



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA APLICADA

Fábio Alves de Freitas

**Uma Solução de Baixo Custo baseada em IoT para o Monitoramento da  
Qualidade de Água na Aquicultura 4.0**

Dissertação de Mestrado

Recife, 2023



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA APLICADA

**Uma Solução de Baixo Custo baseada em IoT para o Monitoramento da  
Qualidade de Água na Aquicultura 4.0**

Dissertação apresentada ao Programa de Pós-Graduação em Informática Aplicada da Universidade Federal Rural de Pernambuco como exigência parcial à obtenção do título de Mestre em Informática Aplicada.

Orientador: Prof. Dr. Fernando Antonio Aires Lins  
Coorientadores: Prof. Dr. Obionor de Oliveira Nóbrega e Profa. Dra. Juliana Ferreira Dos Santos

Recife, 2023

Dados Internacionais de Catalogação na Publicação  
Universidade Federal Rural de Pernambuco  
Sistema Integrado de Bibliotecas  
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

---

F866s

Freitas, Fábio Alves de Freitas

Uma Solução de Baixo Custo baseada em IoT para o Monitoramento da Qualidade de Água na  
Aquicultura 4.0 / Fábio Alves de Freitas Freitas. - 2023.

100 f. : il.

Orientador: Fernando Antonio Aires Lins.

Coorientador: Obionor de Oliveira Nobrega.

Inclui referências.

Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em  
Informática Aplicada, Recife, 2023.

1. Internet das Coisas. 2. Baixo Custo. 3. Aquicultura 4.0. 4. Aprendizado de Máquina. 5. Estimação de  
Oxigênio Dissolvido. I. Lins, Fernando Antonio Aires, orient. II. Nobrega, Obionor de Oliveira, coorient. III.  
Título



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA APLICADA

**Uma Solução de Baixo Custo baseada em IoT para o Monitoramento da  
Qualidade de Água na Aquicultura 4.0**

Fábio Alves de Freitas

Dissertação julgada adequada como requisito parcial para obtenção do título de Mestre em Informática Aplicada (área de concentração: Computação Inteligente e Modelagem) pelo Programa de Pós-Graduação em Informática Aplicada da Universidade Federal Rural de Pernambuco. A dissertação foi aprovada por unanimidade em sua forma final em sessão pública de defesa em 28/08/2023.

Orientador:

---

Prof. Dr. Fernando Antonio Aires Lins  
Universidade Federal Rural de Pernambuco

Coorientadores:

---

Prof. Dr. Obionor de Oliveira Nóbrega  
Universidade Federal Rural de Pernambuco

---

Profa. Dra. Juliana Ferreira Dos Santos  
Universidade Federal Rural de Pernambuco

Banca Examinadora:

---

Prof. Dr. Danilo Ricardo Barbosa De Araújo  
Universidade Federal Rural de Pernambuco

---

Prof. Dr. Marco Antonio de Oliveira Domingues  
Instituto Federal de Pernambuco

*Dedico este trabalho a Deus, a minha família e a todos que me apoiaram nesta  
jornada.*

## **AGRADECIMENTOS**

Agradeço, primeiramente, a Deus pela dádiva da vida. Pelo discernimento e paciência durante esta jornada. Por me prover a sabedoria necessária para lidar com os momentos de paz e de dificuldade e durante esta jornada.

Aos meus orientadores, os professores doutores Obionor Nóbrega, Fernando Aires e Juliana Ferreira, pelos inestimáveis aconselhamentos que me proveram, aprendizados de vida proporcionados e principalmente pela amizade que consolidados.

Ao meu pai, Joselito, a minha mãe Joana, e a minha irmã, Eduarda, por estarem sempre presentes e me apoiando em todos os momentos. No choro, no riso, da angústia e na conquista. Obrigado por terem me feito seguir em frente. A minha companheira, Talita, pelo apoio por noites a fio, me acolhendo durante esta fase conturbada da minha vida. Seu companheirismo e seu amor foram essenciais nestes tempos difíceis. A minha família materna. Aos meus tios, tias, primos, primas, e a minha avó, Clarice, por terem acompanhado esta trajetória de perto, fazendo parte de cada pequena conquista.

Ao departamento de computação (DC), pelo espaço que possibilitou o desenvolvimento de toda a presente pesquisa, e a todos os seus professores, em especial aos professores Péricles Miranda, Danilo Araújo e Jeísa Domingues, por todos os aconselhamentos. A toda a coordenação do programa de pós-graduação em informática aplicada (PPGIA), em especial ao seu secretário, Eduardo Chaves, por todas as broncas que me ajudou a resolver.

Ao departamento de pesca e aquicultura (DEPAq), pela disponibilização de laboratórios para a elaboração e condução da pesquisa. Aos professores, Alfredo Galvez, Danielli Matias e Dijaci Araújo. E aos colegas Jessika Lima, Deyvid Willame e Álvaro Cirino. Obrigado por todo o apoio.

Ao todos os amigos, em especial a Victor Matheus, Eduardo Lima, Elizabeth Pereira, Islaine Felix e Rildo José, por toda a força prestada durante os inúmeros experimentos, escritas de trabalhos, prototipações e trabalhos em inúmeros finais de semana e madrugadas. Agradeço imensamente.

Aos membros da banca, Marco e Danilo, pela disposição e interesse em contribuir para o melhoramento deste trabalho. Obrigado!

A FACPE, pela bolsa de mestrado proporcionada e pelo apoio, que possibilitou a aplicação desta pesquisa junto a pequenos aquicultores do estado de Pernambuco.



“Tenho cicatrizes na alma, deixadas pelos tombos que a vida me deu, pois precisei ver as pedras de muito perto para aprender a apreciar a sutileza das flores, por que fui medo antes de ser coragem”

Joselito Alves de Freitas, 2020

## RESUMO

A qualidade da água desempenha um papel fundamental na aquicultura, influenciando diretamente o desenvolvimento dos animais cultivados. Seu monitoramento correto reflete em tomadas de decisão mais assertivas, aumentando a produtividade do empreendimento. A qualidade da água é determinada através dos parâmetros da água, como a temperatura, pH e o oxigênio dissolvido (OD), sendo este último o mais crítico, pois é o fator mais impactante na taxa de sobrevivência dos animais. Na maioria dos sistemas produtivos, esse monitoramento é feito de forma manual, causando lentidão nas tomadas de decisão, podendo levar os animais a condições insalubres de cultivo. Os sistemas baseados na Internet das Coisas (IoT) desempenham um papel central na aquicultura, possibilitando um monitoramento em tempo real da qualidade da água por meio de sensores e tomadas de decisão mais rápidas e eficazes devido análises automáticas de dados. No entanto, o custo elevado desses sistemas, principalmente nos países em desenvolvimento, dificulta a sua popularização e deve-se principalmente ao alto preço dos sensores físicos de OD. Isso faz com que esses sistemas não sejam tão acessíveis a pequenos produtores de aquicultura. Nesse contexto, esta dissertação propõe uma solução de IoT de baixo custo para o monitoramento da qualidade da água na aquicultura 4.0. A principal vantagem dessa abordagem é o desenvolvimento e a integração de um modelo de aprendizado de máquina para estimar o OD usando as leituras de temperatura e pH como entrada, dispensando o uso do sensor físico de OD, reduzindo assim seu custo de mercado. A solução desenvolvida foi implantada em uma piscicultura para acompanhamento das medições, permitindo uma avaliação mais precisa os dados coletados. Além disso, o protótipo IoT desenvolvido dispensa modificações estruturais em viveiros, evitando custos adicionais de infraestrutura física. Os resultados obtidos mostraram que todos os parâmetros de qualidade da água coletados obtiveram um *coefficient of variation of root-mean squared error* CV(RMSE) inferior a 20%, que segundo a avaliação estatística aplicada, representa um nível de precisão similar ao dos medidores manuais de parâmetros convencionalmente empregados nesses ambientes. Além disso, mostrou que a solução proposta representa uma economia de curto prazo de pelo menos 44% em comparação com sistemas similares de monitoramento da qualidade da água por IoT disponíveis no mercado.

**Palavras-chave:** Internet das Coisas; Baixo Custo; Aquicultura 4.0; Aprendizado de Máquina; Estimação de Oxigênio Dissolvido.

## ABSTRACT

Water quality plays a fundamental role in aquaculture, directly influencing the development of farmed animals. Its correct monitoring results in more assertive decision-making, increasing the productivity of the enterprise. Water quality is determined through water parameters such as temperature, pH and dissolved oxygen (DO), the latter being the most critical, as it is the factor with the bigger impact on animal survival rates. In most production systems, this monitoring is done manually, which slows down decision-making and can lead to unhealthy farming conditions for the animals. Systems based on the Internet of Things (IoT) play a central role in aquaculture, enabling real-time monitoring of water quality using sensors and faster, more effective decision-making due to automatic data analysis. However, the high cost of these systems, especially in developing countries, hinders their popularization and is mainly due to the high price of physical DO sensors. This makes these systems less accessible to small aquaculture producers. In this context, this dissertation proposes a low-cost IoT solution for monitoring water quality in aquaculture 4.0. The main advantage of this approach is the development and integration of a machine learning model to estimate DO using temperature and pH readings as input, dispensing with the use of the physical DO sensor, thus reducing its market cost. The solution developed was deployed in a fish farm to monitor measurements, allowing for a more accurate assessment of the data collected. In addition, the IoT prototype developed requires no structural modifications to fish farms, avoiding additional physical infrastructure costs. The results obtained showed that all the water quality parameters collected obtained a coefficient of variation of root-mean squared error CV(RMSE) of less than 20%, which according to the statistical evaluation applied, represents a level of precision like that of the manual parameter meters conventionally used in these environments. It also showed that the proposed solution represents short-term savings of at least 44% compared to similar IoT water quality monitoring systems available on the market.

**Keywords:** Internet of Things; Low-Cost; Aquaculture 4.0; Machine Learning; Dissolved Oxygen Estimation.

## LISTA DE FIGURAS

Figura 1 - Arquitetura de três camadas. ....	27
Figura 2 - Arquitetura IoT proposta com suas respectivas camadas.....	50
Figura 3 - Modelo proposto para o hardware do dispositivo IoT.....	51
Figura 4 – Modelo do mecanismo de alimentação elétrica por energia solar.....	53
Figura 5 – Design industrial do dispositivo IoT. ....	54
Figura 6 - Dispositivo IoT montado.....	57
Figura 7 - Rotina do modo de inicialização. ....	59
Figura 8 - Rotina de execução de requisições HTTP. ....	59
Figura 9 - Rotina do modo de configuração. ....	60
Figura 10 - Página web para configuração do dispositivo IoT.....	61
Figura 11 - Rotina do modo de operação.....	62
Figura 12 - Interface da plataforma <i>Thingsboard Community Edition</i> . ....	71
Figura 13 - Cadeia de regras da execução primária do <i>Thingsboard</i> .....	74
Figura 14 - Cadeia de regras para chamada do modelo de estimação de OD.....	75
Figura 15 - Cadeia de regras de gestão de alertas. ....	76
Figura 16 - <i>Dashboard</i> de gestão de <i>thresholds</i> e alertas.....	76
Figura 17 - <i>Dashboards</i> responsivos desenvolvidos. (A) Web; e (B) Mobile.....	78
Figura 18 – Comparação entre o OD da base de dados e OD estimado. ....	83
Figura 19 – Ranqueamento dos modelos sob o teste post-hoc Nemenyi. ....	85
Figura 20 - Dispositivo IoT instalado em um viveiro de tilápias da UFRPE.....	86
Figura 21 - Comparação entre dados de controle e de telemetria. ....	88
Figura 22 - Entrega protótipo desenvolvido a aquicultura do estado Pernambuco. ...	93

## LISTA DE TABELAS

Tabela 1 - Arquiteturas e funcionalidades dos trabalhos relacionados. ....	38
Tabela 2 - Características do hardware IoT proposto pelo estado da arte. ....	41
Tabela 3 - Análise comparativa dos preços de sensores subaquáticos. ....	64
Tabela 4 - Estatística descritiva das bases de dados utilizadas nos treinamentos. ..	66
Tabela 5 - Pontuações do RMSE para cada <i>dataset</i> e sua respectiva média. ....	83
Tabela 6 - Média e desvio padrão das séries temporais e valores do CV(RMSE). ...	89
Tabela 7 - Comparação do custo de soluções IoT disponíveis no mercado. ....	90

## LISTA DE ABREVIATURAS E SIGLAS

FAO	Food and Agriculture Organization
TDS	Total Dissolved Solids
ORP	Oxidation-Reduction Potential
OD	Concentração do Oxigênio Dissolvido
SOD	Solubilidade do Oxigênio Dissolvido
PH	Potencial Hidrogeniônico
EC	Electrical Conductivity
IOT	Internet of Things
SOC	System-on-a-Chip
UART	Universal Asynchronous Receiver/Transmitter
I2C	Inter-Integrated Circuit
SPI	Serial Peripheral Interface
RTC	Real Time Clock
ADC	Analog Digital Conversor
HTTP	HyperText Transfer Protocol
MQTT	Message Queuing Telemetry Transport
LORAWAN	Long Range Wide Area Network
UFRPE	Universidade Federal Rural de Pernambuco
MATLAB	Matrix Laboratory
PAAS	Platform as a Service
IAAS	Infrastructure as a Service
IFTTT	If This Than That
PCB	Printed Circuit Board
ML	Machine Learning
CV(RMSE)	Coefficient of Variation of Root-Mean Squared Error
RMSE	Root-Mean Squared Error

## SUMÁRIO

1	INTRODUÇÃO .....	16
1.1	CONTEXTO E MOTIVAÇÃO .....	17
1.2	OBJETIVOS .....	18
1.3	ORGANIZAÇÃO DA DISSERTAÇÃO .....	19
2	FUNDAMENTAÇÃO TEÓRICA.....	20
2.1	AQUICULTURA .....	21
2.1.1	Parâmetros da Água .....	21
2.1.1.1	<i>Temperatura</i> .....	22
2.1.1.2	<i>Turbidez</i> .....	22
2.1.1.3	<i>Condutividade, Totais de Sólidos Dissolvidos e Salinidade</i> .....	23
2.1.1.4	<i>Potencial Hidrogeniônico</i> .....	24
2.1.1.5	<i>Oxigênio Dissolvido</i> .....	24
2.1.1.6	<i>Amônia, Nitrito e Nitrato</i> .....	25
2.1.1.7	<i>Potencial de Oxidação-Redução (ORP)</i> .....	26
2.2	IOT .....	26
2.2.1	Arquitetura de IoT .....	27
2.2.2	IoT aplicada na aquicultura .....	28
2.3	COMPONENTES ELETRÔNICOS IOT .....	29
2.3.1	Microcontroladores.....	29
2.3.2	Sensores .....	30
2.3.3	Atuadores.....	31
2.3.4	Relógios de Tempo Real (RTC) .....	31
2.3.5	Conversores Analógico Digital (ADS) .....	32
2.3.6	Gateway para IoT.....	32
2.3.7	Gerenciador de Carga.....	32
2.3.8	Baterias de Lítio .....	33
2.3.9	Painel Solar .....	33
2.4	CONSIDERAÇÕES FINAIS .....	33
3	TRABALHOS RELACIONADOS .....	35
3.1	CONSIDERAÇÕES INICIAIS.....	36
3.2	ARQUITETURAS DE IOT APLICADAS À AQUICULTURA .....	36
3.3	PROJETO DE HARDWARE IOT APLICADO À AQUICULTURA .....	39

3.4	INTELIGÊNCIA ARTIFICIAL APLICADA NA AQUICULTURA.....	42
4	UMA SOLUÇÃO DE BAIXO CUSTO BASEADA EM IOT PARA O MONITORAMENTO DA QUALIDADE DE ÁGUA NA AQUICULTURA 4.0.....	46
4.1	CONSIDERAÇÕES INICIAIS.....	47
4.2	LEVANTAMENTO DE REQUISITOS.....	47
4.3	ARQUITETURA IOT PROPOSTA.....	50
4.3.1	Camada de Percepção .....	50
4.3.1.1	<i>Projeto</i> .....	50
4.3.1.2	<i>Implementação</i> .....	55
4.3.1.2.1	Desenvolvimento do Hardware.....	55
4.3.1.2.2	Desenvolvimento do Firmware .....	58
4.3.2	Camada de Transporte .....	62
4.3.2.1	<i>Projeto e Implementação</i> .....	62
4.3.3	Modelo de machine learning para estimação de od.....	64
4.3.3.1	<i>Projeto</i> .....	64
4.3.3.1.1	Avaliação de Custos de Sensores de Qualidade da Água .....	64
4.3.3.1.2	Modelos de ML propostos .....	65
4.3.3.2	<i>Implementação</i> .....	65
4.3.3.2.1	Treinamento dos Modelos de ML .....	66
4.3.3.2.2	Construção de API REST para modelo de ML .....	67
4.3.4	Camada de Processamento.....	68
4.3.4.1	<i>Projeto</i> .....	68
4.3.4.2	<i>Implementação</i> .....	70
4.3.4.2.1	Infraestrutura em Nuvem e Plataforma IoT .....	70
4.3.4.2.2	Configuração da Plataforma IoT.....	72
4.3.5	Camada de Aplicação .....	77
4.3.5.1	<i>Projeto</i> .....	77
4.3.5.2	<i>Implementação</i> .....	77
5	AVALIAÇÃO DE DESEMPENHO E ANÁLISE DE RESULTADOS.....	80
5.1	CONSIDERAÇÕES INICIAIS.....	81
5.2	METODOLOGIA DE AVALIAÇÃO DOS MODELOS DE ML.....	81
5.3	RESULTADOS DOS MODELOS DE ML .....	82
5.4	METODOLOGIA DE AVALIAÇÃO DO SISTEMA IOT .....	85
5.5	RESULTADOS DO SISTEMA IOT.....	86

5.5.1	Estudo de Caso do Sistema IoT implantado em Aquicultura 4.0. ....	86
5.5.2	Resultados da Acurácia da Coleta de Dados do Sistema IoT.....	87
5.5.3	Análise de Custos da Solução IoT proposta .....	89
6	CONCLUSÕES E TRABALHOS FUTUROS.....	91
6.1	CONSIDERAÇÕES INICIAIS.....	92
6.2	CONTRIBUIÇÕES .....	92
6.3	PRODUTOS CIENTÍFICOS E DE INOVAÇÃO GERADOS .....	94
6.4	TRABALHOS FUTUROS .....	94
	REFERÊNCIAS BIBLIOGRÁFICAS.....	96

## 1 INTRODUÇÃO

---

Este Capítulo relata as principais motivações para realização desta dissertação, descreve o contexto do problema, apresenta seus objetivos, expõe suas contribuições e indica a estrutura dos capítulos seguintes desta dissertação.

---

## 1.1 CONTEXTO E MOTIVAÇÃO

Diante do desafio global de atender às crescentes demandas de alimentos para uma população projetada de 9,7 bilhões de pessoas até o ano de 2050 (ONU, 2020), a aquicultura surgiu como um setor fundamental para suprir essa demanda, além de gerar oportunidades de emprego para as próximas décadas (FAO, 2022). A aquicultura pode ser definida como o cultivo de organismos aquáticos em ambientes controlados, e o crescimento desse setor deve ser conduzido levando-se em conta os requisitos de sustentabilidade, como bem enfatizado pelos objetivos para o desenvolvimento sustentável da ONU.

Paralelamente, a Internet das Coisas (Internet of Things - IoT), conceito tecnológico que visa interconectar objetos físicos do cotidiano à Internet, é um tema chave em pesquisas acadêmicas realizadas na atualidade, e sendo amplamente aplicado no meio industrial (ATZORI et al, 2010). A IoT possibilita o desenvolvimento da aquicultura através da viabilização da Aquicultura 4.0 (aquicultura de precisão) (DUPONT et al, 2018), através da aplicação de tecnologia de ponta na automação de processos, na redução de custos e no aumento sustentável da produtividade (CLERCQ et al, 2018).

Embora a aquicultura seja uma prática milenar, com atividades datadas desde os antigos egípcios, um dos seus principais desafios é o gerenciamento da qualidade da água. Sua gestão tem uma forte dependência de medidores manuais, levando a um tempo maior para execução deste monitoramento. Neste contexto, três parâmetros da água se destacam como essenciais: a temperatura, o pH e o oxigênio dissolvido (OD), medidos respectivamente por termômetros, pHmetros e oxímetros. Além do difícil uso destes equipamentos, que necessitam de constante manutenção envolvendo sua limpeza e calibração antes de cada medição, seu alto custo de mercado é um grande empecilho, principalmente considerando a fragilidade deles. Desta forma, o monitoramento manual através destes medidores resulta em problemas como: leituras inconsistentes, devido a sua má manutenção; erros durante a anotação de registros, geralmente realizada por meio de escrita manual ou em planilhas digitais; e a demora na coleta de dados de múltiplos viveiros de cultivo. Todos estes fatores contribuem para uma lenta análise de dados, que consequentemente gera atrasos no processo de tomada de decisão do cultivo, prejudicando a produtividade a lucratividade do empreendimento.

Neste contexto, soluções baseadas em IoT para o monitoramento autônomo da qualidade da água em ambientes de aquicultura foram propostas pela literatura, como é mostrado em Dzulqornain (DZULQORNAIN et al, 2018) e em Billah (BILLAH et al, 2019). Estas soluções são endereçadas aos problemas trazidos pela coleta manual, atrelando a um fator crítico que impede sua ampla aplicação, que é seu o alto custo de mercado. Isto muitas vezes as tornam economicamente inacessíveis para pequenos e médio produtores de aquicultura, que descredita a aplicação destas tecnologias tanto por desconhecê-las quanto pelo receio do não retorno de seu investimento. Segundo Dupont (DUPONT et al, 2018) este alto preço é um fator ainda mais crítico em países em desenvolvimento, que devido a falta do acesso local a este tipo de tecnologia estão sujeitos a custos adicionais para sua importação, como impostos, câmbios e taxas de entrega.

## 1.2 OBJETIVOS

Motivado pelos problemas citados na Seção 1.1, o objetivo geral deste trabalho foi o desenvolvimento uma solução IoT de baixo custo para o monitoramento da qualidade da água na aquicultura 4.0. Além disso, frente ao rápido desenvolvimento da inteligência artificial, surgem aplicações baseadas em aprendizagem de máquina para operar junto destes sistemas IoT, com o intuito tanto de trazer ganhos no desempenho, quanto proporcionar reduções nos custos de mercado destes sistemas. Dentre elas destaca-se a proposta da estimação do OD, que proporciona a redução de custo através da remoção da obrigatoriedade do sensor de OD nestes sistemas IoT, que representa grande parte dos custos de produção do hardware.

Como meta para que este objetivo seja atingido, os seguintes objetivos específicos são definidos:

- Desenvolver uma arquitetura IoT de baixo acoplamento para o monitoramento em tempo real da qualidade da água;
- Desenvolver modelos de aprendizagem de máquina para a estimação do oxigênio dissolvido através das medições de temperatura e pH;
- Desenvolver uma plataforma IoT para o apoio a transmissão sem fio heterogênea, baseada no contexto da eficiência energética, para o provisionamento de dados em nuvem;

- Desenvolver uma solução com nível melhorado de robustez, com o objetivo de suportar intempéries presentes na aquicultura.
- Desenvolver mecanismo de notificações de alertas em tempo real.

### 1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

Esta dissertação está organizada conforme a seguinte estrutura. No Capítulo 2 é apresentada a fundamentação teórica envolvendo aquicultura e seus parâmetros da água, a Internet das Coisas e a sua arquitetura aplicada na aquicultura e os principais componentes eletrônicos para prototipação. O Capítulo 3 apresenta os trabalhos relacionados a soluções baseadas em IoT e inteligência artificial aplicadas na aquicultura 4.0. No Capítulo 4 é descrita a proposta da solução IoT de baixo custo para o monitoramento da qualidade da água na aquicultura 4.0. O Capítulo 5 se destina a discussão dos experimentos conduzidos e análise de resultados obtidos. Por fim, no Capítulo 6 são apresentadas as conclusões da dissertação, suas principais contribuições, produções científicas e de propriedade intelectual desenvolvidas e as sugestões de trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

---

O objetivo do Capítulo atual é fornecer uma visão geral sobre conceitos básicos de IoT (Internet das Coisas) e como eles podem ser aplicados na área da aquicultura. Serão discutidos também os principais parâmetros de qualidade da água; a arquitetura IoT básica aplicada na aquicultura; e os principais componentes de hardware IoT utilizados neste contexto.

---

## 2.1 AQUICULTURA

A aquicultura é a prática do cultivo de organismos aquáticos, podendo ser continental ou marinha. Em outras palavras, trata-se da produção de pescados, incluindo peixes, moluscos, algas, camarões e outros, em sistemas controlados, como tanques e viveiros. Segundo aborda Funge (FUNGE-SMITH, S; PHILLIPS, 2000), esses sistemas de produção são subdivididos de acordo com sua capacidade produtiva, sendo elas: extensiva, semi-intensiva, intensiva e superintensiva, cada uma com uma capacidade produtiva, complexidade e precisão de cultivo maior que a anterior.

A aquicultura é uma atividade antiga, com evidências de criação de tilápia pelos antigos egípcios às margens do rio Nilo, como é exibido em Soliman (SOLIMAN; DALIA, 2016). Apesar disso, muitas das antigas práticas manuais ainda são utilizadas atualmente. Diante do desafio do aumento da população mundial e da crescente demanda por alimentos saudáveis (FAO, 2020), é fundamental desenvolver técnicas para tornar a produção mais eficiente, nos limites da sustentabilidade.

Desta forma, aquicultura de precisão visa promover o desenvolvimento sustentável desta prática, com a aplicação de tecnologia para automação dos processos na produção, aplicando otimizações no uso de insumos, como energia elétrica e ração, para trazer o aumento da produtividade e da lucratividade do setor. Sendo assim, devido a sua maior complexidade requer o envolvimento das práticas de pesquisa e desenvolvimento de forma multidisciplinar, agregando áreas como a engenharia de pesca, biologia, química, tecnologia da informação, etc.

### 2.1.1 Parâmetros da Água

Um dos grandes desafios da aquicultura é a manutenção da qualidade da água, pois ela é a principal responsável pelo bom crescimento e saúde dos animais, além de determinar a taxa de sobrevivência dos mesmos (SANTOS, 2018).

Os parâmetros avaliados para manutenção da qualidade da água podem ser divididos em três categorias, como aborda Poonam (POONAM et al, 2013), que são: os físicos, como a temperatura, turbidez, condutividade, totais de sólidos dissolvidos (TDS); os químicos, como o oxigênio dissolvido, pH, salinidade, nitrito, nitrato e potencial de oxidação-redução (ORP); e os biológicos, como algas e bactérias. Indicadores da qualidade da água são extraídos através das leituras destes

parâmetros, que ditam os processos de tomada de decisão realizados durante cultivo.

Os parâmetros interagem de maneira dinâmica e relacional, de modo que alterações nos níveis ideais de um deles pode influenciar nos demais parâmetros, tornando o ambiente tóxico e aumentando a mortalidade no cultivo. Por exemplo, o aumento da temperatura pode diminuir a solubilidade do oxigênio dissolvido na água, segundo aborda Apha (APHA, 1995). Portanto, o monitoramento regular desses parâmetros é uma tarefa essencial para garantir um ambiente produtivo saudável. Por isto, é de suma importância compreender o funcionamento dos parâmetros mais relevantes para o contexto do cultivo tratado, para determinar quais devem ser monitorados.

Nas subseções a seguir são descritos o funcionamento e importância de alguns dos principais parâmetros da água utilizados na aquicultura.

#### 2.1.1.1 Temperatura

A temperatura da água é um dos parâmetros mais importantes na aquicultura, pois afeta o metabolismo, o crescimento e a saúde dos organismos aquáticos (OLIVEIRA, 2000). Alguns peixes, como o salmão, tem um limite de tolerância voltado para as temperaturas mais baixas, enquanto outros, como a tilápia, por exemplo, podem tolerar temperaturas mais altas. Temperaturas muito baixas diminuem a taxa metabólica reduzindo desempenho produtivo dos animais, enquanto temperaturas elevadas podem aumentar estas taxas causando problemas de saúde, como o estresse térmico. Somado a isto, as variações bruscas de temperatura podem ser ainda mais prejudiciais. Portanto, este é um dos parâmetros essenciais a serem monitorados. Para mantê-lo dentro dos limites ideais utilizam-se técnicas que vão desde sistemas de aquecimento ou resfriamento, até estruturas com capacidade para manutenção das temperaturas desejadas, a depender claro, das condições climáticas locais e das necessidades dos organismos cultivados. O instrumento utilizado para sua aferição é o termômetro.

#### 2.1.1.2 Turbidez

A turbidez representa a ausência de transparência na água causada pela presença de materiais orgânicos ou minerais. Níveis elevados da turbidez causam a

diminuição da eficiência alimentar, a redução do crescimento e um aumento na taxa de mortalidade (OLIVEIRA, 2000). Além disso, segundo EPA (EPA, 2003), ela pode ser ocasionada por fatores como: o escoamento de água de áreas agrícolas; a erosão do solo; a presença de sedimentos; a quantidade de matéria orgânica na água; dentre outros, afetando a capacidade de absorção de luz pela água, prejudicando a fotossíntese e ocasionando alterações nos níveis do oxigênio dissolvido. Para seu controle é importante adotar práticas que vão de encontro aos fatores supracitados, como um monitoramento regular e ajustes quando necessário. Alguns métodos utilizados para reduzir a turbidez incluem o uso de filtros e o aumento da circulação da água. A turbidez é medida através de turbidímetros ou de testes químicos.

#### 2.1.1.3 Condutividade, Totais de Sólidos Dissolvidos e Salinidade

A condutividade é a medida da capacidade em conduzir corrente elétrica. Este parâmetro é medido por meio de um condutivímetro ou por meio de testes químicos. Sua importância na aquicultura está ligada à sua relação direta com a salinidade e com a quantidade de sólidos dissolvidos (TDS), cujos valores podem ser calculados a partir das equações propostas por Machado (MACHADO, 2006).

A salinidade, medida em partes por mil (ppm), é a quantidade de sais dissolvidos na água, em especial o cloreto de sódio. Na aquicultura, ela é especialmente importante em ambientes costeiros, onde seus níveis podem variar significativamente, influenciando nos cultivos de espécies tolerantes a esta variação, como o robalo e o camarão branco, por exemplo. De acordo com Maciel (MACIEL, 2005), a salinidade altera a oferta de energia disponível para o desenvolvimento dos animais devido a sua influência nos custos energéticos para as regulações iônica e osmótica. Portanto, a manutenção dos níveis de salinidade influencia no desenvolvimento do animal e conseqüentemente na qualidade final do produto.

Já o parâmetro Total de Sólidos Dissolvidos (TDS), medido em partes por mil (ppm), mede a quantidade de sólidos gerais na água, incluindo os sais considerados na medição da salinidade. Altos níveis de TDS podem reduzir a eficiência alimentar, a taxa de crescimento e a reprodução dos peixes, além de aumentar o risco de doenças (WEBER; LAWRENCE, 2007).

#### 2.1.1.4 Potencial Hidrogeniônico

O potencial hidrogeniônico, comumente conhecido como pH, representa o grau de acidez ou alcalinidade de uma solução. Ele varia de 0 a 14, sendo neutro quando é igual a 7. Valores inferiores a 7 indicam acidez e valores superiores a 7 indicam alcalinidade. Um pH inadequado na água pode afetar a respiração, a digestão, a reprodução e o sistema imunológico dos organismos aquáticos, levando a problemas de saúde, estresse e mortalidade. O pH também afeta a disponibilidade de nutrientes para os animais. Por exemplo, alguns nutrientes, como o fósforo, estão mais disponíveis em pHs mais baixos, enquanto outros, como o cálcio, estão mais disponíveis em pHs mais altos. Além disso, ele afeta a toxicidade de substâncias na água, como a amônia, que é mais tóxica em pHs mais altos, enquanto o dióxido de carbono é mais tóxico em pHs mais baixos. Este parâmetro pode ser medido através de testes químicos ou por meio dos medidores de pH, comumente chamado de pHmetro.

#### 2.1.1.5 Oxigênio Dissolvido

O oxigênio dissolvido (OD) é um dos fatores mais críticos que afetam a saúde e o crescimento dos organismos aquáticos em sistemas de aquicultura. Os peixes, camarões, moluscos e outras espécies aquáticas precisam de uma quantidade adequada de oxigênio para sobreviver e se desenvolverem de forma saudável.

Na literatura, duas terminologias são comumente apresentadas para este parâmetro: a concentração de oxigênio dissolvido (OD) e a saturação/solubilidade de oxigênio dissolvido (SOD). O OD é a medida da quantidade de oxigênio presente na água, medida em miligramas por litro (mg/L) ou partes por milhão (ppm). Pode ser medida através de um medidor de OD (oxímetro) ou por meio de testes químicos. Já o SOD se refere à quantidade máxima de oxigênio que pode ser dissolvida na água. Ela é determinada principalmente por fatores como a temperatura, pressão atmosférica e a salinidade. É calculada através da medição destes parâmetros como entradas para as equações de Benson-Krause (BENSON; KRAUSE, 1984).

Níveis de OD abaixo do ideal eleva o estresse dos organismos aquáticos e os tornam mais suscetíveis a doenças e infecções, reduzindo sua taxa de crescimento e ocasionando mortalidade nos cultivos. Níveis muito altos de OD também são prejudiciais, causando: alterações no comportamento e metabolismo;

dano no sistema respiratório; e a supersaturação de gás, que causa o surgimento de bolhas nos tecidos dos animais, e que também pode acarretar morte.

Segundo Daoliang (DAOLIANG et al, 2022), dentre as diferentes formas de ajustar os níveis de OD na água, destacam-se: o uso de aeradores, como difusores de ar ou aeradores de superfície, que misturam o oxigênio da atmosfera com a água; a presença de fitoplanctons, que produzem oxigênio através da fotossíntese; a troca de água, quanto esta é substituída por uma com concentração mais alta de oxigênio; o uso de peróxido de oxigênio; dentre outros.

#### 2.1.1.6 Amônia, Nitrito e Nitrato

A amônia, o nitrito e o nitrato são compostos químicos que têm grande importância na aquicultura porque afetam diretamente a saúde e o bem-estar dos organismos aquáticos cultivados. Eles compõem o ciclo do nitrogênio e são subprodutos do metabolismo dos organismos presentes no cultivo (KUBITZA, 2017).

A amônia é produzida pela excreção de peixes, camarões e outros organismos, e pela decomposição de matéria orgânica, como a própria ração excedente. Altos níveis de amônia na água podem ser tóxicos para os animais e prejudicar seu crescimento e desenvolvimento. A amônia é convertida em nitrito por bactérias nitrificantes do gênero *Nitrosomonas*, substância ainda mais tóxica que a amônia. Altos níveis de nitrito podem levar a uma condição conhecida como "síndrome do nitrito", que causa danos às brânquias dos peixes e prejudica sua capacidade de respirar. O nitrito por sua vez, é convertido em nitrato por bactérias nitrificantes do gênero *Nitrobacter*. O nitrato é um subproduto menos tóxico, entretanto, pode ocasionar problemas de saúde em humanos ao consumir organismos cultivados sob alta concentração desta substância. De acordo com Mensinga (MENSINGA et al 2003), algumas das doenças que acometem humanos devido ao consumo de altas concentrações de nitrato são metemoglobinemia, toxicidade gastrointestinal e efeitos carcinogênicos. Além disso, altos níveis de nitrato na água podem estimular o crescimento excessivo de algas e plantas aquáticas, levando a um processo conhecido como eutrofização, drasticamente reduzindo os níveis do OD na água, impedindo a respiração dos animais, além de ser um dos principais indicadores de poluição.

Desta forma, se faz necessário monitorar regularmente os níveis de amônia, nitrito e nitrato na água da aquicultura e tomar medidas para controlá-los, como

realização de trocas parciais de água, utilização de biofiltros e controle da alimentação dos organismos cultivados. Todos os três compostos são comumente monitorados através de testes químicos de colorimetria em laboratórios. Existem sensores e medidores eletrônicos disponíveis para sua medição, entretanto são equipamentos de alto custo de aquisição e manutenção.

#### 2.1.1.7 Potencial de Oxidação-Redução (ORP)

O Potencial de Oxidação-Redução (ORP), também conhecido como potencial redox, é uma medida da capacidade de um meio aquático para suportar reações de oxidação ou redução. Em outras palavras, mede a capacidade da água em transferir elétrons para outras substâncias. Na aquicultura ele é frequentemente utilizado como um indicador da qualidade da água e pode ser usado para monitorar a presença de contaminantes orgânicos e inorgânicos. Valores de ORP abaixo de um certo limiar podem indicar a presença de compostos tóxicos, como amônia e nitrito (RACYS et al, 2017). Poder ser medido através de testes químicos e por meio do sensor de ORP.

## 2.2 IOT

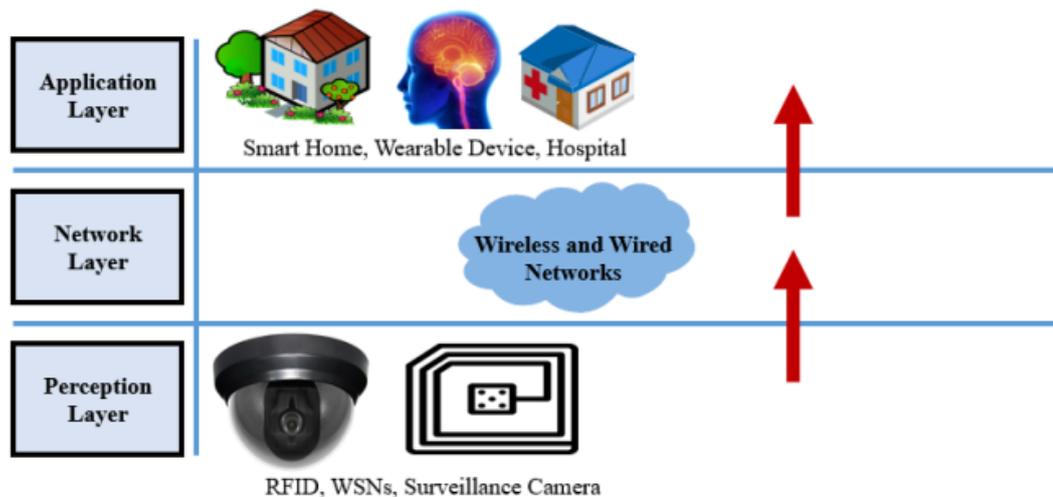
O monitoramento manual dos parâmetros da água nos cultivos de aquicultura traz consigo alguns gargalos, como: a dificuldade na realização de um monitoramento contínuo; erros durante a coleta de dados devido ao mal uso dos medidores ou erro na anotação dos registros de dados, o que pode ocasionar em tomadas de decisões incorretas; dificuldade do monitoramento de fazendas com grandes extensões de lâmina d'água; o alto custo de tempo e de trabalho; e dificuldades na rastreabilidade e na análise de dados. Desta forma, a Internet das Coisas (IoT), conceito que visa a integração de todo tipo de dispositivo do dia a dia à Internet para a resolução de problemas complexos, possibilita o desenvolvimento de tecnologias para a realização de um monitoramento automático de parâmetros da água. Ela está se tornando uma ferramenta essencial na promoção do desenvolvimento sustentável na aquicultura de precisão. As subseções abaixo discutem a respeito do funcionamento básico da arquitetura IoT e de suas aplicações na aquicultura de precisão.

### 2.2.1 Arquitetura de IoT

O termo IoT refere-se à interconexão de dispositivos físicos, veículos, objetos e outras coisas através da Internet. A ideia por trás do conceito é permitir que esses objetos se comuniquem e troquem dados entre si, sem a necessidade de intervenção humana direta. Isso é possível por meio da incorporação de sensores, software e conectividade de rede em objetos do mundo real, permitindo que eles coletem e compartilhem informações.

De acordo com Burhan (BURHAN et al, 2018), os sistemas IoT podem ser descritos por meio de uma arquitetura base, composta por três camadas: camada física; camada de rede; e camada de aplicação. Seu propósito primário é o de interconectar o usuário do sistema com o ambiente físico, permitindo que ele tome decisões baseada em dados gerados automaticamente pelo sistema, bem como apoiar a automação de processos manuais. Esta arquitetura é ilustrada na Figura 1.

Figura 1 - Arquitetura de três camadas.



Fonte: (BURHAN et al, 2018)

A camada física é a responsável pela coleta de dados dos dispositivos físicos e sensores. Seu propósito é capturar informações do mundo físico, como temperatura, umidade, movimento, entre outros, e transmiti-las para a próxima camada. Também é nela que são acoplados atuadores, dispositivos que visam realizar uma ação no ambiente físico, permitindo assim o controle remoto.

A camada de rede é responsável pela comunicação entre dispositivos, permitindo que os dados sejam transmitidos de um dispositivo para outro. Essa camada inclui protocolos de comunicação, como *Bluetooth*, *Wi-Fi*, *Zigbee* dentre outros, que são utilizados para conectar dispositivos em uma rede. Ela também

realiza a conexão do sistema com a Internet e servidores online, permitindo que os dados trafeguem para as camadas superiores para processamentos, análises e armazenamento.

E por fim, a camada de aplicação é responsável por fornecer a interface que permite que os usuários interajam com os dispositivos IoT. Essa camada inclui aplicativos e serviços que podem ser executados em dispositivos móveis, computadores ou servidores na nuvem, permitindo que os usuários monitorem e controlem dispositivos em uma rede IoT.

À medida que os sistemas IoT tornam-se mais complexos, novas funcionalidades são exigidas deles, como mecanismos de segurança, de prevenção a perda de dados e de interconexão entre os outros dispositivos IoT, trazendo mais inteligência e versatilidade a eles. Por outro lado, estas adições aumentam o custo de desenvolvimento e de manutenção destes sistemas, sendo necessárias adições de novas subcamadas na arquitetura base de três camadas, para permitir o funcionamento de sistema sem o aumento da complexidade e o alto acoplamento. Neste contexto, tecnologias como a Inteligência Artificial, *Big Data* e a Computação em Nuvem são amplamente difundidas, pois oferecem muitas dos recursos necessários para suprir estes novos requisitos.

### 2.2.2 IoT aplicada na aquicultura

A IoT abrange uma ampla gama de aplicações e setores, desde casas inteligentes e cidades inteligentes até indústrias, saúde, transporte, agricultura e muito mais (BURHAN et al, 2018). É uma tecnologia que permite a criação de ecossistemas interconectados, onde dados são coletados, transmitidos e analisados para tomar decisões inteligentes e melhorar a eficiência, produtividade e qualidade de vida. Desta forma, ela pode ser aplicada no contexto da aquicultura de precisão de modo a apoiar seus processos produtivos (DUPONT et al, 2018).

A conexão à Internet de elementos já presentes nas fazendas, como alimentadores e aeradores, somado à instalação de equipamentos para o monitoramento remoto do cultivo, permite a automação, coleta de dados mais precisos e a realização de tomadas de decisões mais rápidas, eficientes e eficazes.

O maior ganho da aplicação do IoT na aquicultura é a possibilidade do monitoramento em tempo real da qualidade da água, sendo um dos principais fatores a influenciar na saúde e no crescimento animal, bem como na produtividade

e lucratividade (CLERCQ et al, 2018). Isto só é possível devido a aplicação de sensores de qualidade da água, com módulos eletrônicos que coletam registros dos parâmetros de forma autônoma. O ato de utilizar os sensores físicos para realização do monitoramento é chamado de coleta física.

O poder computacional trazido pelos sistemas IoT permite a aplicação de mecanismos complementares à coleta física para a aquisição de dados paramétricos, que utilizam estes dados como entrada. Dentre estes mecanismos temos: o cálculo paramétrico, que faz uso de equações bem definidas para a obtenção do valor de parâmetros destino, como é o caso da salinidade ou do SOD; a predição por IA, na qual modelos de inteligência artificial realizam a predição do valor futuro de um dado parâmetro; e a estimação por IA, na qual também são utilizados modelos de inteligência artificial, para estimar o valor presente de um parâmetro destino.

## 2.3 COMPONENTES ELETRÔNICOS IOT

As seções abaixo discutem a respeito dos principais componentes eletrônicos utilizados na composição do hardware IoT.

### 2.3.1 Microcontroladores

O microcontrolador é um sistema em chip (*system-on-a-chip* - SoC) que inclui um processador, memória e interfaces de entrada/saída em um único dispositivo. Ele é projetado para realizar tarefas específicas em sistemas embarcados, como controle de motores, leitura de sensores e comunicação com outros dispositivos. Sua operação ocorre através de um firmware, que é um software incorporado na memória do microcontrolador, que dita seu comportamento com base na programação desenvolvida. É possível conectar periféricos através de pinos de entrada/saída e utiliza protocolos de comunicação seriais como *UART*, *I2C* e *SPI*.

Existem vários microcontroladores populares no mercado que são frequentemente utilizados para o desenvolvimento de protótipos de sistemas embarcados e IoT, como o ESP32, ESP8266 e o Arduino, segundo discute Karvinen (KARVINEN; TERO, 2018).

O ESP32 e o ESP8266 são microcontroladores com conectividade *Wi-Fi* e *Bluetooth* fabricados pela empresa chinesa *Espressif Systems*. Ambos possuem processadores de baixo consumo e são capazes de se conectar a uma variedade de

dispositivos e serviços em nuvem. O ESP32 tem maior capacidade de processamento e memória em relação ao ESP8266, o que o torna mais adequado para projetos mais complexos.

O Arduino, por sua vez, é uma plataforma de hardware e software open-source que utiliza microcontroladores da família AVR, fabricados pela empresa americana *Microchip Technology*. O Arduino é conhecido por ser fácil de usar e é amplamente utilizado em projetos de eletrônica e programação, tanto por iniciantes quanto por profissionais. O Arduino oferece uma ampla variedade de placas, cada uma com suas próprias especificações e recursos, permitindo que os usuários escolham a melhor opção para o seu projeto.

Todos esses microcontroladores oferecem uma variedade de opções de conectividade e podem ser programados usando uma variedade de linguagens de programação, incluindo C/C++, Python e Java. Com o suporte de uma ampla comunidade de desenvolvedores, é fácil encontrar documentação, tutoriais e exemplos de projetos para cada um deles.

### 2.3.2 Sensores

Segundo Wendling (WENDLING, 2010), um sensor é um transdutor, dispositivo capaz de converter um estímulo físico, como temperatura, pressão, luz ou movimento, em um sinal elétrico. São subdivididos entre os tipos, analógico e digital, referenciando a forma do sinal que estes módulos entregam como saída.

Os analógicos medem o estímulo físico como uma grandeza física e convertem essa informação em um sinal elétrico proporcional à magnitude da grandeza medida. A unidade física que geralmente é utilizada para representar este sinal é a tensão elétrica, medida em volts (V). Esse sinal representado por um valor contínuo, geralmente na faixa de 0 a 5 volts. O principal benefício deles é a simplicidade de funcionamento, podendo ser utilizados em automações a nível de hardware, sem a necessidade de processamentos lógicos adicionais para a realização de uma dada tarefa.

Já os sensores digitais, convertem esta grandeza medida em um sinal discreto, representado por um valor binário. Ou seja, o dado de saída já se encontra processado em sua unidade destino, tornando a leitura do valor coletado menos propensa a interferências do ambiente, uma vez que não há perda de informação no processo de conversão. Além disso, mecanismos de prevenção e correção de erro

podem ser aplicados durante o processo de transferência do dado, trazendo ainda mais confiabilidade nos valores de saída dos sensores digitais. Além disso, eles geralmente possuem uma maior capacidade de processamento, permitindo a realização de funções mais complexas diretamente no próprio sensor, como filtros, calibrações e compensações. Isso reduz a carga de processamento do microcontrolador, tornando o sistema mais eficiente e preciso.

### 2.3.3 Atuadores

Atuadores são dispositivos que convertem energia em movimento ou força física, sendo utilizados para controlar ou manipular o ambiente em que estão inseridos. Eles são responsáveis por receber um sinal de controle vindo de um sistema eletrônico e transformá-lo em uma ação física no mundo real (GARCÍA et al, 2017). Alguns exemplos comuns de atuadores são motores elétricos, solenoides, relés, válvulas, entre outros. Esses dispositivos são amplamente utilizados em sistemas automatizados e em sistemas de controle de processos industriais, além de serem comuns em aplicações de robótica e em sistemas IoT. No contexto da aquicultura, os atuadores mais utilizados são os aeradores, alimentadores, bombas d'água e aquecedores.

### 2.3.4 Relógios de Tempo Real (RTC)

Os RTCs (Real Time Clock) são circuitos integrados que têm como objetivo fornecer uma contagem de tempo preciso, autônoma e confiável. Eles são usados para manter o tempo atualizado em sistemas que não possuem uma conexão constante com a Internet, como sistemas embarcados, dispositivos móveis, sistemas de segurança e outros dispositivos eletrônicos que precisam manter a data e hora atualizada (FERRÃO, 2018). São geralmente compostos por um oscilador de cristal, que opera como um contador de tempo e determinam sua precisão.

São muito úteis em aplicações em que é necessário registrar o tempo em que ocorrem eventos, como em sistemas de monitoramento ambiental, automação industrial, controle de acesso, sistemas de segurança, sistemas de medição e controle de energia, entre outros. Eles também são usados em sistemas que exigem registros precisos de data e hora, como em sistemas de gravação de dados (*datalogger*) e dispositivos de rastreamento.

### 2.3.5 Conversores Analógico Digital (ADS)

Os Conversores Analógico Digital (ADCs) são componentes eletrônicos utilizados para converter um sinal analógico, como o de um sensor, em um sinal digital que pode ser processado por um microcontrolador ou outro dispositivo digital.

Eles podem ser classificados de acordo com a resolução, velocidade de amostragem, número de canais e outras características técnicas. Muitos microcontroladores já possuem ADCs embutidos em seu circuito integrado, entretanto, podem ser adequados para todas as aplicações, devido a limitações de precisão de requisitos elétricos. Neste cenário, ADCs externos podem ser utilizados, operando como interfaces tanto para aumentar a precisão quanto suprir estes requisitos elétricos do módulo conectado.

### 2.3.6 Gateway para IoT

Gateways para IoT são dispositivos responsáveis pela conexão e comunicação entre dispositivos de IoT. Eles podem ser vistos como intermediários entre os dispositivos de campo (sensores, atuadores, microcontroladores etc.) e a nuvem, permitindo que os dados sejam enviados e recebidos de forma segura e eficiente. Eles geralmente possuem recursos para processamento de dados, armazenamento temporário (*cache*), conversão de protocolos de comunicação, segurança e gerenciamento de dispositivos. Eles geralmente possuem interfaces de rede como *Wi-Fi*, *Ethernet* e *Bluetooth*, além de suportar protocolos de comunicação como (*Message Queuing Telemetry Transport*) *MQTT*, (*HyperText Transfer Protocol*) *HTTP* e (*Long Range Wide Area Network*) *LoRaWAN*.

### 2.3.7 Gerenciador de Carga

O gerenciador de carga é um dispositivo eletrônico que tem como função controlar o processo de carga e/ou descarga de baterias. Muitos gerenciadores de cargas são projetados para operarem em sistemas de geração de energia solar, balanceando a carga gerada pelos painéis solares para os demais módulos conectados a ele. Neste cenário, como é ilustrado por Gaikwad (GAIKWAD, 2020) o gerenciador de carga também monitora a tensão elétrica das baterias recarregáveis, interrompendo sua carga ou descarga quando atinge os níveis máximo e mínimo

respectivamente. A corrente de descarga gerada é utilizada para alimentação de módulos terceiros.

#### 2.3.8 Baterias de Lítio

As baterias de lítio são dispositivos de armazenamento de energia elétrica recarregável que utilizam compostos de lítio como um dos componentes de suas células eletroquímicas. Elas são amplamente utilizadas em dispositivos eletrônicos portáteis, como telefones celulares, tablets, entre outros, devido à sua alta densidade de energia e capacidade de manter a carga por longos períodos de tempo. Além disso, as baterias de lítio também são amplamente utilizadas em veículos elétricos e sistemas de armazenamento de energia para residências e empresas, pois apresentam alta eficiência e longa vida útil. No entanto, também podem apresentar riscos de segurança, como superaquecimento ou explosão, se não forem fabricadas e manuseadas corretamente.

#### 2.3.9 Painel Solar

Os painéis solares convertem a energia solar em eletricidade para alimentar os dispositivos IoT, como sensores, atuadores e microcontroladores, permitindo que operem sem a necessidade de estar conectados a uma fonte de alimentação externa. Além disso, eles podem ser equipados com recursos adicionais, como gerenciadores de carga, para proteger as baterias recarregáveis e prolongar sua vida útil, além de reguladores de tensão para fornecer energia estável e consistente aos dispositivos.

### 2.4 CONSIDERAÇÕES FINAIS

Foram apresentados os conceitos básicos ligados à aquicultura e seu desenvolvimento tecnológico. Também foi destacado o funcionamento da aquicultura e a importância do monitoramento dos parâmetros da água, bem como parâmetros mais relevantes para a aferição da qualidade da água neste contexto. Em seguida, foram discutidos os conceitos básicos de IoT, seu funcionamento como uma arquitetura, bem como sua aplicação na aquicultura e os benefícios associados a esta interação, como o controle remoto de equipamentos da fazenda, monitoramento automático e em tempo real de parâmetros da água e o apoio à

tomada de decisão. Por fim, foram apresentados os principais componentes eletrônicos utilizados na composição do hardware IoT.

### 3 TRABALHOS RELACIONADOS

---

Neste Capítulo são apresentados os principais trabalhos relacionados ligados a aplicação de soluções baseadas em IoT na aquicultura, bem como limitações destas soluções quanto ao problema do monitoramento em tempo real da aquicultura. Também são apresentados trabalhos que tratam da aplicação da inteligência artificial nestes sistemas baseados em IoT.

---

### 3.1 CONSIDERAÇÕES INICIAIS

Três grandes áreas foram consideradas para melhor compreender o estado da arte da aplicação de soluções IoT de baixo custo na aquicultura 4.0 quanto ao problema do monitoramento em tempo real da qualidade da água. A primeira foi a análise quanto às arquiteturas IoT propostas; a segunda quanto ao projeto de hardware IoT aplicado à aquicultura; e a terceira a respeito da aplicação de modelos de IA para a redução de custos de soluções baseadas em IoT. As seções abaixo discutem os trabalhos relacionados sob estas três óticas.

### 3.2 ARQUITETURAS DE IOT APLICADAS À AQUICULTURA

Propostas para o monitoramento da qualidade da água na aquicultura tendo como soluções IoT foram realizadas pela literatura. Muitas delas utilizam como base uma arquitetura IoT de três camadas, descrita por Burhan (BURHAN et al, 2018) como a representação das operação básicas que compõem um sistema de IoT, cujas funcionalidades são subdivididas nas camadas: física, responsável pela coleta dados ambientais por meio de sensores e atuar no ambiente físico através de atuadores; rede, responsável pela transferência dos dados gerados pela camada física através dos canais de redes, especialmente a Internet; e aplicação, responsável pelo contato com os usuários finais do sistema IoT, realizando o informe dos dados coletados em tempo real e remotamente.

É possível observar que a proposta trazida por Zaini (ZAINI et al, 2020) adota esta arquitetura IoT de três camadas. Neste trabalho, é realizado o monitoramento remoto da temperatura, pH e oxigênio dissolvido em uma fazenda de camarões através de sensores eletrônicos. Um aplicativo móvel é usado para apresentar dados de telemetria em tempo real por meio de um *dashboard*. A arquitetura suporta essa funcionalidade, com a camada de rede atuando como canal direto entre as camadas física e de aplicação, sem servidores em nuvem ou armazenamento de dados. Devido aos requisitos da proposta, esta arquitetura supre as necessidades do projeto, entretanto, poderia ser aperfeiçoada para trabalhar em cenários comerciais e de maior escala pela não realização do armazenamento de dados, a falta de processamento remoto e a não emissão de notificações de alertas.

Embora possua estas limitações, a arquitetura IoT de três camadas é amplamente utilizada em soluções do estado da arte, como pode ser observado nas seguintes propostas. Olmedo (OLMEDO; SMITH, 2021), que desenvolveu um

sistema baseado em IoT para o monitoramento da qualidade da água em áreas costeiras, para a identificação de locais adequados para a criação de ostras. Yauri (YAURI et al, 2017), que implantou um sistema IoT para o monitoramento da qualidade da água de rios na Amazônia peruana. Rasheed (RASHEED et al, 2020), que propôs um sistema de monitoramento da qualidade da água em ambientes de aquicultura, com foco em reduzir o consumo elétrico do hardware desenvolvido e propor equações para apoiar o processo de dimensionamento dos painéis solares e baterias recarregáveis para projetos similares. O ponto em comum que une estas três propostas é a sua aplicação em ambientes experimentais, cujos requisitos são supridos pela simplicidade apresentada pela arquitetura IoT de três camadas, apresentando as mesmas limitações listadas anteriormente.

Por outro lado, outras propostas adotaram arquiteturas IoT baseadas em quatro camadas. No trabalho de Billah (BILLAH et al, 2019), foi desenvolvido um sistema de monitoramento da qualidade da água em tempo real para fazendas de peixes. Essa solução adotou uma quarta camada, a camada de nuvem, que opera entre as camadas de rede a aplicação, sendo responsável por lidar com funcionalidades como o armazenamento, o processamento e a análise de dados em nuvem. Esta arquitetura possui uma maior complexidade de implementação, porém apresenta um menor acoplamento em relação a arquitetura de três camadas, devido a melhor subdivisão das responsabilidades de cada camada. Apesar destes ganhos, a proposta apresentada por Billah não realiza operações como o tratamento prévio de dados de telemetria, armazenando-os em sua forma bruta, aumentando desnecessariamente o consumo de processamento na camada de aplicação.

De forma similar, a mesma arquitetura IoT de quatro camadas foi adotada por outros trabalhos da literatura. Na proposta de Dzulqornain (DZULQORNAIN et al, 2018), a camada de nuvem foi implementada através da ferramenta (*If This Than That*) IFTTT, uma plataforma como um serviço (PaaS), que permite a integração de serviço de terceiros, como e-mail, SMS e APIs por meio de regras personalizadas. Essas regras foram usadas para gerenciar a operação automática de aeradores em um viveiro de aquicultura, controlados através de aplicativos web e móveis. Em contrapartida, não há suporte para emissão de notificações de alertas em tempo real, funcionalidade que apoia o processo de monitoramento. Na proposta de Duangwongsa (DUANGWONGSA et al, 2021) foi desenvolvido um sistema para notificação em tempo real da qualidade da água. Os autores também utilizaram uma

PaaS para implementar sua camada de nuvem, a ferramenta Thingspeak<sup>1</sup>. Neste contexto, é notório que a aplicação de PaaS para apoiar o desenvolvimento em arquiteturas IoT de quatro camadas é uma alternativa que vem sendo muito utilizada. Em compensação, surge também o desafio de selecionar a plataforma considerando seus custos à medida que demandas de maior escalabilidade apareçam.

A Tabela 1 apresenta a relação entre as arquiteturas observadas nas propostas dos trabalhos analisados, bem como presença de certas funcionalidades essenciais ao apoio do monitoramento em tempo real da aquicultura, como o armazenamento e processamento remoto e notificações de alerta.

Tabela 1 - Arquiteturas e funcionalidades dos trabalhos relacionados.

Referência	Arquitetura	PaaS	Armazenamento Remoto	Processamento Remoto	Notificações de Alerta
(ZAINI et al, 2020)	3 camadas	Não	Não	Não	Não
(OLMEDO; SMITH, 2021)	3 camadas	Não	Não	Não	Não
(YAURI et al, 2017)	3 camadas	Não	Não	Não	Não
(RASHEED et al, 2020)	3 camadas	Não	Não	Não	Não
(BILLAH et al, 2019)	4 camadas	On-Premises	Sim	Não	Não
(DZULQORNAIN et al, 2018)	4 camadas	IFTTT	Sim	Sim	Não
(DUANGWONGSA et al, 2021)	4 camadas	Thingspeak	Sim	Sim	Sim

Fonte: elaborado pelo autor

Analisando a Tabela 1 é possível afirmar que a arquitetura IoT de três camadas é comumente utilizada em soluções voltadas a aquicultura 4.0. Entretanto esta arquitetura não supre as necessidades de cenários onde há a necessidade de processamento remoto, devido a seu projeto ser destinado apenas ao envio de dados da camada física à de aplicação. Sua adaptação para tais requisitos implica num maior acoplamento da arquitetura, aumentando o número de funcionalidades presentes em cada camada, aumentando sua complexidade e os custos de

<sup>1</sup> <https://thingspeak.com/>

desenvolvimento e manutenção. Quatro dos trabalhos relacionados observados adotaram esta arquitetura. A adoção de uma arquitetura IoT de quatro camadas também foi observada em três trabalhos relacionados, onde a camada de nuvem é adicionada entre as camadas de rede e aplicação, sendo responsável primariamente pelo armazenamento de dados em nuvem. Dois destes realizaram a implementação desta camada através de PaaS, que apoiou o desenvolvimento dos mecanismos de processamento remoto. Já quanto a funcionalidade de notificação de alertas, capaz de apoiar o monitoramento remoto do cultivo de forma mais assertiva, só foi implementada em um dos trabalhos relacionados.

### 3.3 PROJETO DE HARDWARE IOT APLICADO À AQUICULTURA

Além de questões envolvendo a lógica de negócio e implementações de sistema, outro fator crucial no monitoramento da qualidade da água em sistemas IoT é o projeto do hardware a coleta de dados paramétricos. Este hardware é comumente concretizado no formato de protótipos.

No estudo conduzido por Romli (ROMLI et al, 2017) o protótipo foi projetado para operar apenas em ambientes laboratoriais, tendo sua implementação realizada em placa de prototipação (protoboard), tornando o circuito elétrico mais sujeito a problemas com mal contato, e não tendo utilizado invólucro impermeável, para proteção de intempéries, umidade e infiltrações, tornando-o sua instalação em viveiros de aquicultura imprópria. Outro aspecto relevante é que o mecanismo de alimentação do dispositivo, que usa a rede elétrica cabeada, limitando sua usabilidade e aumentando os custos de implantação com a instalação de infraestrutura cabeada.

De forma similar, o protótipo desenvolvido por Billah (BILLAH et al, 2019) também foi desenvolvido para operar em laboratório, também tendo utilizado protoboard para a montagem do hardware. Utilizou um invólucro para proteger o hardware e facilitar seu transporte, entretanto, por não ser impermeável, também está sujeito a danos decorrentes de condições ambientais adversas, como umidade e chuva, que podem comprometer a funcionalidade e a durabilidade do sistema.

Já a protótipo proposto por Zaini (ZAINI et al, 2020) foi implantado em um viveiro real e utilizou uma quantidade significativa de sensores para medir temperatura, pH e OD (seis unidades de cada) distribuídos ao longo do viveiro. Os autores mapearam a posição física de cada sensor para melhorar a precisão das

leituras e os conectaram por meio de cabos ao microcontrolador, que ficou fixado nas margens do viveiro. Embora essa abordagem possibilite um monitoramento de múltiplos pontos do viveiro, ela também aumenta os custos com a aquisição de hardware, implementação, instalação e manutenção do sistema. Em particular, a instalação do protótipo é complexa, exigindo uma análise técnica da posição de cada sensor, prejudicando seu processo de transporte para outros viveiros, devido a sua natureza estática. Além disso, a manutenção dos sensores é difícil, especialmente em viveiros com grandes dimensões de lâmina d'água.

Dzulqornain (DZULQORNAIN et al, 2018) propôs dois tipos de protótipos, para as funcionalidades de monitoramento e de controle. Eles interagem entre si através da análise de dados e regras pré-configuradas na plataforma IFTTT, alimentados pelos dados de temperatura, pH e OD coletados para permitir o funcionamento autônomo de aeradores. Ambos os protótipos foram construídos em invólucros impermeáveis, reduzindo sua degradação por intempéries, porém, seu circuito elétrico foi montado em placa de prototipação. Apesar de apresentar maior transportabilidade que a proposta de Zaini, ambos os protótipos precisam ser fixados à margem do viveiro, limitando o seu local de coleta de dados e muitas vezes implicando na adequação da infraestrutura física da fazenda para tal. Além disso, devido ao fato de utilizarem a rede elétrica cabeada como alimentação contribui para o aumento de custos para a implantação da solução.

Já o protótipo desenvolvido por Duangwongsa (DUANGWONGSA et al, 2021) apresentou maior confiabilidade no circuito elétrico por realizar sua montagem em placa de circuito impresso (PCB), mais robusta que circuitos montados em placa de prototipação uma vez que todos os componentes são soldados, dificultando que os módulos eletrônicos se soltem e aumentando sua maior vida útil. Também utilizou invólucro impermeável para fixação do circuito elétrico. Apesar disso, de modo similar a Dzulqornain, utiliza o mecanismo de instalação por fixação às margens do viveiro e alimentação elétrica cabeada.

A proposta de protótipo de Olmedo (OLMEDO; SMITH, 2021) foi desenvolvida para aplicações no mar, em áreas litorâneas, para apoiar a criação de ostras. Os autores propuseram uma estrutura flutuante, comportando um invólucro impermeável e placas solares em sua parte superior. Desta forma, a alimentação do circuito elétrico é realizada via energia solar. Esta proposta beneficia a facilidade de manutenção e instalação do equipamento num viveiro, não dependendo da

adequação do mesmo por meio de rede cabeada ou estruturas de fixação. Porém, devido a aplicações marítimas, a estrutura flutuante proposta é de difícil montagem, encarecendo seu processo de fabricação.

A Tabela 2 mostra uma relação dos estudos previamente discutidos em relação as características do projeto de hardware propostos pelos trabalhos relacionados, sendo elas: a necessidade de se utilizar rede cabeada como fonte de alimentação; utilização de invólucro impermeável; utilização de PCB para montagem de circuito elétrico; se requer instalação fixa na borda dos viveiros; se utiliza alimentação por energia solar; e se apresenta mecanismo para a configuração sem fio do protótipo.

Tabela 2 - Características do hardware IoT proposto pelo estado da arte.

Referência	Rede elétrica cabeada	Invólucro impermeável	PCB	Instalação independente de infraestrutura	Energia solar	Mecanismo de configuração sem fio
(ZAINI et al, 2020)	sim	não	não	não	não	não
(ROMLI et al, 2017)	sim	não	não	não	não	não
(BILLAH et al, 2019)	sim	não	não	não	não	não
(DZULQORNAIN et al, 2018)	sim	sim	não	não	não	não
(DUANGWONGSA et al, 2021)	sim	sim	sim	não	não	não
(OLMEDO; SMITH, 2021)	não	sim	não	sim	sim	não

O uso de redes cabeadas como fonte de alimentação pode fornecer uma fonte de energia estável e confiável, no entanto, ela implica num investimento adicional de insumos pelo produtor, e a complexidade no processo de adequação da rede elétrica da fazenda, principalmente nas de grandes dimensões de terreno, dificultam o processo de instalação e manutenção do sistema. Ainda assim, é uma metodologia comum, sendo utilizada em cinco dos trabalhos relacionados.

A impermeabilização do invólucro do protótipo é importante para garantir que ele possa ser instalado sob a água sem riscos de danos elétricos. Além disso, deve-

se ter cuidado com o tipo de material utilizado para evitar a corrosão de componentes eletrônicos, devido a fatores como a variação da temperatura e umidade, trazendo maior robustez e aumentando a vida útil do equipamento. Esta característica só foi aplicada em três dos trabalhos relacionados.

A utilização de PCB aumenta a vida útil da porção elétrica do protótipo, também ajudando a reduzir seu tamanho, que é um fator importante em ambientes onde o espaço é limitado, além de evitar o mau contato entre conexões e trazer maior confiabilidade no transporte do protótipo. Entretanto, esta característica só foi aplicada em um dos trabalhos relacionados.

Além disso, tornar o processo de instalação do protótipo independente da infraestrutura física existente, resulta em um menor custo de manutenção e economia com insumos adicionais. Essa característica é especialmente importante para permitir uma maior transportabilidade do protótipo entre viveiros, permitindo sua aplicação em mais ciclos de produção. Ainda assim, apenas um dos trabalhos relacionados utilizaram esta característica.

A alimentação via energia solar é outra característica que incrementa os mesmos benefícios trazidos pela independência de infraestrutura. É uma opção eficiente para alimentação elétrica do protótipo, especialmente em áreas remotas onde não há acesso à rede elétrica. Permite uma maior autonomia de operação do protótipo, reduzindo sua necessidade com contato humano. Entretanto, apenas um dos trabalhos relacionados a adicionaram em seus protótipos.

Por fim, uma característica que não esteve presente em nenhum dos trabalhos relacionados é a capacidade de configurar o protótipo a distância. Diferente de equipamentos de uso dedicado, cujo manuseio ocorre através de botões ou interfaces em sua estrutura, a proposta da configuração a distância permite ajustar estes protótipos sem a necessidade de interação física. Esta pode ser vista como uma característica que beneficia sua usabilidade, pois com o uso de equipamentos do próprio dia a dia, como *smarphones*, podem ser utilizados para configurá-los, sem a necessidade de retirá-los dos tanques de produção, simplificando sua instalação e manutenção.

### 3.4 INTELIGÊNCIA ARTIFICIAL APLICADA NA AQUICULTURA

Atualmente, ferramentas baseadas em inteligência artificial vêm sendo desenvolvidas para operarem em conjunto com sistemas IoT voltados para

aquicultura. Grande parte delas surgem no formato de mecanismos de aprendizagem de máquina, com a principal vantagem de proporcionar reduções nos custos destes sistemas, seja através da melhoria da automação de processos ou por meio extração inteligência a partir dos dados coletados.

A proposta trazida por Bokinkito (BOKINGKITO; LOMESINDO, 2018) aplicou lógica fuzzy para apoiar o processo de tomada de decisão quanto a qualidade da água. Regras definindo a qualidade de cada parâmetro coletado foram consideradas numa linguística, utilizada pela lógica fuzzy para determinar automaticamente a qualidade da água e auxiliar com maior assertividade as ações necessárias para a manutenção do cultivo. Neste contexto é possível observar a cooperação deste tipo de ferramentas com sistemas IoT, que alimenta o modelo proposto pelos autores com os dados coletados.

Outras propostas com foco no uso de aprendizagem de máquina (*Machine Learning* – ML) na predição da qualidade da água também foram realizadas. Nos trabalhos de Swetha (SWETHA et al, 2023) e Wang (WANG et al, 2017), foram propostos modelos que preveem o valor futuro de uma variável objetivo, como a temperatura, o pH, a salinidade, o total de fósforo e o oxigênio dissolvido (OD). Para isto, todos estes parâmetros da água são utilizados como entrada dos modelos. A saída é definida pela forma que o treinamento foi realizado.

Os modelos são treinados com base em aprendizado supervisionado e utilizando bases de dados contendo históricos de qualidade da água. Embora essa abordagem de previsão seja muito útil para prospectar situações críticas antes que elas aconteçam, ela falha na obtenção do valor desta variável objetivo no tempo presente.

Foram realizadas propostas promovendo reduções de custos em sistemas de IoT aplicados a aquicultura. Em Galajit (GALAJIT et al, 2018), modelos de ML baseados em redes neurais artificiais (ANN) e regressão quadrática foram treinados para descrever a dinâmica do oxigênio dissolvido (OD) em um ambiente controlado de cultivo de camarão branco (*Litopenaeus vannamei*). Seu principal objetivo era o de substituir os sensores de OD por esses modelos, tendo em vista que estes são um dos sensores mais caros do mercado. Os modelos propostos foram treinados com os próprios dados coletados durante os 50 dias de cultivo. Os modelos eram alimentados com registros temporais contendo data e hora, sendo treinados para prever os níveis de OD correspondentes, permitindo assim a análise das variações

ao longo do dia. Utilizaram como função objetivo a Raiz Quadrada do Erro Médio (*Root Mean Squared Error* - RMSE), que calcula o erro médio e tem como meta aproximar suas pontuações de zero. Apesar do RMSE médio ter sido de 0,35, os autores destacam que o comportamento estável do OD seria exclusivo do ambiente altamente controlado não representando adequadamente as condições comuns em tanques de aquicultura. Além disso, a abordagem proposta considerou apenas a utilização de registros de tempo como entrada dos modelos, ignorando a influência de outros parâmetros nas dinâmicas do OD, como a temperatura e o pH, que afetam significativamente seu comportamento.

Já em Araujo (ARAUJO et al, 2015), modelos de aprendizado de máquina (ML) baseados em redes neurais artificiais (ANNs) foram propostos para estimar o OD na água do Rio Alegria, localizado no Paraná, Brasil. Como no trabalho anterior, esses modelos tem como variável objetivo de saída o OD, porém, neste cenário os modelos utilizam gama maior de parâmetros de entrada, incluindo: demanda bioquímica de oxigênio, demanda química de oxigênio, condutividade elétrica (EC), temperatura e pH. Somente o próprio OD não é considerado como dado de entrada. A inclusão de um número maior de parâmetros como entrada fornece aos modelos maior poder de análise quando as dinâmicas do OD, tornando a proposta mais próxima do cenário real de aquisição dos níveis deste parâmetro e melhorando a precisão dos algoritmos. Entretanto, também está associada a um alto custo no sistema IoT, devido a grande quantidade de sensores, aumentando os custos com aquisição de hardware e manutenção de cada um deles.

Neste contexto, a solução de Shandikri (SHANDIKRI; BAYU, 2021) propõe um método para estimar a concentração de amônia não ionizada (tipo mais tóxico de amônia) e a solubilidade do oxigênio dissolvido (SOD) sem depender dos sensores físicos destes parâmetros. Em vez disso, sensores de pH e temperatura são utilizados para obter essas estimativas destas variáveis, através das equações de Ermerson e Beson-Krause, que utilizam justamente estes registros como entrada. Os valores de RMSE obtidos foram de 0,48 para SDO e 0,13 para amônia, na mesma ordem de grandeza dos resultados obtidos por Galajit. Por outro lado, a metodologia aplicada não foi a de utilizar modelos de aprendizagem de máquina, mas sim equações conhecidas para realizar o cálculo destes parâmetros. Além disso, embora a amônia não ionizada seja muito importante para os ambientes de cultivo, o SOD não é tão relevante, pois representa apenas a máxima saturação

possível de oxigênio dissolvido numa solução. O indicador realmente crucial neste contexto é a concentração de oxigênio dissolvido (OD). Desta forma, embora a solução proposta traga consigo reduções consideráveis no custo de sistemas IoT, permitindo a obtenção de quatro parâmetros com o uso de apenas dois sensores, não supre as reais necessidades de cultivos de aquicultura, que exigem a coleta do OD para o apoio de seus processos.

Em resumo, diversas abordagens de inteligência artificial e aprendizado de máquina foram exploradas visando à otimização dos sistemas de IoT, com o intuito de diminuir custos financeiros associados. Embora propostas focadas na previsão de parâmetros futuros ofereçam celeridade à tomada de decisões, como a de Wang (WANG et al, 2017), elas não conseguem proporcionar a medição imediata dos valores correntes das variáveis de interesse. Em relação à redução dos custos através da eliminação do sensor de OD, duas estratégias foram investigadas. Na primeira delas, proposta por Araujo (ARAUJO et al, 2015), um grande volume de sensores físicos é empregado para estimar o OD, entretanto, isso pode acarretar encarecimento devido à necessidade de outros sensores. Na segunda delas, proposta por Shandikri (SHANDIKRI; BAYU, 2021), a amônia não ionizada e a saturação do OD são inferidas exclusivamente a partir dos sensores de pH e temperatura. No entanto, essa alternativa peca ao não conseguir mensurar diretamente os níveis de OD, uma vez que o indicador de saturação apenas indica o valor máximo teoricamente possível de oxigênio presente no meio.

Desta forma, foi observado que à medida que mais parâmetros de entrada são utilizados nos modelos de ML, maiores serão os custos de fabricação e de manutenção do hardware IoT. Além disso, embora dois estudos relacionados tenham proposto a estimativa do OD como resultado, nenhum deles realizou essa tarefa considerando dados de sensores de baixo custo como entrada.

## 4 UMA SOLUÇÃO DE BAIXO CUSTO BASEADA EM IOT PARA O MONITORAMENTO DA QUALIDADE DE ÁGUA NA AQUICULTURA 4.0

---

Neste Capítulo é discutida a solução proposta da dissertação, abordando aspectos como o levantamento de requisitos, a arquitetura de IoT proposta, o projeto e a implementação de cada um dos requisitos mapeados nesta arquitetura.

---

#### 4.1 CONSIDERAÇÕES INICIAIS

No presente Capítulo é apresentada a contribuição trazida pela presente dissertação, a proposta de uma solução IoT de baixo custo para o monitoramento da qualidade da água na aquicultura 4.0. Inicialmente é abordado o processo de levantamento de requisitos. Também é discutido o processo do projeto da solução, agrupando funcionalidades e tecnologias necessárias para a concretização numa arquitetura IoT de baixo acoplamento, ou seja, que apresenta baixa dependência entre os módulos e camadas do sistema, tornando seu escalonamento, construção e manutenção mais simples e barato. Por fim, são discutidos os aspectos de implementação de cada camada IoT, apresentando as técnicas, tecnologias, e padrões aplicados.

#### 4.2 LEVANTAMENTO DE REQUISITOS

Com o foco em possibilitar uma solução IoT de baixo custo para o monitoramento da qualidade da água na aquicultura 4.0, primeiramente foi analisado as funcionalidades essenciais para este tipo de sistema no contexto do público-alvo que mais carece do acesso a este tipo de tecnologia, os pequenos e médios aquicultores, que representam a base da cadeia produtiva. As formas de uso básica são para que os produtores sejam capazes de monitorar a qualidade da água de seu empreendimento remotamente e o de poderem receber notificações de alertas em casos de alterações na qualidade da água. Embora simples, estas duas formas de uso representam as necessidades básicas de um sistema IoT para aquicultura. Porém, o alto custo de aquisição e manutenção destes sistemas os tornam muitas vezes inacessíveis a este nicho. Desta forma, foram mapeados os seguintes objetivos: desenvolver uma arquitetura IoT de baixo acoplamento para o monitoramento em tempo real da qualidade da água; desenvolver e integrar ao sistema IoT modelos de inteligência artificial para a estimação de oxigênio dissolvido através das medições de temperatura e pH; desenvolver plataforma IoT para o apoio a transmissão sem fio heterogênea, baseada no contexto da eficiência energética, para o provisionamento de dados em nuvem; desenvolver hardware IoT para medição de pH e temperatura, com robustez suficiente para suportar as condições adversas dispostas em unidades reais de cultivo de aquicultura; e desenvolver mecanismo de notificações de alertas em tempo real.

O desenvolvimento de uma arquitetura IoT de baixo acoplamento para o monitoramento da qualidade da água se faz importante, pois reduz a complexidade de implementação e de manutenção e manutenção do sistema desenvolvido, facilitando o mapeamento do consumo de recursos de cada camada IoT e permitindo uma melhor análise de custos do sistema.

Um dos maiores problemas da aquicultura convencional é o desregularidade do monitoramento da qualidade da água, que dependente de medidores manuais, que possuem preços elevados, grande fragilidade e difícil utilização. Além disso erros oriundos do registro manual das coletas de dado também prejudicam o processo do monitoramento da qualidade da água. A aplicação de IoT permite a automação deste processo de monitoramento, entretanto, os projetos destes sistemas ainda são elevados, principalmente devido aos elevados custos de aquisição e manutenção dos sensores de OD. Neste contexto, foi realizada uma pesquisa envolvendo o desenvolvimento de modelos de aprendizagem de máquina para a estimação do OD através das aferições de temperatura e pH, oriundas de sistemas IoT de monitoramento. Isso afeta diretamente a redução de custos de mercado desses sistemas de IoT, tornando possível a substituição do sensor de OD por outros sensores de menor custo. O modelo de melhor desempenho apresentado neste trabalho foi considerado para integração junto a solução proposta.

Outra característica inerente a sistemas baseados em IoT é a conectividade com a Internet. Um dos maiores desafios nos cultivos de aquicultura é a falta de conectividade, tornando necessário a busca de novos mecanismos para garantir que o monitoramento em tempo real não seja prejudicado. A aplicação de redundância de mecanismos de transmissão sem fio é uma opção. O suporte a tecnologias como Wi-Fi e GPRS surge como a opção mais viável de implementação da conectividade, por serem amplamente difundidas e terem alta disponibilidade de serviços, mesmo em área de cultivo remota. Além disso, os gateways para IoT são acessíveis no mercado, sendo um facilitador na produção do hardware da solução.

Ainda nesta linha, um fator que prejudica a correta tomada de decisão na aquicultura é a perda de dados. Este problema é ocasionado principalmente devido a falhas de conectividade dos dispositivos IoT com a Internet. Desta forma, também entra como requisito o desenvolvimento de mecanismo para registro de dados temporários (*data logger*), responsável por armazenar dados cuja transferência à Internet falhou, permitindo seu envio posterior e reduzindo perdas de dados.

Já com relação ao funcionamento lógico do sistema, ele concretizado através da implementação de suas funcionalidades através de uma plataforma de IoT, que simplifica o processo de integração dos dispositivos IoT e de módulos de armazenamento, provisionamento e análise de dados remotos. Somado a isto, para a aplicação do sistema proposto em escala comercial, ocorre a necessidade do suporte a alta disponibilidade e escalabilidade, podendo ser endereçada com a combinação da plataforma IoT integrada a plataforma como um serviço (PaaS) ou infraestrutura como um serviço (IaaS).

Com relação ao hardware IoT para a realização da coleta de dados, seu requisito foi o de utilizar sensores de pH e de temperatura, de modo a apoiar o funcionamento da solução proposta junto do modelo de inteligência artificial para estimação do OD, dispensando assim o uso do sensor de OD. Além disso, o projeto estrutural deste hardware precisa considerar sua robustez, de modo a suportar as diversas intempéries da natureza e a interação com os próprios animais do cultivo, que podem danificar o equipamento. Desta forma, todo o circuito elétrico precisa ser integrado em placa de circuito impresso (PCB), para reduzir a probabilidade de falhas elétricas como interferências e curtos-circuitos. Somado a isto, todo o invólucro do hardware precisa ser impermeável, impedindo infiltrações e o impacto de variações de umidade.

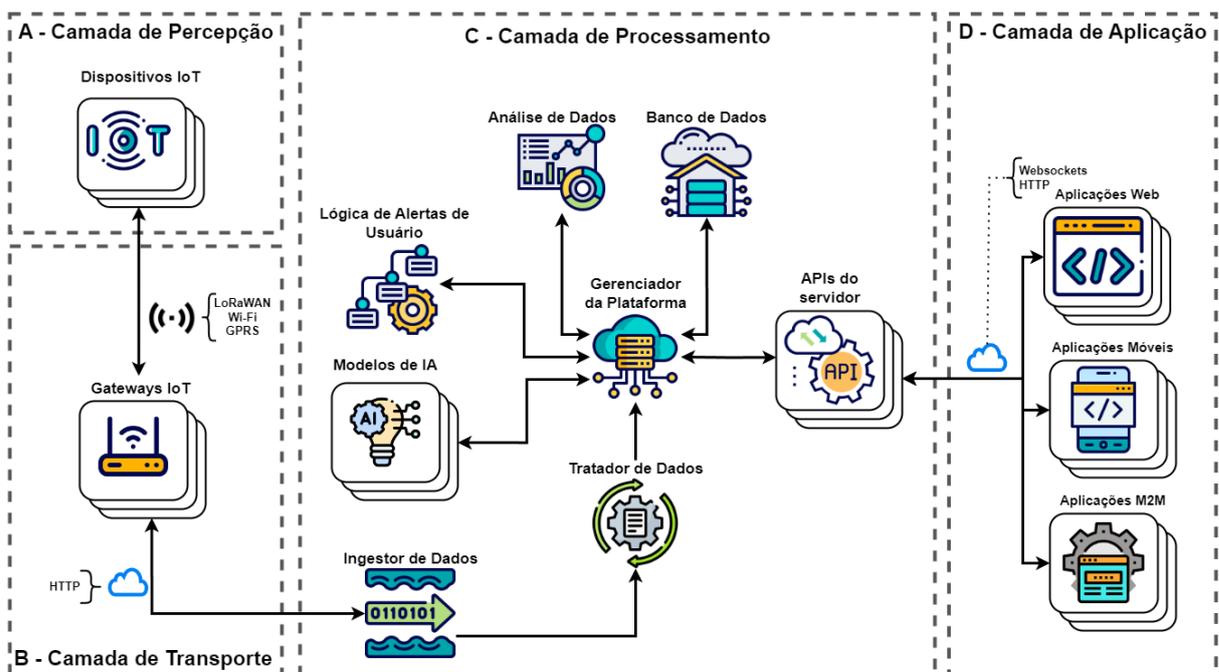
Com o objetivo de estender o período de operação sem intervenção humana e aproveitando a abundante exposição à luz solar, também foi incluído o projeto de um mecanismo de alimentação elétrica por meio de energia solar. Somado a isto, a fixação do hardware sob uma estrutura flutuante para uma maior transportabilidade sob a lâmina d'água de viveiros de criação. Desta forma, estes dois fatores permitem uma maior facilidade de adequação do equipamento físico em ambientes produtivos, não sendo necessária a instalação de suportes nos arredores, dispensando alterações na infraestrutura e na rede elétrica cabeada da fazenda.

Por fim, a usabilidade do equipamento físico também entra como requisito chave para uma boa adequabilidade do mesmo em ambientes produtivos. A presença de um mecanismo para a configuração sem fio do mesmo traz uma maior aceitabilidade da tecnologia por parte do nicho de mercado da solução. Desta forma, o desenvolvimento de uma interface de fácil configuração torna-se necessária para o sistema proposto, para que os próprios usuários sejam capazes de configurá-los, sem a necessidade de técnicos especializados para isto.

### 4.3 ARQUITETURA IOT PROPOSTA

Com base no levantamento de requisitos, foi proposta a arquitetura IoT ilustrada na Figura 2, sendo composta por quatro camadas: (A) camada de percepção; (B) camada de transporte; (C) camada de processamento; e (D) camada de apresentação. Esta arquitetura foi projetada com foco na escalabilidade de sistema em níveis comerciais, possuindo um baixo acoplamentos entre as camadas e melhor aproveitamento dos recursos computacionais disponíveis. Estas características e as responsabilidades de cada camada são descritas nas seções abaixo.

Figura 2 - Arquitetura IoT proposta com suas respectivas camadas.



Fonte: elaborado pelo autor. Ícones (<https://www.flaticon.com>)

#### 4.3.1 Camada de Percepção

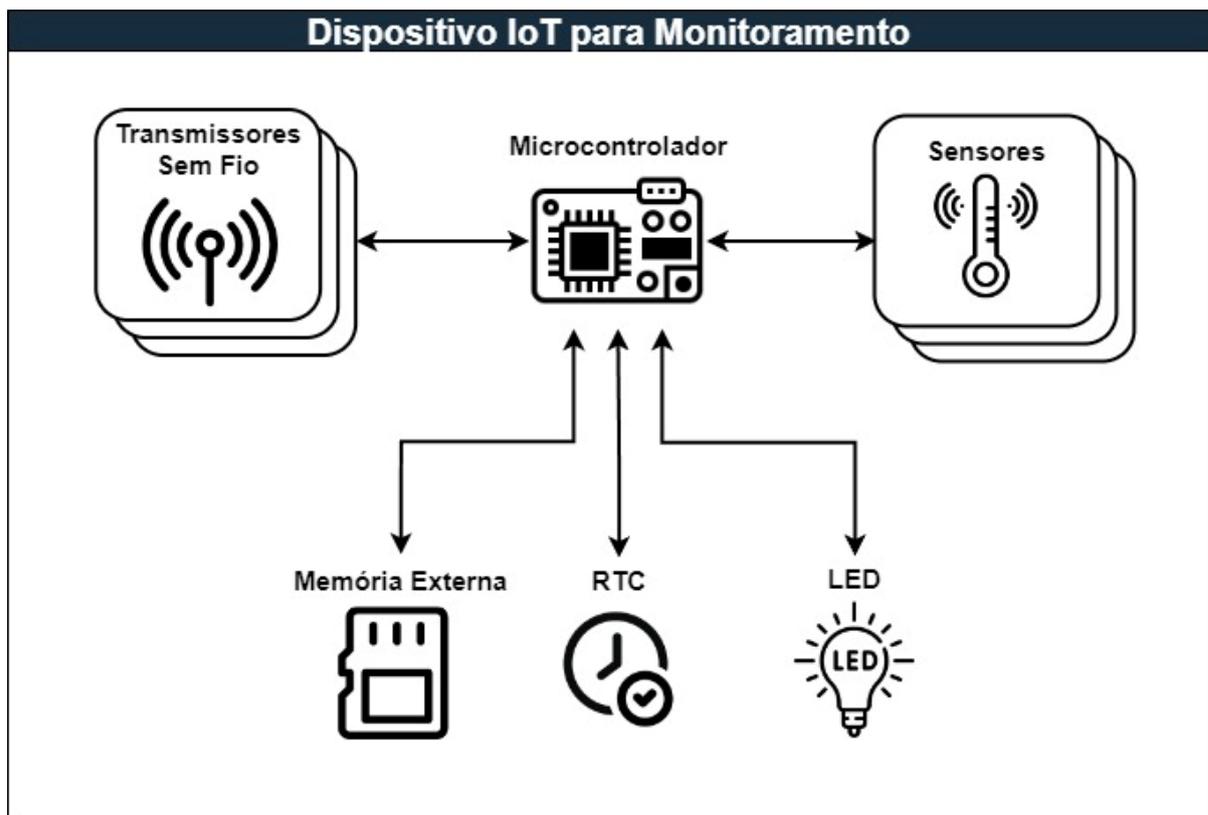
##### 4.3.1.1 Projeto

A camada de percepção é responsável pela interação física com o ambiente de aquicultura. Nela estão presentes os dispositivos IoT (*device IoT*) responsáveis por realizar a coleta física de dados através de sensores subaquáticos de pH e temperatura. Diversos destes dispositivos podem ser instalados numa mesma propriedade, idealmente com um dispositivo por viveiro de criação. O objetivo deles é o de realizar o monitoramento remoto e em tempo real da qualidade da água,

garantindo que nenhum dado coletado seja perdido, reduzindo a probabilidade de registros faltantes nas bases de dados do sistema.

Desta maneira, os dispositivos foram projetados no modelo ilustrado na Figura 3, sendo compostos por seis tipos de módulos: os sensores, que realizam a coleta física de dados; os transmissores sem fio, que transmitem esses dados para a camada de transporte; o LED RGB, utilizado para emitir sinais de status de operação do hardware; o relógio de tempo real (RTC), que registra a data e a hora para propósitos de sincronização de tempo do sistema; a memória externa, que armazena dados de configuração e os registros dos sensores; e o microcontrolador, que gerencia o funcionamento entre os módulos anteriores.

Figura 3 - Modelo proposto para o hardware do dispositivo IoT.



Fonte: elaborado pelo autor. Ícones (<https://www.flaticon.com>)

O funcionamento por trás deste dispositivo IoT inicia-se com a coleta física de dados através de sensores prosseguida com seu envio através dos transmissores sem fio. Devido a instabilidades das conexões com a Internet comumente presentes nos ambientes de cultivo de aquicultura, transferência mal sucedidas podem ser comuns, e acarretam em perdas de dados e prejuízos aos

processos de tomada de decisão do cultivo. Desta forma, de modo a sanar este problema, o RTC e a memória externa operam de maneira conjunta, como um *datalogger*, registrando dados coletados em memória quando a conectividade é interrompida, para envios posteriores após a conexão ser restabelecida. Desta forma, mesmo que em momentos pontuais existam dados faltantes nos bancos de dados do sistema, a longo prazo todos os dados coletados serão armazenados, entregando um histórico de dados completo aos usuários do sistema.

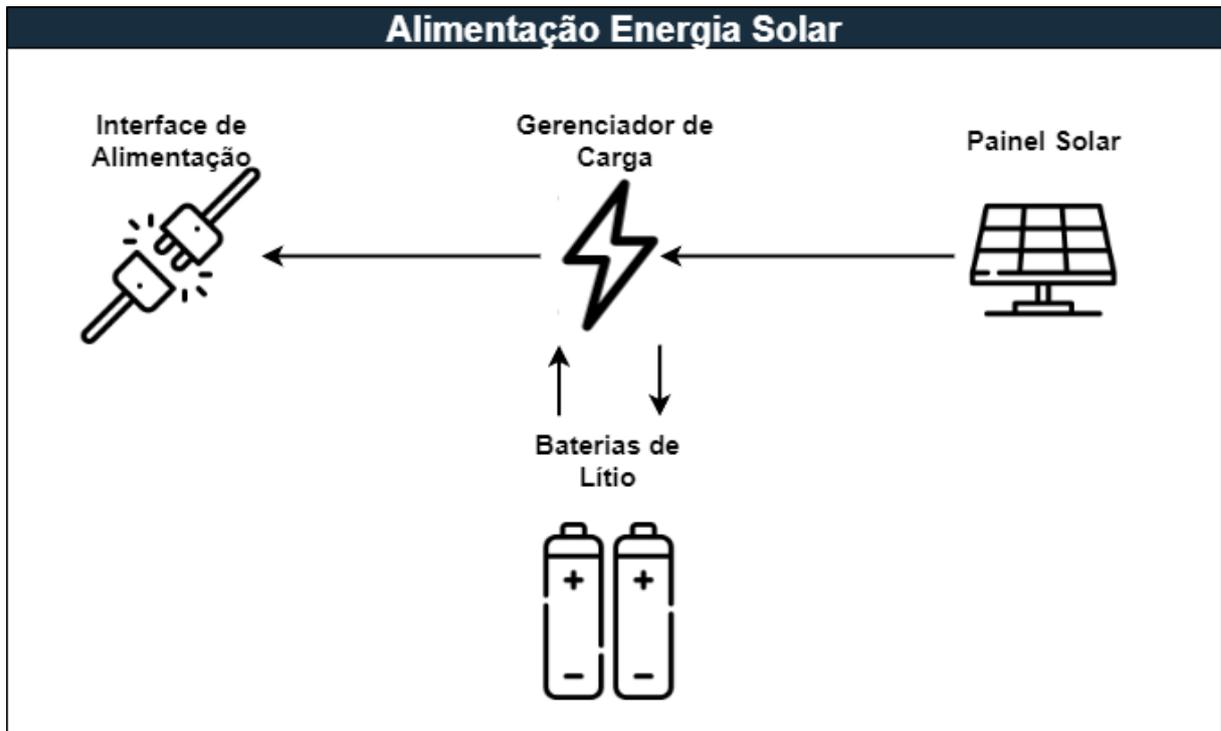
Na Figura 3, os módulos são apresentados de maneira genérica, ou seja, isto indica que desde que os requisitos elétricos e a lógica de funcionamento sejam satisfeitas, a concepção do dispositivo funcionará como esperado independente dos módulos utilizados. Desta forma, para possibilitar uma implementação de baixo custo, a escolha dos módulos eletrônicos foi realizada conforme os critérios a seguir.

Foram utilizados sensores de pH e temperatura para o a coleta física de dados. Esta escolha se deu devido a integração com o modelo de inteligência artificial para a estimativa do oxigênio dissolvido desenvolvido na presente dissertação, que utiliza justamente estes dois parâmetros de entrada para seu funcionamento.

Quanto aos módulos de transmissão de dados, as tecnologias Wi-Fi e GPRS foram selecionadas. Segundo observações empíricas realizadas durante visitas *in-situ* em propriedades de produção aquífera no estado de Pernambuco, constatou-se que estas são tecnologias de transmissão de dados amplamente difundida nestes meios. Além disso, a ampla disponibilidade de módulos eletrônicos para estes gateways nacionalmente simplifica o processo de desenvolvimento do equipamento, barateando de seu custo de produção e de manutenção.

Em paralelo a isto, o projeto de um mecanismo para alimentação elétrica do dispositivo foi realizado. Devido a alta incidência solar sob grande parte dos viveiros de produção aquífera, a geração de energia solar foi utilizada a favor do aumento da autonomia do dispositivo IoT. Desta forma, com base no modelo ilustrado na Figura 4, foi proposto um sistema de alimentação via energia solar para ser integrado ao dispositivo IoT. Ele possibilita seu acionamento independente da rede elétrica cabeada da fazenda, não sendo necessária infraestrutura cabeada adicional, reduzindo assim os custos com insumos e com a concessionária de energia.

Figura 4 – Modelo do mecanismo de alimentação elétrica por energia solar.



Fonte: elaborado pelo autor. Ícones (<https://www.flaticon.com>)

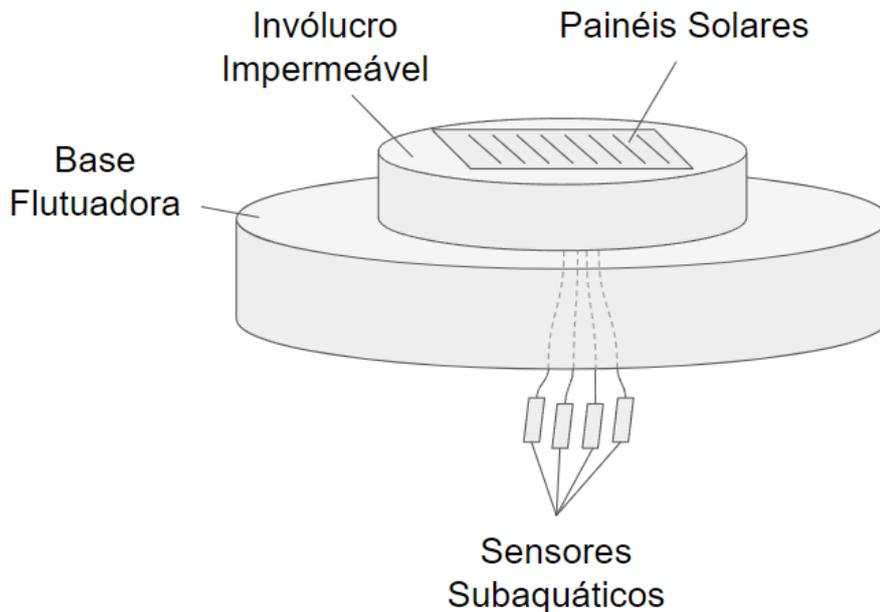
O sistema de alimentação via energia solar é composto por quatro módulos: os painéis solares, que ficam expostos ao sol e geram energia elétrica; baterias de lítio, que armazenam a energia gerada; o gerenciador de carga, que controla a carga e a descarga das baterias a níveis seguros, a fim de aumentar sua autonomia; e a interface de alimentação, que regula a tensão elétrica para valores estáveis.

Outro fator considerado foi a adequabilidade física dos dispositivos IoT em ambientes de produção. Elementos como as intempéries da natureza, como a chuva, sol e variações de umidade podem ser extremamente severas a eles, podendo gerar a oxidação e rompimento de conexões, interferências elétricas, mau contato e até a queima dos módulos eletrônicos. Desta forma foi projetado uma placa de circuito impresso (PCB), a fim de aumentar a vida útil do hardware da solução, por tornar as fixações definitivas através de soldagem, evitando falhas elétricas.

Além disso, também foi considerado o aumento da robustez estrutural dos dispositivos, também a fim de aumentar sua vida útil frente a problemas como o constante transporte, manuseio e manutenção destes equipamentos que podem

ocasionar danos. Desta forma, foi realizado o design industrial desta estrutura nestes moldes, como é ilustrado na Figura 5.

Figura 5 – Design industrial do dispositivo IoT.



Fonte: elaborado pelo autor

Como o meio primário ao qual estes equipamentos serão inseridos é na superfície da água, todo o circuito elétrico foi fixado dentro de um invólucro impermeável (IP68), de modo que infiltrações e a umidade não afetem. Este invólucro é fixado numa base flutuadora, que fica sob a lâmina d'água do viveiro. Esta base pode ser facilmente manuseada, sendo fixada nos viveiros através dos próprios cabos presentes nas laterais dos viveiros, de modo semelhante a outros equipamentos amplamente utilizados na aquicultura, como aeradores e alimentadores. Desta forma, o presente projeto dispensa alterações física na infraestrutura da fazenda, reduzindo o custo com mão de obra, e melhorando a transportabilidade destes equipamentos. Na parte superior do invólucro impermeável são fixados os painéis solares, para aumentar a incidência solar direcionada a eles. Este posicionamento também beneficia a autonomia do dispositivo, visto que grande parte da sujeira acumulada nos painéis é removida pela própria água do viveiro que cai sobre eles. Por fim, os sensores subaquáticos são fixados em conectores nas laterais do invólucro. A profundidade da instalação destes sensores pode ser ajustada durante a sua instalação no viveiro.

#### 4.3.1.2 Implementação

A implementação do dispositivo IoT de acordo com o que foi projetado é dividida em duas etapas: o desenvolvimento do hardware e de seus requisitos elétricos; e o desenvolvimento do firmware, ou seja, o software que representa a lógica de negócio por trás do hardware.

##### 4.3.1.2.1 Desenvolvimento do Hardware

O desenvolvimento do hardware do dispositivo IoT iniciou-se a partir da seleção dos módulos eletrônicos necessários para sua composição, que tomou como base os requisitos elétricos do microcontrolador. Módulos com alimentação de até 5v e de nível lógico de 3,3v foram priorizados. Isto se deu de modo a reduzir o número de componentes eletrônicos. Foi utilizado um microcontrolador baseado em ESP32, pois estes possuem integração nativa com módulos de comunicação sem fio, como WI-Fi, BLE. Foi integrado ao microcontrolador um módulo SIM800L para permitir comunicações GPRS. Além disso, microcontroladores ESP32 possuem mecanismos de economia de energia, como *Modem Sleep*, *Light Sleep* e *Deep Sleep*, e canais de comunicação serial para os protocolos UART, I2C e SPI, que simplificam o processo de desenvolvimento do hardware.

Foram utilizados os seguintes módulos eletrônicos periféricos na composição do circuito elétrico do dispositivo: LED RGB; leitor de cartão de memória; ADC; (D) módulo de geolocalização; RTC; e sensores de pH e de temperatura.

O LED RGB foi utilizado para a emissão de sinais luminosos, convencionados durante o desenvolvimento do firmware, ou seja, serviu como interface para os usuários do sistema observarem o status do *device* IoT a distância. O módulo de geolocalização foi utilizado para como mecanismo de prevenção de falhas na análise de dados do sistema, impedindo o cruzamento de dados paramétricos de viveiros distintos num mesmo dispositivo virtual.

Devido ao fato nível lógico do microcontrolador utilizado ser de 3,3 volts e de que o pH (pH-4502c) emitir um sinal de até 5 volts, para evitar danos devido a tensões acima de 3,3v foi utilizado um ADS externo para atender aos requisitos elétricos de ambos. Para o sensor de temperatura foi utilizado o modelo DS18B20,

por ser a prova d'água. Devido ao fato de emitir um sinal digital de dados de até 3,3 volts, foi conectado diretamente ao microcontrolador por meio de portas lógicas.

Foi utilizado um módulo RTC para o registro do tempo mesmo enquanto o dispositivo IoT permanece desligado, permitindo que o mesmo registre coletas paramétricas mesmo sem ainda ter acesso à Internet. Além disso, o RTC opera em conjunto com o leitor de cartão de memória como um *datalogger*, registrando dados quando há falhas de transferência para a camada de transporte.

Já em relação ao mecanismo de alimentação via energia solar, foram utilizados os seguintes módulos: gerenciador de carga; interface de alimentação; painel solar; bateria de lítio; suporte para bateria de lítio; e chave switch gangorra.

O painel solar fotovoltaico utilizado tem capacidade de geração de até 6 watts de potência, com uma tensão elétrica máxima de até 6 volts. O cabo na parte inferior do painel foi utilizado para conectá-lo ao gerenciador de carga. Como medida de proteção, foi utilizado um diodo no polo positivo do painel, para evitar danos por corrente reversa. Para o gerenciador de carga foi utilizado o modelo TP4056, pois é construído justamente para conectar painéis solares e baterias de lítio numa mesma placa. Este módulo também possui um mecanismo de proteção contra a carga e a descarga excessiva das baterias, que reduz sua autonomia. Foram utilizadas duas baterias de lítio em paralelo, para aumentar a corrente (carga) disponível. Por fim, como o gerenciador escolhido emite um sinal de saída equivalente a tensão elétrica das baterias, foi utilizado um regulador de tensão do tipo step-up, para elevá-la para 5 volts estáveis, como sugere o manual do microcontrolador.

A montagem do hardware em estrutura física foi a última etapa do desenvolvimento do hardware. Ela se deu por meio de quatro etapas: o desenvolvimento da PCB; a furação do invólucro de fixação do hardware; a adaptação dos conectores dos módulos eletrônicos; a união dos componentes de montagem; e por fim, a fixação de todo este aparato na boia flutuadora.

A PCB desenvolvida teve o papel é o de unir todos os módulos eletrônicos descritos anteriormente em um circuito elétrico definitivo. Foi projetada com foco na instalação de sensores diversos, suportando a conexão de até 4 sensores digitais diretamente aos pinos de dados do microcontrolador e de até dois módulos ADC externos, cada um suportando até 4 sensores analógicos. O limite destes sensores que podem ser instalados depende apenas da corrente elétrica de entrega disponível pelo microcontrolador.

Paralelo isto, foi selecionado um invólucro impermeável, para fixação do hardware em seu interior. Foi utilizada uma caixa de montagem de dimensões 170x145x90mm, com proteção IP68, ou seja, impede completamente tanto a entrada de poeira quanto de líquidos. Em sua lateral foram realizadas furações para a fixação dos conectores dos sensores de temperatura e pH, chave switch, LED e conector da placa solar. Foram impressos quatro suportes em 3D, para a fixação do painel solar na parte superior da caixa de montagem, que utilizam as furações do próprio painel solar para a inserção de parafusos para isto. Foi realizada a instalação dos conectores impermeáveis nos cabos do painel solar, do sensor de temperatura e nos pinos do LED RGB.

Em seguida foi realizado o processo de soldagem dos módulos na PCB e a montagem tanto da PCB quanto dos conectores na caixa de montagem. A placa solar foi fixada na parte superior da caixa montagem com o auxílio de parafusos e porcas inoxidáveis. E por fim, o mesmo tipo de boia flutuante utilizada para fixação de aeradores foi aplicada para instalar o aparato mencionado anteriormente, concretizando assim a fabricação do dispositivo IoT proposto, conforme é ilustrado na Figura 6.

Figura 6 - Dispositivo IoT montado.



Fonte: elaborado pelo autor

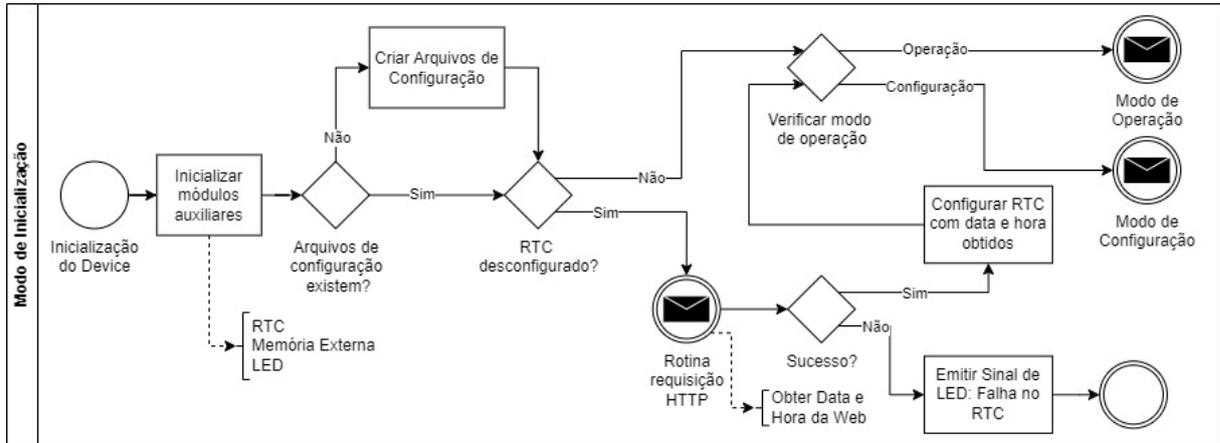
#### 4.3.1.2.2 Desenvolvimento do Firmware

A lógica de negócio do dispositivo é construída com base na programação armazenada no microcontrolador, também conhecida como firmware. Este, que desempenha o papel de unidade central de processamento, gerenciando os módulos periféricos através desta lógica. Essas placas possuem capacidade computacional limitada, portanto, as tarefas de processamento mais intensivas são executadas remotamente na camada de processamento. Foi utilizada a interface de desenvolvimento Arduino, utilizando a linguagem de programação C++.

Paralelo a isto, devido ao fato de o mecanismo de alimentação do hardware ser baseado em baterias de lítio e energia, a energia elétrica disponível é um recurso escasso, mesmo que este sistema tenha sido projetado para suprir completamente a descarga do hardware durante períodos sem sol. Em cenários onde a incidência solar seja muito baixa por longos períodos, firmwares que demandem alto consumo energético dos módulos periféricos podem esgotar as baterias, desligando o *device* e prejudicando o monitoramento em tempo real. Desta forma, o requisito base para a implementação do firmware foi a economia de energia. A ideia central por trás desta economia de energia é a de acionar os módulos periféricos sob demanda, evitando o consumo de outros módulos ociosos.

O modo de inicialização, ilustrado na Figura 7, representa o fluxo por onde o funcionamento do firmware começa. Inicialmente são acionados os módulos RTC, memória externa e LED, pois estes recebem demandas constantes de todas as demais rotinas. São criados os arquivos de configuração do sistema, caso eles não existam. É verificado se o RTC está configurado com a data e hora corretas. Caso não esteja, então é chamada a rotina de requisição HTTP, ilustrada na Figura 8, com o propósito de obter a data e hora (GMT). Caso ocorra algum erro durante este procedimento, então é emitido um sinal de erro no LED, porém, caso funcione, o RTC é configurado e volta ao seu estado funcional. Caso desde o início o RTC já esteja configurado corretamente, então é verificado o modo de operação do firmware, determinado pela quantidade de vezes que o usuário pressiona o *power switch*. Um acionamento inicia o modo de operação, mais de um inicia o modo de configuração. A contagem de acionamentos é armazenada nos arquivos de configuração criados como primeira etapa da rotina de inicialização.

Figura 7 - Rotina do modo de inicialização.

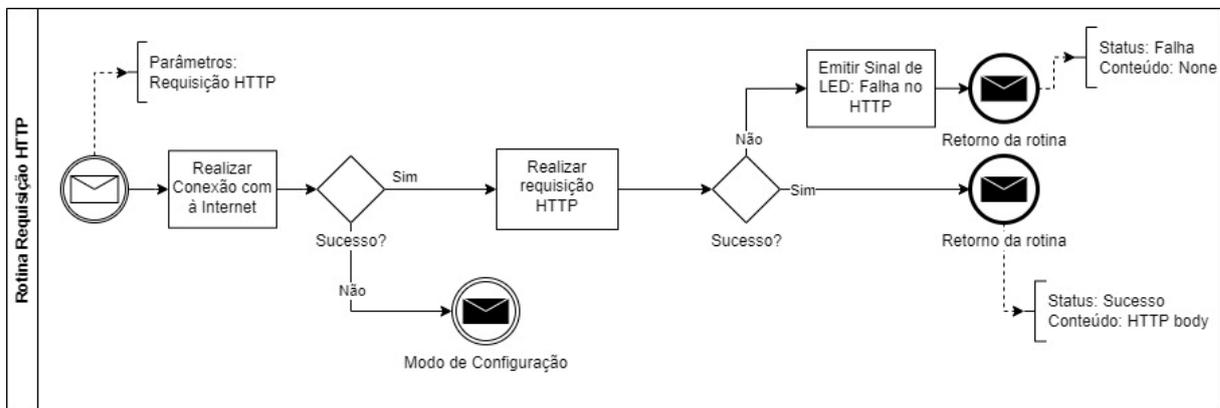


Fonte: elaborado pelo autor

A rotina de execuções de requisições HTTP POST é ilustrada na Figura 8. Dentro da lógica de negócio do firmware, dado que o *device* é projetado exclusivamente para o envio de dados dos sensores às camadas superiores, a execução constante dos módulos de transmissão de dados é desnecessária, sendo habilitadas apenas nos modos de configuração e nesta presente rotina.

Desta forma, seu funcionamento é iniciado com o recebimento da requisição HTTP como parâmetro. Em seguida, é realizada a tentativa de conexão com a Internet. Caso ela não seja bem-sucedida, então é chamado o modo de configuração. Caso contrário, é realizada a requisição HTTP. Caso o código de status da resposta da requisição seja igual a 200, então são retornados o status marcado como sucesso e o conteúdo como o http body da requisição. Caso contrário, o status é marcado como falha e o conteúdo marcado como vazio.

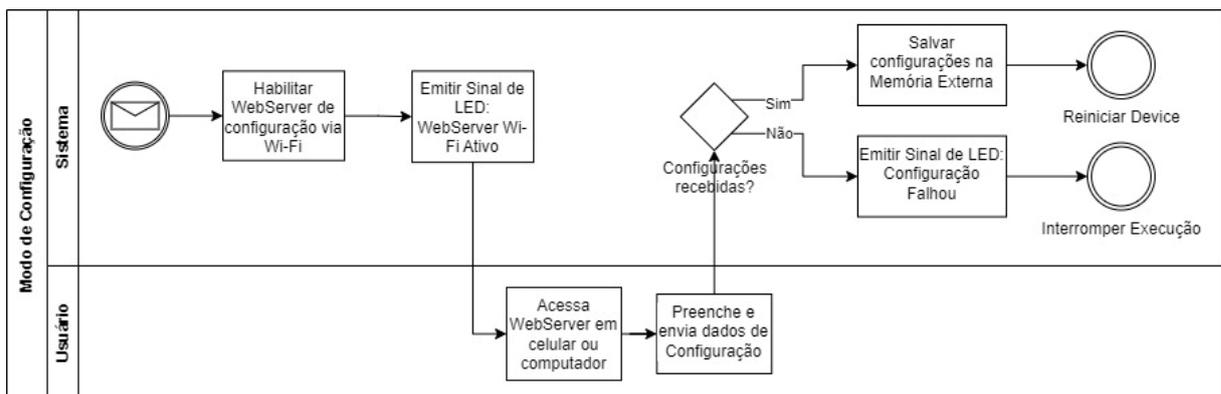
Figura 8 - Rotina de execução de requisições HTTP.



Fonte: elaborado pelo autor.

O modo de configuração, ilustrado na Figura 9, representa o fluxo por trás da inserção das credenciais para conexão Wi-Fi e GPRS e de acesso à plataforma IoT. Seu fluxo é dividido por duas entidades, o próprio sistema do *device* e o usuário. O fluxo inicia-se com a habilitação do transmissor Wi-Fi do microcontrolador no modo *access point* sem senha, a partir do qual é hospedada uma página web no formato de um *captive portal*, que pode ser acessado por um aparelho celular ou computador. Assim que o usuário se conecta nesta rede é exibida a página Web ilustrada na Figura 10. O LED emite o sinal de que o modo de configuração está ativo. O usuário acessa a página web e preenche os dados de configuração e clica em salvar. Após isso, o sistema verifica se estas configurações foram recebidas com sucesso. Caso sim, as credenciais são salvas nos arquivos de configuração e o *device* é reiniciado. Caso contrário, é emitido um sinal de falha de configuração no LED.

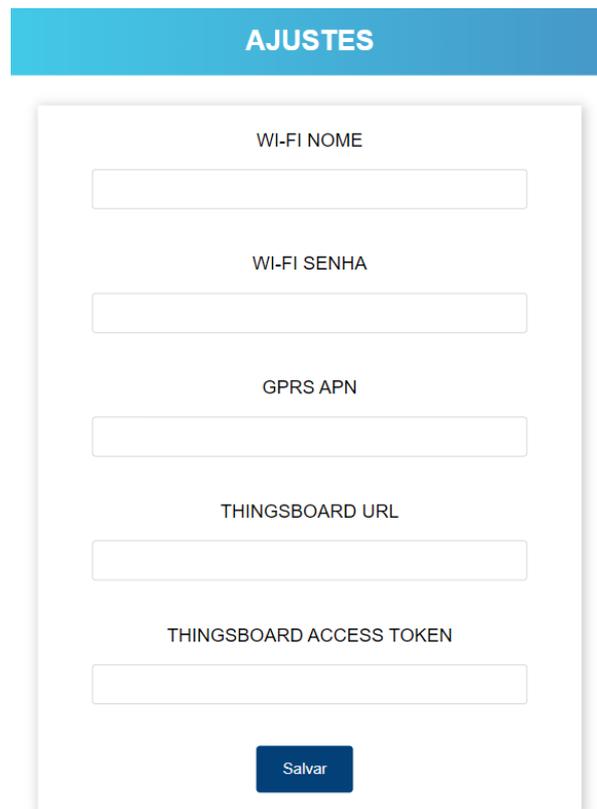
Figura 9 - Rotina do modo de configuração.



Fonte: elaborado pelo autor

A página Web apresentada para configuração é a ilustrada na Figura 10. Nela são solicitados o nome e senha de acesso do Wi-Fi desejado, nome do ponto de acesso GPRS, o endereço de Internet e o token de acesso da plataforma IoT.

Figura 10 - Página web para configuração do dispositivo IoT.



The image shows a web interface for configuring an IoT device. At the top, there is a blue header with the word "AJUSTES" in white. Below the header, there is a white form with a light gray border. The form contains six input fields, each with a label above it: "WI-FI NOME", "WI-FI SENHA", "GPRS APN", "THINGSBOARD URL", and "THINGSBOARD ACCESS TOKEN". At the bottom of the form, there is a blue button with the word "Salvar" in white.

Fonte: elaborado pelo autor

O modo de operação, ilustrado na Figura 11, representa a principal funcionalidade do *device*, a de coletar e enviar dados paramétricos. Inicialmente os módulos de operação, o GPS e os sensores são acionados. Em seguida o fluxo lógico se divide em dois processos que operam em paralelo: o primeiro (Fluxo A), para a coleta de novos registros de dados; e um outro (Fluxo B), para tratar do envio de dados armazenados no *data logger*, cujo envio falhou em iterações passadas.

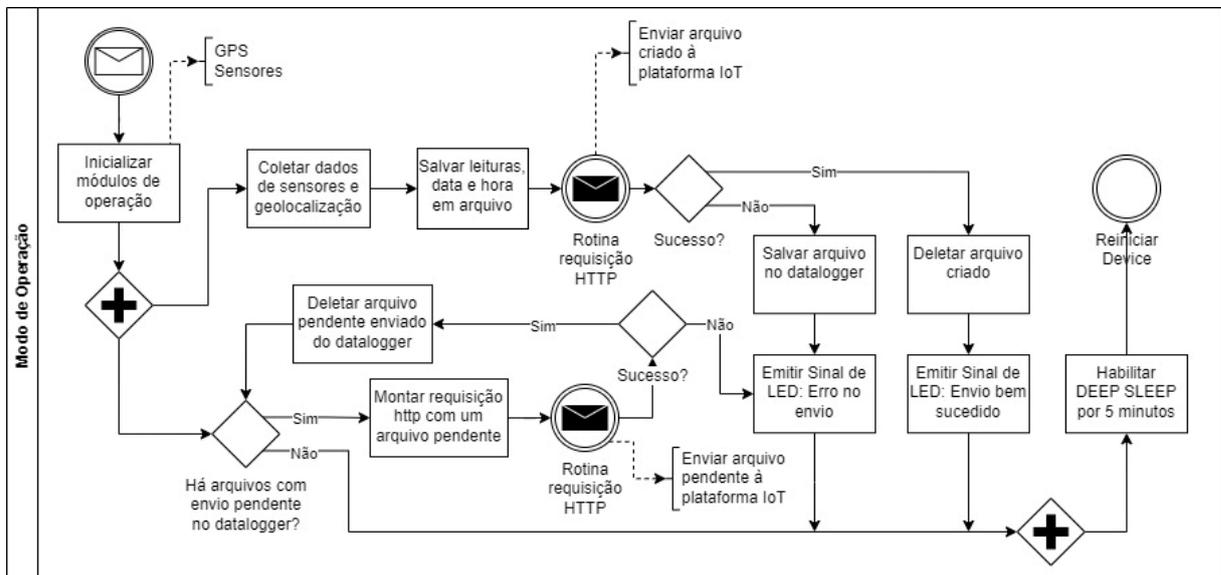
No Fluxo A, são solicitados ao GPS a leitura da geolocalização e aos sensores os registros da temperatura e do pH. Estes dados são salvos num arquivo, juntamente com a data e hora oriundas do RTC, de modo a registrar o momento exato que a leitura ocorreu. Após isto, é realizada a transferência do conteúdo deste arquivo à plataforma IoT, através de uma chamada a rotina de requisição HTTP. Caso o procedimento funcione, então este arquivo é deletado, é emitido um sinal no LED de envio bem-sucedido e o fluxo lógico junta-se à execução principal do modo de operação.

No Fluxo B, primeiramente é verificado se há arquivos de envio pendentes armazenados no *data logger*. Caso existam, então é recuperado um dos arquivos

salvos da memória e seu conteúdo carregado no corpo de uma requisição HTTP. É chamada a rotina de requisição HTTP para o envio desta requisição. Caso a requisição seja bem-sucedida, então se remove este arquivo e a verificação de arquivos pendentes é reiniciada. Caso a requisição falhe ou não existam arquivos de envio pendentes no *datalogger*, então o fluxo lógico junta-se à execução principal do modo de operação.

Uma vez que os ambos os fluxos em paralelo retornam à execução principal, é habilitado o modo de economia de energia no microcontrolador, o *deep sleep*, por cinco minutos. Em seguida, o *device* é reiniciado e o fluxo se repete no modo de inicialização mais uma vez. Este tempo foi definido com base em observações empíricas e heurísticas recomendadas por engenheiros de pesca especialistas em análises de dados de qualidade da água. Cinco minutos foi o tempo selecionado de modo a evitar o acúmulo excessivo de dados não trariam diferença significativa às análises e seriam esparsos o suficiente para manter economizar energia e tornar o protótipo autônomo por maiores períodos.

Figura 11 - Rotina do modo de operação.



Fonte: elaborado pelo autor

#### 4.3.2 Camada de Transporte

##### 4.3.2.1 Projeto e Implementação

A camada de transporte é responsável por fornecer comunicação confiável entre os dispositivos IoT com a Internet. Ela garante a entrega ordenada e sem erros dos dados transmitidos, além de lidar com a segmentação e remontagem de

pacotes, controle de fluxo e controle de congestionamento. Na arquitetura IoT proposta, a camada de transporte garante a transmissão eficiente e segura dos dados coletados na camada de percepção para os sistemas de processamento e análise de dados. Isso permite o monitoramento contínuo e a tomada de decisões em tempo real com base nas informações recebidas. Esta camada atua diretamente no requisito do apoio à transmissão sem fio heterogênea e tem seu funcionamento baseado na operação de gateways para IoT.

Os gateways para IoT são responsáveis por realizar a conexão direta com os dispositivos IoT, recebendo as transferências de dados oriundas dos seus transmissores de dados. Estes gateways são representados como múltiplas instâncias no esquema citado, pois para cada transmissor sem fio instalado em um dispositivo IoT, um gateway para atender a respectiva transmissão é necessário. Exemplos de rádios neste contexto são: o Wi-Fi e GPRS, que operam com os protocolos IPv4 ou IPv6; o LoRa, que utiliza o protocolo LoRaWAN; o ZigBee, que denominam tanto o nome do rádio quanto do protocolo; dentre outros.

Conforme discutido no projeto da camada de percepção, a escolha dos transmissores sem fio para os rádios Wi-Fi e GPRS beneficiou a implementação da camada de transporte, bem como a escolha dos gateways utilizados. No caso do Wi-Fi, os gateways são os próprios roteadores de Internet, que permitem uma integração direta com a infraestrutura de rede existente. Já o GPRS utiliza a infraestrutura das operadoras de telefonia, aproveitando suas redes de dados móveis por meio Estações Rádio Base (ERB) distribuídas em todo o território nacional, que oferecem ampla cobertura para as comunicações deste tipo. Essas decisões de projeto garantem uma implementação eficiente e abrangente das soluções de conectividade sem fio heterogêneas.

Além da capacidade de tratar as questões físicas de comunicação via rádio, como modulação ou multiplexação, os gateways para IoT também realizam conexão com a Internet, permitindo a integração dos dispositivos IoT com os servidores em nuvem. Na presente proposta, essa integração ocorreu utilizando o protocolo de aplicação HTTP, amplamente adotado no contexto do IoT devido ao seu suporte abrangente para o desenvolvimento de aplicações e compatibilidade com diversas plataformas IoT.

É importante ressaltar que, na prática, dependendo dos módulos de transmissão de dados escolhidos na camada de percepção, podem ser necessárias

configurações adicionais de lógica e infraestrutura para viabilizar a comunicação. No entanto, na presente proposta, tais implementações não foram necessárias, uma vez que as tecnologias de rede foram selecionadas para promover a fácil integração dos dispositivos nas fazendas de cultivo. Isso contribui para uma implantação mais eficiente e simplificada.

#### 4.3.3 Modelo de machine learning para estimação de od

##### 4.3.3.1 Projeto

##### 4.3.3.1.1 Avaliação de Custos de Sensores de Qualidade da Água

O requisito de desenvolver modelos de ML para a estimação do OD em ambientes de aquicultura a fim de dispensar o uso obrigatório do sensor de OD surgiu como uma opção para proporcionar uma redução de custos na solução IoT proposta. Desta forma, uma análise de custo de sensores subaquáticos foi realizada, para melhor compreender a redução proporcionada pela retirada do sensor de OD. A Tabela 3 mostra o preço dos sensores de temperatura, pH, OD, EC e de ORP em dólar em relação a dois dos maiores fabricantes de sensores, a DFRobot<sup>2</sup> e a Atlas Scientific<sup>3</sup> (Atlas).

Tabela 3 - Análise comparativa dos preços de sensores subaquáticos.

Fabricante	Parâmetro	Modelo do Sensor	Preço (US\$)
DFRobot	Temperatura	KIT0021	7,50
	pH	SEN0169-V2	64,90
	Oxigênio Dissolvido	SEN0237-A	169,00
	Condutividade	SEN0451	199,00
	ORP	SEN0464	129,00
Atlas Scientific	Temperatura	KIT-304	29,99
	pH	KIT-103P	67,99
	Oxigênio Dissolvido	Kit-103DX	259,99
	Condutividade	EC-KIT-1.0	199,99
	ORP	KIT-102O	149,99

Fonte: elaborado pelo autor. Pesquisa realizada em 13/08/2023.

<sup>2</sup> <https://dfrobot.com/>

<sup>3</sup> <https://atlas-scientific.com/>

Considerando o somatório de custos dos sensores de temperatura, pH e OD de cada fabricante observa-se um total de US\$ 242,39 para a DFRobot e de US\$ 357,97 para a Atlas. Se deste somatório desconsiderarmos a compra do sensor de OD, então o respectivo custo total seria de US\$ 72,4 para a DFRobot e de US\$ 97,98 para a Atlas. Isto representa uma economia de 70% no custo com sensores. Além disso, considerando que outros sensores, como o de condutividade elétrica (EC) e o de potencial de oxidação-redução (ORP), com aplicações menos comuns que os outros três citados têm custos da mesma ordem de grandeza que o do sensor de OD, então a seleção dos sensores de temperatura e do pH se alinha com os objetivos da proposta da dissertação.

#### 4.3.3.1.2 Modelos de ML propostos

Os modelos de ML propostos foram baseados em algoritmos de regressão usados no aprendizado supervisionado: *Linear Regression* (LR); *Support Vector Regressor* (SVR); *Regressor Random Forest* (RF); *Regressor K-Nearest Neighbors* (KNN); *Multi Layer Artificial Neural Network* (MANN); e *Long Short Term Memory* (LSTM). Eles são divididos em dois conjuntos. Os modelos LSTM e MANN, baseados em redes neurais, foram projetados com base nos modelos propostos por Dabrowski (DABROWSKI et al, 2018) e Zhang (ZHANG et al, 2019). Além disso, o parâmetro de *epoch*, que define o número máximo de iterações do modelo sob o mesmo conjunto de dados, foi definido como 32 iterações para esses dois modelos, e para taxa de aprendizado atribuído o valor de 0.01 unidades.

Os LR, KNN, SVR e RF, foram escolhidos com base nas propostas de Galajit (GALAJIT et al, 2018) e de Swetha (SWETHA et al, 2023), a fim de comparar modelos clássicos da aprendizagem de máquina com modelos de redes neurais, que naturalmente consomem mais recursos computacionais. Dessa forma, foi avaliada a possibilidade aplicar um modelo de menor demanda computacional para resolver o mesmo problema, economizando processamento

#### 4.3.3.2 Implementação

O processo de implementação dos modelos de ML envolveu duas etapas: o treinamento dos modelos utilizando base de qualidade da água e a construção de uma API REST para permitir a comunicação destes modelos treinados com a camada de processamento.

#### 4.3.3.2.1 Treinamento dos Modelos de ML

A estimação do OD como uma variável objetiva não é uma tarefa trivial. Devido ao fato de que o comportamento do OD é influenciado pelas nuances de outros parâmetros da água em diferentes janelas de tempo, aplicar apenas os registros mais recentes de temperatura e pH como entrada para os modelos pode não ser suficientemente representativo. Assim, essas entradas foram modeladas como séries temporais, representando essas janelas temporais e permitindo que os modelos se ajustassem melhor à dinâmica da variação do OD.

Dessa forma, o banco de dados do estuário do Baffle-Creek (BAFFLE CREEK, 2023), referente ao ano de 2021, foi usado para realizar o treinamento dos modelos. A escolha desse banco de dados foi devido a presença de vários registros de parâmetros de água, como temperatura, pH e OD, coletados em intervalos de 10 minutos por um medidor multiparâmetro de parâmetros de água. O número de 22.255 registros nesse banco de dados contribuiu para a modelagem de várias séries temporais de entrada para o treinamento dos modelos. Na Tabela 4 é apresentada a estatística dos treinamentos dos modelos.

Tabela 4 - Estatística descritiva das bases de dados utilizadas nos treinamentos.

Dataset	Parâmetro	Mínimo	Máximo	Média	Desvio Padrão	Coefficiente de Variação (%)
All-Year	°C	9,61	31,9	25,75	5,02	19,50
	pH	7,00	8,35	7,93	0,15	1,89
	DO	0,69	9,54	6,00	1,34	22,33
Dry-Season	°C	9,61	31,9	20,21	6,77	33,50
	pH	7,00	8,17	7,81	0,17	2,18
	DO	0,69	8,61	5,11	2,03	39,73
Wet-Season	°C	18,8	31,2	27,71	1,80	6,50
	pH	7,32	8,35	7,98	0,12	1,50
	DO	3,69	9,54	6,32	0,78	12,34

Fonte: Elaborado pelo autor.

Além disso, como o banco de dados contém dados de 2021, foram realizados três experimentos de treinamento, considerando as estações seca e úmida da região de Queensland – Austrália, que foi o local onde estes dados foram coletados. Desta forma, três bases de dados: a original, considerando o ano inteiro, nomeada para propósitos didáticos de All-Year; para a estação seca (maio a outubro), compondo o dataset Dry-Season; e a estação úmida (novembro a abril), compondo o dataset Wet-Season. Para cada experimento aplicou um destes

conjunto de dados, que são compostos pela seguinte quantidade registros: All-Year (22255 registros), Dry-Season (5816 registros) e Wet-Season (16439 registros). A avaliação desses diferentes bancos de dados foi útil determinar se os conjuntos de dados de diferentes épocas do ano influenciam o desempenho dos modelos.

Antes do processo de treinamento, os dados passaram por um pré-processamento que incluiu a remoção de registros sem leituras de temperatura, pH ou OD. Em seguida, os dados de pH e temperatura foram normalizados usando a técnica de normalização estatística, transformando-os em uma escala de 0 a 1. Isso permitiu que os modelos analisassem cada entrada com a mesma importância. Posteriormente, as séries temporais foram formatadas como listas contendo 10 registros, com cada registro contendo uma leitura de pH e temperatura, espaçados a cada 10 segundos. Essas listas foram usadas como entrada para os modelos de treinamento, sendo assim configuradas para realizar estimativas com base em 1 minuto e 40 segundos de leituras.

O treinamento dos modelos foi realizado em três etapas, uma para cada banco de dados. Durante todo o treinamento, foi aplicada a validação cruzada com 10 dobras, dividindo os conjuntos de dados em proporções de 90% para treinamento e 10% para teste. Esta proporção foi utilizada devido ao fato além de ser amplamente utilizada para problemas de regressão similares à apresentada, como foi no caso de Zhang (ZHANG et al., 2019). A validação cruzada foi usada para expandir o espaço de pesquisa e melhor observar a capacidade de generalização dos modelos.

#### 4.3.3.2.2 Construção de API REST para modelo de ML

Após o treinamento dos modelos, foram realizados os processos de avaliação de resultados e ranqueamento estatísticos de modelos. Estas etapas são discutidas de forma mais detalhada nas seções 5.1 e 5.3. O modelo que apresentou melhor performance quanto a sua acurácia foi o Random Forest, sendo o mais adequado para ser integrado ao sistema IoT. Desta forma, foi realizada a exportação deste modelo treinado para sua operação de forma definitiva. Foi construída uma API REST para comportá-lo e permitir a comunicação dos demais módulos do sistema com o mesmo. Esta aplicação foi desenvolvida na linguagem Python, com o apoio do framework Flask fazendo uso de requisições HTTP POST como interface de comunicação com o modelo treinado. Em seguida foi desenvolvido um *script* para

implantação da aplicação em container Docker, para os processos futuros de instalação junto dos módulos da camada de processamento.

#### 4.3.4 Camada de Processamento

##### 4.3.4.1 Projeto

A camada de processamento desempenha um papel fundamental no contexto da Internet das Coisas (IoT), especialmente no apoio ao monitoramento e controle de sistemas complexos, como a qualidade da água na aquicultura. Seu propósito principal é processar e analisar os dados provenientes dos dispositivos IoT, proporcionando *insights* valiosos. É nesta camada que o poder computacional do sistema IoT está concentrado, compensando esta lacuna presente na camada de percepção.

Na presente dissertação, ela é responsável por receber os dados de telemetria coletados pelos sensores e dispositivos conectados, realizando ações como filtragem, normalização, agregação e análise desses dados. Isso envolve a aplicação de algoritmos e técnicas específicas para transformar os dados brutos em informações compreensíveis e úteis para os usuários e sistemas envolvidos.

Além disso, a camada de processamento pode incluir funcionalidades como detecção de anomalias, previsão de eventos, geração de alertas e tomada de decisões automatizadas com base nos dados coletados e nos modelos de análise implementados. Essas funcionalidades visam melhorar a eficiência operacional, permitir ações proativas e garantir a segurança e a qualidade dos sistemas monitorados.

Ela também desempenha um papel importante na integração dos dados com outros sistemas terceiros, como plataformas em nuvem, sistemas de gerenciamento e aplicações de análise de dados, e aplicativos web, mobile e *machine-to-machine* (M2M). Isso permite a disponibilização dos dados processados para visualização, relatórios, monitoramento em tempo real e suporte à tomada de decisões.

No contexto da viabilização de um sistema IoT de baixo custo, foi incorporado o modelo de estimação do Oxigênio Dissolvido (OD) discutido na Seção 4.3.3, como módulo da presente camada.

Desta forma, devido a gama de atividades delegadas à camada de percepção, foi realizado o seu projeto subdividindo estas funções em módulos distintos, para tratar cada responsabilidade separadamente, simplificando seu

desenvolvimento, sua manutenção, sua identificação de erros e a integração desses módulos através de um gerenciamento central. Este projeto desta camada é composto pelos seguintes módulos: ingestão de dados; armazenamento de dados; análise de dados; tratamento de dados; controle de lógica do usuário e alertas; inteligência artificial; e APIs para provisionamento de dados.

O módulo de ingestão de dados é responsável por receber os dados provenientes da camada de transporte, oriundo dos dispositivos IoT. Ele opera dentro da plataforma IoT e sua função é a de garantir o recebimento e encaminhamento desses dados aos demais módulos da camada de processamento. Desta forma, é necessário que ele tenha suporte a altas cargas de dados, realizando o escalonamento do poder computacional da plataforma sob demanda.

O módulo de tratamento de dados envolve o processamento dos dados oriundos do módulo de ingestão, para torná-los adequados para análise e interpretação. Isso inclui etapas como limpeza de dados, normalização, agregação e transformação. O tratamento de dados é necessário para garantir a qualidade e confiabilidade dos dados utilizados nas análises subsequentes, eliminando inconsistências e preparando-os para serem utilizados de forma eficiente.

O módulo de armazenamento tem como objetivo armazenar os dados coletados de forma segura e eficiente. É importante ter um sistema de armazenamento confiável para trazer maior integridade e disponibilidade dos dados ao longo do tempo. Além disso, o armazenamento adequado permite a consulta e análise posterior dos dados, possibilitando a identificação de padrões, tendências e correlações relevantes.

O módulo de análise de dados permite extrair informações significativas dos dados coletados. Através de algoritmos e técnicas de análise, é possível identificar padrões, anomalias e *insights* relevantes para o sistema. Essa análise dos dados possibilita a compreensão do desempenho do sistema, a detecção precoce de problemas e a tomada de decisões informadas.

O módulo de lógica de usuário desempenha um papel fundamental na interação e controle do sistema IoT. Ele é responsável por fornecer uma interface intuitiva e amigável, permitindo que os usuários interajam com os dados e funcionalidades do sistema. Por meio desse módulo, os usuários podem configurar e personalizar as preferências de monitoramento e receber alertas em tempo real sobre a qualidade da água. Esses alertas podem ser acionados quando os

parâmetros da água ultrapassam limites pré-estabelecidos, indicando condições indesejáveis ou perigosas. Essa funcionalidade permite que os usuários monitorem continuamente os dados e tomem medidas proativas para garantir a qualidade da água, evitando riscos à saúde dos animais e maximizando a eficiência da produção aquícola.

Todos estes módulos operam de forma independente, porém, de modo a coordenar o funcionamento conjunto, o módulo de gerenciamento da plataforma IoT é utilizado. Nele o gestor do sistema pode personalizar o fluxo de operação entre os módulos, possibilitando sua adaptação sob cada necessidade.

#### 4.3.4.2 Implementação

##### 4.3.4.2.1 Infraestrutura em Nuvem e Plataforma IoT

Visto que o poder computacional do sistema IoT é concentrado na camada de percepção, a utilização da computação em nuvem disponibiliza as ferramentas necessárias para a implantação da infraestrutura necessária para servir de base à operação dos módulos mencionados na Seção 4.3.4.1. Benefícios como a escalabilidade automática e as políticas de pagamento sob demanda fazem com que se torne muito mais barato financeiramente adotar soluções baseadas em computação em nuvem para a presente proposta.

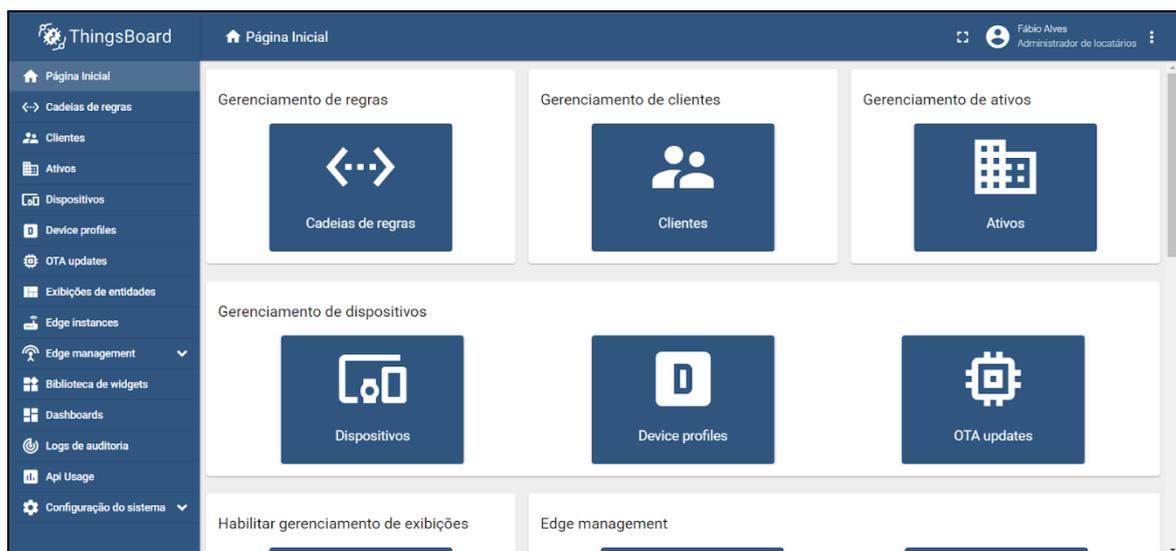
Foi utilizada a plataforma EC2 (Elastic Computing Cloud) da plataforma em nuvem AWS (Amazon Web Services), para a criação das máquinas virtuais (VM) que são utilizadas como servidores do sistema. Esta abordagem foi a mais adequada para os cenários de teste do sistema, pois devido a seus custos reduzidos, possibilitou a realização dos experimentos da proposta por maiores períodos de tempo. Embora não seja adequada para ambientes de produção de sistema, a arquitetura é totalmente adaptável a estes cenários, pois seu funcionamento interno permanece o mesmo, com apenas a infraestrutura base sendo alterada.

Foi necessária a seleção de uma plataforma IoT que já fornecesse suporte aos módulos discutidos anteriormente, a ambientes de desenvolvimento e a ambientes de produção. A plataforma escolhida para isto foi o *Thingsboard*, projetada justamente para realizar a representação virtual dos dispositivos IoT e com completo suporte a todos os módulos da camada de processamento. Além disso, com versões gratuitas (*Community Edition - CE*) e pagas (*Professional Edition - PE*),

possibilitam a adequação do sistema IoT proposto até mesmo para escalas comerciais. Ambas as versões possuem suporte para implantações em todos os sistemas operacionais, bem como a ambientes de desenvolvimento com instalações baseadas em instaladores e containers docker e a ambientes de produção, através da utilização clusters para orquestração de containers, como o *Google Kubernetes Engine* (GKE) ou o *Amazon Elastic Computing System* (ECS).

Desta forma, a versão adotada foi a versão do *Thingsboard Community Edition* (TB CE). Para sua instalação foi alocada uma máquina virtual EC2 composta por dois vCPUs, quatro GB de RAM e com sistema operacional Ubuntu 22.04 LTS. Como banco de dados, foi utilizado o PostgreSQL, ferramenta padrão de armazenamento para ambientes de experimentação do TB CE, conforme discutido em sua documentação. A Figura 12 ilustra a interface inicial, de administração da plataforma.

Figura 12 - Interface da plataforma *Thingsboard Community Edition*.



Fonte: elaborado pelo autor

O funcionamento do *Thingsboard* é baseado na interação entre três módulos de gerenciamento: o de dispositivos virtuais; o de controle da plataforma; e o de interfaces de usuário.

No módulo de gerenciamento de dispositivos, os dispositivos IoT físicos são abstraídos como dispositivos virtuais (*v-devices*) e podem ser conectados à plataforma por meio de diferentes protocolos de comunicação, como MQTT, CoAP, HTTP, entre outros. No presente contexto, os gateways para IoT da camada de transporte enviam os dados destes dispositivos IoT, para respectivos *v-devices*.

O módulo de gerenciamento da plataforma é responsável pelo processamento, armazenamento e análise dos dados recebidos dos dispositivos. Também é nele que ocorre a ingestão dos dados, funcionalidade nativa da mesma, garantindo que nenhum registro se perca, e armazena-os em um banco de dados escalável e executa análises em tempo real, se necessário. Ele também permite a configuração de regras e alertas para acionar ações com base nos dados recebidos, através das cadeias de regras (*Rule Engine*), que permite a customização da lógica de negócio do sistema IoT.

Já o módulo de gerenciamento de interfaces do usuário oferece uma interface de usuário amigável e personalizável, na qual os usuários podem visualizar, analisar e interagir com os dados dos dispositivos IoT. Além disso, o *Thingsboard* suporta a criação de painéis personalizados, gráficos, tabelas e widgets para fornecer informações relevantes de forma visualmente atraente.

Uma segunda máquina virtual EC2 também foi utilizada para a instalação do container Docker contendo a API REST e modelo treinado do estimador de OD. A separação desta aplicação numa VM a parte permitiu um isolamento da infraestrutura dos servidores utilizados, evitando que erros oriundos de um deles prejudicasse a operação do outro.

#### 4.3.4.2.2 Configuração da Plataforma IoT

Devido a ampla capacidade de personalização e adaptação do *Thingsboard*, somado ao fato dela possuir ferramentas para cada um dos módulos discutidos durante a Seção de projeto, não foi necessária a implementação do zero destes módulos, de modo que a configuração da plataforma através das cadeias de regras permitiu o funcionamento da mesma nos moldes projetados.

A Figura 13 ilustra a cadeia de regras do fluxo de execuções principal da plataforma. O procedimento é acionado sempre que uma nova mensagem chega à plataforma, como chamadas de procedimentos remotos (RPC) ou geração de dados de telemetria oriunda dos dispositivos IoT. No caso deste último, após o processo automático de ingestão de dados ocorrer, estes dados são encaminhados ao respectivo *v-device*, juntamente com metadados como o seu identificador e marca de tempo (*timestamp*), no formato *unix*. Estes metadados são utilizados como parâmetros nos procedimentos seguintes.

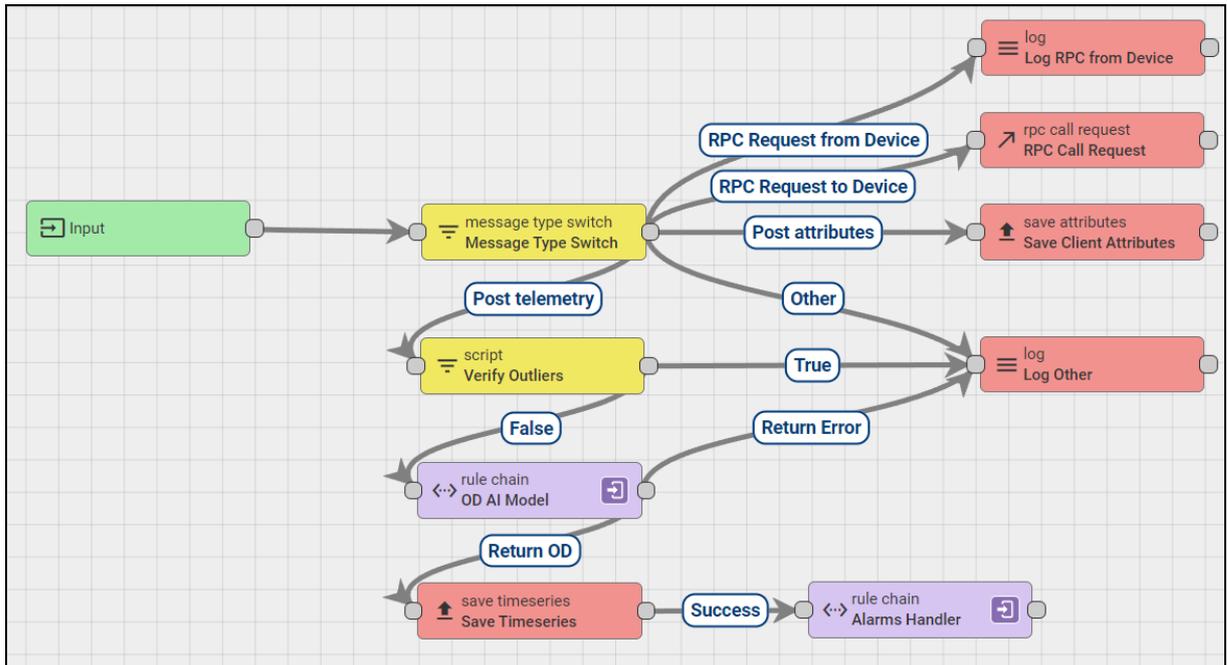
Em seguida, é realizada a filtragem do tipo de mensagem que chegou ao servidor, no bloco “Message Type Switch”. Se for do tipo RPC, armazenamento de

atributos de cliente ou qualquer outro tipo exceto dados de telemetria, a mensagem é salva automaticamente em seu respectivo bloco no banco de dados. Caso seja um dado de telemetria, então foi originada de um *v-device*, e passará por um processo distinto das demais mensagens.

Como discutido no projeto da camada de percepção, os *devices* IoT da presente proposta são compostos por dois sensores, um de pH e um de temperatura. Desta forma, é necessário a verificação da integridade das leituras destes parâmetros antes da mensagem ser salva. É neste momento que o módulo de tratamento de dados opera, realizando a verificação dos outliers destas leituras, que são: temperatura igual ao valor -127, que representa uma mensagem de erro nos sensores de temperatura DS18B20; e pH menor do 0 ou superior a 14, valores inconsistentes com o parâmetro. Esta verificação é realizada no bloco “Verify Outliers”, e caso o resultado seja verdadeiro, então foram encontrados erros na mensagem e ela deve ser salva como log para verificações de erro no *device* IoT, e caso o resultado seja falso, então as leituras estão consistentes.

Em seguida, é realizada a chamada de uma outra cadeia de regras, representada pelo bloco “OD AI Model”, ilustrada na Figura 14, responsável pela chamada à API da IA do modelo de estimação de OD. Caso a resposta do procedimento tenha sido “Return Error”, então ocorreu algum erro na API e uma mensagem com log do erro é encaminhada ao bloco de logs do sistema. Caso a resposta do procedimento tenha sido “Return OD”, então a API retornou a estimação do OD corretamente e ela foi adicionada ao corpo da mensagem de telemetria inicial. Neste cenário, a mensagem é então salva no banco de dados, por meio da execução do bloco “Save Timeseries” e em seguida encaminhada a um segundo procedimento, representado pelo bloco “Alarms Handler”, responsável pelo gerenciamento da geração de alertas de criticidade dos parâmetros da água.

Figura 13 - Cadeia de regras da execução primária do *Thingsboard*.

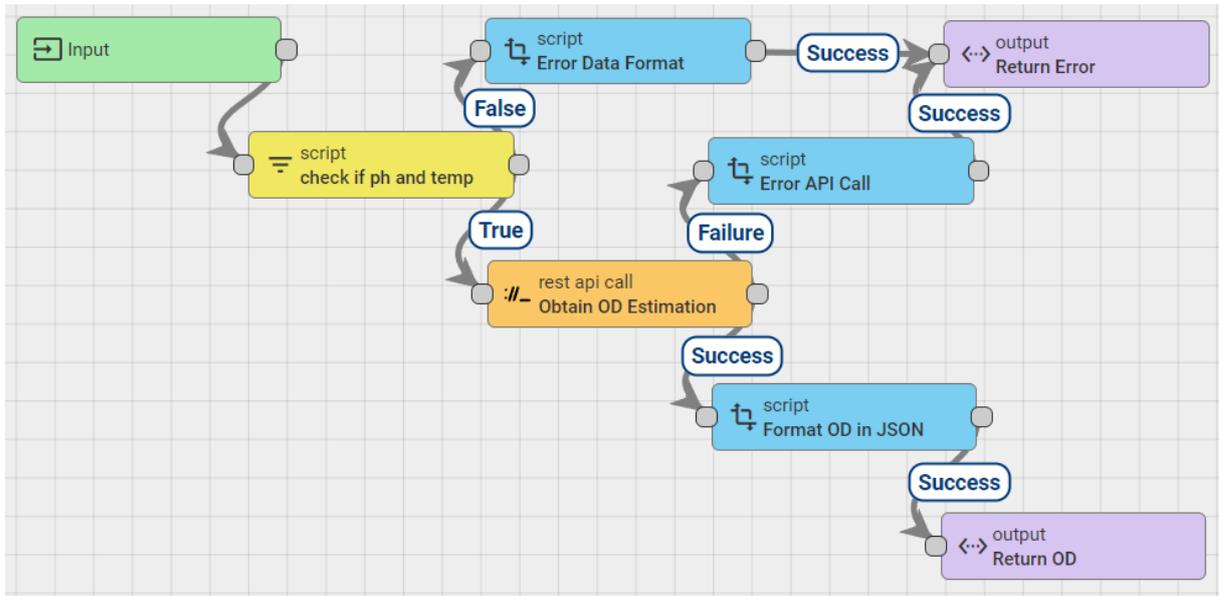


Fonte: elaborado pelo autor

Na Figura 14 é ilustrado o procedimento de chamada da REST API que integra o modelo estimador de OD. Ele é acionado quando é chamado na cadeia de regras primária. Inicialmente é recebida a mensagem de telemetria oriunda do dispositivo IoT. Em seguida, é verificado se os campos de “ph” e “temperature” estão definidos na mensagem. Caso não estejam, então uma mensagem de erro é gerada encaminhada como retorno do procedimento. Caso estejam definidos, então é realizada a chamada à API da IA, através do bloco do através do bloco “Obtain OD Estimation”.

Caso a API retorne o valor da estimacão do OD, então ela é adicionada ao corpo da mensagem de telemetria recebida como parâmetro, que é em seguida encaminhada como retorno do procedimento. Caso não retorne devido a algum erro de comunicação ou problemas na API, então uma mensagem detalhando o problema é criada e encaminhada como log de erro no retorno do procedimento.

Figura 14 - Cadeia de regras para chamada do modelo de estimação de OD.

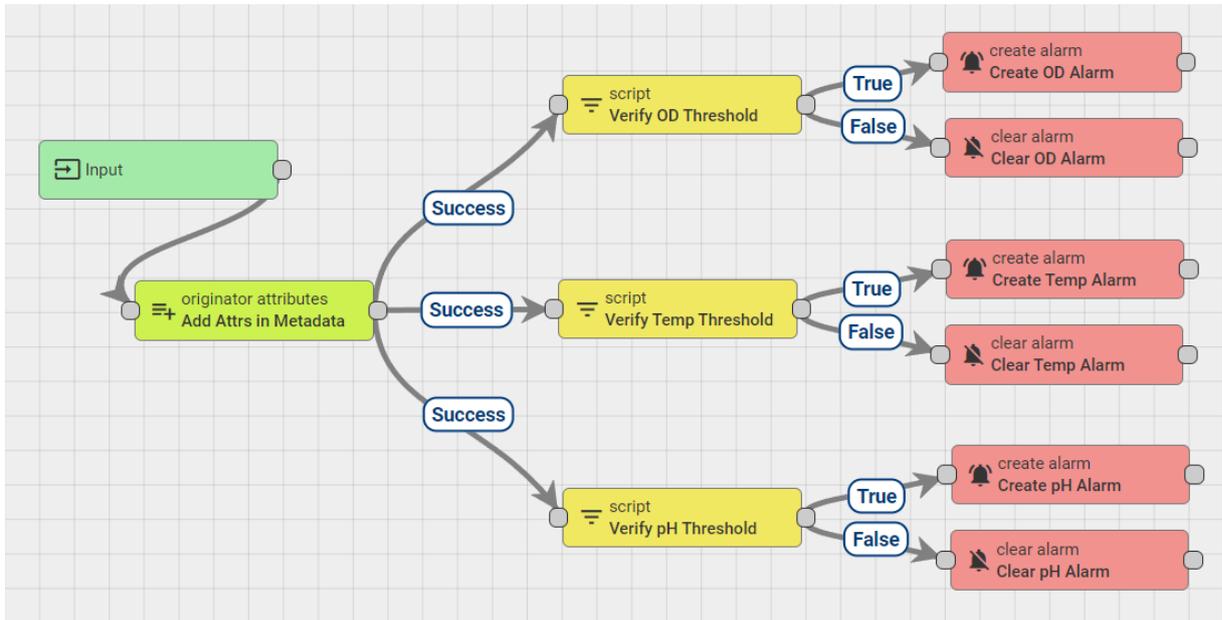


Fonte: elaborado pelo autor

Na lógica de negócio da presente proposta, são adicionados através da API HTTP de gestão da plataforma atributos de servidor em cada *v-device* criado, para representar os *thresholds*, mínimo e máximo, dos três parâmetro de qualidade da água considerados no sistema, o pH, temperatura e OD, sendo eles nomeados como: *max\_ph*, *min\_ph*, *max\_temp*, *min\_temp*, *max\_od* e *min\_od*. Estes atributos auxiliam o processo de análise de dados.

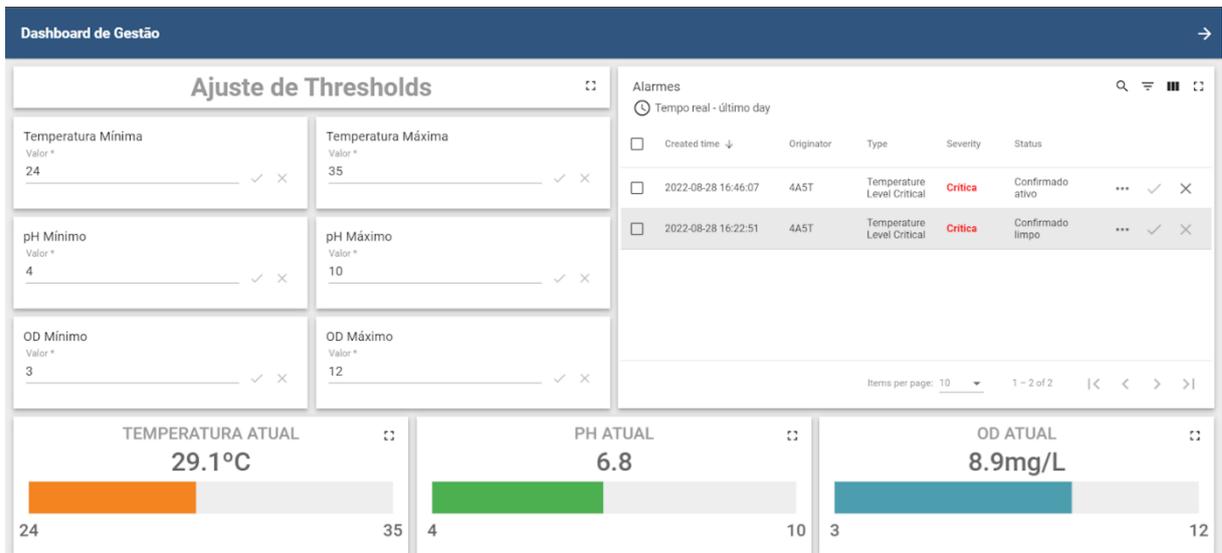
Quando a cadeia de regras de gestão de alertas, ilustrado na Figura 15, é executada na cadeia de regras primária, então espera-se que seja enviado como parâmetro uma mensagem de telemetria que com os campos de “ph”, “temperature” e “oxygen” definidos. Em seguida, são adicionados os atributos mencionados acima, referentes ao dispositivo que originou a mensagem. Isto é feito pelo bloco “Add Attrs in Metadata”. Em seguida, três fluxos semelhantes, um para cada parâmetro é realizado em paralelo. Neles são verificados se cada parâmetro está dentro dos níveis indicados como mínimo e máximo nos atributos do *v-device*. Caso não estejam, então é criado um alarme de nível crítico, indicando que atenção ao usuário. Caso contrário os alarmes são desabilitados.

Figura 15 - Cadeia de regras de gestão de alertas.



Fonte: elaborado pelo autor

Os níveis mínimos e máximos (*thresholds*) podem ser ajustados no *dashboard* de gestão ilustrado na Figura 16, onde também é possível monitorar alertas gerados e os níveis mais recentes de cada parâmetro em tempo real.

Figura 16 - *Dashboard* de gestão de *thresholds* e alertas.

Fonte: elaborado pelo autor

### 4.3.5 Camada de Aplicação

#### 4.3.5.1 Projeto

A camada de aplicação desempenha um papel essencial no envio de dados de telemetria a aplicações terceiras, como plataformas mobile, Web ou *machine-to-machine* (M2M). Seu objetivo principal é permitir a interação entre os dispositivos IoT, os sistemas em nuvem e os usuários finais, possibilitando o monitoramento em tempo real da qualidade da água em cada viveiro de produção e apoiando a tomada de decisão.

Um aspecto fundamental no projeto da camada de aplicação é a definição da comunicação com as APIs da camada de processamento e a escolha dos protocolos a serem utilizados. Essas decisões são cruciais, pois afetam a eficiência das comunicações, impactando tanto o desempenho das interfaces como a carga recebida pelas APIs. Além disso, é necessário projetar as interfaces de interação com o usuário, uma vez que é por meio delas que os usuários interagem com o sistema.

Para resolver essas questões, a arquitetura da camada de aplicação na presente proposta foi projetada para abordar esses dois aspectos, tratando tanto da comunicação com os servidores quanto da apresentação dos dados. Com essa abordagem, busca-se garantir uma comunicação eficiente e uma experiência de usuário satisfatória, contribuindo para o sucesso do projeto de monitoramento da qualidade da água na IoT.

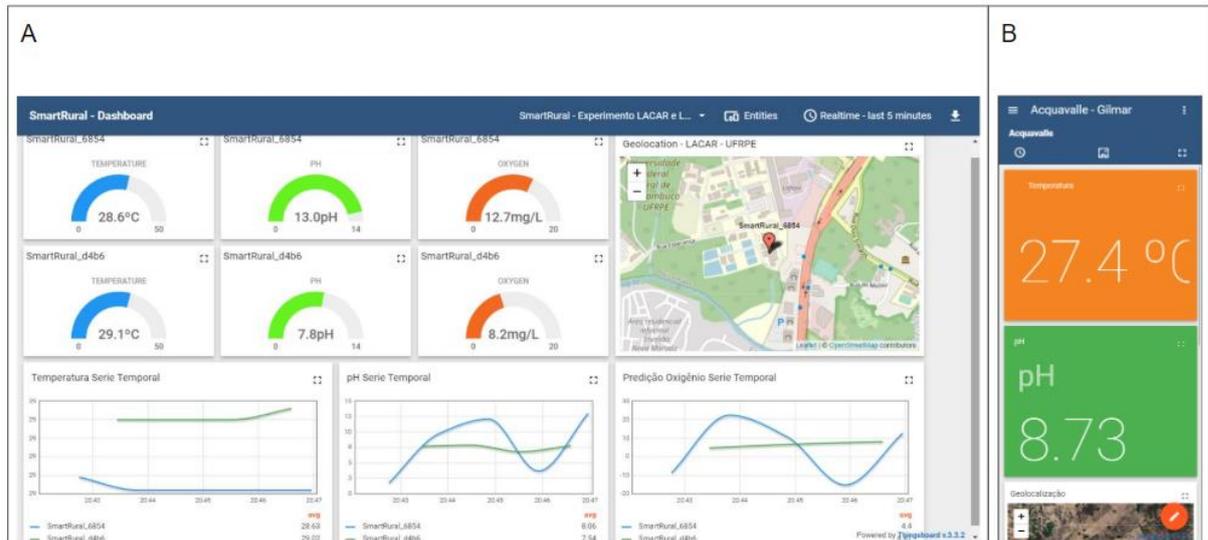
#### 4.3.5.2 Implementação

Desta forma, a implementação da camada desta camada no presente sistema tomou inicialmente como base quais APIs e protocolos de aplicação são necessários para permitir uma comunicação eficiente e de baixo consumo computacional dos dispositivos utilizados pelos usuários, além do desenvolvimento de interfaces Web e Mobile.

Como discutido na Seção 4.6.2, foi utilizada a plataforma IoT *Thingsboard* como ferramenta para implementação dos módulos da camada de processamento, devido a sua gama de ferramentas que condizem com os objetivos da mesma. Além disso, o *Thingsboard* também disponibiliza de ferramentas para o desenvolvimento

de interfaces responsivas, ou seja, aplicáveis tanto em ambientes Web quanto mobile. Estas interfaces são ilustradas na Figura 17.

Figura 17 - *Dashboards* responsivos desenvolvidos. (A) Web; e (B) Mobile.



Fonte: elaborado pelo autor

Foram utilizadas a API REST e a API *WebSocket* do *Thingsboard* como mecanismo de comunicação com as aplicações desenvolvidas. A API REST é utilizada primariamente para autenticação, realizando-a através dos *Java-Web-Tokens* (JWT). Ela também provê o gerenciamento completo da plataforma IoT, assim como a obtenção de dados de telemetria. Entretanto, para que isto ocorra, a coleta de dados ocorre através de comunicações baseadas em *short-polling*, ou seja, baseado num temporizador, onde o cliente constantemente solicita novos dados ao servidor. Esta abordagem é custosa, visto que não há garantias que o servidor retornará novos dados, além de prejudicar o desempenho da API em larga escala.

Para sanar este problema, a API *WebSocket* foi utilizada, pois permite a criação de um canal full-duplex com o servidor, delegando o controle desta comunicação a ele, de modo que sempre que um novo dado de telemetria for gerado, ele é imediatamente retornado ao cliente, reduzindo o consumo de rede e processamento de ambos os lados.

Esta abordagem é um facilitador para as implementações de aplicativos terceiros, bem como para a integração M2M, de modo a permitir o controle de

atuadores a partir de análises e heurísticas obtidas através dos dados de telemetria enviados.

## 5 AVALIAÇÃO DE DESEMPENHO E ANÁLISE DE RESULTADOS

---

Neste Capítulo é discutida a avaliação dos resultados obtidos pelos experimentos conduzidos. É apresentada a metodologia de avaliação da acurácia dos modelos de ML. São discutidos os resultados obtidos através do treinamento dos modelos de ML propostos. Estes resultados serviram de base para a condução da metodologia de avaliação do sistema IoT, que é apresentada logo em seguida. Por fim, são discutidos os resultados da implantação do sistema de IoT em cultivo de piscicultura.

---

## 5.1 CONSIDERAÇÕES INICIAIS

Este Capítulo é subdividido em quatro subseções. A primeira abordando a metodologia de treinamento e a métrica indicadora de desempenho dos modelos estimadores de OD. Na segunda é realizada a discussão dos resultados obtidos após o treinamento dos modelos, apresentando gráficos para comparar os valores da estimação em relação a dados reais de oxigênio dissolvido, além de analisar estatisticamente a acurácia dos modelos, realizando um ranqueamento quando a melhor performance apresentada. Na terceira subseção é abordada a metodologia aplicada na avaliação da acurácia dos dados de telemetria coletados pelo sistema IoT proposto e o projeto de implantação do mesmo em ambiente produtivo de aquicultura. Por fim, na quarta subseção são apresentados os resultados obtidos após a condução do experimento mencionado. Além disso, são exibidos os objetivos alcançados no formato de um estudo de caso e realizada uma análise comparativa de custo de sistemas IoT presente no mercado, a fim de determinar o ganho trazido pela redução de custo empregada na presente dissertação.

## 5.2 METODOLOGIA DE AVALIAÇÃO DOS MODELOS DE ML

Com o objetivo selecionar o melhor modelo treinado para ser integrado ao sistema IoT para operação em cultivo de aquicultura, foi aplicada a seguinte metodologia de avaliação da acurácia. Para o processo de treinamento dos modelos propostos foi aplicada validação cruzada com 10 dobras, dividindo os conjuntos de dados em proporções de 90% para treinamento e 10% para teste. Esta técnica foi usada para expandir o espaço de pesquisa e melhorar a capacidade de generalização dos modelos.

A métrica Root Mean Square Error (RMSE) foi usada para avaliar a acurácia dos modelos. Ela quantifica o desempenho de um modelo de regressão com base no erro médio apresentado ao comparar o resultado de saída com um valor base de controle, considerado o ideal. Ela foi escolhida por ser uma métrica amplamente usada em tarefas de regressão e por estar presente em quatro dos artigos relacionados analisados na Seção 3.4. É descrita na Equação 1 e compara a similaridade de dois conjuntos de dados, um para os valores de dados reais ( $Y_i$ ) e outro para os valores de previsão do modelo ( $\hat{Y}_i$ ). Uma de suas vantagens é retornar o valor de saída em uma escala semelhante à dos dados de entrada, o que facilita a comparação com os valores reais.

$$\text{RMSE} = \sqrt{\frac{\sum_{i=0}^N (Y_i - \hat{Y}_i)^2}{N}}$$

Equação 1 – Forma Algébrica da métrica RMSE.

Os valores da métrica variam de zero ao infinito positivo, com valores esperados se aproximando de zero, o que indica menor erro médio entre os dados reais e os previstos. Dos trabalhos relacionados que empregaram essa métrica na análise de resultados de seus modelos apresentaram valor abaixo de 1,0 em seus modelos de melhor performance.

Considerando a similaridade entre os problemas de predição e estimação endereçados na Seção 3.4 e ao fato de que os modelos de melhor performance nestes trabalhos apresentaram RMSE abaixo de 1,0 unidade, então para a presente dissertação os resultados de treinamentos considerados ótimos são os que apresentam RMSE inferior a 1,0.

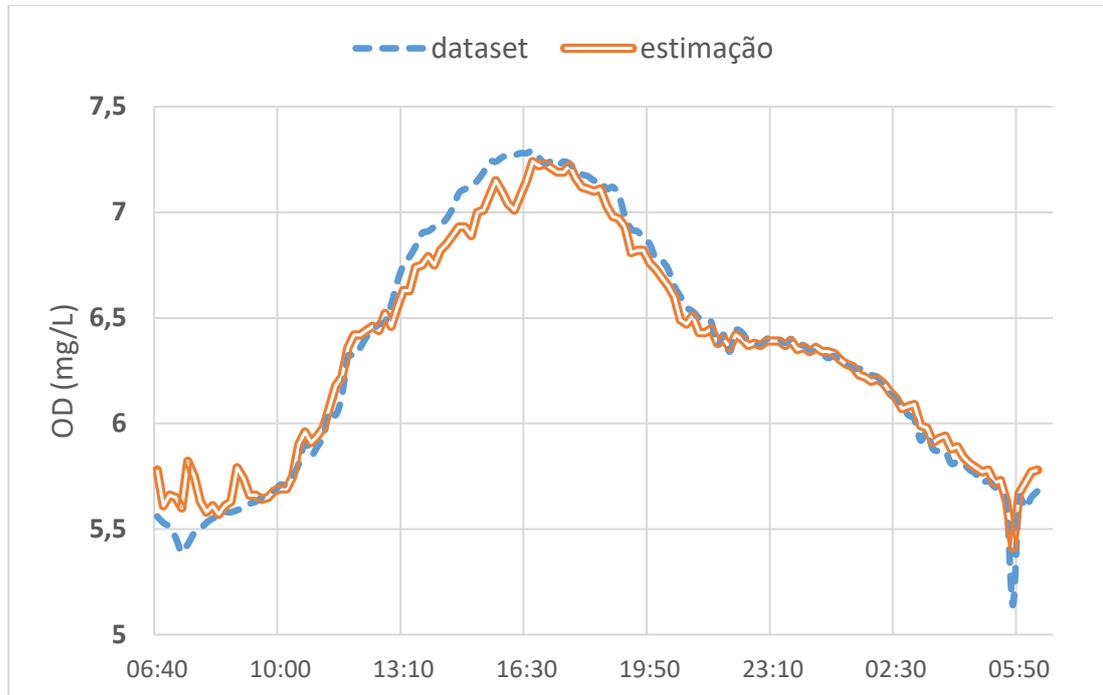
Além disso foi aplicado o teste post-hoc de Nemenyi (NEMENYI, 1963) para realizar um ranqueamento com base na performance dos modelos e reduzir o viés da análise por meio de uma análise estatística aplicada. Esse teste é capaz de avaliar as disparidades entre o desempenho de múltiplos modelos de aprendizagem de máquina. Dois modelos são considerados significativamente diferentes em termos de desempenho se suas classificações médias mostrarem uma diferença igual ou superior a um valor específico de diferença crítica (*Critical Difference* - CD). Além disso, a representação gráfica conhecida como diagrama CD, proposta por Demšar (DEMŠAR, 2006), foi utilizada para retratar visualmente o ranqueamento estatístico obtido, facilitando uma avaliação criteriosa dos modelos com melhor performance quanto a acurácia apresentada.

### 5.3 RESULTADOS DOS MODELOS DE ML

Nesta são apresentados os resultados dos experimentos realizados, fazendo análises comparativas entre as leituras reais de OD dos conjuntos de dados e os valores estimados pelos modelos treinados. Para uma representação mais abrangente do desempenho dos modelos, a Figura 18 mostra uma comparação gráfica entre os valores reais de oxigênio dissolvido (DO) extraídos do conjunto de dados e as estimativas correspondentes feitas pelo modelo de RF treinado no conjunto de dados All-Year. Os dados apresentados referem-se aos dois primeiros dias do ano de 2022. As leituras de OD foram usadas para traçar a linha pontilhada

e as leituras de pH e temperatura como entradas para derivar as estimativas de OD do modelo mencionado.

Figura 18 – Comparação entre o OD da base de dados e OD estimado.



Fonte: Elaborado pelo autor.

O comportamento natural do OD é cair durante a noite, devido à respiração de plantas e animais. A partir do nascer do sol, quando o processo de fotossíntese é reiniciado, os níveis de OD aumentam novamente, até o pôr do sol, quando seus níveis reduzem mais uma vez. Esse é o comportamento exato apresentado pelos dados da base de dados na Figura 18. O fato dos dados apresentados pela estimativa de OD serem graficamente muito próximos dos anteriores sustenta a expectativa de que os modelos podem aprender os padrões e a dinâmica do comportamento do OD usando o pH e a temperatura como entrada. Isso é reforçado pelos resultados obtidos nos experimentos, que são apresentados na Tabela 5.

Tabela 5 - Pontuações do RMSE para cada *dataset* e sua respectiva média.

Base de Dados	KNN	LR	LSTM	MANN	RF	SVR
All-Year	1,05	1,01	1,19	1,09	0,89	0,97
Dry-Season	1,07	2,55	1,14	1,87	0,97	1,41
Wet-Season	0,75	0,67	0,69	0,79	0,78	0,69
Pontuações Médias	0,95	1,41	1,00	1,24	0,88	1,02

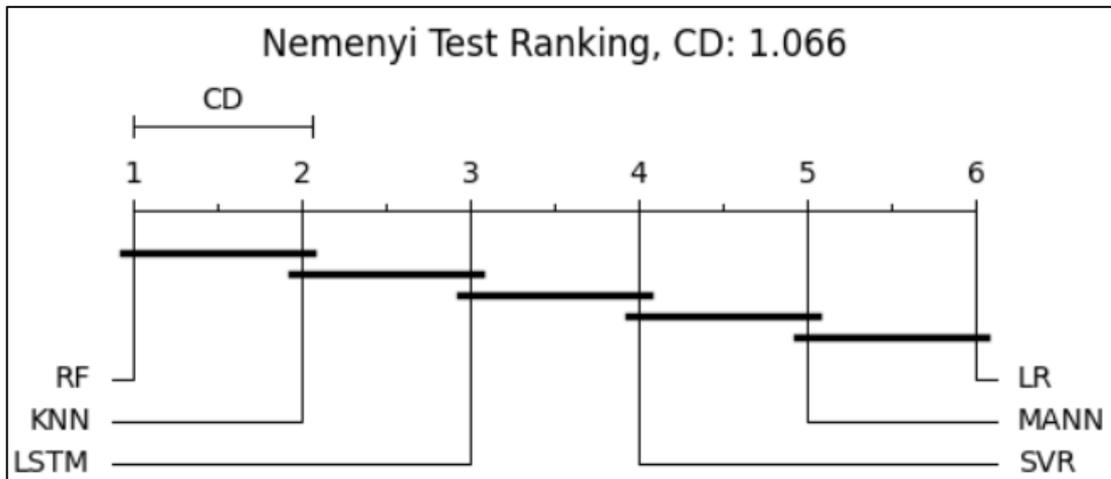
Fonte: Elaborado pelo autor.

A Tabela 5 mostra as pontuações de RMSE de todos os modelos treinados em cada conjunto de dados usado. O primeiro ponto a ser observado é o de que todos os resultados obtidos estão na mesma ordem de grandeza dos problemas de predição de DO listados nos trabalhos relacionados. Levando em consideração os modelos que apresentaram melhores pontuações de RMSE em cada experimento, fica evidente que o modelo Random Forest obteve as pontuações mais favoráveis nos conjuntos de dados All-Year e Dry-Season, com pontuações de 0,89 e 0,97, respectivamente. Para o conjunto de dados Wet-Season, o modelo Linear Regression obteve a melhor pontuação, com um RMSE de 0,67.

Pode-se observar que a maneira pela qual os dados dos parâmetros de água foram coletados na base de dados original influenciou a precisão dos algoritmos, dependendo da época do ano. Entre os meses de julho e dezembro a coleta de dados foi realizada apenas nos dois primeiros dias de cada mês, resultando em 1679 registros. Comparativamente, a quantidade de registros entre os meses de janeiro a junho foi de 20576. Esta disparidade gerou um número reduzido de registros durante a estação seca do ano. Consequentemente, devido à maior quantidade de registros durante a estação úmida, foram obtidos resultados mais satisfatórios durante esta estação, com todos os modelos exibindo um RMSE abaixo de 1,0 unidade. Durante a estação seca os modelos apresentaram um RMSE acima de 1,0 unidade, com exceção para o RF. As pontuações dos modelos obtidas com o conjunto de dados All-Year permaneceram na média entre os resultados obtidos nas demais bases de dados.

Para classificar o melhor modelo global, foi realizado o teste de Nemenyi e os seus resultados foram plotados no diagrama CD ilustrado na Figura 19. O processo de classificação leva em conta os resultados obtidos de todos os treinamentos de cada modelo como sua média. Para evitar análises tendenciosas, esse processo foi essencial para indicar de forma assertiva o melhor modelo.

Figura 19 – Ranqueamento dos modelos sob o teste post-hoc Nemenyi.



Fonte: Elaborado pelo autor.

Conforme mostrado na Figura 19, o RF foi o modelo com melhor desempenho global, seguido pelo KNN. Devido à média de pontuação RMSE de 0,88 para o RF e 0,95 para o KNN, o teste os considerou estatisticamente equivalentes, pois a diferença crítica não foi grande o suficiente para diferenciá-los. O terceiro lugar ficou com o modelo LSTM, mostrando que, nas condições apresentadas, os modelos baseados em redes neurais foram superados por modelos menos dependentes do poder computacional, como o RF e o KNN.

#### 5.4 METODOLOGIA DE AVALIAÇÃO DO SISTEMA IOT

De modo semelhante a metodologia de avaliação da acurácia dos modelos de ML, para a avaliação da acurácia dos dados coletados de temperatura, de pH e de OD coletados pelo sistema IoT desenvolvido, foi utilizada a métrica do coeficiente de variação da raiz do erro quadrático médio  $CV(RMSE)$ , caracterizada pela Equação 2.

$$CV(RMSE) = \frac{1}{\bar{Y}} \sqrt{\frac{\sum_{i=0}^N (Y_i - \hat{Y}_i)^2}{N}}$$

Equação 2 - Forma Algébrica da métrica  $CV(RMSE)$ .

Diferente do RMSE, que representa numa escala numérica semelhante aos dados inseridos como entrada, o  $CV(RMSE)$  expressa a sua saída na forma percentual. Para isto, o valor do RMSE obtido é dividido pelo valor médio dos dados de controle ( $\bar{Y}$ ). De forma similar, quanto mais próximo este valor estiver de zero,

mais similares são as séries temporais de teste e de controle. De acordo com a análise proposta por Kolassa (KOLASSA, 2020), valores CV(RMSE) inferiores a 20% indicam uma alta acurácia entre as séries temporais alta.

## 5.5 RESULTADOS DO SISTEMA IOT

### 5.5.1 Estudo de Caso do Sistema IoT implantado em Aquicultura 4.0.

O experimento final conduzido para os testes do sistema IoT desenvolvido ocorreu em um cenário de produção real. Para isso, o protótipo foi instalado em um dos tanques de aquicultura da Universidade Federal Rural de Pernambuco (UFRPE), referente ao cultivo de Tilápia do Nilo (*Oreochromis niloticus*). O experimento teve duração de quatro meses, compreendendo todas as fases de desenvolvimento do animal. A Figura 20 ilustra o protótipo instalado no tanque.

Figura 20 - Dispositivo IoT instalado em um viveiro de tilápias da UFRPE.



Fonte: Elaborado pelo autor.

Durante os primeiros trinta dias do experimento, foram feitas medições manuais de temperatura, pH e OD usando o ph-meter AKSO AK-90<sup>4</sup> e o oxímetro Alfakit AT-160<sup>5</sup>. O oxímetro tem um termômetro embutido. Esses medidores são os mesmos usados nos processos de cultivo desses tanques. Os dados coletados por ele formaram os dados de controle. As leituras ocorreram duas vezes por dia, às 9 horas e às 16 horas, entre 1º de agosto de 2022 e 1º de setembro de 2022.

---

<sup>4</sup> <https://www.akso.com.br/>

<sup>5</sup> <https://alfakit.com.br/>

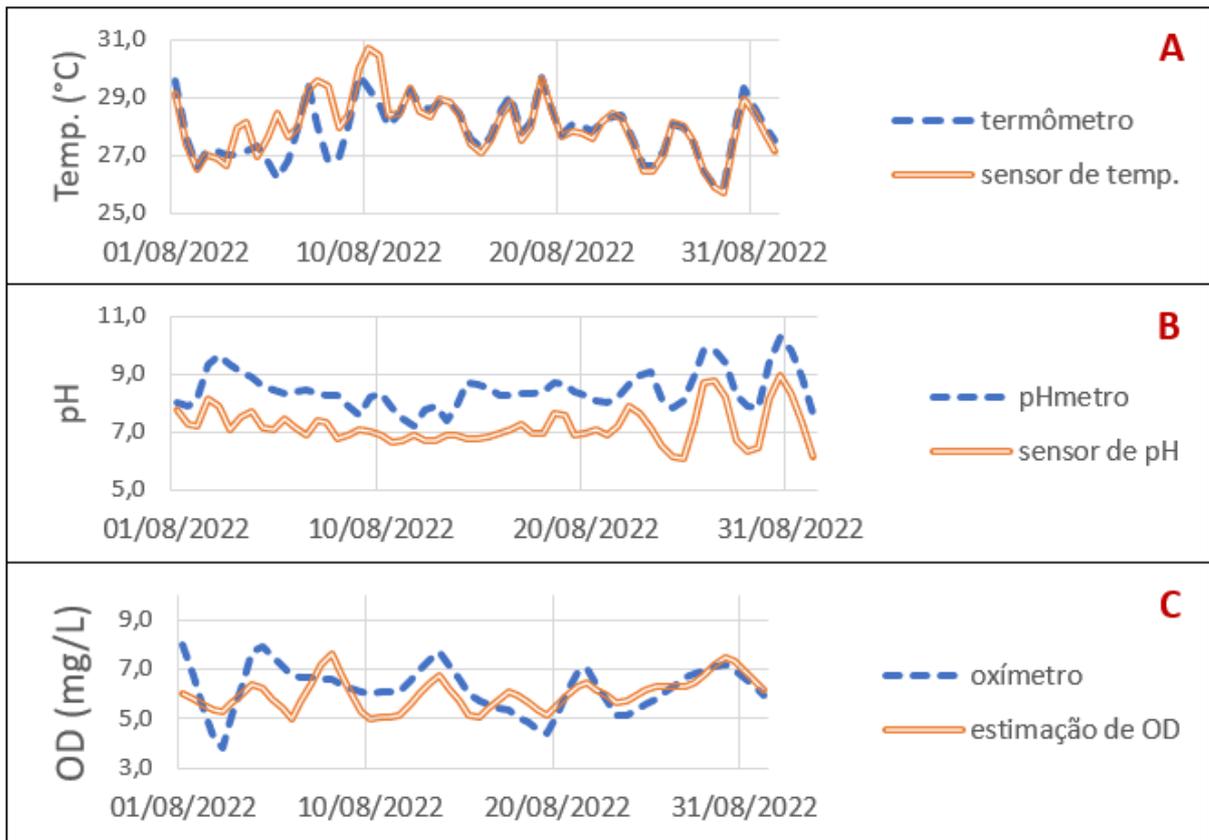
A manutenção preventiva foi realizada mensalmente para limpeza dos sensores. Ao final do experimento, foi possível determinar a resiliência do protótipo, pois ele realizou a coleta de dados durante todo o processo ininterruptamente, sem apresentar falhas como infiltrações ou problemas de hardware. Além disso, no nível do sistema, o monitoramento autônomo do tanque foi bem-sucedido. Utilizando o painel avançado mostrado na Figura 17, o monitoramento em tempo real das condições do tanque pode ser feito de qualquer lugar. Além disso, o painel apresentado na Figura 16 ajudou no processo de tomada de decisões, informando os níveis críticos dos parâmetros qualidade da água por meio de notificações de alertas. Isso demonstrou que o projeto e a implementação da solução proposta atingiram os objetivos definidos.

#### 5.5.2 Resultados da Acurácia da Coleta de Dados do Sistema IoT

Embora o sistema IoT proposto possibilite a redução de custos com a remoção do sensor de OD como requisito de hardware, ele torna-se dependente da acurácia dos dados coletados pelos sensores de pH e temperatura para apresentar o desempenho esperado. Desta forma, a metodologia descrita na Seção 5.4 foi aplicada para avaliar a acurácia tanto dos dados coletados pelos sensores quanto das estimações realizadas pelo modelo de IA desenvolvido.

Como descrito na Seção anterior, o monitoramento a partir de medidores manuais foi realizado durante o primeiro mês de experimento, com a obtenção de 60 registros de dados ao final deste processo. Na Figura 21 os dados coletados pelo sistema IoT (telemetria) foram plotados junto destes dados de controle para uma análise gráfica de sua similaridade.

Figura 21 - Comparação entre dados de controle e de telemetria.



Fonte: Elaborado pelo autor

O gráfico (A) compara a temperatura do sensor e do termômetro. Ele mostra graficamente que ambas as curvas seguem um padrão semelhante ao longo do tempo, com uma breve variação no final da primeira semana, mas mantendo o mesmo comportamento nos dias restantes. O gráfico (B) compara o pH do sensor e do pHmetro. Ele exibe uma variação de deslocamento entre as curvas, indicando que as leituras do sensor estavam ligeiramente abaixo dos dados de controle. Essa variação foi estável ao longo do tempo, sugerindo um possível problema no ajuste da calibração do sensor.

No gráfico (C), é realizada uma comparação entre a estimativa de oxigênio dissolvido (OD) e as medições do oxímetro. A curva gerada pela estimativa de OD segue de perto o padrão das leituras do oxímetro nas últimas três semanas. Entretanto, na primeira semana, há uma diferença maior entre as curvas, que pode ser atribuída a discrepâncias nas leituras de temperatura e pH durante esse período. Isso indica que o estimador de OD tem o potencial de fornecer resultados precisos, mas seu desempenho é fortemente influenciado pela precisão dos sensores. Este

fator pode ser amenizado tanto através da utilização de sensores de maior precisão quanto por ajustes finos na calibração dos sensores utilizados.

A Tabela 6 mostra as informações estatísticas sobre a média da série temporal (AVG) e o desvio padrão (SD) dos dados de telemetria e controle, e as pontuações CV(RMSE) para todos os parâmetros de água avaliados.

Tabela 6 - Média e desvio padrão das séries temporais e valores do CV(RMSE).

	Temperatura	pH	Oxigênio Dissolvido
Dados de Telemetria	28,01± 1,04	7,19 ± 0,62	6,0 ± 0,65
Dados de Controle	27,88 ± 0,95	8,45 ± 0,66	6,21 ± 0,92
CV(RMSE)	2,94%	14,90%	19,25%

Fonte: Elaborado pelo autor.

Segundo a Tabela 6, a temperatura apresentou uma pequena diferença de 0,13 unidades para a média e 0,05 para o desvio padrão, indicando que o sensor exibe níveis de variabilidade semelhantes aos do termômetro. Para o pH, embora haja uma variação de deslocamento nos gráficos, com uma diferença de 1,3 unidades em média, ele ainda apresenta o mesmo comportamento de dispersão, com desvio padrão de apenas 0,05 unidades. Para o DO, apesar da discrepância na média dos valores de pH, a estimação de OD obteve média de 0,3 unidades, mostrando mesmo com este empecilho, foi possível realizar uma estimação acurada do OD. As pontuações de CV (RMSE) colaboram ainda mais com estes resultados positivos, pois todos os três parâmetros considerados do sistema IoT obtiveram pontuações inferiores a 20%, e que de acordo com a discussão trazida por Kolassa (KOLASSA, 2020) é um indicador de alta acurácia.

### 5.5.3 Análise de Custos da Solução IoT proposta

A avaliação de custo da solução IoT proposta foi realizada com base no preço dos componentes de hardware para a fabricação do dispositivo de IoT, estimado em US\$ 250,00 e nos custos de desenvolvimento do software e do hardware, também estimado em US\$ 250,00. Desta forma, o custo de mercado estimado da solução foi de US\$ 500,00.

Foi realizada uma análise de custo de soluções IoT presente no mercado, similares a da presente proposta. Para isto, foram consideradas ferramentas que

também endereçam o problema do monitoramento em tempo real de ambiente de aquicultura 4.0. A Tabela 7 ilustra os valores observados. Estes valores foram obtidos a partir do levantamento de cotações com os respectivos fabricantes. Todos os valores citados são referentes a data 14 de agosto de 2023.

Tabela 7 - Comparação do custo de soluções IoT disponíveis no mercado.

Nome da Solução	Valor (Dólar)	Taxa de redução de custos (%)
Solução IoT proposta (Brasil)	US\$ 500,00	N/A
Atlas Scientific (EUA)	US\$ 900,00	44%
Aquanetix (Grécia)	US\$ 2.250,00	78%
Tatlfish (Brasil)	US\$ 2.750,00	82%

Fonte: Elaborado pelo autor. Pesquisa realizada em 14/08/2023.

Examinando a Tabela 7, torna-se evidente que a solução IoT proposta oferece uma redução de custo significativa de pelo menos 44% em comparação as soluções listadas. Essa redução de custo é obtida primariamente através da utilização da proposta de estimação do oxigênio dissolvido via inteligência artificial, dispensando o uso do sensor de OD, e permitindo que a solução proposta ofereça uma alternativa mais econômica no mercado. Este ganho econômico é ainda mais significativo frente a realidade de países em desenvolvimento, cujo custo de aquisição destas soluções é consideravelmente maior, devido a adicionais como câmbio, importação e impostos. A viabilização do acesso deste tipo de tecnologia localmente oferece a estes países um grande potencial de crescimento econômico.

## 6 CONCLUSÕES E TRABALHOS FUTUROS

---

Neste Capítulo, são apresentadas as conclusões obtidas após a condução da presente pesquisa científica, abordando o estado da arte do problema estudado, bem como entraves observados na mesma. Também discutidas as principais contribuições realizadas, produtos científicos e de propriedade intelectual gerados. Por fim, apresentadas as dificuldades encontradas e os trabalhos futuros.

---

## 6.1 CONSIDERAÇÕES INICIAIS

As soluções baseadas em Internet das Coisas (IoT) no contexto da aquicultura 4.0 (aquicultura de precisão) estão sendo desenvolvidas para promover o crescimento desta área nos limites da sustentabilidade, melhorando o aproveitamento dos recursos já presentes nos ambientes de cultivo, a fim de aumentar sua produtividade e lucratividade. Dentre estas soluções, destaca-se o monitoramento em tempo real, que soluciona o problema do monitoramento manual de parâmetros da água, proporcionando um acompanhamento dinâmico do estado do cultivo, trazendo maior rapidez e confiabilidade nos processos de análise de dados e tomadas de decisão, essenciais para a manutenção da qualidade da água e conseqüentemente para a saúde dos animais. Diante disso, frente ao alto custo de sistemas IoT para o monitoramento da qualidade da água disponíveis no mercado, é essencial o desenvolvimento de novas propostas com foco no baixo custo, proporcionando em especial a base da cadeia produtiva, os pequenos e médio produtores, um maior acesso a este tipo de tecnologia.

## 6.2 CONTRIBUIÇÕES

A principal contribuição deste trabalho foi a proposta de uma solução IoT de baixo custo para o monitoramento da qualidade da água na aquicultura 4.0. Esta solução utilizou como base a redução de custos de modelos de aprendizagem de máquina para estimação de oxigênio dissolvido, a fim de excluir a obrigatoriedade do uso de sensores de OD, que representam mais de 50% dos custos de produção do hardware IoT.

Para isto foram projetadas e desenvolvidas duas tecnologias que operam em conjunto. A primeira foi uma inteligência artificial baseada em aprendizagem de máquina para a realização da estimação do OD a partir das leituras dos sensores de pH e temperatura. A segunda foi um sistema IoT para o monitoramento da qualidade da água, projetado com base numa arquitetura IoT de baixo acoplamento e com suporte à integração à IA mencionada anteriormente. A implementação e integração destas tecnologias em um sistema IoT concretizou a proposta da solução de baixo custo prospectada.

Este sistema IoT foi submetido a testes em ambiente real de aquicultura 4.0, na qual foi avaliada a acurácia dos dados de telemetria coletados, caracterizadas por coletas físicas dos sensores de temperatura e de pH, e pela estimação do OD através do modelo de aprendizagem de máquina desenvolvido. Esta avaliação

revelou que o sistema tem capacidade de ser implantado em ambiente produtivo real, visto que o percentual de erro médio (CV RMSE) dos parâmetros da água avaliados apresentara valores inferiores a 20%, sendo indicador de alta acurácia, segundo a avaliação estatística empregada. Quanto a performance do modelo de estimação de oxigênio dissolvido, o de melhor acurácia foi o baseado no algoritmo Random Forest, atingindo um RMSE médio de 0,88. Este resultado foi obtido através de um ranqueamento estatístico através o teste post-hoc de Nemenyi para comparar os modelos desenvolvidos. Além disso, foi observado que os modelos baseados em redes neurais avaliados foram superados por modelos como o Random Forest, que necessitam de um menor poder computacional para operar.

Além disso, o apoio de editais da Fundação do Amparo a Ciência e Tecnologia de Pernambuco (FACEPE) possibilitou tanto o desenvolvimento do sistema IoT de baixo custo proposto quanto a instalação do mesmo em fazendas de aquicultura do estado de Pernambuco. Dentre os objetivos listados nestes editais está o desenvolvimento da cadeia produtiva do estado de Pernambuco, de modo que além das experimentações realizadas, também foram construídas outras unidades o protótipo e entregues a produtores que apoiaram o desenvolvimento da pesquisa. A Figura 22 ilustra a entrega do protótipo desenvolvido do dispositivo IoT ao piscicultor Gilmar Aguiar, proprietário da Acquavalle de São José do Egito - PE, e ao Sr. Francinaldo Souza e Silva, conhecido como “Sr. Neném”, produtor local familiar do assentamento Serrinha, Serra Talhada - PE.

Figura 22 - Entrega protótipo desenvolvido a aquicultura do estado Pernambuco.



Fonte: Elaborado pelo autor.

### 6.3 PRODUTOS CIENTÍFICOS E DE INOVAÇÃO GERADOS

Durante o curso da pesquisa foram realizadas produções tanto de artigos científicos quanto de propriedade intelectual. Quando ao desenvolvimento acadêmico, foram submetidos dois artigos científicos.

O primeiro artigo, intitulado “*An IoT-Based Solution for Water Quality Monitoring in Aquaculture 4.0*” foi submetido em uma das maiores conferências de Internet das Coisas do mundo, a “*IEEE 9th World Forum on Internet of Things*”, com QUALIS A2. O segundo artigo, intitulado “*Machine Learning Models for the Estimation of Dissolved Oxygen on Aquaculture 4.0*” foi submetido ao periódico “*Aquaculture Engineering*”, pertencente a Elsevier, uma das maiores revistas científicas com foco no projeto e o desenvolvimento tecnológico de sistemas aquícolas. Este periódico também possui QUALIS A2.

Quanto a propriedade intelectual, foi realizado o pedido de patente da solução proposta, registrado sob número de processo “BR1020220076421” e foi intitulado “*Dispositivo de Internet das coisas para o monitoramento remoto de parâmetros da água e processo para a estimação dos níveis de oxigênio dissolvido*”. Além disso, foi submetido e aprovado um pedido de registro de software quando ao modelo de inteligência artificial desenvolvido. Ele foi registrado sob número de processo “BR512022000809-2” e foi intitulado “*Modelo estimador de oxigênio dissolvido baseado em regressão de redes neurais*”.

### 6.4 TRABALHOS FUTUROS

Apesar do fato de todos os parâmetros coletados pelo sistema desenvolvido tenham apresentado acurácia aceitável, de acordo com a metodologia de avaliação aplicada, é relevante a realização de estudos mais aprofundados da avaliação de outros modelos de sensores subaquáticos, de modo a aprimorar a acurácia da coleta de dados.

Um ponto em aberto observado foi a falta de informações quanto a calibração do sensor de pH (ph-4502c) utilizado no desenvolvimento do hardware proposto. Embora existam discussões e suporte de fóruns online, não há documentações oficiais disponibilizadas pela fabricante do sensor para apoiar seu processo de instalação. Isto dificulta o desenvolvimento de equações de interpolação, para a conversão da tensão elétrica de saída do sensor na unidade de

pH. Desta forma, pode ser possível aprimorar a acurácia da coleta de dados nas condições apresentadas, através do estudo mais aprofundado do processo de calibração deste sensor.

Além disso, devido às limitações presentes na base de dados de qualidade da água utilizada (Baffle-Creek), como as coletas de dados apenas nos dois primeiros dias entre os meses de julho a dezembro, foi gerada uma disparidade entre a quantidade de registro da estação úmida e seca do ano. Desta forma, a construção de uma base de dados própria, com dados especificamente de viveiros de aquicultura, permitirá aos modelos de estimação de OD serem treinados com as dinâmicas reais de variação do OD, podendo melhorar seu poder de generalização e sua acurácia. Estas bases de dados também podem servir como base para outras pesquisas deste meio, como a descoberta de novos relacionamentos entre os parâmetros da água, semelhante as equações de Benson-Krause.

Outro trabalho futuro relevante é validar o sistema desenvolvido durante todo um ciclo produtivo, considerando diferentes espécies e tipos de sistemas de produtivos, como o extensivo, semi-intensivo, intensivo e superintensivo.

Paralelo a isto, a análise de questões de segurança envolvendo a arquitetura IoT proposta também é um ponto a ser analisado. O desenvolvimento do *IoT security* é um tópico em alta atualmente, principalmente envolvendo os frequentes problemas com vazamento de dados e ataques de *ransomware*. Este trabalho futuro envolve a aplicação de novas soluções, que consideram novas camadas específicas para propósitos de autenticação e autorização de seus dispositivos físicos à camada de transporte. Estas questões de segurança também envolvem o problema da vulnerabilidade nos próprios microcontroladores IoT, que muitas vezes permanecem desatualizados devido às limitações de seu consumo energético.

Por fim a integração do sistema IoT proposto à softwares terceiros do tipo *machine-to-machine*, como automações com aeradores e alimentadores, pode permitir tanto o monitoramento em tempo real quanto a operação autônoma e inteligente destes equipamentos, trazendo maior comodidade e melhor aproveitamento de insumos da fazenda.

## REFERÊNCIAS BIBLIOGRÁFICAS

APHA. Standard methods for the examination of water and wastewater. Health Assoc. 1995.

ARAUJO, S., et al Simulation of the concentration of dissolved oxygen in river waters using Artificial Neural Networks. 2015 11th International Conference on Natural Computation (ICNC). IEEE, 2015.

ATZORI, L., et al The Internet of things: A survey. Computer networks 54.15. pg. 2787-2805. 2010.

BAFFLE CREEK. Baffle Creek water quality monitoring data - Historical. Disponível em: <<https://www.data.qld.gov.au/dataset/baffle-creek-water-quality-monitoring-data-historical>>. Acesso em: 14 ago. 2023.

BENSON, B. B.; KRAUSE, D. The concentration and isotopic fractionation of oxygen dissolved in freshwater and seawater in equilibrium with the atmosphere<sup>1</sup>. Limnology and Oceanography, v. 29, n. 3, p. 620–632, maio 1984.

BILLAH, M., et al Quality Maintenance of Fish Farm: Development of Real-time Water Quality Monitoring System. 2019 IEEE International Conference on Smart Instrumentation, Measurement and Application (ICSIMA). 2019.

BOKINGKITO, B.; LOMESINDO, T. Using Fuzzy logic for real-time water quality assessment monitoring system. Proceedings of the 2018 2nd ICACR. 2018.

BURHAN, M., et al. IoT elements, layered architectures and security issues: A comprehensive survey. Sensors. v. 18.9, p. 2796. 2018.

CLERCQ, M., et al. Agriculture 4.0: The future of farming technology. Proceedings of the World Government Summit, Dubai, UAE. p. 11-13. 2018.

DAOLIANG, I.; ZOU, M.; JIANG, L. Dissolved oxygen control strategies for water treatment: a review. Water Science & Technology 86.6 (2022). p. 1444-1466. 2022.

DEMŠAR, J. Statistical comparisons of classifiers over multiple data sets. The Journal of Machine learning research 7. p. 1-30. 2006.

DUANGWONGSA, J., et al. Real-time Water Quality Monitoring and Notification System for Aquaculture. 2021 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunication Engineering. IEEE, 2021.

DUPONT, C. et al. IoT for aquaculture 4.0 smart and easy-to-deploy real-time water monitoring with IoT. 2018 global Internet of things summit (GloTS). IEEE, 2018.

DZULQORNAIN, M. I.; et al. Design and Development of Smart Aquaculture System Based on IFTTT Model and Cloud Integration. MATEC Web of Conferences, v. 164, p. 01030, 2018.

EPA. ENVIRONMENTAL PROTECTION AGENCY. Ambient Water Quality Criteria for Dissolved Oxygen, Water Clarity and Chlorophyll a for the Chesapeake Bay and Its Tidal Tributaries. 2003.

FAO. Food and Agriculture Organization of the United Nations: The State of World Fisheries and Aquaculture 2022. Towards Blue Transformation. Food and Agriculture Organization. Rome, 2022.

FERRÃO, D. R. F. Design of an Ultra-Low Power RTC for the IoT. Diss. Universidade do Porto (Portugal). 2018.

FREITAS, F., A.; et al. Machine Learning Models for the Estimation of Dissolved Oxygen on Aquaculture 4.0. Aquacultural Engineering (escrita em desenvolvimento). Agosto de 2023.

FUNGE-SMITH, S; PHILLIPS, M.J. Aquaculture systems and species. Technical Proceedings of the Conference on Aquaculture in the Third Millennium. Bangkok, Thailand, p. 129-135. fev. 2000.

GAIKWAD, V.; et al. Optimizing power consumption for solar powered rechargeable lithium ion (li-ion) battery operated IoT based sensor node using wemos d1 mini. 2020 International conference on emerging smart computing and informatics (ESCI). IEEE, 2020.

GALAJIT, K., et al. Prediction of dissolved oxygen concentration for shrimp farming using quadratic regression and artificial neural network. 2018 IISAI-NLP. IEEE, 2018.

GARCÍA, C.; DANIEL M.; AND JUAN M. A review about Smart Objects, Sensors, and Actuators. International Journal of Interactive Multimedia & Artificial Intelligence 4.3 (2017). 2017.

KARVINEN, K.; TERO, K. IoT rapid prototyping laboratory setup. International Journal of Engineering Education 34.1 (2018). p. 263-272. 2018

KOLASSA, S. Why the "best" point forecast depends on the error or accuracy measure. International Journal of Forecasting 36.1. p. 208-211. 2020.

KUBITZA, F. A água na aquicultura, Parte 3. Panorama da Aquicultura, v. 27, n. 164, p. 14-27, dezembro 2017.

MACHADO, B. C. Avaliação da qualidade dos efluentes das lagoas de estabilização em série da Estação de Tratamento de Esgoto de Samambaia, DF para o cultivo de tilápia (*Oreochromis niloticus*). Dissertação (Mestrado) – Universidade de Brasília, Faculdade de Tecnologia, Brasília, DF. 2006.

MACIEL, J. C. Efeito da salinidade na sobrevivência e no crescimento de juvenis de robalo-peva *Centropomus parallelus*. Universidade Federal de Santa Catarina. 2005.

MENSINGA, T. T., et al. Health implications of exposure to environmental nitrogenous compounds. *Toxicological reviews* 22. p. 41-51. 2003.

NEMENYI, P. B. Distribution-free multiple comparisons. Princeton University, 1963.

OLIVEIRA, L. Manual de qualidade da água para aquicultura. Alfakit LTDA. Florianópolis. 2000.

OLMEDO, E.; SMITH, M. S. Development of an IoT Water Quality Monitoring System for Data-Based Aquaculture Siting. 10 mar. 2021.

ONU. World population prospects 2022: Summary of results. United Nations Department of Economic and Social Affairs, Population Division. 2022.

POONAM, T., et al. Water quality indices-important tools for water quality assessment: a review. *International Journal of Advances in chemistry* 1.1. p. 15-28. 2013.

RAČYS, V. et al. Application of Orp for the Evaluation of Water Contamination. *Linnaeus Eco-Tech*, p. 1082–1089, 29 ago. 2017.

RASHEED, A.; HARIGOVINDAN, V. P. Water Quality Monitoring and Reporting System for Aquaculture with Solar Energy Harvesting. 2020 International Conference on Smart Technologies in Computing, Electrical and Electronics (ICSTCEE), 9 out. 2020.

ROMLI, M. A., et al. Automatic RAS data acquisition and processing system using fog computing. 2017 IEEE 13th Malaysia International Conference on Communications (MICC). IEEE, 2017

SANTOS, C. C. Parâmetros da qualidade de água na piscicultura de água doce. 2018.

SHANDIKRI, R.; BAYU, E. Internet of Things: Water Quality Classifying Based on Estimation Dissolved Oxygen Solubility and Estimation Unionized Ammonia for Small-scales Freshwater Aquaculture. *Kinetik*, 2021.

SOLIMAN, Naglaa F.; DALIA, MM. Yacout. Aquaculture in Egypt: status, constraints and potentials. *Aquaculture international* 24 (2016). p. 1201-1227. 2016.

SWETHA, P., et al. Random Forest Regression based Water Quality Prediction for Smart Aquaculture. 2023 4th I3CS. IEEE, 2023.

WANG, Y., et al. Water quality prediction method based on LSTM neural network. 2017 12th international conference on intelligent systems and knowledge engineering (ISKE). IEEE, 2017.

WEBER, P. K.; LAWRENCE K. D. Effects of total dissolved solids on aquatic organisms: A review of literature and recommendation for salmonid species. American Journal of Environmental Sciences 3.1. pg. 1-6. 2007.

WENDLING, M. Sensores. Universidade Estadual Paulista. São Paulo 2010 (2010). p. 20. 2010.

YAURI, R., M.; JINMI L. Water quality monitoring of Peruvian Amazon based in the Internet of Things. 2017 IEEE XXIV International conference on electronics, electrical engineering and computing (INTERCON). 2017.

ZAINI, A.; et al. Data Visualization on Shrimp Pond Monitoring System Based on Temperature, pH, and DO (Dissolved Oxygen) with IoT. 17 nov. 2020.