diagnóstico Temático do SNIS 2023 confirma esse panorama, evidenciando que a ausência de planejamento técnico, a falta de setorização e a baixa taxa de substituição de redes antigas continuam sendo gargalos estruturais (Secretaria Nacional de Saneamento Ambiental, 2023).

Como forma de mitigar essa crise, a Portaria nº 490/2021, do Ministério do Desenvolvimento Regional, estabelece procedimentos e metas obrigatórias para a redução progressiva das perdas nos sistemas de distribuição. O normativo exige dos prestadores a elaboração de diagnósticos detalhados, planos de ação e o monitoramento de indicadores como o volume de água não faturado e o índice de perdas na distribuição. Estima-se que, com a redução dessas perdas para um patamar de 25%, o país pode obter um ganho líquido de até R\$ 20,4 bilhões até

2034, além de ampliar a resiliência climática do setor (Ministério do Desenvolvimento Regional, 2021).

Estudos de caso reforçam a viabilidade dessas metas. Em Salvador, por exemplo, (Magalhães, 2017) identificou perdas da ordem de 48%, e demonstrou que a redução para 25% permitiria uma economia anual superior a 78 bilhões de litros de água e ganhos operacionais de aproximadamente R\$ 13 milhões por mês. Autores como (Souza *et al.*, 2023) argumentam que o enfrentamento das perdas não requer, necessariamente, grandes obras de engenharia, mas sim a adoção sistemática de boas práticas operacionais, como o combate a fraudes, a renovação de ramais e a micromedição eficiente.

Por fim, tecnologias de automação, georreferenciamento e Internet das Coisas (IoT) vêm ganhando espaço como alternativas viáveis para o monitoramento contínuo das redes. (Santos *et al.*, 2021) destaca que a ausência de supervisão em tempo real dificulta o controle ativo de perdas e compromete a gestão eficiente do abastecimento.

Dentre os diversos componentes envolvidos nas perdas, os vazamentos configuram a principal causa das chamadas perdas reais, enquanto erros de leitura e a ausência de medição individualizada explicam grande parte das perdas aparentes (Bezerra; Cheung, 2013). Diante disso, as próximas seções fundamentam aspectos cruciais para o desenvolvimento deste trabalho, abordando a classificação dos vazamentos e o papel estratégico da micromedição na redução do desperdício e na melhoria dos indicadores operacionais dos sistemas de abastecimento.

2.1.1 Classificação dos Vazamentos

A compreensão da tipologia dos vazamentos é essencial para a definição de estratégias eficazes de controle de perdas. A Figura 1 apresenta essa classificação de forma esquemática, com base em (Lambert, 2001), sendo amplamente utilizada em trabalhos aplicados, como os de (TARDELLI FILHO, 2006).

Figura 1 – Ilustração dos tipos de vazamentos.



Fonte: Adaptado de (Bezerra; Cheung, 2013).

Segundo (Lambert, 2001), os vazamentos podem ser classificados em três categorias principais: visíveis, não visíveis e inerentes. Essa distinção considera tanto a possibilidade de visualização direta quanto a capacidade de detecção por equipamentos, além da natureza e localização dos vazamentos nas redes de abastecimento. A seguir, são descritas as principais características de cada tipo:

- **Vazamentos visíveis:** são aqueles que afloram à superfície e, por isso, costumam ser identificados rapidamente, geralmente por meio de relatos da população. Sua duração tende a ser curta devido à pronta detecção;
- **Vazamentos não visíveis:** ocorrem sem afloramento à superfície e, portanto, exigem o uso de métodos acústicos ou tecnologias específicas para sua detecção. São mais difíceis de localizar e podem permanecer ativos por longos períodos;
- **Vazamentos inerentes:** são perdas contínuas e geralmente de pequeno volume, causadas por microvazamentos em juntas, conexões ou materiais porosos. Esses vazamentos são praticamente indetectáveis individualmente, mesmo com equipamentos de precisão.

Essa classificação orienta a seleção de técnicas de inspeção e intervenções operacionais, uma vez que cada tipo de vazamento requer abordagens distintas quanto à priorização, localização e reparo.

Essa tipologia evidencia que o principal desafio para as operadoras de saneamento reside na detecção e quantificação dos vazamentos não visíveis e inerentes (Bezerra; Cheung, 2013). A dificuldade e o alto custo associados aos métodos tradicionais de inspeção reforçam a necessidade de abordagens inovadoras. Nesse contexto, soluções de monitoramento contínuo e automatizado, baseadas em IoT, surgem como uma alternativa estratégica para a gestão proativa de perdas, conforme será discutido na próxima seção.

2.1.2 Micromedição no Controle de Perdas


A micromedição, definida como a medição individualizada do volume de água consumido por cada ligação domiciliar, constitui uma ferramenta indispensável para a gestão eficiente dos sistemas de abastecimento e, em particular, para a redução das perdas aparentes (TARDELLI FILHO, 2006). Sua implementação permite a quantificação precisa do consumo, o que é crucial para a detecção de fraudes, a correção de erros de leitura e, consequentemente, o aumento da eficiência no faturamento dos serviços prestados pelas companhias de saneamento.

Conforme destacado por (Tsutiya *et al.*, 2006), a micromedição é o processo que

determina o volume de água a ser faturado ao cliente, sendo a base para a emissão da conta. A ausência de hidrômetros, ou o uso de equipamentos descalibrados, pode comprometer significativamente esse processo, representando até 50% das perdas aparentes. Além disso, hidrômetros antigos ou mal dimensionados frequentemente resultam em submedição, especialmente em faixas de vazão reduzida. Essa imprecisão não apenas afeta a justiça tarifária para o consumidor, mas também impacta diretamente a receita das prestadoras de serviço, limitando sua capacidade de investimento em melhorias e na manutenção da infraestrutura.

A Figura 2 apresenta, de forma ilustrada, os diferentes níveis de medição ao longo do sistema de abastecimento de água, desde a macromedição até a micromedição nas unidades consumidoras. Essa representação permite visualizar a hierarquia entre as etapas de monitoramento e o papel de cada uma no controle operacional e na redução de perdas.

Figura 2 – Síntese das ações para o controle de perdas aparentes.



Fonte: Adaptado de (Bezerra; Cheung, 2013).

Conforme ilustrado na Figura 2, a medição do consumo de água nos sistemas de abastecimento pode ser realizada em diferentes níveis, cada um com finalidades e abrangências distintas ao longo da cadeia operacional. Segundo (TARDELLI FILHO, 2006), esses níveis englobam desde o monitoramento global do sistema até a quantificação individual do consumo por unidade usuária:

- **Macromedição:** realizada por medidores de vazão instalados em pontos estratégicos do sistema, como na saída de estações de tratamento ou em reservatórios, permitindo o controle global do volume distribuído;
- **Setorização:** refere-se à subdivisão da rede em setores de abastecimento com medição própria, o que possibilita a identificação de perdas localizadas e o gerenciamento operacional por zona;
- **Micromedição:** efetuada por hidrômetros instalados na entrada dos imóveis, voltada à

quantificação individualizada do consumo por unidade usuária.

Cada uma dessas formas de medição cumpre um papel distinto no controle operacional e na gestão das perdas. No entanto, este trabalho concentra-se especificamente na micromedição aplicada a ambientes residenciais, com ênfase nos hidrômetros instalados na entrada de imóveis unifamiliares.

A relevância da micromedição é amplificada pela integração de sensores conectados à IoT, conforme demonstrado por (Mauro *et al.*, 2019), que desenvolveram um sistema de monitoramento em tempo real do consumo hídrico em ambientes residenciais, possibilitando maior precisão, automação e análise preditiva do uso da água. Essa abordagem tecnológica potencializa a automação, a precisão e a confiabilidade da medição, permitindo o monitoramento em tempo real do consumo e a integração dos dados com plataformas analíticas avançadas. Tal sinergia entre micromedição e IoT abre caminho para uma gestão mais proativa e inteligente das perdas, facilitando a identificação precoce de anomalias e a otimização dos recursos hídricos.

2.2 Internet das Coisas (IoT)

A IoT, do inglês *Internet of Things* refere-se à interconexão de dispositivos físicos capazes de coletar, transmitir e processar dados por meio da internet (Ashton, 2009). Essa integração entre o mundo físico e o virtual promove uma transformação significativa na forma como ambientes são monitorados, controlados e otimizados (Atzori *et al.*, 2010).

O termo *Internet of Things* foi apresentado por (Ashton, 2009), porém, o conceito de conectar dispositivos está presente na literatura há décadas. (Weiser, 2002) já afirmava que dispositivos seriam conectados de forma transparente para o ser humano, tornando-se invisíveis no dia a dia e possibilitando a realização de tarefas de maneira totalmente automatizada.

Segundo (Al-Fuqaha *et al.*, 2015), a IoT configura-se como um ecossistema composto por tecnologias habilitadoras, protocolos de comunicação leves e arquiteturas escaláveis, capazes de suportar aplicações em diversos domínios, como cidades inteligentes, saúde, agricultura, indústria e saneamento. Já (Atzori *et al.*, 2010) definem a IoT como um paradigma que considera a presença pervasiva ao nosso redor de uma variedade de coisas ou objetos, como etiquetas RFID, sensores, atuadores, entre outros, capazes de interagir e cooperar entre si por meio de esquemas de endereçamento exclusivos.

Nesse contexto, (Gubbi *et al.*, 2013) destacam a importância da infraestrutura unificada e da computação em nuvem como elementos centrais para viabilizar aplicações inovadoras

em ambientes IoT:

A interconexão de dispositivos de detecção e de atuação, fornecendo a capacidade de compartilhar informações entre plataformas por meio de uma estrutura unificada, desenvolvendo um quadro operacional comum para permitir aplicativos inovadores. Isso é conseguido por uma detecção onipresente, análise de dados e representação de informações com a computação em nuvem como a estrutura unificadora. (Gubbi *et al.*, 2013, traduzido pelo autor).

2.2.1 Arquitetura da Internet das Coisas

A arquitetura da IoT é fundamental para garantir a comunicação eficiente entre dispositivos físicos e sistemas computacionais, possibilitando a coleta, o processamento e a utilização de dados em tempo real (Hussain; Saqib, 2021). A literatura propõe diferentes modelos arquiteturais, sendo a mais comum aquela composta por três camadas principais: percepção, rede e aplicação (Al-Fuqaha *et al.*, 2015).

- **Camada de Percepção:** Também chamada de camada física, é responsável por identificar, medir e adquirir dados do ambiente. Compreende sensores, atuadores, etiquetas RFID e outros dispositivos embarcados.
- **Camada de Rede:** Faz a transmissão dos dados coletados para os centros de processamento, utilizando tecnologias como Wi-Fi, Bluetooth, ZigBee, LoRa, NB-IoT e redes celulares (2G–5G).
- **Camada de Aplicação:** É responsável por fornecer os serviços finais ao usuário, realizando o processamento, visualização e controle inteligente dos dados. Pode incluir interfaces com a nuvem ou computação de borda.

Modelos mais recentes estendem essa visão tradicional para acomodar a crescente complexidade e diversidade das aplicações IoT. Segundo (Lin *et al.*, 2017), é comum incorporar camadas adicionais, como:


- **Camada de Processamento:** Engloba recursos de computação em nuvem, névoa (*fog*) e borda (*edge*), responsáveis por analisar e armazenar dados de forma distribuída e com menor latência.
- **Camada de Gerenciamento:** Trata da configuração, autenticação, gerenciamento de dados, controle de acesso e integração entre os dispositivos e serviços.

Com a evolução para redes 6G e a incorporação de inteligência artificial embarcada (*Edge AI*), a arquitetura da IoT caminha para um modelo ainda mais distribuído, autônomo e inteligente (Nguyen *et al.*, 2022). Tecnologias emergentes como Superfícies Inteligentes Recon-

figuráveis (RIS), comunicação em múltiplos domínios (terra, ar, espaço e mar) e aprendizado de máquina local tornam-se cada vez mais presentes, expandindo o potencial das aplicações IoT.

Essas arquiteturas modernas priorizam aspectos como baixa latência, segurança de ponta a ponta, sustentabilidade energética e interoperabilidade global, consolidando a IoT como uma infraestrutura crítica para aplicações em cidades inteligentes, saúde, agricultura e saneamento. A Figura 3 ilustra um exemplo de casa inteligente, evidenciando o fluxo de dados desde sensores e atuadores até os servidores de aplicação em nuvem. A imagem também destaca os diferentes tipos de comunicação utilizados, como ZigBee, BLE e IP.

Figura 3 – Exemplo de casa inteligente baseada em IoT.



Fonte: (Momote, 2016).


Nesse cenário, cresce a necessidade de soluções que aliem eficiência computacional e energética. Como destacado por Mehta e Aneja (Mehta; Aneja, 2024), o uso de IoT deve ser complementado por técnicas de análise de dados avançadas e inteligência artificial para otimizar o consumo de recursos em diferentes setores da economia. Essa preocupação se torna ainda mais crítica em aplicações remotas, autônomas ou alimentadas por energia restrita, como aquelas encontradas no monitoramento ambiental e em sistemas de saneamento. Esses fatores vêm se refletindo diretamente nas estratégias de expansão do mercado de IoT, conforme discutido na seção seguinte.

2.2.2 Panorama Atual do Mercado de IoT

O mercado global da IoT apresenta crescimento constante, impulsionado pela digitalização de processos em diversos setores, como saúde, agricultura, energia e saneamento (Al-Fuqaha *et al.*, 2015). De acordo com a *IoT Analytics* (Sinha, 2024), o número de dispositivos IoT conectados cresceu de 16,6 bilhões em 2023 para uma projeção de 18,8 bilhões ao final de 2024, representando um crescimento anual de 13%. A expectativa é que esse número ultrapasse 40 bilhões até 2030, demonstrando a consolidação da IoT como infraestrutura digital essencial.

Esse crescimento está diretamente relacionado à disseminação de sensores de baixo custo, à expansão das redes de comunicação (Wi-Fi, LPWAN, NB-IoT, 5G) e à integração com tecnologias emergentes como *edge computing* e inteligência artificial embarcada. A Figura 4 ilustra a projeção do número global de conexões IoT até 2030, segmentadas por tipo de conectividade (Singh, 2025).

Figura 4 – Projeção global do número de dispositivos IoT conectados até 2030.



Fonte: (Sinha, 2024).

Além do crescimento no número de dispositivos, há um avanço qualitativo: a integração entre IoT e inteligência artificial, especialmente via *edge AI*, tem possibilitado análises e tomadas de decisão mais próximas da fonte de dados. Segundo (Mehta; Aneja, 2024), o uso combinado de IoT com técnicas de aprendizado de máquina e análise avançada de dados é essencial para a otimização de recursos em diversos setores da economia.

Esse cenário demonstra que o mercado de IoT não apenas se expande em escala,

mas também se diversifica em aplicações e complexidade técnica. Essa evolução reforça a necessidade de arquiteturas eficientes, interoperáveis e energeticamente sustentáveis.

2.2.3 *Desafios da Internet das Coisas*

Apesar do avanço acelerado e das inúmeras aplicações da IoT, diversos desafios ainda comprometem sua adoção plena e sustentável. Um dos principais entraves diz respeito à interoperabilidade entre dispositivos e plataformas. Como discutido por (Höller *et al.*, 2014) e (Al-Fuqaha *et al.*, 2015), a padronização ainda é fragmentada, com múltiplos protocolos e arquiteturas coexistindo de maneira descoordenada, o que dificulta a integração eficiente de soluções em diferentes domínios.

A segurança e a privacidade também se configuram como barreiras críticas. O volume massivo de dados coletados por sensores conectados, muitas vezes em tempo real, expõe os usuários a riscos consideráveis de vazamento de informações sensíveis. Modelos como o IoT-A (Höller *et al.*, 2014) e os levantamentos de (Gubbi *et al.*, 2013) destacam a importância de mecanismos de autenticação, autorização e gerenciamento de identidades para garantir a confiança nas interações entre dispositivos e serviços.

Outro desafio recorrente está relacionado à eficiência energética. Dispositivos IoT são, muitas vezes, alimentados por baterias ou fontes de energia intermitente, o que exige arquiteturas e algoritmos otimizados para prolongar sua autonomia. A necessidade de soluções baseadas em *edge computing*, que minimizem o tráfego de dados para a nuvem e realizem parte do processamento localmente, é destacada por (Mauro *et al.*, 2019) e também por (Mehta; Aneja, 2024), como uma abordagem promissora para mitigar o consumo energético e a latência.

A escalabilidade se destaca como preocupação estrutural, especialmente em cenários com milhares de dispositivos em operação simultânea. A heterogeneidade de hardware e software, a evolução tecnológica constante e a exigência por integrações com sistemas legados impõem desafios adicionais à construção de arquiteturas resilientes e flexíveis (Höller *et al.*, 2014; Al-Fuqaha *et al.*, 2015).

Por fim, a sustentabilidade a longo prazo emerge como ponto de atenção. Questões como o ciclo de vida dos dispositivos, reutilização de componentes, descarte responsável e viabilidade econômica devem ser consideradas desde o planejamento da solução. Tais aspectos são frequentemente ignorados, mas aparecem como tendência crescente nos estudos recentes (Mehta; Aneja, 2024; Al-Fuqaha *et al.*, 2015). Esses desafios, embora significativos, representam tam-

bém oportunidades para inovação e pesquisa, fomentando o desenvolvimento de soluções mais robustas, éticas e sustentáveis no ecossistema da IoT.

2.2.4 IoT Aplicada ao Saneamento

No contexto do saneamento, a IoT vem sendo amplamente explorada para modernizar os sistemas de abastecimento de água e esgotamento sanitário, promovendo maior controle operacional, redução de perdas e melhoria na prestação dos serviços (Mehta; Aneja, 2024). Sensores conectados a hidrômetros, válvulas, reservatórios e estações de bombeamento viabilizam o monitoramento contínuo de variáveis como pressão, vazão e volume consumido (Selvaparakash *et al.*, 2025).

Ainda em 2006, (TARDELLI FILHO, 2006) já descrevia um modelo de operação que se alinha perfeitamente aos padrões atuais da IoT, ao enfatizar a coleta remota, a transmissão por diferentes meios e o armazenamento histórico de dados como base para ações estratégicas:

“Os dados podem ser registrados e acumulados no local, sendo coletados posteriormente, ou transmitidos por telemetria (linhas telefônicas privativas, linhas discadas, rádio, satélite, etc) a uma central, onde serão processados e divulgados às áreas responsáveis.
É fundamental contar com o histórico das medições, de forma a acompanhar a evolução dos parâmetros, realizar trabalhos estatísticos e identificar eventuais alterações de comportamento no sistema.” (TARDELLI FILHO, 2006)

Essa visão antecipa os conceitos atuais de monitoramento contínuo, conectividade ubíqua e análise de séries temporais, pilares fundamentais para as soluções IoT aplicadas à gestão hídrica inteligente.

A integração da IoT com sistemas de micromedição permite a leitura automática e remota dos hidrômetros, elimina a necessidade de visitas manuais, reduz erros de faturamento e permite a análise de séries temporais para detecção de anomalias. Trabalhos como o de (Mauro *et al.*, 2019) demonstram a viabilidade de soluções embarcadas baseadas em IoT para o consumo residencial, ampliando a precisão da medição e a inteligência operacional do sistema.

Além disso, essas soluções têm se mostrado promissoras na identificação de padrões de consumo e na gestão da demanda, favorecendo a redução de perdas e o uso racional da água (Cabral *et al.*, 2025a; Kulikovas; Packevičius, 2023). O uso de dispositivos de medição inteligente (*smart water meters*) e plataformas em nuvem ou em borda (*edge/fog computing*) permite não apenas o armazenamento, mas também o processamento e análise de dados em tempo real (Mauro *et al.*, 2019).

A aplicação de técnicas de desagregação do consumo, viabilizada por sensores instalados em pontos finais de uso, fornece informações detalhadas sobre como, onde e quando a água é utilizada (Mauro *et al.*, 2019). Isso permite desde ações corretivas em tempo real até o aprimoramento de estratégias de planejamento em sistemas de abastecimento, reforçando a interseção entre saneamento, eficiência energética e sustentabilidade urbana.

2.3 Tecnologia LoRaWAN

2.3.1 LoRa e LoRaWAN

LoRa, do inglês *Long Range* é uma técnica de modulação de espectro espalhado baseada em *chirp* (CSS – *Chirp Spread Spectrum*), conhecida por sua capacidade de comunicação a longas distâncias com baixíssimo consumo energético (Ortiz *et al.*, 2019). Opera em bandas *Industrial, Scientific and Medical* (ISM), como 433 MHz, 868 MHz (Europa) e 915 MHz (América), sendo amplamente utilizada em soluções de IoT, especialmente em cenários que exigem autonomia energética e grande cobertura geográfica (Liya; Aswathy, 2020; Zourmand *et al.*, 2019).

Graças à sua resistência ao ruído e operação abaixo do ruído de fundo, a LoRa é capaz de manter comunicação confiável mesmo em ambientes adversos. Parâmetros ajustáveis como o *Spreading Factor* (SF) e a *Bandwidth* (BW) afetam diretamente a taxa de transmissão e a sensibilidade da recepção, sendo essenciais para otimizar o alcance e o consumo de energia dos dispositivos (Zourmand *et al.*, 2019).

Sobre essa camada física, a LoRa *Alliance* desenvolveu o protocolo LoRaWAN, que define a camada MAC, além de aspectos como segurança, gerenciamento de rede e comunicação assíncrona baseada em ALOHA (Milarokostas *et al.*, 2023). Esse protocolo possibilita aplicações como medição remota, controle de iluminação pública, monitoramento ambiental e gestão de recursos hídricos.


2.3.2 Arquitetura LoRaWAN

A arquitetura LoRaWAN é organizada seguindo um modelo em estrela, no qual os dispositivos finais (*End Devices* (EDs)) se comunicam diretamente com *Gateways* (GWs). Esses *gateways* são responsáveis por receber as transmissões dos dispositivos e encaminhá-las para Servidor de redes (NSs), que, por sua vez, autenticam, processam e direcionam as mensagens

aos Servidor de aplicações (ASs), geralmente por meio de infraestrutura IP (Jouhari *et al.*, 2023; Milarokostas *et al.*, 2023).

Esse modelo modular permite escalabilidade e robustez, sendo amplamente adotado em aplicações de IoT que demandam comunicação a longa distância com infraestrutura reduzida. A Figura 5 apresenta o fluxo típico da arquitetura LoRaWAN, desde os sensores de campo até a aplicação final, passando por gateways e servidores intermediários.

Figura 5 – Fluxo típico de dados em uma arquitetura LoRaWAN, desde o dispositivo sensor até a aplicação.



Fonte: (The Things Network, 2024).

A comunicação entre EDs e GWs adota um modelo assíncrono baseado no protocolo ALOHA, o que simplifica a transmissão dos dados sem a necessidade de coordenação prévia. Isso, aliado ao uso de múltiplos canais e à ortogonalidade entre fatores de espalhamento (SF), permite que múltiplas transmissões simultâneas sejam recebidas por um mesmo *gateway*, promovendo larga escalabilidade (Milarokostas *et al.*, 2023).

A LoRaWAN também incorpora mecanismos de segurança que asseguram a integridade e a confidencialidade das comunicações, como a utilização de criptografia AES-128 com chaves distintas para rede e aplicação (Liya; Aswathy, 2020; Tsai *et al.*, 2019). Embora esses recursos não sejam o foco desta seção, sua importância para a confiabilidade da arquitetura é amplamente reconhecida.

Em experimentos práticos, (Zourmand *et al.*, 2019) demonstraram que a configuração adequada de parâmetros como SF e BW permite alcançar cobertura satisfatória mesmo em ambientes internos com obstáculos físicos, como prédios universitários. Isso reforça a viabilidade

da LoRaWAN como solução de baixo custo e ampla cobertura para redes IoT distribuídas.

Dessa forma, a arquitetura LoRaWAN combina simplicidade estrutural com flexibilidade de implementação, oferecendo uma base sólida para aplicações em áreas como agricultura de precisão, monitoramento ambiental e saneamento inteligente.

2.4 Plataforma FIWARE

O avanço da IoT impulsionou o surgimento de plataformas voltadas à integração entre o mundo físico e o digital (Rodriguez *et al.*, 2018). Nesse cenário, a plataforma FIWARE se destaca como uma iniciativa de código aberto, gerida pela *FIWARE Foundation*, que provê um *framework* de componentes para acelerar o desenvolvimento de soluções inteligentes em diversos setores (Guth *et al.*, 2016). O objetivo central da iniciativa é estabelecer um padrão de fato para a gestão de dados de contexto, garantindo que as aplicações sejam portáteis e interoperáveis entre diferentes domínios, como cidades, indústria e agronegócio (FIWARE Foundation, 2025).

Originalmente concebido em ambiente de pesquisa, o FIWARE evoluiu para uma plataforma robusta, sendo amplamente adotada em projetos comerciais e de larga escala, como *SynchroniCity*, *Autopilot* e *IoF2020* (Cirillo *et al.*, 2020). Sua arquitetura modular, baseada no conceito de Habilitadores Genéricos (*Generic Enablers*) (GE), oferece um conjunto de funcionalidades reutilizáveis para gerenciamento de contexto, ingestão de dados de dispositivos IoT, segurança e visualização. No contexto do FIWARE, um GE representa um componente de plataforma open-source que implementa uma funcionalidade bem definida e que pode ser combinado com outros GEs para construir aplicações inteligentes de forma rápida e escalável (FIWARE Foundation, 2025).

O FIWARE é estruturado em módulos independentes agrupados por função, permitindo que os desenvolvedores selecionem apenas os componentes relevantes para cada aplicação (Rodriguez *et al.*, 2018). Os GEs disponibilizam APIs públicas, com código aberto, promovendo interoperabilidade e baixo custo de entrada (López-Riquelme *et al.*, 2017).

- **Gerenciamento de Contexto:** centralizado no *Orion Context Broker*, responsável por gerenciar, atualizar e disseminar informações de contexto em tempo real usando o padrão *Next Generation Service Interfaces* (NGSI). Ele atua como núcleo da plataforma, conectando sensores, aplicações e módulos analíticos com alta escalabilidade e baixa latência (Cirillo *et al.*, 2020).
- **Integração com Dispositivos (IoT):** feita por meio dos *IoT Agents*, que traduzem proto-


colos de sensores para o padrão NGSI (Torrepadula *et al.*, 2025). No presente trabalho, por exemplo, as mensagens recebidas via *TTN* não seguem diretamente o padrão NGSI, exigindo a utilização de um *IoT Agent* intermediário para realizar a tradução e garantir a compatibilidade com o FIWARE.

- **Visualização:** por meio de ferramentas integradas a plataformas externas, permitindo a criação de interfaces e *dashboards* personalizados para aplicações inteligentes (Rodriguez *et al.*, 2018).
- **Segurança:** garantida pelo *KeyRock*, responsável por autenticação, autorização e gestão de identidade com suporte a OAuth2 (FIWARE Keyrock, 2025).

A interoperabilidade no FIWARE é garantida pelo uso do padrão NGSI-LD, uma evolução do NGSI baseada em JSON-LD (*JavaScript Object Notation for Linked Data*). O uso do NGSI permite padronizar as mensagens. Como resultado, diferentes sistemas, mesmo desenvolvidos por provedores distintos ou com finalidades diversas, podem interpretar os dados de maneira consistente (Cirillo *et al.*, 2020).

A Figura 6 ilustra uma arquitetura simplificada baseada no FIWARE, com destaque para os principais componentes envolvidos no fluxo de dados: os sensores IoT se comunicam com o *IoT Agent*, que converte as mensagens para o padrão NGSI e as encaminha ao *Orion Context Broker*. Os dados de contexto podem ser armazenados em série temporal por meio do *QuantumLeap*, que os persiste em um banco como o *CrateDB*, viabilizando sua utilização por aplicações *front-end* e *back-end*.

Figura 6 – Exemplo de arquitetura simplificada com FIWARE



Fonte: Elaborada pelo autor.

A flexibilidade e modularidade do FIWARE o tornam aplicável a diversos domínios, permitindo sua adoção tanto em ambientes urbanos quanto rurais, industriais ou residenciais. Essa adaptabilidade decorre de sua arquitetura modularizada e do uso de padrões abertos, que facilitam a integração com sensores e atuadores. Diversas pesquisas têm investigado o uso do FIWARE em contextos variados, como cidades inteligentes, indústria 4.0, agricultura de precisão, gestão hídrica e saúde digital. Segundo o levantamento de (Rodriguez *et al.*, 2018), que analisou

a evolução e os principais casos de uso da plataforma, o FIWARE se destaca por seu ecossistema maduro, pela forte aderência a padrões abertos e por oferecer ferramentas completas para o gerenciamento de dados de contexto, segurança, interoperabilidade e visualização.

O FIWARE oferece uma alternativa robusta aos provedores de nuvem tradicionais ao disponibilizar uma infraestrutura aberta, extensível e segura, com foco em aplicações verticais (López-Riquelme *et al.*, 2017). A comunidade ativa garante inovação contínua, e o alinhamento com padrões internacionais favorece a adoção em larga escala.

“O FIWARE representa o padrão de fato para sistemas futuros.” (Celesti *et al.*, 2019), Traduzido pelo autor

Conforme discutido por (Celesti *et al.*, 2019), a principal vantagem do FIWARE está em sua arquitetura orientada a contexto, que desacopla dispositivos e aplicações por meio de um modelo padronizado e flexível. Essa abordagem permite construir ecossistemas digitais interoperáveis, promovendo reuso, escalabilidade e portabilidade em soluções IoT complexas.

No contexto deste projeto, a utilização do FIWARE como plataforma de integração foi motivada por essas características: modularidade, aderência a padrões e maturidade do ecossistema. A arquitetura proposta foi validada em ambiente experimental, demonstrando viabilidade técnica para aplicações em saneamento inteligente e servindo de base para expansões futuras com suporte a análise de dados, alertas e integração com sistemas de cidades inteligentes.

2.5 Consumo Energético em Sistemas Embarcados

O consumo energético é um dos principais desafios no desenvolvimento de sistemas embarcados voltados para aplicações de IoT, especialmente quando os dispositivos operam de forma autônoma por longos períodos e são alimentados por baterias (Gubbi *et al.*, 2013). A otimização energética influencia diretamente a vida útil dos dispositivos, os custos operacionais e a sustentabilidade de soluções em larga escala (Al-Fuqaha *et al.*, 2015).


Tecnologias de comunicação como o LoRa, que operam com baixas taxas de transmissão e longo alcance, destacam-se por sua eficiência energética. No contexto do protocolo LoRaWAN, essa eficiência é aprimorada por meio da definição de três classes operacionais (Liya; Aswathy, 2020):

- **Classe A:** modo padrão e mais econômico, no qual os dispositivos apenas recebem dados após uma transmissão. Ideal para sensores com eventos esporádicos.

- **Classe B:** acrescenta sincronização com *beacons* periódicos enviados pelos *gateways*, permitindo janelas de recepção agendadas. É indicada para aplicações com requisitos moderados de latência.
- **Classe C:** mantém a recepção aberta continuamente, exceto durante a transmissão, o que reduz a latência mas exige maior disponibilidade energética.

A escolha adequada da classe de operação é crucial para equilibrar desempenho e autonomia dos dispositivos, sendo um fator determinante em projetos de monitoramento remoto com restrições energéticas. A Figura 7, apresentada por (Cabral, 2019), mostra uma estrutura didática para organizar práticas de eficiência energética em IoT, considerando sensores, controladores e meios de comunicação.

Figura 7 – Técnicas de eficiência energética em IoT.



Fonte: (Cabral, 2019).

Além disso, o trabalho de (Cabral *et al.*, 2025b) mostrou que a escolha da pilha de software embarcada também afeta significativamente o consumo de energia. Em experimentos com o microcontrolador STM32F030C8T6, o uso de FreeRTOS, proporcionou melhor desempenho energético em comparação ao ambiente Arduino, devido à utilização mais eficiente de modos de baixo consumo e do escalonamento baseado em tarefas.

Essas evidências reforçam que a eficiência energética em sistemas embarcados depende da combinação de escolhas estratégicas no nível de hardware, software e protocolo de comunicação. Em aplicações como o monitoramento hídrico, essas decisões são determinantes para a viabilidade técnica e operacional do sistema.

2.6 Técnicas de *Energy Harvesting* para IoT

Em aplicações de IoT, onde os dispositivos precisam operar por longos períodos sem manutenção direta, o uso de técnicas de *energy harvesting* tem ganhado destaque como

alternativa viável ao uso exclusivo de baterias (Zhang *et al.*, 2020; Khernane *et al.*, 2024). O termo refere-se à capacidade de extrair pequenas quantidades de energia do ambiente, como luz, calor, vibração ou ondas de rádio para alimentar sensores, microcontroladores e módulos de comunicação (Priya; Inman, 2009). As principais fontes de energia ambiental utilizadas em sistemas de *harvesting* para IoT incluem:

- **Energia solar:** captada por células fotovoltaicas, é uma das fontes mais comuns e eficientes, especialmente em ambientes externos (Priya; Inman, 2009).
- **Energia térmica:** aproveita diferenças de temperatura por meio de geradores termoeletrônicos (TEGs), ideal em ambientes com variações térmicas constantes (Priya; Inman, 2009).
- **Energia vibracional ou mecânica:** utiliza transdutores piezoelétricos ou eletromagnéticos para converter vibrações em eletricidade, como explorado em microturbinas hidráulicas (Mohamed *et al.*, 2011).
- **Energia de radiofrequência (RF):** captura energia de sinais Wi-Fi, rádio ou celular presentes no ambiente, sendo especialmente útil em aplicações de ultra baixo consumo (Eidaks *et al.*, 2019).

Para que a energia captada possa ser aproveitada eficientemente, é essencial a presença de circuitos de gerenciamento de potência. Chips como o BQ25504, capazes de operar com tensões de entrada extremamente baixas (até 80 mV após a inicialização), permitem que mesmo fontes com energia residual consigam alimentar sensores autônomos (Zhang *et al.*, 2020).

A eficiência do processo de conversão depende tanto do tipo de fonte quanto das características elétricas dos circuitos envolvidos. Estudos demonstraram que o desempenho de conversores RF-DC é altamente sensível ao formato do sinal de entrada. Por exemplo, sinais de múltiplos tons com alta razão pico-médio (PAPR) apresentam melhor eficiência em determinadas faixas de resistência de carga (Eidaks *et al.*, 2019). A escolha da forma de onda e o ajuste do ponto de operação do conversor (por meio de técnicas como MPPT — *Maximum Power Point Tracking*) são determinantes para maximizar a energia capturada (Khernane *et al.*, 2024).

Outros trabalhos, como o de (Zhang *et al.*, 2020), reforçam que a integração entre sensores de baixo consumo, supercapacitores e conversores *boost* baseados em MPPT permite criar nós IoT autônomos capazes de operar mesmo em cenários com fornecimento energético flutuante. Essa arquitetura garante estabilidade na tensão de alimentação e minimiza a necessidade de intervenções humanas.

Além disso, a aplicação de técnicas de *energy harvesting* em ambientes com fluxo contínuo, como redes hidráulicas, tem sido explorada por meio de turbinas microgeradoras, conforme demonstrado em (Mohamed *et al.*, 2011), representando uma alternativa sustentável para sistemas embarcados distribuídos em redes de abastecimento de água. Neste trabalho, um microgerador hidráulico é utilizado, sendo acoplado à tubulação como fonte de energia para alimentar o sistema, viabilizando a operação contínua e autossuficiente do dispositivo em campo.

Dessa forma, a combinação entre *energy harvesting* hidráulico e estratégias de consumo ultrabaixo torna possível o desenvolvimento de dispositivos IoT verdadeiramente autônomos e sustentáveis, especialmente quando aliados a tecnologias como LoRaWAN e microcontroladores otimizados para operação em modos de baixíssimo consumo.

2.7 Detecção de Anomalias e Aprendizado de Máquina Não Supervisionado

A *Machine Learning* (ML), ou aprendizado de máquina, é uma subárea da Inteligência Artificial dedicada à criação de algoritmos capazes de extrair padrões a partir de dados, ajustando seu comportamento para realizar tarefas específicas sem intervenção humana direta (Monard; Baranauskas, 2003). As abordagens de ML dividem-se principalmente em duas categorias: supervisionado e não supervisionado, conforme a disponibilidade de rótulos nos dados utilizados durante o treinamento (Ludermir, 2021).

No aprendizado supervisionado, o modelo aprende a partir de exemplos rotulados, o que o torna eficiente em tarefas como classificação e regressão. No entanto, em muitos contextos, como na detecção de vazamentos em residências, não há um histórico confiável de eventos rotulados, o que inviabiliza essas abordagens. Nesses casos, métodos de aprendizado não supervisionado são preferíveis, pois buscam estruturar e compreender os dados com base em relações de similaridade ou desvios estatísticos (Hastie *et al.*, 2009).

Dentre os métodos não supervisionados, destacam-se as técnicas de detecção de anomalias, voltadas à identificação de padrões que se desviam significativamente do comportamento predominante (Chandola *et al.*, 2009). Essas técnicas são particularmente úteis em cenários com grande volume de dados gerados continuamente, como em aplicações de IoT.


Neste trabalho, foram explorados dois algoritmos amplamente utilizados: o *Isolation Forest* e o *Elliptic Envelope*. O *Isolation Forest*, proposto por (Liu *et al.*, 2008) e posteriormente estendido por (Hariri *et al.*, 2021), parte da premissa de que anomalias são mais fáceis de isolar devido à sua baixa frequência e distância dos demais dados. O algoritmo constrói múltiplas

árvores binárias de partição aleatória e utiliza a profundidade média de isolamento como medida de anomalia.

Já o *Elliptic Envelope* assume uma distribuição normal multivariada dos dados. Ele estima uma elipse de maior densidade, com base na matriz de covariância robusta e considera como anômalos os pontos fora dessa região (Pedregosa *et al.*, 2011). Embora seja mais sensível a ruídos e distribuições não gaussianas, é útil em conjuntos de dados com baixa variabilidade e padrão relativamente estável.

A Figura 8 ilustra, de forma conceitual, o funcionamento do Elliptic Envelope, mostrando os dados normais agrupados dentro de uma região elíptica e os outliers identificados fora dela.

Figura 8 – Exemplo gráfico do Elliptic Envelope.



Fonte: Adaptado de (Manorathna, 2021).

Esses métodos são particularmente adequados para dispositivos embarcados com restrições computacionais, pois não requerem pré-processamento com rótulos e apresentam complexidade reduzida. A utilização combinada com algoritmos como o DBSCAN permite o agrupamento de anomalias temporalmente próximas, com base na densidade dos pontos, facilitando a identificação de eventos reais, como vazamentos persistentes, e reduzindo falsos positivos (Cabral *et al.*, 2025a). Portanto, a detecção de anomalias por aprendizado não supervisionado é uma abordagem eficiente, escalável e compatível com os requisitos de aplicações IoT, sendo ideal para cenários como o monitoramento autônomo de consumo hídrico residencial.

2.8 Análise Espectral e a Short-Time Fourier Transform (STFT)

A análise espectral é amplamente utilizada para investigar padrões e comportamentos recorrentes em sinais temporais. Diferentemente das abordagens puramente temporais, que observam a evolução de um fenômeno apenas ao longo do tempo, a análise espectral permite compreender como a energia do sinal se distribui entre diferentes frequências, revelando componentes periódicos e harmônicos que podem indicar anomalias ou eventos de interesse (Oppenheim *et al.*, 2010; Cohen, 1995).

A STFT estende a transformada de Fourier clássica para o domínio tempo-frequência, permitindo analisar sinais não estacionários, isto é, sinais cujas características espectrais variam ao longo do tempo (Allen, 1977; Boashash, 2003). Por meio da aplicação de janelas deslizantes, a STFT fornece uma visão local da composição espectral do sinal, possibilitando observar como diferentes componentes de frequência evoluem ao longo da duração do registro.

Matematicamente, a STFT de um sinal discreto $x[n]$ é definida como:

$$X(m, \omega) = \sum_{n=-\infty}^{\infty} x[n] w[n-m] e^{-j\omega n} \quad (2.1)$$


em que $w[n]$ representa a janela de análise centrada em m , e ω é a frequência angular. Essa formulação calcula a transformada de Fourier local em torno de cada ponto do tempo, preservando simultaneamente a informação temporal e espectral do sinal (Cohen, 1995; Oppenheim *et al.*, 2010; Allen, 1977).

O módulo de $X(m, \omega)$ fornece o mapa de magnitude, e sua energia $|X(m, \omega)|^2$ é geralmente representada como um espectrograma, exibindo a densidade espectral de potência em função do tempo. Essa visualização facilita a identificação de variações harmônicas, fenômenos transitórios e padrões cíclicos que não são perceptíveis no domínio do tempo.

A STFT é amplamente empregada em aplicações de engenharia para a visualização e análise de sinais não estacionários, fornecendo informações simultâneas de amplitude, tempo e frequência (National Instruments Corporation, 2023). Essa representação bidimensional permite identificar fenômenos transitórios, oscilações periódicas e variações espectrais sutis em sinais complexos.

A Figura 9 apresenta um exemplo de sinal no domínio do tempo, cuja frequência varia gradualmente ao longo da amostra. Esse tipo de comportamento é típico de sistemas reais, nos quais o sinal não apresenta periodicidade constante.


Figura 9 – Sinal no domínio do tempo, evidenciando uma variação progressiva da frequência ao longo do tempo.



Fonte: (National Instruments Corporation, 2023).

Ao aplicar a STFT, nota-se que o espectro apresenta faixas de energia bem definidas em diferentes instantes, tornando evidente a variação de frequência que já é perceptível no domínio temporal, mas que, por meio da STFT, passa a ser representada de forma quantitativa e visualmente destacada no domínio tempo-frequência.

Figura 10 – Representação tempo-frequência obtida pela STFT. Observa-se que as componentes de frequência variam ao longo do tempo, conforme mostrado no espectrograma.



Fonte: (National Instruments Corporation, 2023).

A aplicação da STFT é recorrente em áreas como processamento de áudio, diagnóstico de falhas, reconhecimento de padrões e monitoramento de sistemas físicos (Boashash, 2003; Torrence; Compo, 1998). Em sistemas baseados em IoT, a técnica tem se mostrado eficaz para detectar anomalias em sinais de sensores, especialmente quando os dados apresentam ruído ou variações de baixa amplitude que dificultam a detecção por métodos puramente estatísticos (Xu

et al., 2023; Zhou *et al.*, 2023).

No contexto da detecção de vazamentos, a STFT pode ser empregada para identificar padrões periódicos e harmônicos de baixo fluxo, típicos de microvazamentos, que se manifestam como componentes persistentes no espectro mesmo quando o consumo aparente é estável no domínio temporal. Esses comportamentos cíclicos são particularmente desafiadores para algoritmos de aprendizado de máquina, pois tendem a ser confundidos com padrões normais de uso, especialmente em modelos não supervisionados baseados em distribuição estatística. A análise tempo-frequência, nesse sentido, complementa as abordagens de aprendizado de máquina ao evidenciar assinaturas espectrais consistentes que caracterizam o vazamento como evento recorrente e não aleatório.

Trabalhos recentes destacam o potencial da análise tempo-frequência na identificação de irregularidades em séries de sensores ambientais e sistemas residenciais inteligentes (Ahmad *et al.*, 2023).

Em síntese, a STFT constitui uma ferramenta robusta de análise tempo-frequência capaz de revelar padrões periódicos e comportamentos anômalos em sinais de sensores, sendo particularmente adequada para aplicações IoT que exigem a detecção de microvariações de consumo ou eventos de baixa magnitude, como microvazamentos em sistemas residenciais.

2.9 Métricas de Avaliação

Esta seção apresenta as métricas adotadas para a avaliação dos resultados obtidos nesta dissertação, abrangendo tanto o desempenho dos modelos de aprendizado de máquina utilizados na detecção de vazamentos quanto a análise de eficiência energética do protótipo IoT desenvolvido.

2.9.1 Métricas de Desempenho dos Modelos de Aprendizado de Máquina

As métricas empregadas para avaliar o desempenho dos modelos de classificação, particularmente na detecção de anomalias, são amplamente consolidadas na literatura de aprendizado de máquina e de mineração de dados (Han *et al.*, 2012). As principais métricas utilizadas são *precision*, *recall* e *F1-score*, formalmente definidas a partir da matriz de confusão:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2.2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2.3)$$

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.4)$$

Em que TP representa os verdadeiros positivos, FP os falsos positivos e FN os falsos negativos (Han *et al.*, 2012). Essas métricas foram utilizadas para avaliar o equilíbrio entre sensibilidade e precisão do modelo *Elliptic Envelope* aplicado à detecção de vazamentos.

A *Precision* (Precisão) indica a proporção de previsões corretas dentre todas as ocorrências classificadas como anomalias pelo modelo. Em outras palavras, mede o quanto das ocorrências classificadas pelo modelo como vazamentos são de fato vazamentos reais. Por exemplo, se o sistema identificar dez possíveis vazamentos em uma série temporal e apenas oito forem confirmados como verdadeiros, a precisão será de 80%. Essa métrica é especialmente útil para avaliar o número de falsos positivos (FP), isto é, situações em que o modelo sinaliza um vazamento inexistente (Han *et al.*, 2012).

O *Recall* (Revocação) mede a capacidade do modelo em identificar corretamente todas as anomalias que de fato ocorreram, sendo definido como a proporção de vazamentos reais que foram corretamente detectados. Em um exemplo prático, se ocorrerem dez vazamentos reais em um período de análise e o modelo identificar apenas oito, o *recall* será de 0,8, indicando que dois vazamentos não foram detectados. Essa métrica é particularmente importante em sistemas de monitoramento, nos quais deixar de detectar um vazamento pode implicar desperdício de água e custos adicionais (Han *et al.*, 2012).

Por fim, o *F1-score* representa a média harmônica entre *precision* e *recall*, oferecendo uma medida equilibrada de desempenho. Essa métrica é especialmente valiosa quando há necessidade de balancear a detecção de anomalias verdadeiras com a minimização de falsos alarmes, sendo recomendado para cenários de classes desbalanceadas ou em que os custos de FP e FN devem ser igualmente ponderados (Provost; Fawcett, 2013). No contexto desta dissertação, um alto *F1-score* indica que o modelo consegue detectar a maioria dos vazamentos sem gerar alertas indevidos, alcançando assim um bom compromisso entre sensibilidade e precisão.

Essas métricas são amplamente utilizadas na literatura de aprendizado de máquina e em aplicações de detecção de anomalias (Han *et al.*, 2012; Provost; Fawcett, 2013), sendo

essenciais para quantificar a eficácia do modelo aplicado à identificação de vazamentos em séries temporais de consumo hídrico.

2.9.2 Métricas de Eficiência Energética

A eficiência energética do nó IoT foi avaliada com base no consumo de energia em diferentes estados de operação, segundo a metodologia proposta em (Cabral *et al.*, 2025b). Para a medição, o sensor INA219 foi empregado como um amperímetro digital de alta precisão, responsável por capturar a corrente instantânea (I) consumida pelo circuito. A tensão de alimentação (V) foi mantida constante em 3,7 V, permitindo o cálculo da potência elétrica (P) consumida em cada estado. A potência instantânea é dada pela relação da lei de Ohm:

$$P = V \times I \quad (2.5)$$

Como os dados de potência são capturados em intervalos de tempo discretos, a energia total consumida é determinada pelo somatório da potência medida em cada amostra. O foco na gestão de energia em diferentes estados é um princípio fundamental no projeto de sistemas sem fio e de baixa potência (Benini *et al.*, 2000).

Para fins de análise comparativa do consumo de energia para cada implementação (Arduino, FreeRTOS e bare-metal), foram consideradas métricas estatísticas essenciais, conforme consolidado na literatura (Montgomery; Runger, 2010; Triola, 1992; Cabral *et al.*, 2025b):

- **Média:** fornece uma visão geral do comportamento energético, refletindo o consumo médio observado ao longo do ciclo de operação (Montgomery; Runger, 2010).
- **Mediana:** representa o valor central da distribuição dos dados, sendo útil em situações de assimetria, nas quais valores extremos de pico ou modo *stop* poderiam distorcer a média (Triola, 1992).
- **Moda:** foi utilizada para identificar o valor de consumo de energia mais frequente durante os ciclos de operação.
- **Desvio-padrão:** mensura a dispersão dos dados em torno da média, permitindo avaliar a estabilidade e a consistência energética do sistema (Montgomery; Runger, 2010). Uma menor dispersão indica que o modelo de consumo de energia é mais previsível e estável.

3 TRABALHOS RELACIONADOS

Devido à crise hídrica e à escassez de água potável, a detecção de vazamentos de água tem se destacado na literatura científica, impulsionada pela necessidade crescente de soluções eficientes e sustentáveis para o gerenciamento de recursos hídricos. Neste capítulo, são revisados trabalhos relevantes que utilizam técnicas de inteligência artificial, aprendizado de máquina e Internet das Coisas aplicadas à detecção de vazamentos. O objetivo é contextualizar o estado da arte da área, identificar lacunas e destacar os principais diferenciais da proposta deste trabalho.

Diversos autores têm explorado abordagens distintas que combinam sensores, redes de comunicação e algoritmos inteligentes para resolver esse problema. Um exemplo é o trabalho de (Guezouli *et al.*, 2024), que propõe uma arquitetura denominada QoW-Pro, integrando sensores IoT e algoritmos de aprendizado supervisionado (*Random Forest*) para monitoramento da qualidade da água e detecção de vazamentos. O sistema, testado em ambiente residencial, mostra-se escalável, mas depende de dados rotulados, o que pode comprometer sua viabilidade em larga escala. Não há menção à sustentabilidade energética ou autonomia operacional dos dispositivos utilizados.

(Kulikovas; Packevičius, 2023) investigam abordagens não supervisionadas e semi-supervisionadas aplicadas à detecção de anomalias no consumo de água. São avaliados algoritmos como *Isolation Forest*, PCA e SSDO, utilizando dois conjuntos de dados reais: o *dataset* DAIAD¹, com dados horários de 92 residências, e um segundo conjunto com registros da residência de um dos autores. Como os dados não possuem rótulos de vazamento, os autores inserem artificialmente eventos anômalos para viabilizar a avaliação dos modelos com métricas supervisionadas. O estudo não apresenta protótipo físico nem considera aspectos de consumo energético.

(Selvaprasanth *et al.*, 2025) propõe uma abordagem supervisionada baseada em redes neurais recorrentes com mecanismo de atenção (*LSTM-Attention*), alimentadas por sensores físicos de pressão e vazão conectados a um NodeMCU. A solução apresenta resultados promissores em cenários simulados, porém a necessidade de rotulagem e o custo de implementação limitam sua aplicabilidade em ambientes reais e heterogêneos. O uso de microcontroladores como o NodeMCU implica em um consumo energético considerável, tornando o sistema pouco adequado para aplicações autônomas de longa duração.

(Mauro *et al.*, 2019) desenvolvem uma plataforma IoT de baixo custo para medição

¹ *Dataset* DAID

do consumo hídrico em pontos finais de uso residencial, como torneiras e chuveiros. O sistema utiliza sensores de fluxo conectados a microcontroladores ESP32 e envia os dados, com resolução de até 1 segundo, para a plataforma EmonCMS. Embora o foco esteja mais voltado para o monitoramento detalhado do uso final da água, o estudo contribui com dados de alta granularidade aplicáveis à detecção de vazamentos. A proposta não contempla autonomia energética nem uso em larga escala com baixa manutenção.

(Badar *et al.*, 2023) constroem uma infraestrutura de teste em escala real para avaliação de algoritmos de detecção de vazamentos em dutos de transmissão, utilizando sensores de vazão e pressão integrados a uma arquitetura IoT baseada em SCADA, RTU e conexão via Modbus. Foram testados os algoritmos *Isolation Forest*, SVM e RNN-LSTM. O modelo supervisionado SVM apresentou o melhor desempenho com *F1-score* de 92,3%, mas a solução é dependente de infraestrutura complexa, elevado consumo energético e não é adequada para aplicações autônomas em campo.

(Predescu *et al.*, 2018) propõem uma abordagem híbrida entre modelagem hidráulica e aprendizado de máquina. O sistema compara medições reais com previsões de um modelo dinâmico e utiliza clusterização para identificar padrões de vazamento. A solução é aplicada a dados reais coletados por hidrômetros inteligentes na Itália e se destaca pela capacidade de adaptação a diferentes perfis de consumo. Embora o sistema utilize dados provenientes de dispositivos IoT, não há descrição de protótipo físico próprio nem de aspectos relacionados ao consumo energético.

(Thenmozhi *et al.*, 2021) apresentam uma arquitetura IoT com sensores de pressão e fluxo acoplados a microcontroladores de baixo custo, aplicando aprendizado supervisionado para detecção de vazamentos. Apesar de resultados positivos, o sistema é validado apenas por simulação e não considera sustentabilidade energética, sendo pouco viável em implantações remotas ou com restrições de energia.

O sensor AquaPing, desenvolvido pela MicroPhonon, é um dispositivo acústico de código aberto e baixo consumo projetado para identificar vazamentos em tubulações pressurizadas sem contato direto com a rede hidráulica (MicroPhonon, 2022). O sistema utiliza a Transformada Rápida de Fourier (FFT) para análise espectral, permitindo detectar componentes de frequência que exibem padrões cíclicos, de forma semelhante à metodologia espectral empregada neste trabalho. No entanto, embora essa abordagem acústica seja eficiente para captar assinaturas audíveis de vazamentos, sua sensibilidade tende a diminuir em cenários de

baixa pressão ou microvazamentos silenciosos, nos quais as emissões sonoras são mínimas ou inexistentes. Diferentemente, a metodologia proposta nesta dissertação analisa variações do sinal de consumo diretamente na fonte de medição, possibilitando a identificação de periodicidades sutis mesmo quando não há emissão sonora perceptível.

Diferentemente das abordagens anteriores, este trabalho propõe um sistema completo de coleta, transmissão e análise de dados utilizando aprendizado não supervisionado. A principal vantagem reside na independência de dados rotulados, o que favorece a escalabilidade e a adaptação a diferentes padrões de consumo. Além da detecção de vazamentos convencionais, o sistema introduz uma metodologia de análise espectral capaz de identificar microvazamentos, eventos de baixa magnitude e difícil percepção a partir da STFT. Essa abordagem permite detectar padrões periódicos sutis no consumo, mesmo quando o volume de água perdido é mínimo e não perceptível visualmente, representando um avanço significativo em relação aos métodos tradicionais baseados apenas em séries temporais.

O sistema é composto por um sensor de consumo hídrico baseado no microcontrolador STM32L0 e comunicação LoRaWAN, operando com baixíssimo consumo energético. O consumo médio estimado é inferior a 1 mW, permitindo operação autônoma com painéis solares compactos ou microgeradores hidráulicos, viabilizando aplicações em regiões remotas e com mínima necessidade de manutenção, principalmente de bateria.

A Tabela 1 resume os principais aspectos comparativos entre os trabalhos discutidos e a proposta desenvolvida neste estudo.

Tabela 1 – Comparação entre trabalhos relacionados

Trabalho	Tipo de Aprendizado	Protótipo IoT	Autonomia
(Guezouli <i>et al.</i> , 2024)	Supervisionado	Sim	Não considerado
(Kulikovas; Packevičius, 2023)	Não/semi-supervisionado	Não	Não considerado
(Selvapraakash <i>et al.</i> , 2025)	Supervisionado	Sim	Não
(Mauro <i>et al.</i> , 2019)	IoT sem detecção	Sim	Não
(Badar <i>et al.</i> , 2023)	Sup. e Não sup.	Sim	Não
(Predescu <i>et al.</i> , 2018)	Híbrido (modelo+ML)	Parcial (dados reais)	Não
Este trabalho	Não supervisionado	Sim	Sim

Fonte: Elaborado pelo autor.


4 METODOLOGIA

Este capítulo apresenta a metodologia adotada para o desenvolvimento, integração e validação do sistema IoT proposto para a detecção de vazamentos e microvazamentos de água em ambientes residenciais. O sistema foi concebido de forma modular e escalável, integrando camadas de hardware, comunicação, processamento e análise de dados.

O objetivo final é propor e fundamentar uma arquitetura IoT integrada para a detecção de vazamentos e microvazamentos em ambientes residenciais, combinando baixo consumo energético, comunicação de longo alcance e análise inteligente de dados em nuvem. A contribuição científica deste trabalho está presente na implementação de um protótipo energeticamente otimizado e na integração de um ecossistema FIWARE completo, capaz de operar de forma autônoma e detectar padrões anômalos de consumo. O sistema desenvolvido estabelece uma base experimental e metodológica sólida para futuras pesquisas em gestão inteligente de recursos hídricos, computação em borda e sistemas ciberfísicos sustentáveis.

A Figura 11 apresenta o ecossistema IoT desenvolvido neste trabalho, composto por cinco camadas interdependentes que atuam de forma contínua: o protótipo IoT, responsável pela medição e transmissão dos pulsos de consumo; o gateway e a rede *TTN* que viabilizam a comunicação de longo alcance; a infraestrutura FIWARE em nuvem para gestão e persistência dos dados; a camada de API e visualização, desenvolvida em FastAPI; e a camada analítica, que aplica modelos de aprendizado de máquina para detecção de vazamentos e análise espectral para microvazamentos. Cada uma dessas etapas é detalhada nas seções a seguir.

Figura 11 – Ecossistema IoT proposto para monitoramento e detecção de vazamentos, integrando hardware, rede LoRaWAN, FIWARE, FastAPI e análise inteligente.




Fonte: Elaborado pelo autor.

4.1 Protótipo do sistema

O protótipo do sistema foi implementado em uma única placa de circuito impresso, projetada para operação em campo com foco em compacidade e eficiência energética. A Figura 12 mostra o protótipo final do sistema.

Figura 12 – Placa do protótipo: vista superior e inferior.



Fonte: Elaborada pelo autor.

Cada bloco funcional foi cuidadosamente dimensionado para minimizar o consumo de energia, garantir a estabilidade operacional e permitir a comunicação sem fio com redes LoRaWAN. O tamanho da placa também foi projetado com atenção, utilizando componentes SMD com dimensões reduzidas sempre que possível, resultando em um formato compacto de aproximadamente 2,7 cm × 2,9 cm.

O custo total estimado de fabricação do nó IoT foi de aproximadamente US\$ 14,42, considerando todos os componentes eletrônicos, conectores e a fabricação da placa de circuito impresso. O detalhamento completo dos custos unitários e quantidades encontra-se no Apêndice C, que apresenta a lista de materiais utilizada no protótipo.

4.1.1 Gerenciamento de energia

O protótipo é equipado com um circuito de gerenciamento energético baseado no componente BQ25504, responsável pela captação e armazenamento de energia proveniente de fontes de energia renováveis (*energy harvesting*). A energia é armazenada em uma bateria de íon-lítio (LiPo).

Os limiares de operação do circuito são definidos para proteger a bateria contra sobrecarga e descarga profunda. A Tabela 2 apresenta os principais valores configurados, que

determinam o comportamento do sistema nos diferentes estados de carga. Essa configuração garante a operação contínua do dispositivo, alternando automaticamente entre os modos de operação normal, economia de energia e suspensão, além de indicar ao microcontrolador o estado atual da bateria.

Tabela 2 – Limiar de tensão e comportamento energético do protótipo do sistema.

Pino / Função	Descrição	Tensão (V)
VBAT_OV	Interrompe carregamento (sobretensão)	4,125
VBAT_UV	Desativa saída (VSTOR) em subtensão	2,75
VBAT_OK_PROG	Indica nível baixo de bateria	3,125
VBAT_OK_HYST	Indica carga suficiente para retomada	3,3125

Fonte: Elaborada pelo autor.

Um pino de sinal digital (VBATOK), disponibilizado pelo BQ25504, informa ao microcontrolador se a tensão da bateria está dentro de uma faixa segura de operação. Essa informação é utilizada pelo firmware para decidir o modo de funcionamento, reduzindo a frequência de transmissão até que o nível de carga seja restabelecido. Além disso, o estado lógico desse pino é transmitido periodicamente junto aos dados de consumo hídrico via rede LoRaWAN, permitindo o monitoramento remoto do nível de bateria e contribuindo para a avaliação da autonomia energética do sistema em campo.

4.1.2 Processamento e firmware

O controle do sistema é realizado pelo microcontrolador STM32L031F6P6, baseado na arquitetura ARM Cortex-M0+, amplamente reconhecida por seu baixo consumo energético e pela disponibilidade de múltiplos modos de economia de energia (*Sleep*, *Stop* e *Standby*).

Durante a operação, o sistema permanece predominantemente no modo *Stop*, no qual o consumo de corrente é reduzido a níveis mínimos, mantendo apenas os periféricos essenciais em funcionamento. O microcontrolador é despertado apenas em três situações específicas, todas tratadas por meio de interrupções de hardware ou eventos de temporização.


1. Interrupção de GPIO — Pino Pulse: acionada a cada litro consumido, representando a leitura direta dos pulsos provenientes do hidrômetro. Cada evento incrementa uma variável de contagem de volume no firmware.
2. Interrupção de GPIO — Pino VBATOK: gerada pelo circuito BQ25504 quando há mudança no estado da bateria (normal ou baixa). Essa interrupção ajusta a frequência de transmissão,

alternando entre intervalos de uma e duas horas conforme o nível de carga, conforme ilustrado na Figura 13.

3. Interrupção de RTC (Tempo): configurada para ocorrer a cada minuto. O sistema utiliza essa interrupção para contabilizar o tempo decorrido e verificar se 60 minutos se passaram desde a última transmissão. Quando o intervalo é atingido, os dados de consumo e o estado da bateria são transmitidos via LoRaWAN; caso contrário, os valores são apenas armazenados em memória para envio futuro.

A Figura 13 apresenta o fluxograma geral de funcionamento do firmware, destacando as condições de ativação do microcontrolador e a hierarquia de prioridades entre as interrupções. Essa estrutura garante a execução eficiente das tarefas de medição e transmissão, otimizando o uso energético ao limitar o tempo ativo do sistema e priorizar os eventos mais críticos.

Figura 13 – Fluxograma do funcionamento do firmware, indicando as três interrupções principais que despertam o microcontrolador do modo *STOP*.



Fonte: Elaborado pelo autor.


4.1.3 Testes de Consumo Energético

Com o objetivo de avaliar a eficiência energética do protótipo e quantificar o impacto dos modos de operação no consumo de corrente, foram realizados testes experimentais de medição de potência em bancada, conforme metodologia semelhante à empregada por (Cabral *et al.*, 2025b).

O arranjo experimental é apresentado na Figura 14. O sistema foi alimentado por uma fonte de bancada DC ajustável, configurada para tensão nominal de 3,7 V, com monitoramento preciso da corrente fornecida ao circuito. Um módulo sensor INA219 foi utilizado para leitura

da corrente e da tensão em tempo real, permitindo calcular a potência instantânea consumida pelo protótipo. As medições foram realizadas em intervalos de 100 ms, registradas via interface serial e posteriormente processadas em ambiente Python para obtenção dos valores estatísticos em cada modo de operação.

Figura 14 – Montagem experimental para medição do consumo energético do protótipo.



fritzing

Fonte: Elaborado pelo autor.

Foram avaliados três modos principais de funcionamento:

1. **Modo ativo:** caracterizado pela execução de tarefas de processamento ou atualização de contadores;
2. **Modo de espera (Stop):** estado predominante de operação, no qual apenas os periféricos essenciais permanecem alimentados, aguardando interrupções externas;
3. **Transmissão de dados:** etapa de maior consumo energético, na qual o sistema utiliza o transceptor SX1262 para enviar as informações ao gateway LoRaWAN.

Durante os experimentos, foram realizadas múltiplas execuções para garantir reprodutibilidade estatística dos resultados. Para o ensaio energético, foi configurado um cenário

experimental controlado, em que o sistema simulou o registro de 100 pulsos de consumo ao longo de 20 minutos, realizando um envio por minuto via LoRaWAN. Esse arranjo foi adotado exclusivamente para fins de teste, de modo a acelerar a coleta de dados e caracterizar o comportamento energético do sistema sob diferentes condições de operação. No funcionamento real, o intervalo de transmissão segue o regime nominal de 60 minutos, com o microcontrolador permanecendo em modo *Stop* na maior parte do tempo e despertando apenas nas interrupções descritas na Figura 13. A metodologia adotada segue os princípios e procedimentos descritos em (Cabral *et al.*, 2025b), estudo prévio realizado como parte desta dissertação.

Diferentemente do estudo anterior, que avaliou implementações baseadas em *FreeRTOS* e no *framework* do Arduino, nesta dissertação foram desenvolvidas e analisadas duas abordagens de software executadas sobre o novo protótipo: uma versão utilizando o *framework* Arduino, e outra em modo *bare-metal*. Essa escolha teve como objetivo principal comparar o impacto energético entre um modelo de execução tradicional, baseado e uma implementação otimizada, orientada a interrupções e hibernação, ambas operando sob as mesmas condições experimentais e executando as mesmas tarefas.

No trabalho anterior, o sistema foi implementado em um protótipo composto pelo microcontrolador STM32F030C8T6 e pelo módulo RFM95W, que integra o transceptor SX1276. Esse módulo foi amplamente utilizado na literatura para experimentos com LoRaWAN, mas apresenta consumo significativamente maior em relação às novas gerações de dispositivos de ultra baixo consumo. A nova configuração apresentada na Figura 12 foi projetada especificamente para otimizar a eficiência energética, utilizando o chip sx1262, mantendo totalmente a compatibilidade com o protocolo LoRaWAN e operando de forma autônoma em ambientes de energia restrita.

Cabe ressaltar que o *FreeRTOS* não pôde ser utilizado no novo protótipo devido à limitação de memória do microcontrolador STM32L031F6P6, que dispõe de apenas 32 KB de *Flash*. A combinação da pilha LoRaWAN com as estruturas internas do sistema operacional, como filas, semáforos e tarefas excedeu a capacidade disponível, inviabilizando sua execução.

A abordagem utilizando *bare-metal*, substituiu o FreeRTOS na análise de consumo energético. Embora similar em termos de estrutura modular e uso de interrupções, o *bare-metal* não possui a camada de kernel responsável pelo agendamento de tarefas, gerenciamento de pilha e controle de contexto. A ausência dessa camada reduz significativamente a sobrecarga de processamento e de memória. Além de que o sistema proposto executa um conjunto reduzido de ações, como a contagem de pulsos, o monitoramento do nível de bateria e o envio periódico de

dados. Por não se tratar de um sistema crítico, não há necessidade de garantir o cumprimento de prazos rígidos (*deadlines*) ou de realizar a execução concorrente de múltiplas tarefas, o que torna desnecessário o uso de um sistema operacional de tempo real.

Adicionalmente, o FreeRTOS requer que a unidade de processamento permaneça ativa para o funcionamento adequado do agendador de tarefas e das filas internas, o que aumenta o tempo em modo ativo e, conseqüentemente, o consumo energético. Considerando que o novo protótipo dispõe de apenas 32 KB de memória *Flash*, a soma da pilha LoRaWAN com o FreeRTOS excedeu a capacidade de memória disponível, inviabilizando sua execução. Dessa forma, a adoção do *bare-metal* ao invés do *FreeRTOS* permitiu desenvolver um firmware mais enxuto, tanto em tamanho quanto em consumo de energia e totalmente otimizado para operar em longos períodos de hibernação, despertando apenas por interrupções externas ou eventos de temporização.

Essa abordagem mais direta de controle do hardware foi determinante para explorar plenamente os modos de baixo consumo do microcontrolador, especialmente o modo *Stop*, cuja eficiência energética é central para a operação autônoma do sistema. De acordo com o *datasheet* do STM32L031F6P6, a corrente típica nesse modo é da ordem de poucos microampères, podendo atingir valores inferiores a 1 μA , dependendo da configuração dos periféricos. Essa faixa de corrente encontra-se abaixo da resolução de medição do sensor INA219 e de outros amperímetros comerciais de precisão equivalente, o que impossibilita a mensuração direta desse estado de ultra baixo consumo. Assim, os valores apresentados para o modo *Stop* são estimados a partir das especificações do fabricante, servindo como referência para o cálculo da autonomia teórica do sistema.

Essas medições permitiram quantificar o impacto efetivo da estratégia de economia de energia implementada no firmware e fundamentar as estimativas de autonomia do sistema quando alimentado por bateria e assistido por *energy harvesting*.

4.1.4 Comunicação LoRa

A transmissão dos dados é realizada pelo transceptor SX1262, da Semtech, que opera na faixa de 915 MHz com modulação LoRa. O circuito de *Radio Frequency* (RF) foi desenvolvido com base nas recomendações oficiais do fabricante, garantindo impedância característica de 50 Ω , estabilidade de oscilador e adequada filtragem harmônica. A comunicação é configurada em modo *Adaptive Data Rate* (ADR), otimizando o consumo energético e a confiabilidade do

enlace LoRaWAN, de acordo com as condições do canal.

O gerenciamento da pilha LoRaWAN é realizado por meio da biblioteca LoRaMAC-in-C (LMIC), amplamente utilizada em implementações embarcadas. O dispositivo opera no modo *Activation by Personalization (ABP)*, no qual as chaves de autenticação são configuradas diretamente no firmware. Após cada transmissão, o nó aguarda a confirmação de recebimento enviada pela rede. Caso o pacote não seja confirmado, o firmware realiza até três tentativas de retransmissão, reduzindo a probabilidade de perda de dados devido a interferência ou atenuação de sinal.

Durante a execução, a biblioteca LMIC é temporariamente desativada quando o microcontrolador entra no modo *Stop*, de forma a reduzir o consumo energético. Entretanto, esse procedimento implica na perda das informações internas da pilha, incluindo o *frame counter*, contador responsável por garantir a unicidade de cada pacote transmitido. Para contornar essa limitação, foi implementado um mecanismo de persistência utilizando os registradores de backup do RTC, que permanecem alimentados mesmo durante o modo *Stop*. Dessa forma, o valor do contador é restaurado corretamente após o despertar do sistema, evitando que a rede LoRaWAN descarte o pacote por detecção de duplicidade.

Devido às restrições de memória do microcontrolador STM32L031F6P6, que dispõe de apenas 32 kB de *Flash*, foi necessário otimizar a biblioteca LMIC para adequá-la ao espaço disponível. As seções de código relacionadas a funcionalidades não utilizadas, como *ping slots*, *beacon tracking* e *join procedure*, foram removidas, preservando apenas os módulos essenciais à comunicação em modo *ABP*. Após essa reorganização, o firmware completo pôde ser compilado e armazenado integralmente na memória de programa, mantendo a estabilidade e a conformidade com o protocolo LoRaWAN.

Essas modificações permitiram conciliar o baixo consumo energético, a limitação de hardware e a integridade do protocolo de comunicação, assegurando o envio confiável dos dados de consumo e do estado da bateria à rede pública *TTN*.

4.2 Gateway LoRaWAN e Servidor de Rede LoRaWAN

Para viabilizar a recepção dos dados transmitidos pelo protótipo e seu encaminhamento à nuvem, foi implementado um gateway LoRaWAN baseado na combinação entre uma Raspberry Pi 4 e o módulo Elecrow LR1302. Essa configuração permite a recepção simultânea de múltiplos pacotes LoRa, operando na frequência de 915MHz com suporte a até 8 canais LoRa

físicos (Elecrow, 2025).

O concentrador LR1302 é baseado no chip Semtech SX1302, um componente amplamente utilizado em gateways LoRa comerciais por sua capacidade de operação contínua com baixo consumo e suporte a redes públicas como a *TTN*. A placa de expansão foi conectada via SPI à Raspberry Pi, usando uma placa intermediária que fornece energia separadamente e conecta corretamente os pinos de controle (*reset* e *enable*), conhecida como *Hardware Attached on Top (HAT)*. (Zwetsloot, 2024).

A Raspberry Pi 4 utilizada no projeto roda o sistema operacional Raspberry Pi OS Lite (64-bit). Para habilitar a comunicação com a rede LoRaWAN da *TTN*, foi instalado o software oficial (Gateway Stack V3), incluindo os componentes *ttn-lw-gateway-bridge* (responsável pela integração entre o hardware do gateway e a rede *TTN*) e o *packet-forwarder* (encarregado de encaminhar os pacotes LoRa entre os dispositivos e o servidor da rede) (Cumps, 2023). A Figura 15 ilustra o arranjo físico do gateway em bancada.

Figura 15 – Gateway LoRaWAN implementado com Raspberry Pi 4 e Elecrow LR1302.



Fonte: Elaborada pelo autor.

4.2.1 Servidor de rede LoRaWAN

A *TTN* foi utilizada como servidor de rede LoRaWAN responsável pelo roteamento dos pacotes transmitidos pelo protótipo. No painel da *TTN*, foi criado um *end-device* associado

ao projeto, no qual foram cadastradas as mesmas chaves de autenticação utilizadas no nó IoT, assegurando a comunicação correta no modo *ABP*.

Com a autenticação concluída, os pacotes enviados pelo dispositivo são recebidos pelo gateway e encaminhados automaticamente à *TTN*. Em seguida, ocorre o processo de decodificação do *payload*, no qual os bytes recebidos são convertidos em valores legíveis de consumo e status de bateria, conforme o código de decodificação apresentado no Apêndice B.

A Figura 16 apresenta um exemplo de pacote recebido na *TTN* após a decodificação do *payload*. O campo "minute_counts" contém o vetor de leituras acumuladas a cada minuto, representando o volume de água consumido no período.

Figura 16 – Exemplo de pacote recebido e decodificado na *TTN*, posteriormente encaminhado à infraestrutura FIWARE



Fonte: Elaborada pelo autor.


Após a decodificação, os dados são repassados para o ambiente em nuvem hospedado na *Amazon Web Services* (AWS), por meio de um *webhook* configurado na própria *TTN*. Esse mecanismo atua como um mensageiro automático, que envia as informações sempre que o nó transmite novos dados. O *webhook* realiza requisições HTTP POST diretamente ao serviço *fiware-connector*, responsável por receber, tratar e encaminhar as informações para o *Orion Context Broker* no ecossistema FIWARE, conforme descrito na Seção 4.3.

4.3 Integração com o Framework FIWARE

A infraestrutura em nuvem do sistema foi desenvolvida com base no framework FIWARE, implantada em uma máquina virtual hospedada na AWS e executada em contêineres Docker.

A Figura 17 apresenta uma visão geral da integração entre o servidor de rede *TTN*, o middleware, apelidado de *fiware-connector* e os principais GE utilizados neste trabalho. O fluxo de dados inicia-se com o envio do pacote LoRaWAN pelo dispositivo IoT, que é recebido pela *TTN* e repassado automaticamente ao *fiware-connector*. Este serviço, implementado em Python, utilizando o framework Flask atua como intermediário entre a rede LoRaWAN e a infraestrutura FIWARE, convertendo os dados para o formato NGSI-v2, requerido pelo Orion Context Broker. O Orion publica as atualizações de contexto para o QuantumLeap, que realiza a persistência das medições no banco de dados temporal CrateDB.

Figura 17 – Fluxo de integração entre nó IoT, *TTN*, *fiware-connector* e infraestrutura FIWARE na AWS.



Fonte: Elaborada pelo autor.

Os componentes que compõem essa arquitetura são descritos detalhadamente nas subseções a seguir, destacando suas funções, configurações e o papel de cada um no fluxo de processamento e armazenamento de dados do sistema proposto.

4.3.1 Orion Context Broker

O Orion Context Broker é o componente central da arquitetura FIWARE e o principal responsável pela gestão de contexto do sistema. Ele atua como ponto de entrada para todas as informações provenientes dos dispositivos IoT, armazenando e atualizando os dados conforme o modelo de entidade definido. Cada dispositivo é representado como uma entidade no formato

NGSI-v2, que organiza as informações em atributos e metadados contextuais (Cirillo *et al.*, 2020).

No sistema desenvolvido, foram definidos três atributos principais: `reading`, `measurementTime` e `vbatOkStatus`, que correspondem, respectivamente, ao vetor de 60 posições contendo os valores de consumo hídrico por minuto, ao instante de recebimento do pacote e ao estado atual da bateria reportado pelo nó IoT.

O Orion foi configurado para operar na porta 1026, em um contêiner dedicado, interligado aos demais GEs por meio de uma rede interna do Docker. As requisições de atualização são enviadas diretamente pelo serviço *fiware-connector*, que publica novas medições a cada evento de *uplink* proveniente da TTN. O Orion, por sua vez, notifica automaticamente os componentes inscritos, como o QuantumLeap, sempre que ocorre uma alteração de contexto, garantindo a atualização contínua das entidades registradas.

4.3.2 *QuantumLeap*

O componente QuantumLeap é responsável por converter as atualizações de contexto enviadas pelo Orion em séries temporais e armazená-las no banco de dados CrateDB (FIWARE Foundation, 2024). A cada nova leitura recebida, o QuantumLeap cria ou atualiza uma tabela correspondente à entidade do dispositivo, registrando o valor medido e o respectivo carimbo de tempo. Dessa forma, o histórico de consumo hídrico e os eventos de nível de bateria ficam disponíveis para análise posterior por meio de consultas diretas em SQL ou APIs REST.

4.3.3 *CrateDB*

O CrateDB é o banco de dados utilizado para armazenar as séries temporais geradas pelo QuantumLeap. Baseado em uma arquitetura distribuída e otimizada para grandes volumes de dados IoT, o CrateDB combina as vantagens do SQL tradicional com a escalabilidade de sistemas NoSQL (Crate.io GmbH, 2024).


No ambiente em nuvem, o contêiner do CrateDB foi configurado com persistência de dados em volume dedicado, garantindo a integridade das informações em caso de reinicialização do serviço. As tabelas criadas seguem a convenção de nomes padronizada pelo QuantumLeap, refletindo as entidades registradas no Orion Context Broker.

4.4 Aplicação

A camada de aplicação reúne os componentes responsáveis pelo processamento analítico e pela interface de visualização do sistema, permitindo o acesso, consulta e interpretação dos dados provenientes da infraestrutura FIWARE. Essa camada foi projetada de forma modular e independente do armazenamento de dados, de modo que seus serviços possam operar de forma distribuída, tanto em ambiente local quanto em nuvem. Essa abordagem favorece a escalabilidade, a manutenção e a integração com novos modelos de aprendizado de máquina ou interfaces de usuário.

A Figura 19 apresenta a arquitetura geral da aplicação, que conecta o *CrateDB* ao *backend* analítico e ao *frontend* de visualização. O fluxo de dados inicia com a leitura das séries temporais de consumo e status energético, processadas no *backend* e disponibilizadas via *API HTTP* ao painel web.

Figura 19 – Arquitetura geral da camada de aplicação.



Fonte: Elaborada pelo autor.

Nas subseções a seguir são apresentados os dois módulos que compõem essa camada: o *backend* analítico, desenvolvido em *FastAPI*, responsável pela coleta, análise e disponibilização dos dados; e o *frontend* web, que oferece ao usuário a visualização e o monitoramento dos dados.

4.4.1 Backend Analítico

O módulo analítico do sistema foi desenvolvido em Python utilizando o framework *FastAPI*, devido à sua leveza, suporte nativo a operações assíncronas e integração simplificada com aplicações de ciência de dados (Ramírez, 2025). Esse módulo opera como a camada

intermediária entre o banco de dados temporal CrateDB e o ambiente de visualização, oferecendo uma interface REST para consulta, inferência e análise inteligente de consumo hídrico.

A aplicação foi implantada em contêiner dedicado na infraestrutura hospedada na AWS e se comunica diretamente com o CrateDB por meio da biblioteca `psycopg2`¹. A biblioteca é utilizada pela compatibilidade nativa do CrateDB com o protocolo do PostgreSQL, o que possibilita a utilização das mesmas interfaces de conexão e comandos SQL sem necessidade de adaptações adicionais (Crate.io GmbH, 2025). Essa integração permite o acesso eficiente aos dados provenientes do QuantumLeap.

O *backend* integra duas abordagens complementares de análise voltadas à identificação de anomalias no consumo hídrico. A primeira, baseada no modelo não supervisionado *Elliptic Envelope*, é responsável pela detecção de vazamentos por meio da caracterização estatística de padrões de consumo anômalos, conforme proposto e validado em (Cabral *et al.*, 2025a). A segunda, fundamentada na análise espectral por meio da STFT, visa detectar microvazamentos contínuos e de baixa intensidade.

Essas análises são processadas de forma automatizada no servidor e seus resultados são disponibilizados por meio de uma interface REST desenvolvida em *FastAPI*. Por meio dessa interface, o sistema oferece rotas de acesso que permitem tanto a consulta dos dados de consumo quanto a execução remota dos algoritmos de inferência e treinamento. As principais rotas implementadas no *backend* são descritas a seguir:

- **/api/status:** apresenta o consumo total da última hora, o estado atual do modelo de detecção (normal, anômalo ou pendente de treinamento) e o status energético do dispositivo.
- **/api/inferences_min, /api/inferences_hour e /api/inferences_day:** retornam séries de consumo rotuladas com o resultado da detecção de anomalias em diferentes granularidades temporais.
- **/api/train:** executa o processo de treinamento do modelo *Elliptic Envelope*, salvando os parâmetros e escalonadores para uso subsequente.
- **/api/analyze_spectrogram:** realiza a análise espectral baseada em STFT sobre períodos de baixa demanda, retornando os resultados da detecção de microvazamentos.

Essa arquitetura mantém o núcleo analítico independente dos demais componentes da infraestrutura FIWARE, o que facilita a integração de novos modelos de aprendizado de máquina sem exigir alterações no fluxo de comunicação existente.

¹ Biblioteca oficial de integração do PostgreSQL ao Python

4.4.2 Frontend Web

O *frontend* do sistema é uma parte que fica visível ao usuário, foi desenvolvido como uma aplicação web responsiva e independente, voltada à visualização dos dados e à interação do usuário com o sistema de monitoramento. Essa camada é responsável por apresentar, de forma intuitiva, os resultados das análises executadas no *backend*, incluindo o histórico de consumo hídrico, alertas de vazamento e microvazamento, e o estado energético do dispositivo e histórico de inferências do modelo de aprendizado de máquina.

A aplicação foi construída utilizando as tecnologias *HTML5*, *CSS3* e *JavaScript*. O código foi desenvolvido para consumir os dados do *backend* de forma independente de sua implementação interna, exigindo apenas que as rotas *HTTP*, descritas na Seção 4.4.1 estejam disponíveis. Os dados retornam em formato JSON e são processados dinamicamente para atualização dos gráficos e indicadores do sistema.

A interface é organizada em quatro seções principais:


- **Status do sistema:** apresenta o estado atual do sistema, o consumo total da última hora e o nível da bateria.
- **Painel de microvazamentos:** exibe o resultado mais recente da análise espectral, permitindo configurar o período e a quantidade de dias analisados.
- **Gráficos de consumo:** mostram o consumo hídrico em minutos, horas e dias, com destaque para os pontos classificados como anômalos.
- **Log de inferências:** apresenta um histórico de alertas e anomalias detectadas, facilitando a análise de padrões recorrentes ao longo do tempo.

A Figura 20 ilustra o painel principal da aplicação web, que consolida em um único ambiente a visualização temporal, o status energético e as inferências realizadas pelos modelos de aprendizado de máquina.

O *frontend* também oferece mecanismos de interação direta com o sistema analítico, permitindo o acionamento manual do treinamento do modelo *Elliptic Envelope*, por meio do botão “*Retreinar Modelo ML*”, e a execução da análise espectral através do botão “*Executar Análise*”. Além disso, a aplicação foi projetada para se adaptar automaticamente a diferentes tamanhos de tela, assegurando que o sistema possa ser acessado e monitorado tanto em computadores de mesa quanto em dispositivos móveis, sem perda de funcionalidade ou legibilidade visual.

Encerradas as etapas de implementação e integração das camadas de hardware, comunicação, nuvem e aplicação, torna-se necessário estabelecer os critérios adotados para

Figura 20 – Interface principal do *frontend* web, com visualização temporal e alertas de anomalias.



Fonte: Elaborada pelo autor.

avaliar o desempenho global do sistema proposto. As métricas apresentadas a seguir definem os parâmetros quantitativos utilizados para validar tanto a eficiência energética e operacional do nó IoT quanto a precisão dos algoritmos de detecção empregados na camada analítica.

5 CAMADA ANALÍTICA

Com todas as camadas da arquitetura do sistema devidamente definidas, desde a aquisição de dados até a interface de visualização, este capítulo apresenta em detalhe a camada analítica, responsável por transformar os dados brutos de consumo hídrico em informações interpretáveis sobre o funcionamento do sistema hidráulico residencial.

Diferentemente de soluções convencionais de telemetria, que apenas coletam e exibem medições ao usuário, a camada analítica introduz inteligência ao sistema, aplicando modelos de aprendizado de máquina e análise espectral para interpretar o comportamento hidráulico. Essa camada constitui o núcleo cognitivo da arquitetura proposta, pois transforma medições brutas em informações contextuais úteis à tomada de decisão e à detecção precoce de anomalias.

Essa abordagem é especialmente relevante considerando a natureza dos diferentes tipos de vazamentos existentes. Conforme discutido na Seção 2.1.1, com base em (Lambert, 2001), os vazamentos podem ser classificados em três categorias: visíveis, não visíveis e inerentes. Os vazamentos visíveis são mais facilmente identificados, pois afloram à superfície e tendem a ser reportados rapidamente. Em contrapartida, os vazamentos não visíveis e os inerentes apresentam detecção mais complexa, podendo ocorrer em diferentes magnitudes e por longos períodos sem manifestação perceptível. São justamente esses tipos, sobretudo os inerentes, de pequeno volume e natureza contínua que a camada analítica proposta busca identificar de forma automatizada, integrando processamento estatístico e análise espectral para detectar padrões sutis de consumo anômalo.

Neste trabalho, os vazamentos são definidos como consumos anômalos persistentes e de maior magnitude, identificáveis por padrões estatísticos no domínio do tempo, enquanto os microvazamentos correspondem a fluxos residuais de baixa intensidade e caráter cíclico, detectáveis apenas por análise espectral. Essa distinção é fundamental para caracterizar o escopo do sistema proposto, que busca não apenas registrar o consumo, mas também identificar, de forma autônoma, diferentes categorias de perdas, desde vazamentos perceptíveis até microvazamentos sutis, fornecendo ao usuário e às concessionárias de água uma visão abrangente e inteligente do comportamento hídrico.


As subseções seguintes descrevem as abordagens utilizadas para identificar esses fenômenos: a análise estatística baseada em *Elliptic Envelope* e DBSCAN, aplicada à detecção de vazamentos, e a análise tempo-frequência via STFT, voltada à detecção de microvazamentos.

5.1 Detecção de Vazamentos por Aprendizado de Máquina

A detecção de vazamentos em sistemas residenciais de abastecimento é um desafio recorrente, especialmente quando se busca identificar padrões de consumo anômalos a partir de medições de baixo custo e alta variabilidade (Araújo, 2015). Vazamentos de maior magnitude, ainda que não visíveis, tendem a produzir alterações persistentes no perfil de consumo, manifestando-se como elevações sustentadas no volume registrado (TARDELLI FILHO, 2006).

Para lidar com esse cenário, o sistema proposto inclui uma abordagem de aprendizado não supervisionado, na qual o modelo não depende de rótulos previamente definidos que indiquem a ocorrência ou ausência de vazamentos durante o treinamento. Em vez disso, o algoritmo analisa o comportamento estatístico das séries temporais e identifica automaticamente pontos que divergem do padrão esperado. A Figura 21 apresenta um exemplo real com o *Elliptic Envelope*: os trechos em amarelo indicam instantes classificados como anômalos pelo modelo.

Figura 21 – Exemplo de execução do modelo Elliptic Envelope.



Fonte: Elaborado pelo autor.

Abordagens supervisionadas, como em (Mauro *et al.*, 2019; Guezouli *et al.*, 2024), exigem bases rotuladas e processos manuais de anotação, o que limita a escalabilidade, dado que cada residência possui um perfil de consumo próprio. Métodos não supervisionados, por sua vez, são adequados à detecção de padrões irregulares em dados ruidosos e desbalanceados, características típicas de medições reais de consumo hídrico (Liu *et al.*, 2008; Li, 2023). Contudo, como ilustra a Figura 21, parte das anomalias detectadas pode corresponder a consumos legítimos

(por exemplo, banhos ou lavagens). Assim, é necessário um segundo estágio que verifique a persistência temporal dessas anomalias para caracterizar um vazamento verdadeiro.


5.1.1 Agrupamento temporal de anomalias com DBSCAN

Mesmo com um classificador pontual eficaz (*Elliptic Envelope*), picos eventuais de consumo legítimo podem ser sinalizados como anomalias. Para diferenciar esses eventos de uso normal de um vazamento real, foi realizado um agrupamento temporal das anomalias usando o algoritmo *Density-Based Spatial Clustering of Applications with Noise* (DBSCAN). Esse algoritmo é um método de agrupamento baseado em densidade que mapeia as anomalias no eixo do tempo e forma aglomerados (*clusters*) quando ocorrem próximas entre si. Ele é robusto para a detecção de *outliers* (pontos fora da curva) e não exige que o número de grupos seja predefinido, sendo adequado para identificar anomalias em séries temporais. Dois parâmetros principais são necessários para a configuração do DBSCAN:

- **ϵ ou eps:** No contexto temporal, ϵ representa o intervalo máximo de tempo entre duas anomalias para que sejam consideradas vizinhas e, portanto, potencialmente pertençam ao mesmo aglomerado.
- **min_sample:** número mínimo de pontos dentro da vizinhança ϵ para que um evento seja considerado contínuo.

Em essência, o DBSCAN exige que a anomalia seja constante e persistente no tempo para que seja indicada como um vazamento real. Um conjunto de anomalias que ocorrem com uma frequência mínima (*min_sample*) dentro de um curto período de tempo (ϵ) é classificado como um *cluster*. Este *cluster* representa a persistência temporal do consumo anômalo, caracterizando um vazamento real. Por outro lado, um pico isolado de consumo legítimo que foi classificado como anomalia, como um banho ou rega de plantas será rotulado pelo DBSCAN como ruído, pois o consumo retorna ao normal após o evento, e não haverá vizinhos suficientes dentro de ϵ para formar um *cluster* contínuo. A Figura 22 mostra o mesmo trecho da Figura 21, mas com um vazamento simulado contínuo de 10 litros no fim dos dados. O DBSCAN foi capaz de verificar que a primeira anomalia (trecho em amarelo) foi anômalo, mas logo retornou ao consumo normal, enquanto o trecho em vermelho foi anômalo e persistente.

Figura 22 – Elliptic Envelope com DBSCAN.



Fonte: Elaborado pelo autor.

5.1.2 Hiperparâmetros

O desempenho de qualquer sistema baseado em aprendizado de máquina é ligado à correta configuração de seus hiperparâmetros, que são as configurações dos modelos (Bergstra; Bengio, 2012). No contexto deste trabalho, a escolha dos parâmetros do *Elliptic Envelope* e DBSCAN é crítica para balancear a sensibilidade na detecção de anomalias pontuais e a precisão na identificação de eventos persistentes.

A Tabela 3 resume os valores finais dos hiperparâmetros selecionados, cuja justificativa é detalhada a seguir.

Tabela 3 – Valores dos hiperparâmetros utilizados.

Algoritmo	Parâmetro	Valor
<i>Elliptic Envelope</i>	contamination	0,007
DBSCAN	ϵ (eps)	60 min
DBSCAN	<i>min_samples</i>	30

Fonte: Elaborada pelo autor.

O hiperparâmetro principal do *Elliptic Envelope* é o *contamination*, que define a proporção esperada de anomalias na base de dados de treinamento. Um valor baixo torna o modelo mais conservador na identificação de anomalias. Após análise exploratória e validação rigorosa em estudos prévios (Cabral *et al.*, 2025a), o valor foi definido em 0,007, ou seja, 0,7% dos pontos estão fora da elipse e serão considerados anômalos. Este valor foi escolhido

para minimizar falsos positivos na primeira etapa, focando apenas nas anomalias mais severas, permitindo que o estágio subsequente do DBSCAN se concentre em eventos de longa duração. Os valores de ε e *min_sample* foram escolhidos para manter a robustez e precisão na detecção.

- ε : O parâmetro ε foi definido como 60 minutos. Esse valor foi escolhido com base na frequência de amostragem do sistema, uma leitura por minuto e no comportamento típico de vazamentos residenciais, que tendem a apresentar fluxo contínuo de longa duração. Além disso, o uso de uma janela de uma hora garante que pequenas variações temporais decorrentes de latência na coleta, pequenas falhas de comunicação ou atrasos de registro não fragmentem um mesmo evento em múltiplos grupos distintos, preservando assim a coerência do agrupamento temporal.
- *min_samples*: O parâmetro *min_samples* foi configurado como 30, representando o número mínimo de anomalias necessárias dentro da janela ε para que um evento seja classificado como vazamento persistente. Esse valor foi escolhido de forma a exigir que o comportamento anômalo se mantenha por pelo menos metade da janela temporal, ou seja, 30 minutos consecutivos, o que reduz a sensibilidade a picos pontuais de consumo legítimo e aumenta a precisão na detecção de vazamentos reais.

Os hiperparâmetros apresentados são totalmente configuráveis no sistema, permitindo ajustes dinâmicos conforme o perfil de consumo e o comportamento hidráulico de cada residência monitorada. Essa flexibilidade é essencial para garantir a adaptabilidade do modelo em diferentes contextos residenciais, uma vez que fatores como número de moradores, hábitos de uso e pressões na rede podem alterar significativamente o padrão de consumo e a manifestação de anomalias. Os valores padrão adotados foram definidos com base nos resultados obtidos em (Cabral *et al.*, 2025a), em que o mesmo conjunto de hiperparâmetros apresentou equilíbrio entre precisão e robustez, reduzindo falsos positivos sem comprometer a detecção de eventos reais. Dessa forma, além de assegurar coerência metodológica com estudos anteriores, o presente trabalho mantém a possibilidade de reconfiguração desses parâmetros em tempo de execução, permitindo que o usuário ajuste a sensibilidade do sistema conforme o ambiente e o comportamento hidráulico observado.


5.2 Detecção de Microvazamentos por Análise espectral

Além da detecção de vazamentos por meio de algoritmos de aprendizado de máquina, este trabalho também aborda a identificação de microvazamentos, um tipo de ocorrência mais

sutil e de difícil detecção. Conforme (Lambert, 2001) e descrito na Seção 2.1.1, diferentemente dos vazamentos de maior magnitude que geram elevações perceptíveis no volume registrado, os microvazamentos se manifestam como oscilações periódicas de baixa intensidade, muitas vezes confundidas com ruído de medição ou pequenas flutuações naturais do sistema hidráulico.

A Figura 23 mostra um recorte dos dados durante a madrugada, onde um consumo de 6 Litros foi detectado em um período de aproximadamente duas horas. Durante esse período, porém não houve nenhum consumo real dos moradores da residencia. Esse comportamento cíclico, na ausencia de consumo real caracteriza a ocorrência de um microvazamento e se dá pela granularidade do hidrometro, que emite um pulso a cada um litro de água, ou seja, enquanto o sensor não detectar exatamente um litros de água, o pulso não será emitido, não sendo possivel verificar por exemplo quantos mililitros passaram pelo hidrometro entre um periodo.


Figura 23 – Exemplo de microvazamento no gráfico.



Fonte: Elaborado pelo autor.

Quando há um microvazamento com uma pequena magnitude, o comportamento tende a ter um padrão, por exemplo, se há uma conexão com uma trinca, a quantidade de água que será derramada tende a ser constante, sofrendo pequenas variações de acordo com a pressão da rede, que pode deixar o vazamento mais forte ou fraco. A Figura 24 ilustra um consumo de frequência variável ao longo do tempo. Essa variação é evidenciada pelas marcações no gráfico, que indicam de forma aproximada a mudança de periodicidade dos picos, iniciando em 18 minutos, reduzindo para 10 minutos e posteriormente retornando aos 18 minutos, até que os picos cessam completamente.

Figura 24 – Exemplo de microvazamento detectado por análise espectral.



Fonte: Elaborado pelo autor.

Para identificar esse tipo de evento, foi desenvolvida uma metodologia baseada em análise tempo-frequência utilizando a STFT, capaz de revelar padrões periódicos discretos no domínio espectral. Essa técnica permite observar o comportamento do consumo simultaneamente nos domínios do tempo e da frequência, destacando componentes cíclicos persistentes que indicam a presença de microvazamentos contínuos.

Embora tais oscilações sejam perceptíveis na série temporal, os algoritmos de detecção de anomalias, como o *Elliptic Envelope* e o *Isolation Forest*, tendem a classificá-las como comportamentos normais. Isso ocorre porque esses picos de consumo se repetem de forma constante ao longo de todo o período monitorado, sendo incorporados ao padrão estatístico do conjunto de dados. Assim, por apresentarem baixa amplitude e alta regularidade, esses eventos não são interpretados como anomalias pelos modelos não supervisionados, mas sim como parte do comportamento usual do sistema.

Por outro lado, a STFT demonstra excelente desempenho na análise desses padrões periódicos, permitindo visualizar as frequências dominantes associadas a cada janela de observação $w[n]$, conforme descrito na equação 2.1. Por meio da decomposição tempo-frequência, é possível estimar a periodicidade aproximada dos picos de consumo e identificar variações sutis na frequência de ocorrência, evidenciando o comportamento cíclico típico de microvazamentos.

Entretanto, para que a aplicação da STFT produza resultados consistentes e sem interferências, é essencial que não haja consumo real de água durante o período analisado. A presença de usos legítimos, como descargas, banhos ou torneiras abertas podem introduzir ruídos

e descontinuidades no sinal, mascarando as oscilações sutis associadas aos microvazamentos.

5.2.1 *Pré-processamento dos dados para detecção de microvazamentos*

Com o objetivo de minimizar a influência de consumos legítimos e reduzir o ruído no sinal analisado, o processo de análise espectral foi projetado para atuar apenas sobre intervalos temporais com baixa probabilidade de uso real de água. Essa decisão é fundamental para garantir que os padrões periódicos observados pela STFT representem efetivamente microvazamentos e não variações decorrentes de atividades humanas, como banhos, lavagem de roupas ou acionamento de torneiras, que introduziriam descontinuidades bruscas no sinal e mascarariam as oscilações sutis de vazamentos contínuos.

O período padrão de análise compreende o intervalo entre 0h e 6h, definido na etapa de pré-processamento dos dados. Essa janela pode, entretanto, ser ajustada dinamicamente pela interface do sistema, como mostra a Figura 25, permitindo adaptar a configuração aos hábitos de consumo específicos de cada residência. Dessa forma, assegura-se que os dados submetidos à análise tempo-frequência sejam extraídos de momentos com mínima atividade, favorecendo uma detecção mais precisa e livre de artefatos.

Figura 25 – Configuração do período de análise de microvazamentos na interface do sistema.



Fonte: Elaborado pelo autor.

Além da definição do horário de menor probabilidade de consumo, o sistema realiza uma filtragem adicional sobre os dados brutos, com o propósito de eliminar dias que possam comprometer a consistência espectral da análise. São removidos automaticamente os períodos em que são observados os seguintes padrões de uso:

- Qualquer leitura com consumo superior a 2 L por minuto;
- Duas ou mais leituras consecutivas com consumo igual ou superior a 1 L por minuto.

Caso ocorra qualquer um desses padrões, o respectivo dia (dentro do período configurado) é removido da análise, por ser considerado como um evento de consumo real ou um vazamento de maior magnitude, casos tratados por métodos baseados em aprendizado de

máquina. A Figura 26 apresenta um exemplo dos registros do sistema indicando que, dentre 31 dias analisados, 5 foram desconsiderados por apresentarem consumo real detectado.

Figura 26 – Remoção automática de dias com consumo real detectado nos logs do sistema.

```

ubuntu@ip-172-31-36-41: ~
00 OK [65/4303]
Removidos 5 dias com consumo real de 31: ['22-10-2025', '15-10-2025', '03-10-2025', '12-10-2025', '17-10-2025']
Iniciando!
nperseg= 360
[fiware] 0:[tmux]* "ip-172-31-36-41" 16:03 30-Oct-25

```

Fonte: Elaborado pelo autor.

Com os dados devidamente pré-processados e livres de períodos com consumo real, a etapa seguinte consiste em identificar padrões espectrais recorrentes que possam indicar a presença de microvazamentos. Para isso, aplica-se a STFT sobre o sinal de consumo agregado, resultando em um espectro de magnitudes médias que representa a energia do consumo em função da frequência. No entanto, nem todos os picos observados nesse espectro correspondem a eventos relevantes, pois muitos decorrem de ruído de medição, flutuações transitórias ou harmônicos de frequências mais baixas. Assim, torna-se necessário um critério robusto capaz de realçar apenas os picos mais consistentes e estáveis.

5.2.2 Critério de detecção de picos espectrais (Δmag)

Para identificar os picos espectrais mais consistentes e suprimir variações aleatórias no espectro, foi adotado um critério diferencial baseado na variação local da magnitude média, denominado Δmag . Esse parâmetro mede, para cada frequência f_i , o quanto sua magnitude média $|X(f_i)|$ se destaca em relação à média das magnitudes de suas vizinhanças imediatas, conforme expresso por:


$$\Delta mag(i) = |X(f_i)| - \frac{1}{2w} \sum_{j=1}^w [|X(f_{i-j})| + |X(f_{i+j})|] \quad (5.1)$$

em que w representa o tamanho da janela de vizinhança considerada ao redor de cada frequência. Neste trabalho, foi adotado $w = 5$, o que equivale à comparação local entre cada ponto e seus cinco vizinhos anteriores e posteriores no domínio da frequência.

Após o cálculo de $\Delta mag(i)$, aplica-se um limiar de detecção (*threshold*) que define o quanto uma variação local deve se destacar para ser considerada relevante. Frequências cujo valor de $\Delta mag(i)$ ultrapassa esse limiar são interpretadas como pertencentes a regiões de interesse espectral. Entretanto, para evitar a detecção de múltiplos picos redundantes em uma mesma região, os pontos consecutivos acima do limiar são agrupados, e apenas o ponto com maior valor de $\Delta mag(i)$ em cada grupo é mantido como pico representativo. Esse procedimento reduz ruídos e garante que apenas os picos fundamentais, associados a oscilações periódicas e estáveis do sinal, sejam preservados para análise posterior. O limiar foi determinado empiricamente, sendo ajustável conforme a sensibilidade desejada. Nos experimentos deste trabalho, o valor de 0,0015 mostrou-se adequado para distinguir flutuações residuais de padrões consistentes associados a microvazamentos.

A Figura 27 ilustra o funcionamento do critério Δmag sobre um espectro de magnitude. No gráfico superior, observa-se a curva $|X(f)|$, que representa a magnitude média das componentes de frequência após a aplicação da STFT. Já o gráfico inferior mostra a variação local $\Delta mag(i)$ calculada em torno de cada frequência, juntamente com uma linha tracejada indicando o valor do limiar de detecção (*threshold*).

Figura 27 – Picos fundamentais identificados no espectro médio de consumo noturno.



Fonte: Elaborado pelo autor.

Quando a diferença entre uma frequência e a média de suas vizinhas ultrapassa esse limiar, o ponto é classificado como um pico significativo, destacado em vermelho no gráfico. Esses picos correspondem às regiões do espectro em que há maior concentração de energia periódica, indicando oscilações consistentes no sinal. Assim, o gráfico exemplifica como o Δmag atua para isolar padrões frequenciais relevantes e suprimir pequenas flutuações locais, servindo como um mecanismo robusto de realce de picos mesmo em espectros discretos e ruidosos.

Conceitualmente, o parâmetro Δmag apresenta semelhanças com a derivada discreta, uma vez que ambos quantificam variações locais em uma função. No entanto, diferentemente da derivada clássica, que pressupõe continuidade e suavidade da curva, a análise espectral neste trabalho é realizada sobre amostras discretas e potencialmente ruidosas, provenientes da decomposição tempo-frequência do sinal de consumo.

5.2.3 Hiperparâmetros

A etapa de detecção de microvazamentos é fortemente dependente da configuração dos hiperparâmetros associados à análise espectral e ao critério Δmag . Esses parâmetros controlam o equilíbrio entre resolução temporal e frequência, a sensibilidade à variação local e a robustez frente a ruídos do sinal. Todos os valores foram ajustados empiricamente com base em experimentos sobre dados reais de consumo residencial, buscando maximizar a capacidade de detecção de microvazamentos sem aumentar a taxa de falsos positivos.

Diferentemente dos vazamentos de maior magnitude, cuja manifestação e intensidade variam significativamente entre residências em função dos hábitos de consumo e da rotina individual, os microvazamentos apresentam comportamento mais previsível e estável. Por ocorrerem de forma contínua e sem interferência humana direta, esses eventos tendem a exibir padrões espectrais semelhantes entre diferentes ambientes, variando principalmente quanto à frequência dos pulsos, isto é, intervalos mais curtos ou mais longos entre leituras de 1 L de água. Essa característica torna possível definir um conjunto de parâmetros genéricos, ajustáveis conforme o perfil de cada instalação, sem comprometer a sensibilidade da análise.

A frequência de amostragem (f_s) foi fixada em 1/60 Hz, correspondente a uma leitura por minuto, em conformidade com a granularidade do sistema de medição. O tamanho da janela de análise (n_{perseg}) é definido dinamicamente conforme o período de análise selecionado pelo usuário na interface do sistema. Por exemplo, quando o intervalo configurado é de 0h às 6h (totalizando 360 minutos), o valor de n_{perseg} é ajustado para 360; caso o intervalo seja

menor, o parâmetro é recalculado proporcionalmente. Essa abordagem adaptativa permite ajustar a resolução espectral de acordo com o tempo efetivo de análise, garantindo coerência entre a duração da janela e a periodicidade das oscilações detectáveis. A sobreposição entre janelas ($n_{overlap}$) foi mantida em 50% ($n_{overlap} = n_{perseg}/2$), favorecendo uma transição suave entre segmentos consecutivos da análise de curto prazo.

Conforme descrito na Seção 5.2.2, a detecção de picos espectrais é realizada com base no critério diferencial Δmag , que identifica as frequências mais consistentes do espectro ao comparar a magnitude local com a de seus vizinhos. Nesta etapa, foi adotada uma janela de vizinhança de $w = 5$ amostras e um limiar de detecção (*threshold*) de 0,0015, valores que apresentaram bom equilíbrio entre sensibilidade e robustez nos experimentos realizados.

Após a identificação dos picos que excedem o limiar, aplica-se uma filtragem para remoção de harmônicos redundantes, com tolerância de 5%, seguida de um agrupamento de frequências próximas, com tolerância relativa de 10%. Esse processo ajuda para que apenas os componentes fundamentais e estáveis do espectro sejam mantidos, representando as oscilações periódicas características de microvazamentos.

Por fim, um evento é classificado como microvazamento quando pelo menos um período fundamental ($min_leak_periods = 1$) é identificado. Esse parâmetro pode ser ajustado para aumentar a exigência de recorrência antes da confirmação de microvazamento, conforme o nível de sensibilidade desejado.

A Tabela 4 apresenta o conjunto de hiperparâmetros utilizados na análise espectral e suas respectivas finalidades.

Tabela 4 – Hiperparâmetros da análise espectral para detecção de microvazamentos.

Hiperparâmetro	Símbolo / Variável	Valor adotado
Frequência de amostragem	fs	1/60 Hz (1 leitura/minuto)
Tamanho da janela	n_{perseg}	Dinâmico (ex.: 360 para 0–6h)
Sobreposição	$n_{overlap}$	50%
Janela de vizinhança local	w	5
Limiar de detecção	<i>threshold</i>	0,0015
Tolerância de harmônicos	<i>tolerance</i>	5%
Tolerância de agrupamento	<i>rel_tolerance</i>	10%
Períodos mínimos para vazamento	<i>min_leak_periods</i>	1

Fonte: Elaborado pelo autor.

6 RESULTADOS E DISCUSSÃO

Com a arquitetura do sistema IoT devidamente implementada e validada em nível funcional, esta etapa apresenta os resultados experimentais obtidos a partir da operação integrada do protótipo, gateway e infraestrutura FIWARE. Os resultados apresentados neste capítulo representam a etapa de validação prática do sistema desenvolvido, desde testes físicos no protótipo a validação das detecções de vazamento. A arquitetura proposta é analisada quanto ao seu desempenho, eficiência, aplicabilidade, confiabilidade e disponibilidade. A partir dessa avaliação, o sistema deixa de ser tratado apenas como uma proposta conceitual e passa a ser examinado como uma solução concreta, mensurável e comparável a outras abordagens da literatura, evidenciando sua viabilidade técnica e potencial de replicação em larga escala.

A Figura 28 apresenta o protótipo do sistema instalado no ponto principal de medição da residência. A placa possui conexão com uma bateria e um painel solar capaz de fornecer até 22 mW, além de receber o fio do hidrômetro, responsável por sensoriar a vazão e indicar o volume consumido ao protótipo por meio de pulsos elétricos, além de estar envolvido em um *case*. O dispositivo foi desenvolvido com abordagem *plug-and-play*, exigindo apenas a conexão direta ao hidrômetro, o que simplifica significativamente o processo de instalação.

Figura 28 – Protótipo instalado no ponto principal de medição da residência.



Fonte: Elaborado pelo autor.

Os resultados apresentados a seguir correspondem à avaliação experimental e analítica do sistema completo, abrangendo desde a eficiência energética e a estabilidade da comunicação até a precisão dos modelos de detecção de anomalias. As análises consideram tanto os dados coletados diretamente pelo protótipo IoT quanto comparações com conjuntos de dados secundários da literatura, a fim de contextualizar o desempenho do sistema proposto frente a diferentes padrões de consumo residencial.

6.1 Resultados de Consumo Energético

Esta seção apresenta a análise comparativa do consumo energético do protótipo desenvolvido nesta dissertação em relação às versões utilizadas anteriormente no estudo, como a descrita em (Cabral *et al.*, 2025b), utilizando o *bare-metal* e o *framework* do Arduino como base para comparação direta entre duas abordagens de software executadas sobre o mesmo hardware. Esse trabalho faz parte da mesma pesquisa de mestrado e serviu como base metodológica para os experimentos aqui apresentados, especialmente na definição do ambiente de testes, instrumentação e procedimentos de coleta de dados.

Conforme descrito na Seção 4.1, o protótipo desenvolvido nesta dissertação utiliza o microcontrolador STM32L031F6P6, integrante da família *Cortex-M0+ ultra-low-power*, em conjunto com o transceptor SX1262, projetado para operação de baixo consumo e comunicação LoRaWAN de longo alcance. Essa configuração foi concebida com foco em eficiência energética, operação autônoma e baixo custo computacional, mantendo compatibilidade total com a metodologia experimental proposta em trabalhos anteriores.

Para fins de distinção, o protótipo P1 refere-se ao modelo utilizado em (Cabral *et al.*, 2025b), composto pelo microcontrolador STM32F030C8T6 e pelo módulo RFM95W, que integra o transceptor LoRa SX1276. O protótipo P2, por sua vez, corresponde à nova versão apresentada nesta dissertação, que adota o conjunto STM32L031F6P6 + SX1262, otimizado para operação em regimes de ultra baixo consumo e destinado à validação das melhorias de hardware e software implementadas.

A partir dessa base de hardware, foram implementadas e avaliadas duas abordagens de software distintas: (i) uma versão desenvolvida sobre o *framework* Arduino e (ii) uma versão em modo *bare-metal*, que explora diretamente os modos de baixo consumo do microcontrolador e utiliza interrupções para gerenciamento de eventos. Ambas as versões executam o mesmo conjunto funcional de tarefas, apresentado na Figura 13, mas enviando os dados periodicamente

a cada 1 minuto via LoRaWAN, permitindo uma comparação direta dos impactos energéticos relacionados ao modelo de programação. O teste com *FreeRTOS* não pôde ser reproduzido no novo protótipo devido à limitação de memória do microcontrolador, que dispõe de apenas 32 KB de memória *Flash*. O sistema operacional *FreeRTOS* requer estruturas internas complexas, como filas, gerenciamento de tarefas e controle de contexto, que combinadas com a pilha LoRaWAN, excederam a capacidade disponível, inviabilizando sua execução.

A análise comparativa apresentada nesta seção é de suma importância para a escalabilidade, confiabilidade e disponibilidade do sistema, uma vez que a redução do consumo em nível de nó amplia a autonomia energética, reduz a necessidade de manutenção e aumenta a viabilidade de implantação em redes compostas por múltiplos dispositivos distribuídos geograficamente.

6.1.1 Análise estatística do consumo

A Tabela 5 apresenta as estatísticas de consumo energético obtidas para as quatro abordagens avaliadas, incluindo média, mediana e desvio-padrão das amostras coletadas em condições equivalentes de teste. A comparação permite avaliar o impacto das estratégias de software e das gerações de hardware sobre o consumo médio de potência, quantificando de forma objetiva os ganhos de eficiência obtidos com o novo protótipo e as otimizações implementadas nesta dissertação.

Tabela 5 – Comparativo geral de consumo energético entre as quatro abordagens avaliadas.

Implementação	Média (mW)	Mediana (mW)	Desvio-padrão (mW)
Arduino + P1	156,19	150,40	28,36
FreeRTOS + P1	41,45	40,80	27,22
Arduino + P2	2,22	1,60	7,07
Bare-metal + P2	0,79	0,00198	11,06

Fonte: Adaptado de (Cabral *et al.*, 2025b) e elaborado pelo autor.

Os resultados mostram uma redução progressiva e consistente do consumo a cada nova versão. A substituição do transceptor SX1276 pelo SX1262 e a adoção do microcontrolador STM32L031F6P6 proporcionaram uma queda de aproximadamente 98,6% no consumo médio entre as versões baseadas em hardware antigo (utilizado em (Cabral *et al.*, 2025b)) e o novo protótipo (apresentado na Seção 4.1).

Por sua vez, a transição do firmware entre *framework* do Arduino para a implementação *bare-metal* reduziu o consumo médio em mais 64%, atingindo valores abaixo de 1 mW.

Essa redução se deve à eliminação da sobrecarga do *framework* Arduino e ao uso intensivo dos modos de baixo consumo do microcontrolador, que permanece em hibernação por mais de 99% do tempo de operação.

6.1.2 Consumo por modo de operação

A Tabela 6 apresenta o consumo médio estimado em cada estado funcional do sistema. As medições foram obtidas experimentalmente, sendo que, no caso do protótipo proposto utilizando o *bare-metal*, os valores referentes ao modo *Stop* foram complementados com dados de referência do *datasheet* do microcontrolador¹, uma vez que o consumo observado ficou abaixo da sensibilidade do sensor INA219², que possui resolução mínima de aproximadamente 0,37 mW, considerando uma tensão de entrada de 3,7 V.

Tabela 6 – Consumo médio por modo de operação nas quatro abordagens avaliadas.

Modo de Operação	Arduino + P1	FreeRTOS + P1	Arduino + P2	Bare-metal + P2
Sistema em espera	150 mW	40 mW	2 mW	0,0098 mW
Interrupção	200 mW	70 mW	35 mW	35 mW
Envio de dados	1300 mW	1000 mW	230 mW	230 mW

Fonte: Adaptado de (Cabral *et al.*, 2025b) e elaborado pelo autor.

A principal diferença observada entre as abordagens ocorre no modo de espera, que representa mais de 99% do tempo total de operação. Enquanto as versões baseadas no *framework* do Arduino e no *FreeRTOS* mantinham o processador ativo mesmo em repouso, com consumos médios de 150 mW e 40 mW, respectivamente, o novo firmware *bare-metal* reduziu esse valor para apenas 0,0098 mW.

Grande parte dessa diferença está associada à substituição do hardware. O protótipo utilizado em (Cabral *et al.*, 2025b) apresentou consumo médio de aproximadamente 150 mW quando executando o código em Arduino. Já o novo protótipo obteve consumo médio de apenas 2 mW sob as mesmas condições e realizando as mesmas tarefas. Essa redução representa uma diminuição de cerca de 98,6% no consumo médio, demonstrando o impacto direto da modernização do hardware sobre a eficiência energética.

Além disso, ao comparar as duas implementações de software executadas sobre o mesmo protótipo P2, observa-se que a migração do *framework* Arduino para o modelo *bare-metal* resultou em uma redução adicional de aproximadamente 64% no consumo médio (de

¹ *Datasheet* STM32L031F6P6


² *Datasheet* sensor INA219

2 mW para 0,79 mW). Essa diferença evidencia que, além do novo hardware, o software também exerce papel fundamental na otimização energética, uma vez que o modelo *bare-metal* elimina a sobrecarga do *framework* e explora de forma mais eficiente os modos de baixo consumo do microcontrolador.

6.1.3 Comparação gráfica e interpretação dos resultados

A Figura 29 apresenta o perfil de potência do novo protótipo ao longo de 20 minutos de teste. Observa-se a presença de picos de aproximadamente 230 mW, correspondentes aos envios periódicos via LoRaWAN, enquanto o restante da operação mantém-se em níveis inferiores a 40 mW, com longos períodos próximos de 0 mW.

Figura 29 – Perfil de consumo energético do protótipo com transceptor SX1262 executando o firmware *bare-metal* e Arduino.




Fonte: Elaborado pelo autor.

É possível notar também que, entre cada envio, isto é, em intervalos de aproximadamente um minuto ocorrem cinco picos menores, com potência média em torno de 40 mW. Esses eventos correspondem às interrupções simuladas pelo circuito de teste ilustrado na Figura 14, no qual um pino da ESP32 é conectado diretamente ao protótipo, reproduzindo o comportamento

real do hidrômetro durante a detecção de pulsos.

A Figura 30 apresenta um recorte ampliado do primeiro minuto do teste, evidenciando de forma mais clara esses cinco picos de 40 mW. Além disso, observa-se a ocorrência de pequenas oscilações periódicas, de aproximadamente 5 mW, em intervalos de um segundo. Esses picos de menor amplitude provavelmente estão relacionados ao funcionamento do *clock* interno do microcontrolador, que executa breves ciclos de atualização mesmo durante o modo de espera.

Figura 30 – Ampliação do perfil de potência no primeiro minuto de operação, evidenciando picos de interrupção e oscilações periódicas.




Fonte: Elaborado pelo autor.

Ambos os gráficos apresentam comportamento similar, com um leve deslocamento vertical observado na versão baseada no *framework* Arduino. A principal diferença que explica a média de consumo cerca de 64% maior nesse caso é o fato de que o firmware *bare-metal* mantém o consumo praticamente nulo (0,0098 mW) durante a maior parte do tempo, enquanto a implementação em Arduino permanece continuamente em torno de 2 mW mesmo em estado de repouso. Essa diferença é claramente evidenciada na Figura 30, em que se observa a linha correspondente ao Arduino ligeiramente acima da linha do *bare-metal* ao longo entre os picos.

A Figura 31 apresenta graficamente a comparação direta entre as abordagens.

Observa-se que as curvas referentes ao protótipo P2 permanecem praticamente sobrepostas devido à diferença de escala em relação aos valores medidos no protótipo P1 e a similaridade em picos de maior potência, como nos períodos de transmissão. Ambos os firmwares utilizados juntamente ao P2 apresentam desempenho energético substancialmente superior, com reduções expressivas de consumo em todos os modos de operação, como evidenciado pelos resultados apresentados anteriormente. Esse comportamento confirma a eficiência das otimizações de hardware e software adotadas, que resultaram em um sistema capaz de operar com potência média inferior a 1 mW.

Figura 31 – Comparativo de consumo energético entre diferentes versões do sistema.



Fonte: Adaptado de (Cabral *et al.*, 2025b) e elaborado pelo autor.

6.1.4 Síntese dos resultados

De forma geral, os resultados demonstram que as otimizações implementadas no novo protótipo resultaram em um avanço significativo em termos de eficiência energética. A substituição do microcontrolador STM32F030C8T6 pelo STM32L031F6P6 e do transceptor SX1276 pelo SX1262 reduziu o consumo médio de potência em aproximadamente 98,6%,

comprovando a efetividade das decisões de projeto voltadas à operação em regimes de ultra baixo consumo.

Além disso, a utilização da implementação *bare-metal* ao invés do *framework* Arduino proporcionou uma economia adicional de cerca de 64%, permitindo que o sistema atingisse consumo médio inferior a 1 mW e valores mínimos abaixo de 0,01 mW durante o modo de espera. Essa redução está diretamente associada ao uso intensivo do modo *Stop* do microcontrolador, que garante operação quase nula de corrente em períodos de inatividade.

O perfil de consumo observado nas Figuras 29 e 30 confirma que o sistema permanece inativo por mais de 99% do tempo, despertando apenas para eventos de interrupção ou transmissão LoRaWAN, com picos pontuais de até 230 mW. Essa característica reforça a adequação do sistema para aplicações de longa duração com alimentação autônoma, como baterias compactas ou fontes de energia colhida do ambiente.

Por fim, os resultados obtidos confirmam que a integração entre o novo hardware e o firmware otimizado proporciona uma plataforma estável, escalável e energeticamente eficiente, capaz de sustentar o funcionamento contínuo da arquitetura IoT proposta nesta dissertação. Essa eficiência energética constitui um dos pilares fundamentais para o sucesso das etapas seguintes de detecção inteligente de vazamentos, permitindo o processamento local de dados e a transmissão periódica de informações sem comprometer a autonomia do dispositivo.

Os avanços obtidos em termos de eficiência energética estabelecem as bases para a continuidade desta pesquisa, voltada agora à ampliação da autonomia operacional e à sustentabilidade do sistema. O consumo baixíssimo alcançado pelo protótipo torna possível a integração de fontes renováveis de energia, aumentando a confiabilidade e disponibilidade do sistema. Assim, a próxima etapa aborda a incorporação de técnicas de *energy harvesting*, que permitem a recarga autônoma da bateria a partir de fontes como luz solar ou fluxo hidráulico, assegurando funcionamento prolongado mesmo em ambientes remotos.

6.2 Energy Harvesting e Autonomia Operacional

Aliado ao desempenho energético apresentado, o protótipo possui um módulo de carregamento baseado em *energy harvesting*, que amplia significativamente sua autonomia operacional. Esse módulo utiliza o circuito integrado BQ25504³, responsável pelo gerenciamento de energia proveniente de fontes renováveis, como painéis solares e microgeradores hidráulicos,

³ Datasheet BQ25504

permitindo a operação contínua do sistema sem necessidade de intervenção humana para recarga.

A Figura 28 mostra o protótipo equipado com uma bateria LiPo e um painel solar. Durante períodos de irradiação solar, mesmo sob baixa incidência luminosa, o BQ25504 realiza o controle da carga e o armazenamento de energia na bateria, necessitando de apenas 130 mV para iniciar o processo de carregamento. Dessa forma, o sistema mantém-se energeticamente autônomo, mesmo em condições de luminosidade variável.

De forma complementar, o circuito de alimentação permite a utilização de qualquer fonte de energia contínua de 5 V. Um exemplo alternativo para situações em que a luz solar não chega ao local de instalação, é o uso de microgeradores hidráulicos instalados na própria tubulação de água, que utilizam a pressão do fluxo para acionar uma turbina e gerar eletricidade. Pequenos geradores desse tipo são capazes de produzir potência próxima de 2,5 mW (Lima *et al.*, 2019), valor suficiente para suprir o consumo do nó IoT em operação de baixo consumo.

Para avaliar a autonomia do sistema sem o uso de *energy harvesting*, ou seja, sem uma fonte de energia para recarregar a bateria, foram realizadas medições empíricas da descarga da bateria ao longo de 40 dias de operação contínua. Durante esse período, a tensão da bateria baixou de 4,12 V para 3,70 V, o que representou uma taxa média de descarga de 0,0105 V/dia. Considerando a tensão mínima operacional do sistema de 2,75 V e uma bateria de 200 mAh, estima-se uma autonomia total próxima de 130 dias sem recarga. Vale destacar que são essas estimativas são aproximações, visto que a curva de descarga da bateria pode não ser linear e depende de diversos fatores, como temperatura e ciclos de carga anteriores.

Esses resultados evidenciam que, mesmo sem o subsistema de *energy harvesting*, o protótipo é capaz de operar de forma contínua por mais de três meses, o que reforça sua eficiência energética e confiabilidade. Quando aliado ao módulo de carregamento, a autonomia do sistema tende a se tornar praticamente ilimitada, restringindo a necessidade de manutenção apenas a eventuais substituições de componentes.

6.3 Viabilidade Econômica do Sistema

Além do desempenho energético, a viabilidade prática do sistema também foi analisada sob as perspectivas técnica e econômica, uma vez que a escalabilidade da proposta depende diretamente do custo de fabricação, da disponibilidade dos componentes e da simplicidade de replicação do projeto.

O custo total estimado de fabricação do nó IoT é de aproximadamente US\$ 14,42

(cerca de R\$ 80,00), incluindo todos os componentes e o processo de fabricação da placa de circuito impresso, conforme detalhado no Apêndice C. Segundo (Costa; Soares, 2020), o custo unitário de implantação de medidores inteligentes com telemetria em Brasília atingiu aproximadamente US\$ 188 por unidade, além de US\$ 23 anuais de manutenção, o que evidencia o elevado custo dessas soluções comerciais quando comparadas ao sistema proposto nesta dissertação. No mercado de medição inteligente de água, empresas como a Kamstrup oferecem sistemas voltados a redes de larga escala e coleta remota de dados (Kamstrup A/S, 2025), enquanto a IE Tecnologia disponibiliza o modelo SM-LA, um medidor LoRaWAN com múltiplos canais de pulso e alimentação por pilhas (IE Tecnologia Ltda., 2025). Esses dispositivos, porém, tem custos de aquisição e implantação que ainda superam US\$ 90 por unidade.

O protótipo desenvolvido nesta dissertação, porém alia baixo custo de fabricação a um consumo energético extremamente reduzido, inferior a 1 mW em operação média, o que o torna adequado para aplicações autônomas e de longa duração. Essa relação entre eficiência energética e viabilidade econômica representa um dos principais diferenciais do sistema proposto, permitindo sua replicação em grande escala sem comprometer a sustentabilidade financeira do projeto. A combinação entre baixo custo, alta eficiência e carregamento utilizando fontes renováveis reforça o caráter acessível e sustentável da solução, capaz de viabilizar programas de monitoramento contínuo de consumo e detecção de vazamentos com custos significativamente menores de implantação e manutenção, contribuindo para uma gestão hídrica mais inteligente, inclusiva e ambientalmente responsável.

Aliado aos resultados de eficiência energética, o sistema proposto incorpora uma camada analítica que o transforma de um dispositivo de medição convencional em uma plataforma inteligente, capaz de realizar inferências automáticas sobre o consumo e detectar padrões anômalos em tempo real. Essa integração entre a infraestrutura física e as camadas analíticas baseadas em aprendizado de máquina é discutida em maior detalhe na Seção 6.4.

6.4 Resultados da Aplicação de Aprendizado de Máquina

Esta seção apresenta os resultados da aplicação do modelo *Elliptic Envelope* na detecção de vazamentos de água em séries temporais de consumo hídrico. O modelo foi escolhido com base nos experimentos exploratórios realizados em (Cabral *et al.*, 2025a), em que foi comparado ao *Isolation Forest* e apresentou desempenho superior em termos de estabilidade, robustez frente a ruídos e equilíbrio entre *precision*, *recall* e *F1-score*. Assim, nesta dissertação, o

Elliptic Envelope foi adotado como abordagem principal para validação do sistema em ambiente real.

A Tabela 7 apresenta os resultados comparativos obtidos em (Cabral *et al.*, 2025a), considerando três conjuntos de dados distintos. Observa-se que o *Elliptic Envelope* superou o *Isolation Forest* em todos os cenários, com destaque para o *dataset* de (Mauro *et al.*, 2019), no qual atingiu *F1-score* de 0,8815, evidenciando sua capacidade de adaptação a diferentes padrões de consumo hídrico.

Tabela 7 – Desempenho comparativo entre *Isolation Forest* e *Elliptic Envelope* nos experimentos de (Cabral *et al.*, 2025a).

Dataset	Modelo	Precision	Recall	F1-score
(Cabral <i>et al.</i> , 2025a)	Isolation Forest	0,9077	0,8062	0,8534
	Elliptic Envelope	0,9213	0,8202	0,8673
(Kulikovas; Packevičius, 2023)	Isolation Forest	0,8858	0,7959	0,8376
	Elliptic Envelope	0,8898	0,7983	0,8408
(Mauro <i>et al.</i> , 2019)	Isolation Forest	0,8642	0,8702	0,8670
	Elliptic Envelope	0,8664	0,8974	0,8815

Fonte: Adaptado de (Cabral *et al.*, 2025a).

Os resultados demonstraram que o *Elliptic Envelope* apresentou desempenho mais equilibrado e estável, especialmente em contextos de ruído e variação de consumo, justificando sua escolha como modelo principal na etapa de validação experimental desta dissertação.

6.4.1 Desempenho geral do modelo

Os experimentos aqui apresentados combinam duas etapas complementares: (i) a análise de desempenho do modelo sobre conjuntos de dados secundários provenientes da literatura e (ii) a validação sobre o novo *dataset* coletado pelo protótipo IoT desenvolvido nesta pesquisa, com transmissão via LoRaWAN e integração à infraestrutura FIWARE. O objetivo é avaliar a precisão, a sensibilidade e a consistência do modelo em contextos residenciais distintos, sujeitos a diferentes padrões de consumo, frequências de amostragem e níveis de ruído.

A Tabela 8 apresenta as métricas médias obtidas pelo *Elliptic Envelope* nos quatro conjuntos de dados analisados. Os valores referentes ao *dataset* desta dissertação foram obtidos experimentalmente a partir das transmissões reais do protótipo IoT, enquanto os demais correspondem aos resultados previamente validados em (Cabral *et al.*, 2025a). A mesma metodologia é executada de forma contínua no servidor AWS que hospeda a aplicação, alterando-se apenas o conjunto de dados de entrada conforme a residência monitorada. Essa configuração garante

a reprodutibilidade dos experimentos e permite a aplicação prática do modelo em diferentes cenários reais de consumo.

Tabela 8 – Métricas de desempenho do modelo *Elliptic Envelope* nos quatro conjuntos de dados analisados.

Dataset	Precision	Recall	F1-score
(Cabral <i>et al.</i> , 2025a)	0,9213	0,8202	0,8673
(Kulikovas; Packevičius, 2023)	0,8898	0,7983	0,8408
(Mauro <i>et al.</i> , 2019)	0,8664	0,8974	0,8815
Dissertação	0,9065	0,8554	0,8801

Fonte: Elaborado pelo autor.

Os resultados indicam que o modelo manteve desempenho consistente em todos os cenários, com valores de *precision* superiores a 0,88 e *recall* médio em torno de 0,85. Essa estabilidade demonstra que o *Elliptic Envelope* é capaz de generalizar adequadamente entre diferentes padrões de consumo hídrico, preservando sua capacidade de discriminar eventos anômalos mesmo quando exposto a séries temporais com características estatísticas distintas.

Observa-se que o desempenho obtido no *dataset* da dissertação, colhido integralmente pelo sistema IoT é comparável ao alcançado em experimentos controlados e bases de dados públicas, o que reforça a robustez do modelo frente às incertezas de um ambiente real como ruídos instrumentais e pequenas falhas de comunicação. Em particular, a combinação entre alta *precision* (0,90) e *recall* satisfatório (0,85) evidencia o bom equilíbrio entre a capacidade de evitar falsos positivos e a sensibilidade na detecção de vazamentos reais.

Outro ponto relevante é a proximidade entre os resultados do sistema IoT e os obtidos nos *datasets* de (Cabral *et al.*, 2025a) e (Mauro *et al.*, 2019), apesar das diferenças de contexto e aquisição dos dados. Isso sugere que o modelo é pouco dependente de ajustes específicos de calibração, sendo aplicável de forma mais ampla em ambientes residenciais distintos. Dessa forma, os resultados confirmam não apenas a viabilidade prática da arquitetura analítica proposta, mas também seu potencial de replicação em cenários reais de monitoramento de consumo hídrico.

6.4.2 Análise por tipo de vazamento

A Tabela 9 apresenta os valores de *recall* segmentados por intensidade de vazamento (leve, moderado e severo) nos quatro conjuntos de dados. Essa análise permite observar a sensibilidade do modelo frente a diferentes volumes, destacando o quanto a variação de consumo

influencia diretamente na capacidade de detecção automática de padrões irregulares.

Tabela 9 – Desempenho do *Elliptic Envelope* por tipo de vazamento (métrica *Recall*).

Dataset	Leve	Moderado	Severo
(Cabral <i>et al.</i> , 2025a)	0,5391	1,0000	1,0000
(Kulikovas; Packevičius, 2023)	0,4658	1,0000	1,0000
(Mauro <i>et al.</i> , 2019)	0,7697	1,0000	1,0000
Dissertação	0,5596	1,0000	1,0000

Fonte: Elaborado pelo autor.

O modelo apresentou *recall* máximo para os vazamentos moderados e severos em todos os *datasets*, confirmando sua eficácia na identificação de anomalias de maior magnitude. Esse resultado demonstra que o *Elliptic Envelope* é capaz de reconhecer com alta precisão padrões de consumo que se desviam de forma consistente do comportamento esperado, mesmo em séries temporais ruidosas e com variação natural de demanda.


Os vazamentos leves, por outro lado, representaram um desafio mais significativo, com valores de *recall* variando entre 0,46 e 0,77. Essa redução de desempenho está associada à baixa diferença estatística entre o consumo de fundo e as oscilações de pequena amplitude geradas pelos vazamentos leves. Nesses casos, o modelo tende a incorporar parte desses eventos como comportamento normal, uma vez que sua distribuição estatística se sobrepõe ao ruído e às flutuações de uso cotidiano. Além disso, pequenas irregularidades no consumo noturno ou pequenas variações na pressão da rede podem gerar flutuações semelhantes às de um microvazamento, dificultando a distinção entre ambos. Em outras palavras, aproximadamente metade dos vazamentos leves não foram classificados como anomalia, o que evidencia uma limitação natural do modelo na detecção de eventos muito sutis relação ao conjunto de dados.

6.4.3 Análise visual dos resultados

A Figura 32 ilustra a atuação do modelo *Elliptic Envelope* sobre o *dataset* da dissertação, destacando os períodos de vazamentos simulados classificados de acordo com sua intensidade. Os pontos em vermelho indicam vazamentos severos, em laranja os moderados e em amarelo os leves, enquanto os vazamentos não detectados estão marcados com um “x”. Entre os períodos de vazamento simulados, foram intencionalmente inseridos trechos de consumo real extraídos do próprio conjunto de dados original, a fim de avaliar a capacidade do modelo de distinguir eventos anômalos de padrões legítimos de uso residencial. Essa configuração

mista reproduz de forma mais fiel o comportamento de um ambiente real, no qual vazamentos e consumos legítimos podem ocorrer de forma intercalada.

Figura 32 – Detecção de vazamentos pelo modelo *Elliptic Envelope* no *dataset* da dissertação.




Fonte: Elaborado pelo autor.

Observa-se que os eventos simulados ao final do conjunto de dados foram corretamente identificados. Os vazamentos de média e alta magnitude foram detectados em todas as ocorrências, em conformidade com os resultados apresentados na Tabela 9. Já os vazamentos leves mostraram-se mais desafiadores, sendo detectados apenas em parte das ocorrências.

A Figura 33 apresenta um recorte ampliado de um desses vazamentos leves, permitindo observar com maior clareza as oscilações do consumo e a resposta do modelo. Nota-se que os pontos correspondentes a consumos acima de 2 L foram corretamente classificados como vazamento, enquanto os valores inferiores foram interpretados como consumo normal.

Figura 33 – Ampliação de um vazamento leve mostrando oscilações detectadas parcialmente.



Fonte: Elaborado pelo autor.

Esse comportamento está associado não apenas à sensibilidade limitada do modelo para anomalias de baixa amplitude, mas também ao próprio padrão de consumo da residência, no qual pequenas variações de até 2 L são frequentes e, portanto, incorporadas pelo modelo como parte do comportamento normal do sistema.

Essa limitação reflete a dificuldade inerente dos modelos estatísticos em distinguir pequenas variações de ruído em séries temporais com alta variabilidade, especialmente quando o padrão de consumo da residência inclui flutuações intermitentes de baixa magnitude. Nesses cenários, o limite entre um consumo residual e um vazamento leve torna-se estatisticamente similar, levando o modelo a classificar parte dos eventos reais como comportamento normal.

6.4.4 Influência das características dos datasets

A Tabela 10 apresenta as estatísticas descritivas dos quatro conjuntos de dados analisados, destacando como a dispersão e o padrão de consumo influenciam diretamente a sensibilidade do modelo.

Tabela 10 – Estatísticas descritivas dos *datasets* analisados.

Dataset	Média	Mediana	Moda	Desvio-padrão
(Cabral <i>et al.</i> , 2025a)	185,8	137,0	110	138,8
(Kulikovas; Packevičius, 2023)	57,6	55,7	1,5	27,0
(Mauro <i>et al.</i> , 2019)	32,3	23,8	0,0	32,0
Dissertação	178,5	149,5	87,0	122,1

Fonte: Elaborado pelo autor.

O *dataset* de (Mauro *et al.*, 2019) apresenta a menor média e moda igual a zero, indicando longos períodos sem consumo, o que favorece a detecção de vazamentos leves, pois pequenas elevações de consumo se tornam mais perceptíveis no sinal. Em contrapartida, os *datasets* de (Cabral *et al.*, 2025a) e o da dissertação, ambos provenientes da mesma residência, porém em períodos distintos e com metodologias diferentes de coleta exibem médias e desvios-padrão mais elevados, o que dificulta a diferenciação entre flutuações naturais e vazamentos sutis. Já o *dataset* de (Kulikovas; Packevičius, 2023), embora apresente média e moda mais baixas, possui alta variabilidade relativa e intervalos de medição irregulares, o que aumenta a dispersão do sinal e reduz a sensibilidade do modelo a anomalias de pequena amplitude. Essa característica faz com que parte dos vazamentos leves seja interpretada como consumo normal, resultando em desempenho ligeiramente inferior quando comparado aos demais conjuntos de dados.

Em contraste, o sistema desenvolvido nesta dissertação foi projetado para realizar

medições em intervalos fixos de 60 segundos, garantindo amostragem temporal estável e contínua. Essa regularidade elimina lacunas entre leituras e assegura coerência temporal ao conjunto de dados, favorecendo a consistência estatística e a confiabilidade do modelo de detecção. Como consequência, o *Elliptic Envelope* apresenta comportamento mais previsível e robusto, mesmo em cenários de ruído moderado, evidenciando a importância de uma coleta sincronizada e de alta resolução temporal para a eficácia de modelos baseados em aprendizado não supervisionado.

Apesar dessas diferenças estatísticas, o modelo apresentou resultados consistentes em todos os contextos, com *recall* próximo de 0,55 para vazamentos leves e detecção completa para os casos moderados e severos. Esses dados evidenciam, mais uma vez, que o *Elliptic Envelope* mantém desempenho estável e previsível mesmo sob diferentes condições, desde cenários de baixo consumo, como o de (Mauro *et al.*, 2019), até ambientes com padrões mais elevados e variáveis, como os de (Cabral *et al.*, 2025a). Essa robustez reforça a capacidade do modelo de adaptar-se a distintos perfis residenciais sem necessidade de ajustes significativos de parametrização.

6.4.5 Desempenho Computacional do Modelo

Além da análise de precisão e robustez, também foi avaliado o desempenho computacional do *Elliptic Envelope*, considerando o tempo de treinamento e o tempo médio de inferência em diferentes tamanhos de *datasets*. Essa avaliação é fundamental para verificar a viabilidade do modelo em aplicações de monitoramento contínuo e sua integração à infraestrutura FIWARE, na qual as inferências são executadas periodicamente sobre os dados recebidos via LoRaWAN.

O trabalho (Cabral *et al.*, 2025a) já havia demonstrado que o *Elliptic Envelope* apresenta tempos de inferência praticamente instantâneos, mesmo em bases com centenas de milhares de amostras, e desempenho estável independentemente do tamanho do conjunto de dados. A Tabela 11 complementa esses resultados com a inclusão do novo *dataset* real obtido nesta dissertação, coletado pela infraestrutura IoT proposta.

Tabela 11 – Tempo de treinamento e inferência do modelo *Elliptic Envelope* em diferentes *datasets*.

<i>Dataset</i>	Amostras	Treino (s)	Inferência (s)
(Cabral <i>et al.</i> , 2025a)	57.946	4.4144	0.0026
(Kulikovas; Pakevičius, 2023)	263.813	15.0991	0.0037
(Mauro <i>et al.</i> , 2019)	358.569	20.4623	0.0049
Dissertação	47.281	4.0746	0.0021

Fonte: Elaborado pelo autor.

Nota-se que, mesmo com bases superiores a 350 mil amostras, o tempo de inferência permaneceu inferior a 0,005 s, demonstrando a eficiência do modelo para aplicações em tempo real. No *dataset* da dissertação, o treinamento foi concluído em 4,07s e a inferência média manteve-se em apenas 0,0021s, desempenho equivalente ao observado nos experimentos anteriores.

Esses resultados confirmam que o *Elliptic Envelope* é altamente eficiente do ponto de vista computacional, permitindo o processamento de fluxos contínuos de dados sem impacto perceptível na latência total do sistema. Quando integrado à arquitetura FIWARE, o modelo realiza a classificação de novos dados praticamente no mesmo instante em que são inseridos, possibilitando a detecção de vazamentos em tempo real.

É importante destacar que, a cada atualização da interface web do sistema, uma nova inferência é automaticamente executada para refletir o estado mais recente das medições. Nesses casos, tempos de resposta elevados poderiam comprometer a experiência do usuário, resultando em atrasos perceptíveis no carregamento das informações. No entanto, a baixa latência observada, da ordem de milissegundos, garante que o processo de inferência ocorra de forma imperceptível, mantendo a fluidez da interação com o painel e assegurando respostas imediatas às consultas e análises.

O ambiente de execução do sistema foi hospedado em uma instância virtual da AWS EC2, do tipo *t3.small*, na qual os serviços de inferência e armazenamento operam de forma contínua. Mesmo nesse ambiente de produção, os tempos médios de treinamento e inferência mantiveram-se praticamente inalterados em relação aos obtidos nos testes locais, demonstrando estabilidade de desempenho e confirmando a escalabilidade do sistema em infraestrutura de nuvem.

6.4.6 Síntese dos resultados

De modo geral, os resultados confirmam que o modelo *Elliptic Envelope* apresenta desempenho consistente, robusto e computacionalmente eficiente para a detecção de vazamentos em séries temporais de consumo hídrico. Em todos os conjuntos de dados, o modelo manteve *precision* superior a 0,88 e *recall* médio em torno de 0,85, evidenciando sua capacidade de generalizar entre diferentes perfis residenciais e condições de coleta, mesmo na presença de ruídos e variações naturais de consumo.

A combinação de alta *precision* com *recall* satisfatório demonstra o equilíbrio entre

sensibilidade e confiabilidade, assegurando a detecção de vazamentos reais sem comprometer a taxa de falsos positivos. Embora os vazamentos leves ainda representem um desafio, com cerca de metade dos eventos não identificados, os resultados indicam que o modelo é plenamente eficaz para vazamentos moderados e severos, alcançando *recall* máximo em todos os cenários testados.

Além do desempenho estatístico, o modelo se mostrou altamente eficiente do ponto de vista computacional, com tempos de inferência inferiores a 0,005 s mesmo em bases contendo centenas de milhares de amostras. Essa característica é fundamental para aplicações em tempo real, uma vez que o sistema executa uma nova inferência a cada atualização da interface web, garantindo respostas imediatas e interação fluida com o usuário.

A estabilidade observada nos resultados, tanto em ambiente local quanto na instância em nuvem, confirma a viabilidade prática e a escalabilidade da arquitetura proposta, que combina coleta via LoRaWAN, armazenamento distribuído e análise automatizada integrada ao FIWARE. Em síntese, o conjunto de experimentos valida a aplicação do *Elliptic Envelope* como núcleo analítico da plataforma, fornecendo uma base sólida para a investigação de eventos mais sutis e contínuos, abordados nas próximas seções por meio da análise espectral de microvazamentos.

6.5 Resultados da Detecção de Microvazamentos


Esta seção apresenta os resultados obtidos pela camada analítica de detecção de microvazamentos, baseada na análise espectral do consumo hídrico. O método proposto utiliza a Transformada de Fourier de Tempo Curto (STFT) para identificar padrões cíclicos de baixa magnitude e frequência constante, característicos de microvazamentos contínuos. Essa abordagem permite observar variações sutis no domínio da frequência que não seriam perceptíveis apenas pela análise temporal direta, ampliando a capacidade do sistema de reconhecer perdas mínimas e recorrentes.

6.5.1 Identificação das Frequências Fundamentais

A Figura 34 mostra o resultado da análise espectral executada sobre os dados coletados pela infraestrutura IoT descrita nesta dissertação. A análise foi configurada para o intervalo noturno, compreendendo o período entre 0h e 5h, ao longo de 40 dias consecutivos. Desse total, 10 dias apresentaram evidências de consumo real e foram automaticamente excluídos

do processamento, a fim de garantir que apenas períodos de inatividade fossem analisados.

Figura 34 – Frequências fundamentais detectadas pela análise espectral de microvazamentos.



Fonte: Elaborado pelo autor.


Durante os 30 dias restantes, foram identificadas cinco frequências fundamentais associadas a padrões cíclicos de consumo de baixa intensidade. Dentre elas, a frequência dominante observada foi a de aproximadamente 10 minutos, associada ao maior valor de intensidade espectral ($\Delta\text{mag} = 0,0038$). O volume total registrado por esses eventos foi de 317 litros, correspondendo a microvazamentos contínuos e de baixa magnitude que ocorreram durante períodos em que não deveria haver consumo hídrico.

A predominância dessa frequência indica a presença de um consumo cíclico e de baixa intensidade, possivelmente relacionado a microvazamentos periódicos no sistema hidráulico. Esse comportamento é corroborado pelos dados temporais, como mostra a Figura 34, que exibem picos regulares a cada 10 e 18 minutos, coincidindo com os períodos fundamentais identificados no espectro agregado.

6.5.2 Análise Espectral e Score de Detecção

A Figura 35 apresenta o gráfico de magnitude espectral agregada, no qual os picos fundamentais são destacados em vermelho. Cada pico corresponde a um componente periódico detectado no sinal de consumo.

Figura 35 – Magnitude espectral e picos fundamentais identificados com base no Δmag .



Fonte: Elaborado pelo autor.

O cálculo do Δmag foi utilizado como métrica quantitativa de força espectral, permitindo hierarquizar as frequências mais relevantes e distinguir padrões residuais de consumo de variações estatisticamente significativas. A análise mostrou que a frequência de aproximadamente 0,0016 Hz (equivalente a 10,6 minutos) apresenta o maior *score* de detecção ($\Delta\text{mag} =$

0,0038), confirmando sua relevância como indicativo de microvazamento.


Apesar da aplicação de filtros harmônicos na etapa de pós-processamento, é possível observar a presença de múltiplos picos secundários, como os correspondentes a 5, 3 e 2 minutos, que não se manifestam claramente na análise temporal (Figura 34). Esses componentes provavelmente representam harmônicos do sinal principal de 10 minutos, decorrentes da decomposição tempo-frequência e da natureza discreta da STFT. Essa característica é comum em sinais com periodicidade bem definida e confirma a sensibilidade do método em detectar padrões cíclicos mesmo em magnitudes muito baixas.

Ainda que tais harmônicos introduzam múltiplos picos aparentes no espectro, o critério Δ_{mag} permite priorizar as frequências de maior estabilidade e intensidade, assegurando que o sistema identifique corretamente o período fundamental responsável pelo comportamento periódico do consumo. Essa propriedade torna a abordagem robusta mesmo em sinais com sobreposição espectral e variações leves de ruído.

6.5.3 Distribuição Temporal das Frequências

A Figura 36 apresenta o espectrograma correspondente, no qual a energia espectral é distribuída ao longo do tempo. O eixo vertical representa a frequência (Hz), o eixo horizontal o tempo (dias), e o mapa de cores indica a intensidade espectral, com tons mais claros (amarelos) correspondendo a maior potência.

Figura 36 – Espectrograma da série temporal mostrando a estabilidade das componentes espectrais ao longo dos dias.



Fonte: Elaborado pelo autor.

Observa-se que a distribuição espectral se manteve estável ao longo dos 30 dias analisados, sem grandes variações na frequência dominante. As faixas pretas indicam períodos de

ausência de consumo, nos quais não há atividade hídrica registrada, ou dias que foram removidos da análise por apresentarem consumo real.

Nos intervalos ativos, nota-se a recorrência de faixas espectrais de alta energia, destacadas em tons amarelados, que correspondem às frequências previamente identificadas na análise espectral agregada (Figura 35). Esse comportamento confirma a persistência de um padrão cíclico de baixa vazão associado aos microvazamentos contínuos.

Outro aspecto relevante é a presença de pontos de maior intensidade dispostos verticalmente, formando colunas de tonalidade amarela mais brilhante. Esses agrupamentos indicam a ocorrência de múltiplas frequências harmônicas derivadas das componentes fundamentais, especialmente da faixa de 10 minutos. A presença de harmônicos no espectrograma é um fenômeno esperado em sinais periódicos e reforça a interpretação de que os microvazamentos geram oscilações consistentes e regulares ao longo do tempo.

Além disso, o espectrograma se mostra uma ferramenta particularmente útil para a observação de variações temporais nos padrões de consumo. Mudanças graduais na frequência dominante podem indicar uma alteração na taxa do microvazamento, por exemplo, um evento que inicialmente ocorria a cada 18 minutos (1 L) e, ao longo dos dias, passou a se repetir a cada 10 ou 2 minutos. Esse tipo de análise temporal permite não apenas confirmar a presença do vazamento, mas também inferir sua evolução e severidade com base na densidade e deslocamento das faixas espectrais.


Assim, o espectrograma complementa a análise baseada no Δmag ao fornecer uma visão dinâmica do comportamento espectral ao longo do tempo, permitindo detectar tanto microvazamentos estáveis quanto possíveis variações progressivas na sua intensidade.

6.5.4 Comparação com Outros Conjuntos de Dados

Para validar a consistência do método proposto, a mesma análise espectral foi aplicada sobre os conjuntos de dados secundários de (Kulikovas; Packevičius, 2023) e (Mauro *et al.*, 2019). Em ambos os casos, não foram detectadas frequências dominantes associadas a padrões de microvazamento, como mostra a Figura 37.

Os espectros de ambos os conjuntos apresentam magnitudes baixas e ausência de picos definidos, o que confirma a inexistência de padrões cíclicos de consumo característicos de microvazamentos. Essa ausência de periodicidade é compatível com o comportamento esperado de consumo normal, sem vazões residuais contínuas.

Figura 37 – Análise espectral dos *datasets* de (Kulikovas; Packevičius, 2023) e (Mauro *et al.*, 2019), sem indícios de microvazamentos.



Fonte: Elaborado pelo autor.

Ao comparar essas respostas com o espectro obtido no *dataset* da dissertação (Figura 35), observa-se uma diferença expressiva na intensidade das componentes espectrais. Enquanto o sinal da Figura 35 atinge magnitude próxima de 0,02, evidenciando picos bem definidos associados às frequências fundamentais de 10 e 18 minutos, os *datasets* de (Kulikovas; Packevičius, 2023) e (Mauro *et al.*, 2019) não ultrapassam 0,005 e exibem um perfil essencialmente plano, sem qualquer concentração de energia espectral significativa.


Essa discrepância quantitativa reforça a capacidade do método proposto em distinguir contextos residenciais com microvazamentos daqueles com consumo normal, validando tanto a sensibilidade da abordagem espectral quanto sua robustez frente a variações de ruído e padrões de uso. Assim, o sistema demonstrou ser capaz de analisar e identificar, de forma autônoma e confiável, assinaturas de vazamento mesmo em séries temporais de baixa amplitude e alta estabilidade.

6.5.5 Validação no Sistema Integrado

A detecção automática de microvazamentos foi incorporada ao sistema, que integra os módulos de aquisição, armazenamento e análise de dados. O sistema realiza inferências em tempo real sobre as séries temporais recebidas gerenciadas pelo FIWARE e atualiza automaticamente o status da residência conforme o resultado da análise.

A Figura 38 ilustra a interface do sistema em duas condições distintas: uma em que o consumo foi considerado normal (*dataset* de (Kulikovas; Packevičius, 2023)), e outra em que o módulo analítico identificou um possível microvazamento (dados colhidos integralmente pela infraestrutura dessa dissertação).

Figura 38 – Interface do sistema *Smart Water Monitor* mostrando a atualização automática do status de microvazamento.



(a) Status: *Normal*

(b) Status: *Possível microvazamento detectado*

Fonte: Elaborado pelo autor.

Quando a análise espectral identifica uma frequência dominante persistente e um valor de Δmag superior ao limiar configurado, o sistema altera automaticamente o status para “*Possível Microvazamento Detectado*”, sinalizado em amarelo. Esse processo ocorre de forma autônoma e imediata, garantindo resposta rápida sem necessidade de intervenção humana.

Nessa condição, o botão de análise torna-se clicável, permitindo ao usuário visualizar as informações detalhadas do evento detectado. Ao ser acionado, o sistema exibe a lista de picos espectrais identificados, incluindo os períodos em minutos e seus respectivos valores de intensidade (Δmag), conforme ilustrado na Figura 34. Além disso, o usuário pode acessar os

gráficos correspondentes ao espectro agregado e ao espectrograma temporal, que são gerados automaticamente a partir dos dados coletados.

Essa funcionalidade torna o sistema não apenas reativo, mas também exploratório, permitindo que o usuário compreenda a origem e a periodicidade dos microvazamentos detectados. A apresentação direta dos picos e das representações gráficas facilita a análise visual do comportamento do consumo, reforçando a transparência e a interpretabilidade da camada analítica integrada ao sistema.

6.5.6 Síntese dos resultados

Os resultados obtidos confirmam a eficácia da abordagem espectral proposta na identificação de microvazamentos contínuos e de baixa magnitude em séries temporais de consumo hídrico. A análise baseada na STFT demonstrou capacidade de distinguir padrões cíclicos sutis que passam despercebidos por métodos puramente estatísticos, evidenciando sua relevância como complemento à detecção tradicional de vazamentos.

A identificação de cinco frequências fundamentais, com destaque para o ciclo dominante de 10 minutos e intensidade espectral de $\Delta mag = 0,0038$, revelou a presença de microvazamentos persistentes que, ao longo de 30 dias, resultaram em um volume acumulado de 317 litros de perda. A consistência dessas componentes ao longo do tempo, observada no espectrograma, demonstra que o método é capaz de capturar assinaturas estáveis de consumo residual e monitorar sua evolução.

Em contrapartida, os resultados obtidos sobre os conjuntos de dados de (Kulikovas; Packevičius, 2023) e (Mauro *et al.*, 2019) apresentaram espectros planos e sem picos definidos, com magnitudes inferiores a 0,005, confirmando a ausência de vazamentos e validando a seletividade do método. Essa diferença quantitativa reforça a sensibilidade da análise espectral, que responde de forma clara apenas a variações periódicas consistentes, minimizando falsos positivos e ruídos de medição.

Do ponto de vista prático, a integração da detecção de microvazamentos ao sistema IoT permitiu a automatização completa do processo, com atualização instantânea do status na interface web. O sistema interpreta os resultados da análise espectral e sinaliza automaticamente o estado de “possível microvazamento detectado”, tornando o botão de análise interativo para consulta detalhada dos picos e gráficos correspondentes. Essa interação em tempo real transforma o módulo analítico em uma ferramenta explicativa, que não apenas detecta anomalias, mas

também fornece subsídios visuais para sua compreensão.

Em síntese, os resultados demonstram que a camada espectral acrescenta um nível adicional de inteligência ao sistema, possibilitando a detecção de microvazamentos invisíveis à inspeção convencional e fortalecendo a proposta de monitoramento autônomo, interpretável e de baixo custo operacional para gestão hídrica residencial.

6.6 Síntese Integrada dos Resultados

Os resultados apresentados neste capítulo demonstraram a consolidação da arquitetura IoT proposta, validando seu desempenho em todas as camadas, do hardware de baixo consumo à análise inteligente de dados. O sistema mostrou-se funcional, eficiente e escalável, atendendo plenamente aos objetivos definidos nesta dissertação.

Em termos técnicos, o novo protótipo alcançou reduções expressivas de consumo, operando com potência média inferior a 1 mW e apresentando desempenho estável em longos períodos de operação. O firmware *bare-metal* e o uso do transceptor SX1262 obtiveram os melhores resultados no ganho de eficiência energética, garantindo autonomia prolongada e viabilidade de operação com *energy harvesting*.

No campo analítico, o modelo *Elliptic Envelope* e a análise espectral baseada na STFT permitiram detectar desde vazamentos expressivos até microvazamentos de baixa magnitude, demonstrando robustez, precisão e aplicabilidade em cenários reais. A integração desses métodos à infraestrutura FIWARE viabilizou um fluxo contínuo de coleta, processamento e inferência, resultando em um sistema analítico autônomo e interpretável.

Sob a perspectiva econômica, o protótipo desenvolvido alia baixo custo de fabricação (aproximadamente US\$ 14,42) a um consumo energético mínimo, configurando-se como uma alternativa viável e sustentável frente a soluções comerciais mais onerosas. Essa relação entre custo, eficiência e replicabilidade reforça o potencial do sistema para aplicações em larga escala, tanto em contextos residenciais quanto municipais.

De modo geral, a proposta consolida-se como uma plataforma IoT completa, integrando hardware eficiente, comunicação confiável e análise inteligente em um sistema de baixo custo e alto impacto prático.

7 CONCLUSÕES E TRABALHOS FUTUROS

No presente trabalho, foi desenvolvido e avaliado um sistema IoT completo para o monitoramento inteligente do consumo hídrico residencial, com foco na detecção de vazamentos e microvazamentos por meio de técnicas de aprendizado de máquina e análise espectral. A arquitetura proposta integra três camadas principais: um nó sensor de ultra baixo consumo energético, uma infraestrutura de comunicação LoRaWAN conectada à plataforma FIWARE e uma camada analítica para detecção automática de anomalias.

A partir da revisão da literatura, identificou-se a ausência de soluções que combinassem um hardware eficiente e de baixo custo com métodos de análise aplicados à detecção de vazamentos de água residencial. Diante dessa lacuna, este trabalho propôs e implementou uma arquitetura completa de monitoramento hídrico inteligente, abrangendo desde o desenvolvimento do protótipo físico de baixo consumo até a infraestrutura de comunicação LoRaWAN e a camada analítica de detecção de vazamentos. Essa integração permitiu coletar, transmitir e processar dados de consumo em tempo real, demonstrando a viabilidade técnica e científica da IoT como ferramenta de suporte à gestão hídrica inteligente.

7.1 Considerações Finais

Os resultados obtidos consolidam a validação científica e prática da arquitetura desenvolvida, que combina hardware de baixo consumo, aprendizado de máquina e análise espectral na detecção de vazamentos e microvazamentos. Sob a perspectiva tecnológica, a comparação entre as versões de hardware e software revelou diferenças substanciais no consumo energético e na eficiência operacional. A substituição do microcontrolador STM32F030C8T6 pelo STM32L031F6P6 e do transceptor SX1276 pelo SX1262, aliada à implementação *bare-metal*, reduziu o consumo médio de potência em aproximadamente 98,6% em relação ao modelo anterior e em 64% frente à versão em Arduino, atingindo valores inferiores a 1 mW. Esses resultados demonstram que as decisões de arquitetura e otimização de software têm impacto direto na autonomia e na viabilidade prática de sistemas IoT voltados à operação contínua e de longo prazo.

No campo analítico, a aplicação do modelo *Elliptic Envelope* evidenciou a eficiência do aprendizado de máquina não supervisionado na detecção de padrões anômalos em consumo hídrico. Com *F1-score* médio de 0,87, o modelo mostrou-se robusto, leve e adaptável a diferentes

contextos residenciais. Complementarmente, a análise espectral por meio da STFT permitiu identificar microvazamentos contínuos e de baixa magnitude, não perceptíveis no domínio temporal ou por métodos tradicionais. A detecção de frequências dominantes, como o ciclo de 10 minutos, confirmou a sensibilidade da abordagem, que revelou perdas acumuladas de 317 litros ao longo de 30 dias.

Do ponto de vista social e ambiental, o sistema proposto contribui para a redução do desperdício e para o uso racional dos recursos hídricos, possibilitando ações preventivas e reduzindo custos operacionais. Em larga escala, sua aplicação pode apoiar concessionárias e gestores públicos na implementação de políticas de eficiência hídrica, impactando positivamente o planejamento urbano e a preservação dos mananciais.

Em síntese, esta dissertação apresentou e validou uma solução inovadora que combina avanços em hardware, software e camadas analíticas baseadas em aprendizado de máquina e análises espectrais. A arquitetura proposta representa uma contribuição relevante para a literatura e para o contexto prático, ao demonstrar a viabilidade de ecossistemas inteligentes, sustentáveis e energeticamente eficientes de monitoramento hídrico.

7.2 Trabalhos Futuros

Como desdobramentos desta pesquisa, diversos caminhos podem ser explorados para aprimorar e expandir o sistema proposto. Entre as possibilidades mais promissoras, destacam-se:

- Integração de inteligência embarcada: incorporar algoritmos de aprendizado de máquina diretamente no nó IoT, permitindo a detecção de vazamentos localmente, sem depender da conectividade LoRaWAN, reduzindo latência.
- Validação em larga escala: realizar testes prolongados em diferentes residências, condições climáticas e perfis de consumo, avaliando a robustez do sistema em ambientes reais e sua adaptabilidade a padrões diferentes de uso da água.
- Exploração de novas técnicas espectrais: investigar o uso de abordagens alternativas à STFT, como a Transformada Wavelet, visando aprimorar a detecção de microvazamentos por meio de uma análise multi-resolução capaz de capturar variações sutis de frequência ao longo do tempo.
- Expansão da arquitetura FIWARE: integrar novos sensores para colheita de dados, por exemplo meteorológicos ou de pressão da rede para aprimorar ainda mais a detecção de vazamentos.

- Integração com ecossistemas de *Digital Twin*: desenvolver uma representação virtual do ambiente monitorado, sincronizada em tempo real com os dados coletados pelo sistema físico. Essa integração permitiria simular cenários de consumo, prever falhas, otimizar a manutenção e aprimorar o planejamento hídrico urbano.
- Uso de agentes inteligentes para decisão autônoma: implementar uma camada multiagente capaz de analisar os dados do consumo em tempo real e executar ações automatizadas, como ajuste de alertas, recomendação de intervenções ou controle de válvulas inteligentes, tornando o sistema mais adaptativo e proativo.
- Aplicação em sistemas de macromedição: estender a arquitetura proposta para o monitoramento de trechos da rede de distribuição, reservatórios e pontos de saída das concessionárias, visando a detecção de vazamentos estruturais e perdas não visíveis antes da chegada à micromedição residencial.

Essas direções de pesquisa representam a continuidade natural deste trabalho, voltada à consolidação de sistemas IoT de monitoramento hídrico cada vez mais inteligentes, autônomos e sustentáveis, capazes de contribuir de forma efetiva para a preservação dos recursos naturais e a modernização dos serviços de abastecimento de água no Brasil.

REFERÊNCIAS

AHMAD, Z.; KHAN, A.; ZEN, K.; AHMAD, F. Ms-ads: Multistage spectrogram image-based anomaly detection system for iot security. **Transactions on Emerging Telecommunications Technologies**, Wiley-Blackwell, v. 34, n. 8, ago. 2023. ISSN 1124-318X. Funding Information: This research was fully funded by Universiti Malaysia Sarawak, Kota Samarahan, Malaysia under grant number F08/PGRG/2058/2021. Publisher Copyright: © 2023 The Authors. Transactions on Emerging Telecommunications Technologies published by John Wiley & Sons Ltd.

AL-FUQAHA, A.; GUIZANI, M.; MOHAMMADI, M.; ALEDHARI, M.; AYYASH, M. Internet of things: A survey on enabling technologies, protocols, and applications. **IEEE Communications Surveys & Tutorials**, IEEE, v. 17, n. 4, p. 2347–2376, 2015.

ALLEN, J. Short term spectral analysis, synthesis, and modification by discrete fourier transform. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 25, n. 3, p. 235–238, 1977.

ANA. **Conjuntura dos Recursos Hídricos no Brasil 2024**. ANA, 2024. Disponível em: <https://www.ana.gov.br>. Acesso em: 15 jan. 2025.

ARAÚJO, Í. B. Q. d. **Sistema detector de vazamentos em instalações prediais de água fria**. 57 f. p. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Norte (UFRN), Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Natal, RN, janeiro 2015. Dissertação (Mestrado) - Área de Concentração: Automação e Sistemas. Orientador: Prof. Dr. André Laurindo Maitelli.

ASHTON, K. That 'internet of things' thing. **RFID Journal**, v. 22, n. 7, p. 97–114, 2009.

ATZORI, L.; IERA, A.; MORABITO, G. The internet of things: A survey. **Computer Networks**, Elsevier, v. 54, n. 15, p. 2787–2805, 2010.

AYATULLAH, M. D.; WIBOWO, G. H.; FEBRITA, R. E.; PRASETYO, J. A.; SAROSA, M.; HAPSARI, R. I. Smart water meter based on lora communication technology. In: INTERNATIONAL CONFERENCE ON ADVANCED MECHATRONICS, INTELLIGENT MANUFACTURE AND INDUSTRIAL AUTOMATION (ICAMIMIA), 2023, Surabaya, Indonesia. **Proceedings [...]**. Piscataway, NJ, USA: IEEE, 2023.

BADAR, S.; LABGHOUGH, S.; AL-ABDULGHANI, A.; MOHAMMED, E.; BOUHALI, O.; QARAQE, K. A. Machine learning assisted approach for water leaks detection. In: INTERNATIONAL CONFERENCE ON INFORMATION NETWORKING (ICOIN), 37., 2023, Bangkok, Tailândia. **Proceedings [...]**. Piscataway, NJ, USA: IEEE, 2023. p. 433–437.

BENINI, L.; BOGLIOLO, A.; MICHELI, G. D. A survey of design techniques for system-level dynamic power management. **IEEE Transactions on Very Large Scale Integration (VLSI) Systems**, v. 8, n. 3, p. 299–316, 2000.

BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. In: **Journal of machine learning research**. [S. l.: s. n.], 2012. v. 13, n. 2, p. 281–305.

BEZERRA, S. d. T. M.; CHEUNG, P. B. **Perdas de Água**: Tecnologias de controle. João Pessoa: Editora da UFPB, 2013. ISBN 978-85-237-0701-9.

BOASHASH, B. Time-frequency signal analysis and processing: A comprehensive reference. 01 2003.

CABRAL, R.; GONÇALVES, R.; MENEZES, M.; AGUILAR, P.; STANCANELLI, E.; CALLADO, A.; GONÇALVES, E. Unsupervised water leakage detection using iot devices and anomaly detection algorithms. In: SYMPOSIUM ON KNOWLEDGE DISCOVERY, MINING AND LEARNING (KDMILE), 13., 2025, Fortaleza/CE. **Anais [...]**. Porto Alegre: Sociedade Brasileira de Computação, 2025. p. 41–48. ISSN 2763-8944. Disponível em: <https://sol.sbc.org.br/index.php/kdmile/article/view/37207>. Acesso em: 08 out. 2025.

CABRAL, R. A.; C., P. A.; BONFIM, M. S.; COUTINHO, E. F. Desempenho energético no freertos com paralelismo em relação a sistema sequencial em um protótipo de hidrômetro lora. In: SEMINÁRIO INTEGRADO DE SOFTWARE E HARDWARE (SEMISH), 52., 2025, Maceió/AL. **Anais [...]**. Porto Alegre: Sociedade Brasileira de Computação, 2025. p. 179–190. ISSN 2595-6205. Disponível em: <https://sol.sbc.org.br/index.php/semish/article/view/36808>. Acesso em: 01 ago. 2025.

CABRAL, R. de A. **Um Estudo sobre a eficiência energética em sistemas IoT com diversidades de duplicação de pacotes**. Monografia (Trabalho de Conclusão de Curso (Graduação em Engenharia de Computação)) – Universidade Federal do Ceará, Quixadá, 2019. Disponível em: <http://repositorio.ufc.br/handle/riufc/49737>. Acesso em: 05 maio 2025.

CELESTI, A.; FAZIO, M.; MÁRQUEZ, F. G.; GLIKSON, A.; MAUWA, H.; BAGULA, A.; CELESTI, F.; VILLARI, M. How to develop iot cloud e-health systems based on fiware: A lesson learnt. **Journal of Sensor and Actuator Networks**, v. 8, n. 1, 2019. ISSN 2224-2708. Disponível em: <https://www.mdpi.com/2224-2708/8/1/7>.

CHANDOLA, V.; BANERJEE, A.; KUMAR, V. Anomaly detection: A survey. **ACM Computing Surveys**, ACM, v. 41, n. 3, p. 1–58, 2009.

CIRILLO, F.; SOLMAZ, G.; BERZ, E. L.; BAUER, M.; CHENG, B.; KOVACS, E. A standard-based open source iot platform: Fiware. **IEEE Internet of Things Magazine**, IEEE, v. 2, p. 12–18, 2020.

COHEN, L. **Time-Frequency Analysis**. [S. l.]: Prentice Hall, 1995.

COSTA, D. F.; SOARES, A. K. Costs and impacts of a smart metering program in a water distribution system: Case study in Brasília, Brazil. **Environmental Sciences Proceedings**, MDPI, v. 2, n. 1, p. 7, 2020. Presented at the 4th EWaS International Conference: Valuing the Water, Carbon, Ecological Footprints of Human Activities, Online, 24–27 June 2020. Disponível em: <https://www.mdpi.com/2673-4931/2/1/7>.

CRATE.IO GMBH. **CrateDB**: Distributed sql database for iot and time-series data. [S. l.], 2024. Disponível em: <https://cratedb.com/docs/>. Acesso em: 05 nov. 2025.

CRATE.IO GMBH. **PostgreSQL Wire Protocol — CrateDB Documentation**. 2025. Disponível em: <https://cratedb.com/docs/crate/reference/en/latest/interfaces/postgres.html>. Acesso em: 18 out. 2025.

CUMPS, J. **Set up Elecrow TTN LoRaWAN gateway on Raspberry Pi**. 2023. Element14 Community blog. Disponível em: <https://community.element14.com/technologies/internet-of-things/b/blog/posts/set-up-elecrow-ttn-lorawan-gateway-on-raspberry-pi>. Acesso em: 22 jun. 2025.

EIDAKS, J.; LITVINENKO, A.; ABOLTINS, A.; PIKULINS, D. Signal waveform impact on efficiency of low power harvesting devices in wsn. In: **2019 IEEE Microwave Theory and Techniques in Wireless Communications (MTTW)**. [S. l.: s. n.], 2019. v. 1, p. 57–61.

ELECROW. **LR1302 868M/915M LoRaWAN HAT for RPI Datasheet**. 2025. Versão 1.0. Disponível em: <https://www.elecrow.com/lr1302-868m-915m-lorawan-hat-for-rpi-sx1302-long-range-module-support-rpi-1-2-3-4-5-series.html>. Acesso em: 27 out. 2025.

FELINTO FILHO, G. G. **Sistema automatizado de macromedição para redes de abastecimento de água**. 81 f. p. Dissertação (Dissertação (Mestrado em Recursos Naturais)) – Programa de Pós-Graduação em Recursos Naturais, Centro de Tecnologia e Recursos Naturais, Universidade Federal de Campina Grande, Paraíba, Brasil, 2023. Disponível em: <https://dspace.sti.ufcg.edu.br/bitstream/riufcg/32603/1/GENILSON%20GOMES%20FELINTO%20FILHO%20-DISSERTAC%C3%83O%20%28PPGEGRN%29%202023.pdf>. Acesso em: 16 jan. 2025.

FIWARE Foundation. **FIWARE QuantumLeap - Time Series Data Management**. [S. l.], 2024. Disponível em: <https://quantumleap.readthedocs.io/>. Acesso em: 05 nov. 2025.

FIWARE FOUNDATION. **About Us**. 2025. Disponível em: <https://www.fiware.org/about-us/>. Acesso em: 26 jun. 2025.

FIWARE KEYROCK. **Keyrock - FIWARE Identity Management**. 2025. Disponível em: <https://fiware-idm.readthedocs.io/en/latest/>. Acesso em: 26 jun. 2025.

GUBBI, J.; BUYYA, R.; MARUSIC, S.; PALANISWAMI, M. Internet of things (iot): A vision, architectural elements, and future directions. **Future Generation Computer Systems**, v. 29, n. 7, p. 1645–1660, 2013. ISSN 0167-739X. Including Special sections: Cyber-enabled Distributed Computing for Ubiquitous Cloud and Network Services & Cloud Computing and Scientific Applications — Big Data, Scalable Analytics, and Beyond. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0167739X13000241>. Acesso em: 15 fev. 2025.

GUEZOULI, L.; GUEZOULI, L.; DJEGHABA, M.; BENTAHROUR, A. Iot and ai for real-time water monitoring and leak detection. **Journal of Renewable Energies**, v. 27, 12 2024.

GUTH, J.; BREITENBÜCHER, U.; FALKENTHAL, M.; LEYMAN, F.; REINFURT, L. Comparison of iot platform architectures: A field study based on a reference architecture. In: **IEEE INTERNATIONAL CONFERENCE ON CLOUD AND BIG DATA COMPUTING (CBDCCOM)**, 2., 2016, Toulouse, França. **Proceedings [...]**. Piscataway, NJ, USA: IEEE, 2016. p. 1–6.

HAN, J.; KAMBER, M.; PEI, J. **Data Mining: Concepts and techniques**. 3rd. ed. Waltham, Mass: Morgan Kaufmann, 2012.

HARIRI, S.; KIND, M. C.; BRUNNER, R. J. Extended isolation forest. **IEEE Transactions on Knowledge and Data Engineering**, v. 33, n. 4, p. 1479–1489, 2021.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data mining, inference, and prediction**. 2. ed. New York: Springer, 2009. ISBN 978-0-387-84857-0. Disponível em: <https://web.stanford.edu/~hastie/ElemStatLearn/>. Acesso em: 14 set. 2025.

HÖLLER, J.; TSIATSIS, V.; MULLIGAN, C.; AVESAND, S.; KARNOUSKOS, S.; BOYLE, D. **From Machine-to-Machine to the Internet of Things**: Introduction to a new age of intelligence. Amsterdam / Boston: Elsevier, 2014. ISBN 978-0-12-407684-6.

HUSSAIN, M.; SAQIB, M. Internet of things: Architecture, applications and challenges. **International Journal of Computer Applications**, v. 174, p. 975–8887, 04 2021.

IE TECNOLOGIA LTDA. **SM-LA Medidor de Água LoRaWAN – Catálogo e ficha técnica**. 2025. Disponível em: <https://www.ietecnologia.com/medidor-de-agua/conectividade-lorawan/medidor-de-agua-lorawan-sm-la>. Acesso em: 10 nov. 2025.

INSTITUTO TRATA BRASIL. **Estudo de Perdas de Água 2024**: Desafios e oportunidades para o avanço do saneamento no brasil. 2024. Disponível em: <https://tratabrasil.org.br/perdas-de-agua-2024/>. Acesso em: 20 maio 2024.

INTERNATIONAL TELECOMMUNICATION UNION. **Harnessing the Internet of Things for Global Development**. [S. l.], 2021. Disponível em: <https://www.itu.int/en/action/broadband/documents/harnessing-iot-global-development.pdf>. Acesso em: 31 maio 2025.

JOUHARI, M.; SAEED, N.; ALOUINI, M.-S.; AMHOUD, E. M. A survey on scalable lorawan for massive iot: Recent advances, potentials, and challenges. **IEEE Communications Surveys & Tutorials**, v. 25, n. 3, p. 1841–1876, 2023.

KAMSTRUP A/S. **LoRaWAN Smart Water Metering**. 2025. Disponível em: <https://www.kamstrup.com/en-en/insights/lorawan-smart-water-metering>. Acesso em: 10 nov. 2025.

KHERNANE, S.; BOUAM, S.; ARAR, C. Renewable energy harvesting for wireless sensor networks in precision agriculture. **International Journal of Networked and Distributed Computing**, v. 12, p. 8–16, 2024.

KULIKOVAS, L.; PACKEVIČIUS, Š. Anomalous water use detection using machine learning. In: **Information Society and University Studies (IVUS)**. Kaunas, Lithuania: [S. n.], 2023. Disponível em: <https://epubl.ktu.edu/object/elaba:184885406/index.html>. Acesso em: 03 fev. 2025.

LAMBERT, A. **What do we know about pressure**: Leakage relationships in distribution systems? 2001. 8 p.

LI, J. **Federated anomaly detection with isolation forest in the IoT network**. Dissertação (Master of Research Thesis) – Macquarie University, Sydney, Australia, 2023. Disponível em: <https://www.mq.edu.au/>. Acesso em: 20 nov. 2025.

LIMA, B. J.; SILVA, L. M.; HORTA, D. M. Micro e/ou mini central hidrelétrica na geração de energia distribuída. In: SIMPÓSIO DE TCC DAS FACULDADES FINOM E TECSOMA, 1., 2019, Minas Gerais. **Anais [...]**. Minas Gerais: FINOM; Tecsoma, 2019. p. 1231–1248. Disponível em: <https://finom.edu.br/assets/uploads/cursos/tcc/2021042218043616.pdf>. Acesso em: 17 out. 2025.

LIN, J.; YU, W.; ZHANG, N.; YANG, X.; ZHANG, H.; ZHAO, W. A survey on internet of things: Architecture, enabling technologies, security and privacy, and applications. **IEEE Internet of Things Journal**, v. 4, n. 5, p. 1125–1142, 2017.

LIU, F. T.; TING, K. M.; ZHOU, Z.-H. Isolation forest. In: IEEE INTERNATIONAL CONFERENCE ON DATA MINING (ICDM), 8., 2008, Pisa, Itália. **Proceedings [...]**. Piscataway, NJ, USA: IEEE Computer Society, 2008. p. 413–422.

LIYA, M.; ASWATHY, M. Lora technology for internet of things(iot):a brief survey. In: **2020 Fourth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)**. [S. l.: s. n.], 2020. p. 8–13.

LÓPEZ-RIQUELME, J.; PAVÓN-PULIDO, N.; NAVARRO-HELLÍN, H.; SOTO-VALLES, F.; TORRES-SÁNCHEZ, R. A software architecture based on fiware cloud for precision agriculture. **Agricultural Water Management**, v. 183, p. 123–135, 2017. ISSN 0378-3774. Special Issue: Advances on ICTs for Water Management in Agriculture. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378377416304061>. Acesso em: 14 abr. 2025.

LUDELMIR, T. B. Inteligência artificial e aprendizado de máquina: estado atual e tendências. **Estudos Avançados**, SciELO Brasil, v. 35, n. 101, p. 99–118, jan-abr 2021. Disponível em: <https://www.scielo.br/j/ea/a/wXBdv8yHBV9xHz8qG5RCgZd>. Acesso em: 21 maio 2025.

MAGALHÃES, A. R. C. **Perdas de água no sistema de abastecimento de Salvador/BA: políticas de redução – bases para proposta de um projeto de lei**. Tese (Doutorado) – Universidade Salvador – UNIFACS, Salvador, BA, Brasil, 2017. Disponível em: <http://tede.unifacs.br/tede/handle/tede/723>.

MANORATHNA, R. **Two Outlier Detection Techniques You Should Know in 2021**. 2021. Disponível em: <https://towardsdatascience.com/two-outlier-detection-techniques-you-should-know-in-2021-1454bef89331/>. Acesso em: 13 jun. 2025.

MAURO, A. D.; NARDO, A. D.; SANTONASTASO, G. F.; VENTICINQUE, S. An iot system for monitoring and data collection of residential water end-use consumption. In: INTERNATIONAL CONFERENCE ON COMPUTER COMMUNICATION AND NETWORKS (ICCCN), 28., 2019, Valência, Espanha. **Proceedings [...]**. Piscataway, NJ, USA: IEEE, 2019. p. 1–6.

MEHTA, S.; ANEJA, A. Smart water management in agriculture: Iot solutions for reducing water consumption. In: INTERNATIONAL CONFERENCE ON RECENT TRENDS IN MICROELECTRONICS, AUTOMATION, COMPUTING AND COMMUNICATIONS SYSTEMS (ICMACC), 2., 2024, Hyderabad, Índia. **Proceedings [...]**. Piscataway, NJ, USA: IEEE, 2024.

MICROPHONON. **AquaPing**: Open-source, battery powered stand-off acoustic water leak detection. 2022. Funded Sep 16 2022 via Crowd Supply; open-source sensor for acoustic detection of pressurized water leaks behind walls. Disponível em: <https://www.crowdsupply.com/micophonon/aquaping>. Acesso em: 08 out. 2025.

MIGABO, E.; DJOUANI, K.; KURIEN, A. Design of an energy efficient lorawan-based smart iot water meter for african municipalities. In: INTERNATIONAL CONFERENCE ON ELECTRICAL, COMPUTER AND ENERGY TECHNOLOGIES (ICECET), 1., 2021, Cidade do Cabo, África do Sul. **Proceedings [...]**. Piscataway, NJ, USA: IEEE, 2021.

MILAROKOSTAS, C.; TSOLKAS, D.; PASSAS, N.; MERAKOS, L. A comprehensive study on lpwans with a focus on the potential of lora/lorawan systems. **IEEE Communications Surveys & Tutorials**, v. 25, n. 1, p. 825–867, 2023.

MINISTÉRIO DO DESENVOLVIMENTO REGIONAL. **Portaria nº 490, de 22 de março de 2021**. 2021. Estabelece os procedimentos gerais para o cumprimento de índices de perda de água na distribuição. Publicado no Diário Oficial da União em 23 de março de 2021. Disponível em: <https://www.in.gov.br/en/web/dou/-/portaria-n-490-de-22-de-marco-de-2021-309988760>. Acesso em: 16 fev. 2025.

MOHAMED, M. I.; WU, W. Y.; MONIRI, M. Power harvesting for smart sensor networks in monitoring water distribution system. In: INTERNATIONAL CONFERENCE ON NETWORKING, SENSING AND CONTROL (ICNSC), 2011. **Proceedings [...]**. Piscataway, NJ, USA: IEEE, 2011. p. 393–398.

MOMOTE, V. **Modelos de comunicação para IoT**. 2016. Disponível em: <https://embarcados.com.br/modelos-de-comunicacao-para-iot/>. Acesso em: 26 jun. 2025.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. In: REZENDE, S. O. (Ed.). **Sistemas inteligentes: fundamentos e aplicações**. Barueri, SP: Manole, 2003. p. 89–114.

MONTGOMERY, D.; RUNGER, G. **Applied Statistics and Probability for Engineers**. John Wiley & Sons, 2010. ISBN 9780470053041. Disponível em: https://books.google.com.br/books?id=_f4KrEcNAfEC.

NATIONAL INSTRUMENTS CORPORATION. **LabVIEW Advanced Signal Processing Toolkit — API Reference**. Austin, TX, USA, 2023. Version 2023. Disponível em: <https://www.ni.com/docs/en-US/bundle/labview-asp-toolkit-api-reference/page/>. Acesso em: 03 jun. 2025.

NGUYEN, D. C.; DING, M.; PATHIRANA, P. N.; SENEVIRATNE, A.; LI, J.; NIYATO, D.; DOBRE, O.; POOR, H. V. 6g internet of things: A comprehensive survey. **IEEE Internet of Things Journal**, v. 9, n. 1, p. 359–383, 2022.

OPPENHEIM, A.; WILLISKY, A.; NAWAB, S. **Signals & Systems**. PHI Learning Private Limited, 2010. Disponível em: <https://books.google.com.br/books?id=y-I9nwEACAAJ>. Acesso em: 04 jun. 2025.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS. **Objetivo de Desenvolvimento Sustentável 6: Água potável e saneamento**. 2023. Disponível em: <https://brasil.un.org/pt-br/sdgs/6>. Acesso em: 31 maio 2025.

ORTIZ, F. M.; ALMEIDA, T.; FERREIRA, A. E.; COSTA, L. H. Caracterização de desempenho de uma rede lora em ambientes urbanos: Simulação vs. prática. In: WORKSHOP DE COMPUTAÇÃO URBANA, 3., 2019, Gramado, RS, Brasil. **Anais [...]**. Porto Alegre, RS, Brasil: SBC, 2019. p. 167–180. ISSN 2595-2706. Disponível em: <https://sol.sbc.org.br/index.php/courb/article/view/7476>.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E.

Scikit-learn: Machine learning in python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

PREDESCU, A.; MOCANU, M.; LUPU, C. A modern approach for leak detection in water distribution systems. In: INTERNATIONAL CONFERENCE ON SYSTEM THEORY, CONTROL AND COMPUTING (ICSTCC), 22., 2018, Sinaia, Romênia. **Proceedings [...]**. Piscataway, NJ, USA: IEEE, 2018. p. 486–491.

PRIYA, S.; INMAN, D. **Energy harvesting technologies**. United States: Springer US, 2009. ISBN 9780387764634.

PROVOST, F.; FAWCETT, T. **Data Science for Business: What you need to know about data mining and data-analytic thinking**. [S. l.]: O'Reilly Media, 2013. ISBN 978-1449361327.

RAMÍREZ, S. **FastAPI — Modern, Fast (high-performance), web framework for building APIs with Python**. 2025. Disponível em: <https://fastapi.tiangolo.com/>. Acesso em: 18 out. 2025.

RODRIGUEZ, M. A.; CUENCA, L.; ORTIZ, A. Fiware open source standard platform in smart farming - a review. In: CAMARINHA-MATOS, L. M.; AFSARMANESH, H.; REZGUI, Y. (Ed.). **Collaborative Networks of Cognitive Systems**. Cham: Springer International Publishing, 2018. p. 581–589. ISBN 978-3-319-99127-6.

SANTOS, M. M.; FRANCO, M. L.; ALVES, W. M.; SOUZA, M. C. de; BARROS, G. F.; SILVA, M. M. da. Internet das coisas: a busca do conceito e as perspectivas futuras sobre sua aplicabilidade. **Research, Society and Development**, v. 10, n. 10, p. e140101018504, 2021.

SECRETARIA NACIONAL DE SANEAMENTO AMBIENTAL. **Diagnóstico Temático: Visão geral do abastecimento de Água e esgotamento sanitário no Brasil**. 2023. Sistema Nacional de Informações sobre Saneamento (SNIS), Ministério das Cidades. Disponível em: https://www.gov.br/cidades/pt-br/aceso-a-informacao/acoes-e-programas/saneamento/snis/produtos-do-snis/diagnosticos/DIAGNOSTICO_TEMATICO_VISAO_GERAL_AE_SNIS_2023.pdf. Acesso em: 09 jun. 2025.

SELVAPRAKASH, J.; ARASU, P. K.; XAVIER, V. S.; MARIA, O. R. R.; MANIMEGALAI, M.; SEBASTHIRANI, K. Water leakage detection and recognition system. In: INTERNATIONAL CONFERENCE ON INTELLIGENT DATA COMMUNICATION TECHNOLOGIES AND INTERNET OF THINGS (IDCIOT), 3., 2025, Bengaluru, Índia. **Proceedings [...]**. Piscataway, NJ, USA: IEEE, 2025. p. 1020–1028.

SINGH, S. **How LPWAN is Powering the Next Generation of Smart Sensors**. AZoSensors, 2025. Disponível em: <https://www.azosensors.com/article.aspx?ArticleID=3199>. Acesso em: 13 jun. 2025.

SINHA, S. **State of IoT 2024: Number of connected IoT devices growing 13% to 18.8 billion globally**. 2024. Disponível em: <https://iot-analytics.com/number-connected-iot-devices/>. Acesso em: 12 jun. 2025.

SOUZA, R. G.; BARBOSA, A.; MEIRELLES, G. The water–energy nexus of leakages in water distribution systems. **Water**, v. 15, n. 22, 2023. ISSN 2073-4441. Disponível em: <https://www.mdpi.com/2073-4441/15/22/3950>.

TARDELLI FILHO, J. Controle de perdas aparentes: Tecnologias de controle. In: TSUTIYA, M. T.; BARROS, M. T.; CARVALHO, G. (Ed.). **Perdas de Água**. São Paulo: ABES – Associação Brasileira de Engenharia Sanitária e Ambiental, 2006. p. 457–525.

THE THINGS NETWORK. **LoRaWAN Architecture**. 2024. Disponível em: <https://www.thethingsnetwork.org/docs/lorawan/architecture/>. Acesso em: 26 jun. 2025.

THENMOZHI, S.; SUMATHI, K.; ASOKAN, A.; PRIYANKA, B.; MAHESWAR, R.; JAYARAJAN, P. Iot based smart water leak detection system for a sustainable future. In: INTERNATIONAL CONFERENCE ON WIRELESS COMMUNICATIONS, SIGNAL PROCESSING AND NETWORKING (WISPNET), 6., 2021, Chennai, Índia. **Proceedings [...]**. Piscataway, NJ, USA: IEEE, 2021. p. 359–362.

TORRENCE, C.; COMPO, G. P. A practical guide to wavelet analysis. **Bulletin of the American Meteorological Society**, v. 79, n. 1, p. 61–78, 1998.

TORREPADULA, F. R. di; SOMMA, A.; BENEDICTIS, A. D.; MAZZOCCA, N. Smart ecosystems and digital twins: An architectural perspective and a fiware-based solution. **IEEE Software**, v. 42, n. 2, p. 38–46, 2025.

TRIOLA, M. **Elementary Statistics**. Addison-Wesley, 1992. (Elementary Statistics). ISBN 9780805376319. Disponível em: <https://books.google.com.br/books?id=567gAAAAMAAJ>.

TSAI, K.-L.; LEU, F.-Y.; YOU, I.; CHANG, S.-W.; HU, S.-J.; PARK, H. Low-power aes data encryption architecture for a lorawan. **IEEE Access**, v. 7, p. 146348–146357, 2019.

TSUTIYA, M.; BARROS, M.; CARVALHO, G. **Perdas de Água: Tecnologias de controle**. São Paulo: ABES – Associação Brasileira de Engenharia Sanitária e Ambiental, 2006.

WEISER, M. The computer for the 21st century. **IEEE Pervasive Computing**, v. 1, n. 1, p. 19–25, 2002.

XU, Z.; YANG, Y.; GAO, X.; HU, M. Dcfft-mtd: A multivariate time-series anomaly detection model based on dual-channel feature fusion. **Sensors**, v. 23, n. 8, 2023. ISSN 1424-8220. Disponível em: <https://www.mdpi.com/1424-8220/23/8/3910>.

ZHANG, H.; WANG, J.; QIAN, L.-B. Low input power management circuit for ambient energy harvesting. In: IEEE MTT-S INTERNATIONAL WIRELESS SYMPOSIUM (IWS), 7., 2020, Xangai, China. **Proceedings [...]**. Piscataway, NJ, USA: IEEE, 2020. p. 1–3.

ZHOU, H.; CHEN, Z.; XU, Q. A novel time-frequency feature fusion approach for fault detection in a marine main engine. **Journal of Marine Science and Engineering**, MDPI, v. 11, n. 8, p. 1577, 2023.

ZOURMAND, A.; HING, A.; HUNG, C.; ABDULREHMAN, M. Internet of things (iot) using lora technology. In: . [S. l.: s. n.], 2019. p. 324–330.

ZWETSLOOT, R. **LR1302 LoRaWAN HAT + Gateway Module Review**. 2024. Raspberry Pi Official Magazine. Disponível em: <https://magazine.raspberrypi.com/articles/lr1302-lorawan-hat-gateway-module-review>. Acesso em: 30 out. 2025.

APÊNDICE A – DOCKERFILE UTILIZADO NA INTEGRAÇÃO DO MIDDLEWARE COM O FIWARE

```
1 version: "3.8"
2
3 services:
4   mongo:
5     image: mongo:4.4
6     container_name: fiware-mongo
7     command: --nojournal
8     networks:
9       - fiware
10    volumes:
11      - mongo-data:/data/db
12    healthcheck:
13      test: ["CMD", "mongo", "--eval", "db.adminCommand('ping')"]
14      interval: 5s
15      timeout: 2s
16      retries: 5
17
18   orion:
19     image: fiware/orion
20     container_name: fiware-orion
21     depends_on:
22       mongo:
23         condition: service_healthy
24     ports:
25       - "1026:1026"
26     command: -dbURI mongoddb://mongo:27017 -httpTimeout 5000 -logLevel
27               DEBUG
28     networks:
29       - fiware
30
31   cratedb:
32     image: crate:4.5.1
33     container_name: fiware-cratedb
34     ports:
35       - "4200:4200"
36       - "5432:5432"
```

```

36     command: crate -Cauth.host_based.enabled=false -Ccluster.name=
        crate-cluster -Cnetwork.host=0.0.0.0 -Ccluster.blocks.
        read_only=false
37     networks:
38         - fiware
39     volumes:
40         - cratedb-data:/data
41     environment:
42         - CRATE_DB_USER=crate
43         - CRATE_DB_PASSWORD=crate
44
45     quantumleap:
46         image: orchestracities/quantumleap:latest
47         container_name: fiware-quantumleap
48         depends_on:
49             - orion
50             - cratedb
51         ports:
52             - "8668:8668"
53         environment:
54             - CRATE_HOST=cratedb
55             - USE_CRATE=true
56             - CRATE_DB_USER=crate
57             - CRATE_DB_PASSWORD=crate
58         networks:
59             - fiware
60
61     device-connector:
62         build: .
63         container_name: fiware-connector
64         depends_on:
65             - orion
66             - quantumleap
67         ports:
68             - "5000:5000"
69         networks:
70             - fiware
71         environment:
72             - ORION_URL=http://orion:1026/v2/entities

```

```

73     - QUANTUMLEAP_URL=http://quantumleap:8668/v2/notify
74     - PYTHONUNBUFFERED=1
75     - WEBHOOK_SECRET_KEY=<KEY>
76
77 grafana:
78     image: grafana/grafana:latest
79     container_name: fiware-grafana
80     depends_on:
81     - cratedb
82     ports:
83     - "3000:3000"
84     networks:
85     - fiware
86     volumes:
87     - grafana-data:/var/lib/grafana
88
89 dashboard-frontend:
90     build: ./dashboard-frontend
91     container_name: website-dashboard
92     ports:
93     - "80:80"
94     depends_on:
95     - analysis-backend
96     - orion
97     networks:
98     - fiware
99
100 analysis-backend:
101     build: ./analysis-backend
102     container_name: ml-analysis-backend
103     ports:
104     - "8000:8000"
105     depends_on:
106     - orion
107     - cratedb
108     networks:
109     - fiware
110     command: ["uvicorn", "app:app", "--host", "0.0.0.0", "--port", "
      8000"]

```

```
111     volumes:
112         - ml-models:/app/models
113
114 networks:
115     fiware:
116
117 volumes:
118     mongo-data:
119     cratedb-data:
120     grafana-data:
121     ml-models:
```

APÊNDICE B – CÓDIGO UTILIZADO NA DECODIFICAÇÃO DE *PAYLOAD* NA TTN

```
1 function decodeUplink(input) {
2     // O payload e um array de 61 bytes.
3     let bytes = input.bytes;
4
5     // A ultima variavel (o estado de PA2) e o ultimo byte do
        array.
6     let vbatok = bytes[60];
7     let pulse = bytes[61];
8
9     // Os 60 primeiros bytes sao os dados do contador, um por
        minuto.
10    let minuteData = [];
11    for (let i = 0; i < 60; i++) {
12        minuteData.push(bytes[i]);
13    }
14
15    // Retorna os dados decodificados em um objeto JSON.
16    return {
17        data: {
18            minute_counts: minuteData,
19            vbatok: vbatok,
20            pulse: pulse,
21        },
22        warnings: [],
23        errors: []
24    };
25 }
```

APÊNDICE C – DETALHAMENTO DOS CUSTOS DE FABRICAÇÃO DO NÓ IOT

Tabela 12 – Custo de fabricação do protótipo IoT.

Componente	Qtd.	Valor Unit (US\$)	Valor Total (US\$)
Capacitor 10 μ F	5	0,00570	0,0285
Capacitor 10 nF	2	0,00090	0,0018
Capacitor 100 nF	7	0,00090	0,0063
Capacitor 470 nF	1	0,00130	0,0013
Capacitor 5,6 pF	3	0,00100	0,0030
Capacitor 3,3 pF	1	0,00090	0,0009
Capacitor 3,9 pF	1	0,00100	0,0010
Capacitor 4,0 pF	1	0,00090	0,0009
Capacitor 3,0 pF	1	0,00090	0,0009
Capacitor 47 pF	2	0,00090	0,0018
Capacitor 47 nF	3	0,00080	0,0024
Capacitor 1 μ F	1	0,00140	0,0014
Indutor L (geral)	1	0,03430	0,0343
Filtro 2059-302/998-403	1	0,35070	0,3507
Conector 01x04	2	0,00000	0,0000
Indutor 47 nH	1	0,00320	0,0032
Indutor 2,6 nH	1	0,00290	0,0029
Indutor 2,7 nH	1	0,00290	0,0029
Indutor 8,2 nH	1	0,00320	0,0032
Indutor 10 nH	1	0,00280	0,0028
Indutor 3,3 nH	1	0,00320	0,0032
Indutor 15 μ H	1	0,05360	0,0536
Indutor 22 μ H	1	0,15200	0,1520
Resistor 10 k Ω	3	0,00060	0,0018
Resistor 4,7 M Ω	1	0,00040	0,0004
Resistor 1,2 M Ω	3	0,00040	0,0012
Conector SMA-KE-P901	1	0,47830	0,4783
Resistor 1 M Ω	3	0,00050	0,0015
Resistor 1,5 M Ω	1	0,00040	0,0004
Resistor 150 k Ω	1	0,00040	0,0004
Botão TS-1088R-02026	1	0,02210	0,0221
Regulador TPMIC5365-3.3YC5	1	0,12960	0,1296
Carregador BQ25504RGTR	1	4,88600	4,8860
Transceptor SX1262IMLTRT	1	3,16940	3,1694
Microcontrolador STM32L031F6P6	1	1,89560	1,8956
Conector 532610271_C177225	2	0,10640	0,2128
Cristal OW7EL89CENUXK7YLC-32M	1	0,55440	0,5544
Placa PCB (fabricação)	1	2,10200	2,1020
Custo Total Estimado			14,42

Fonte: Elaborado pelo autor.