

Desenvolvimento de uma Plataforma IoT para Monitoramento da Qualidade da Água na Piscicultura

Isaias A. L. Saraiva* Carlos R. P. dos Santos Junior**
Jacó M. dos Santos*** Thiago M. Pereira****
Vicente F. de Lucena Junior† Fabson Gomes Nepomuceno‡

* *IComp, UFAM, Manaus, AM, isaias.saraiva@icomp.ufam.edu.br*

** *SENAI, ISI Microeletrônica, Manaus, AM, carlosrpdj@gmail.com*

*** *IComp, UFAM, Manaus, AM, jaco.santos@icomp.ufam.edu.br*

**** *ICTA, UFOPA, Santarém, PA, tmarinhopereira@gmail.com*

† *CETELI, UFAM, Manaus, AM, vicente@ufam.edu.br*

‡ *CETELI, UFAM, Manaus, AM, fabsongm@gmail.com*

Abstract: This paper describes the development of a platform for monitoring water quality in fish farming using IoT and cloud computing concepts. The tool collects real-time data through sensors on the main physical and chemical parameters of the water, such as temperature, pH, turbidity, and dissolved oxygen. These data are then processed and made available in the cloud for the fish farmer to access. Additionally, to validate the context of the platform's data, a machine learning model was developed using Orange Data Mining to predict the percentage of feed to be given to the fish based on the collected data. The results achieved showed that the platform provides an efficient and effective means for fish farmers to monitor water quality and predict feeding in their fish farming operations.

Resumo: Este artigo descreve o desenvolvimento de uma plataforma para monitoramento da qualidade da água na piscicultura a partir dos conceitos de IoT e computação em nuvem. A ferramenta coleta dados em tempo real por meio de sensores sobre os principais parâmetros físicos e químicos da água, como temperatura, pH, turbidez, e oxigênio dissolvido. Estes dados são tratados e disponibilizados na nuvem para que o piscicultor possa ter acesso. Além disso, para validar o contexto dos dados da plataforma, um modelo de aprendizado de máquina foi desenvolvido usando o Orange Data Mining com o intuito de prever o percentual de alimentação a ser dado para os peixes com base nos dados coletados. Os resultados alcançados mostraram que a plataforma fornece um meio eficiente e eficaz para os piscicultores monitorarem a qualidade da água e preverem a alimentação em suas operações de piscicultura.

Keywords: Fish Farming; IoT; Cloud Computing; Machine Learning.

Palavras-chaves: Piscicultura; IoT; Computação em Nuvem; Aprendizado de Máquina.

1. INTRODUÇÃO

A água é o recurso primário para diversas atividades econômicas, incluindo a aquicultura, que consiste no cultivo de organismos aquáticos, como peixes, moluscos, crustáceos e algas. Este trabalho concentra-se no setor da piscicultura, que é uma subárea da aquicultura, e refere-se especificamente ao cultivo de peixes. Atualmente, a piscicultura é o segmento da produção animal que mais cresce no cenário mundial Figueiredo et al. (2017).

Na atividade de piscicultura, a quantidade e qualidade da água são fatores determinantes para o sucesso da produção (de Oliveira e Santos, 2015). No que diz respeito à quantidade, é essencial considerar a quantidade de água necessária para abastecer as unidades de cultivo, tais

como viveiros e tanques, e para manter a qualidade, os parâmetros físicos e químicos são essenciais para o sucesso. Como em qualquer criação animal, o principal objetivo na piscicultura é o crescimento e o consequente ganho de peso dos peixes (Lourenço et al., 1999). Diante deste cenário, a qualidade da água é crucial para diferenciar o lucro do prejuízo na piscicultura para que o peixe alcance um bom índice de crescimento, portanto, ganhando peso e reduzindo o tempo de cultivo. É imperativo observar que os peixes tenham, além de uma alimentação adequada, uma água de boa qualidade que esteja em condições de suportar a biomassa existente no tanque ou no açude.

Apesar de o Brasil apresentar vantagens competitivas, sendo rico em recursos hídricos, possuindo vasta extensão territorial e grande variedade de espécies, esses recursos não têm sido completamente aproveitados para a produção aquícola (Pantoja-Lima et al., 2021). Em termos de produção global, o mundo alcançou aproximadamente 179

* Agradecemos ao apoio institucional do Departamento de Computação da Universidade Federal do Amazonas e ao Instituto SENAI de Inovação em Microeletrônica.

milhões de toneladas de pescado em 2018 (Odakura et al., 2021). O Brasil ocupa a 13^a posição na produção de peixes em cativeiro e o 8^o lugar na produção de peixes de água doce. Desse total, 87% é destinado ao consumo humano, destacando a relevância do pescado para a segurança alimentar global.

Na aquicultura em tanques-rede, um dos principais problemas é o controle da alimentação e a monitorização da qualidade da água (Winter e Mota, 2021). Apesar do crescimento da piscicultura, a maioria dos produtores ainda realiza manualmente as medições, utilizando kits colorimétricos, de custo acessível, porém com problemas de precisão. Por outro lado, os instrumentos de medição mais confiáveis, capazes de avaliar parâmetros como pH, oxigênio dissolvido, temperatura, entre outros, têm um custo elevado para os piscicultores. No entanto, é incontestável que o monitoramento da qualidade da água seja crítico na piscicultura, assim como a frequência das medições.

A alimentação na piscicultura é crucial, afetando o crescimento dos peixes e representando grande parte dos custos de produção. As exigências nutricionais, como a proteína, são maiores em peixes em comparação com outras espécies. O fornecimento de ração rica em proteínas, essencial mas dispendioso, aumenta os custos. A escolha adequada de alimentos, em quantidade e qualidade, é vital para o sucesso da piscicultura Ribeiro et al. (2012).

Segundo Junior et al. (2019), os processos de automação devem avançar pela agropecuária como forma de assegurar o aumento de produção e produtividade no Brasil e também como objetivo manter e estimular o crescimento das indústrias de máquinas e equipamentos agropecuários.

Atualmente, a medição destes parâmetros é feita por tecnologias comerciais, como equipamentos multiparâmetros, que podem ter alto custo para os piscicultores. Embora os piscicultores possam medir esses dados através de kits colorimétricos, esta abordagem não oferece a mesma precisão que um instrumento de medição mais sofisticado. Assim, surge a necessidade de desenvolver soluções acessíveis para que os piscicultores possam monitorar de forma eficiente e precisa os principais parâmetros da qualidade da água, sem comprometer sua rentabilidade. Como, então, fornecer aos piscicultores ferramentas e tecnologias adequadas e acessíveis para monitorar os parâmetros da qualidade da água e prever a porcentagem de alimentação diária em suas operações de piscicultura?

Neste contexto, este trabalho propõe desenvolver um sistema para monitoramento automatizado através da Internet das Coisas (IoT) dos principais parâmetros físico-químicos da piscicultura e classificar a porcentagem de alimentação com base na temperatura da água da espécie Tilápia. A principal contribuição deste artigo é, portanto, a proposta de um sistema de monitoramento dos principais parâmetros da piscicultura, incluindo oxigênio dissolvido, temperatura, pH e turbidez, e prever a porcentagem de alimentação diária para a Tilápia que é uma das espécies mais comuns produzidas no país.

2. TRABALHOS CORRELATOS

A piscicultura tem buscado aprimorar seus métodos e maximizar a produção. A automação e o monitoramento

dos parâmetros físico-químicos da água tornam-se aspectos cruciais para garantir um ambiente ideal para o crescimento saudável dos peixes. Nesse contexto, uma série de trabalhos tem sido desenvolvida visando otimizar a gestão dos sistemas aquícolas. A seguir, destacam-se alguns desses trabalhos que propõem soluções inovadoras para a monitoramento e controle desses parâmetros. O trabalho Projeto de um Sistema De Automação para Piscicultura conduzido por Junior et al. (2019), apresenta um sistema de automação para a piscicultura que monitora parâmetros físico-químicos, tais como temperatura, pH e turbidez. Esse sistema utiliza um microcontrolador Arduino para coletar e processar os dados, proporcionando uma visualização em tempo real das condições da água. Outra abordagem relevante é o trabalho de Angani et al. (2019) *Realization of Eel Fish Farm with Artificial Intelligence Part 3: 5G based Mobile Remote Control*, que implementa um sistema de monitoramento dos principais parâmetros físico-químicos da piscicultura. Além do monitoramento convencional, esse estudo emprega técnicas de aprendizado de máquina para analisar os dados coletados, proporcionando insights valiosos para a tomada de decisões no manejo dos tanques de criação. O estudo recente de Caldeira (2023), Monitoramento de parâmetros físico-químicos através do sensoriamento para a piscicultura. Concentra-se no desenvolvimento de um protótipo para monitorar três parâmetros essenciais: temperatura, turbidez e pH da água.

Esses estudos representam progressos notáveis na busca por soluções tecnológicas para aprimorar o monitoramento e controle dos parâmetros físico-químicos em piscicultura. No entanto, o trabalho proposto não só oferece uma plataforma de monitoramento, mas também inclui uma capacidade preditiva crucial, a previsão do percentual de alimentação para a espécie Tilápia.

3. METODOLOGIA

O monitoramento dos parâmetros na piscicultura é crucial para assegurar o êxito dessa atividade. No entanto, os dispositivos de medição disponíveis no mercado possuem custos elevados, o que pode representar um obstáculo para os produtores. Diante desse contexto, a proposta de desenvolver um sistema acessível se torna uma alternativa viável. A metodologia para atingir os objetivos seguiu os seguintes passos:

- **Levantamento do estado da arte:** Para elaborar este trabalho, primeiramente realizou-se um levantamento das tecnologias de sensores usadas para monitorar os parâmetros físico-químicos da água na piscicultura.
- **Avaliar e especificar sensores:** Nesta fase do projeto, avaliaram-se e especificaram-se as tecnologias comerciais de sensores para monitorar os parâmetros físico-químicos da água, tais como pH, temperatura, oxigênio dissolvido e turbidez. Com base na avaliação, foram selecionados os sensores mais adequados para automatizar o processo de monitoramento.
- **Realizar a calibração dos sensores:** Nesta fase do projeto, realizou-se a calibração dos sensores de pH utilizando as soluções tampão de pH 4, 7 e 10. Além disso, efetuaram-se a calibração do sensor de oxigênio dissolvido para 100% de saturação em ambiente, e a calibração do sensor de turbidez.

- **Realizar o desenvolvimento da aplicação para monitoramento:** Nesta etapa do projeto, foi realizado o desenvolvimento da aplicação composta pelo hardware e software para o monitoramento dos parâmetros físico-químicos da água.
- **Realizar o desenvolvimento do modelo de aprendizado de máquina na ferramenta Orange Data Mining:** Nesta etapa do projeto, elaborou-se uma base de dados utilizando a coleção SENAR (2019) para treinar, testar e validar o algoritmo. Foram realizados testes com vários algoritmos de classificação, avaliando a acurácia e a matriz de confusão.

4. SOLUÇÃO PROPOSTA

A visão geral da arquitetura proposta para o monitoramento automático dos parâmetros físico-químicos da piscicultura é ilustrada na figura 1.

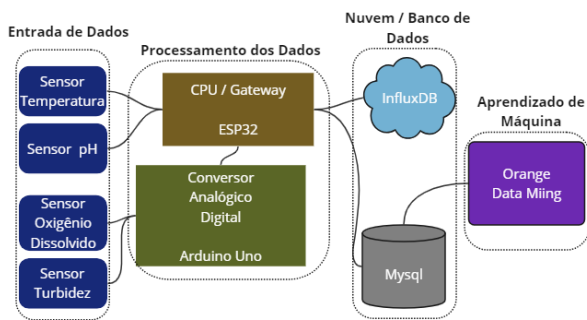


Figura 1. Arquitetura Proposta

A arquitetura proposta funciona da seguinte forma:

- **Entrada de Dados:** Nesta etapa, os sensores são responsáveis por coletar diversas informações do tanque, como temperatura, pH, níveis de oxigênio dissolvido e turbidez.
- **Conversor A/D:** O projeto utiliza como conversor um arduino Uno com o objetivo de fazer a leitura dos sensores que operam com uma voltagem de 5V. Devido o microcontrolador utilizado operar somente com a faixa de 3.3V.
- **Processamento de Dados:** O projeto usa o microcontrolador ESP32 para processar dados coletados. Sensores de temperatura e pH conectam-se à placa, enquanto informações de turbidez e oxigênio vêm pela porta serial do Arduino UNO. O ESP32 se conecta à internet, permitindo comunicação e envio de dados via MQTT (Transporte de telemetria de enfileiramento de mensagens do inglês *Message Queuing Telemetry Transport*) com InfluxDB, MySQL e Orange Data Mining.
- **Nuvem / Visualização dos Dados - InfluxDB:** Para que o piscicultor possa acessar os dados coletados pelo sistema, é utilizada a ferramenta InfluxDB, que permite a visualização de todos os parâmetros medidos em tempo real.
- **MySQL:** O banco de dados MySQL é responsável por armazenar os dados de temperatura, os quais são utilizados pela ferramenta Orange Data Mining para prever a porcentagem de alimentação.
- **Orange Data Mining:** Esta ferramenta visa treinar modelos de classificação para prever a alimentação da

espécie Tilápia. Através desta ferramenta é possível analisar os resultados através de gráficos.

4.1 Protótipo

Na figura 2 é apresentado o protótipo com os materiais utilizados.




Figura 2. Protótipo do hardware para medição dos dados

- **Microcontrolador ESP32:** Para a implementação do projeto, foi utilizado o microcontrolador ESP32. Esse dispositivo possui um módulo de comunicação Wi-Fi, que possibilita a conexão de vários sensores e outros dispositivos à internet por meio de protocolos como HTTP (Protocolo de Transferência de Hipertexto do inglês *Hypertext Transfer Protocol*), MQTT, entre outros.
- **Sensor de Temperatura à Prova d'Água DS18B20:** Este sensor é capaz de operar em diversos ambientes. Uma de suas principais funcionalidades é a capacidade de realizar medições mesmo quando está submerso na água. De acordo com Leira et al. (2017), a temperatura da água é um dos principais fatores nos fenômenos químicos e biológicos de um viveiro, uma vez que todas as atividades fisiológicas dos peixes, como respiração, reprodução e alimentação, estão diretamente ligadas à temperatura da água.
- **Módulo do Sensor de Oxigênio Dissolvido Analógico Gravity:** Este sensor tem como objetivo realizar a leitura de um dos parâmetros mais importantes na atividade de piscicultura. O mesmo faz medições para identificar a presença de oxigênio em porcentagem de saturação. Conforme apontado por Kubitzka (1998), se o valor do oxigênio dissolvido na água for baixo, isso pode resultar em prejuízos para a criação de peixes, como atraso no crescimento, redução na eficiência alimentar e aumento na incidência de doenças
- **Sensor de pH PH4502C com Eletrodo Sonda BNC:** Este módulo amplifica os sinais da sonda de pH e os transmite ao microcontrolador. O pH, é um dos parâmetros químicos monitorados crucial em aquicultura devido ao seu impacto no metabolismo e processos fisiológicos de peixes e organismos aquáticos dos Santos et al. (2018).
- **Módulo Sensor de Turbidez ST100:** A relevância desse parâmetro é destacada por Bartz et al. (2021), pois pode indicar fenômenos como erosão do solo, escoamento, descargas, agitação de sedimentos de fundo ou crescimento excessivo de algas. Neste projeto o sensor utilizado é o ST100.

5. RESULTADOS PRELIMINARES

Nesta seção, serão exibidos os resultados preliminares até o momento. A figura 3 apresenta o dashboard do sistema de monitoramento dos parâmetros da piscicultura, desenvolvido com a assistência do InfluxDB.

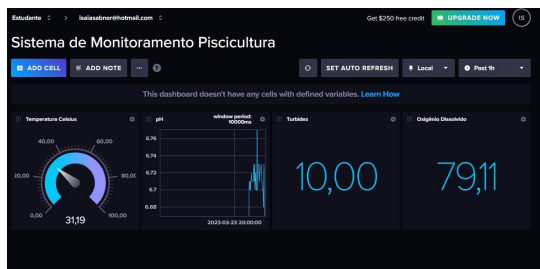


Figura 3. Dashboard para visualização dos dados de Temperatura, pH, Turbidez, e Oxigênio dissolvido

Para monitorar os dados, criou-se um dashboard no InfluxDB. Além de permitir a comunicação via protocolo MQTT, essa ferramenta apresenta uma interface de usuário para visualizar os dados coletados pelos sensores de temperatura, pH, turbidez e oxigênio dissolvido.

Realizaram-se experimentos em laboratório para testar os sensores. Os sensores de turbidez, oxigênio dissolvido e pH foram calibrados de acordo com as instruções do fabricante, que oferece soluções específicas para cada sensor.

A calibração do sensor de pH envolveu soluções com pH 4, 7 e 10. O sensor de oxigênio dissolvido foi calibrado em ambiente atmosférico, enquanto o sensor de turbidez foi calibrado usando uma solução de zero NTU.

Modelos de Aprendizado de Máquina

A aprendizagem de máquina, conforme mencionada por Homem e Ufes (2020), capacita o computador a aprender tarefas específicas a partir de dados. Isso abrange classificação, regressão, agrupamento, associação, previsão e geração. Neste trabalho, é utilizada a técnica de aprendizado supervisionado com algoritmos de classificação para determinar a porcentagem de alimentação de alevinos da tilápia.

Atualmente, está em andamento a implementação da comunicação entre o ESP32 e outras ferramentas de processamento de dados, como MySQL e Orange Data Mining. Essa etapa é crucial para uma análise mais profunda dos dados coletados pelo sistema de monitoramento de qualidade da água e para a previsão de alimentação na piscicultura.

A classificação da porcentagem de alimentação da tilápia foi realizada através dos treinamentos dos modelos na ferramenta Orange Data Mining.

A base de dados com 1131 registros, elaborada neste trabalho, foi construída a partir da coleção SENAR (2019), que exibe a tabela 1 com o percentual adequado de alimentação em relação à temperatura da água para a espécie de Tilápia. Com base nessas informações, foi implementada uma técnica de aprendizado de máquina supervisionado.

Conforme apresentado na tabela 1, a oferta de ração segue um padrão específico conforme a temperatura da água.

Tabela 1. Percentual de Alimentação.

Percentual de alimentação em função da temperatura da água					
Menos de 16 °C	16 a 19 °C	20 a 24 °C	25 a 29 °C	30 a 32 °C	Mais de 32 °C
Não fornecer	60%	80%	100%	80%	Não fornecer

Abaixo de 16°C ou acima de 32°C, a recomendação é não fornecer ração. Entre 16°C e 19°C, a indicação é de 60% da quantidade usual de ração. Nas faixas de 20°C a 24°C e de 30°C a 32°C, a alimentação ideal é de 80%. Entre 25°C e 29°C, a recomendação é fornecer a ração completa.

Neste estudo, cinco modelos foram treinados: CN2 (Ruído de Classe 2 do português *Class Noise 2*), Árvore de Decisão, Naive Bayes, KNN (K-vizinhos mais próximos do inglês *k-nearest neighbors*) e SVM (Máquina de Vetores de Suporte do inglês *Support Vector Machine*), como mostrado na figura 4. O treinamento desses modelos foi realizado na ferramenta Orange Data Mining.

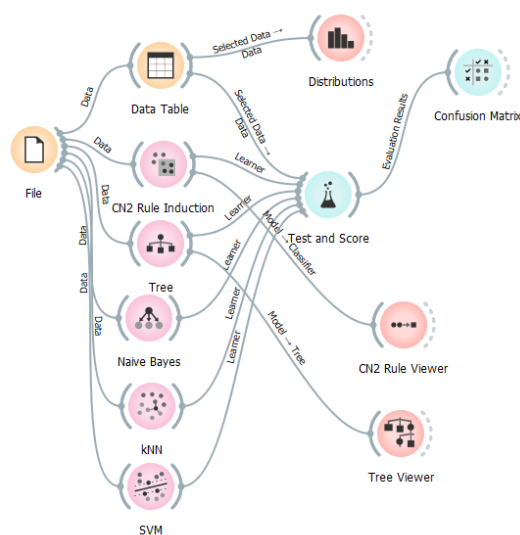


Figura 4. Modelos de Aprendizado de Máquina CN2, Tree, Naive Bayes, KNN, e SVM.

Após concluir os treinamentos, validações e testes dos modelos, foi realizada a avaliação das métricas como acurácia e matriz de confusão. A tabela 2 apresenta os resultados obtidos para cada modelo em termos de acurácia. Nela, observa-se que o algoritmo com melhor avaliação foi a Árvore de Decisão, enquanto o Naive Bayes obteve a menor acurácia.

Tabela 2. Avaliação de Acurácia dos modelos de aprendizado de máquina treinados.

Modelo	Acurácia
KNN	0.993
Árvore de Decisão	0.998
SVM	0.959
Naive Bayes	0.766
CN2	0.995

Outra técnica usada para analisar o desempenho dos algoritmos foi a validação cruzada em 10 partes. Conforme

Santos et al. (2019) afirma, essa técnica envolve a divisão aleatória do conjunto de treinamento em k partes de tamanho igual, onde k-1 partes são usadas para ajustar modelos e a parte restante é usada para avaliar o desempenho. A tabela 3 apresenta as acurácias dos modelos treinados com essa técnica.

Tabela 3. Avaliação de acurácia com validação cruzada dos modelos treinados.

Modelo	Acurácia
KNN (K-vizinhos mais próximos)	0.996
Árvore de Decisão	0.997
SVM (Máquina de Vetores de Suporte)	0.971
Naive Bayes	0.748
CN2	0.996

Os resultados apresentados na tabela 2 refletem o desempenho dos algoritmos em um único conjunto de treinamento e teste, sem a consideração de possíveis variações nos dados.

Por outro lado, os resultados da tabela 3 representam uma avaliação mais ampla do desempenho dos algoritmos, considerando diferentes divisões dos dados em conjuntos de treinamento e teste. Isso proporciona uma visão mais confiável da capacidade de generalização dos modelos.

Ao comparar os resultados, observa-se que, em geral, os valores de acurácia são consistentes entre ambos os cenários. Algoritmos como KNN, Árvore de Decisão e CN2 apresentam resultados semelhantes em ambas as situações, indicando boa capacidade de classificação e generalização. No entanto, o algoritmo Naive Bayes demonstra uma redução na acurácia com a validação cruzada.

Além da acurácia, a matriz de confusão é outra métrica importante para avaliar o desempenho dos algoritmos. Na figura 5, é exibida a matriz de confusão do algoritmo Naive Bayes, que obteve uma avaliação de acurácia inferior.

		Predicted				Σ
		alimenta 60%	alimenta 80%	alimenta 100%	não alimenta	
Actual	alimenta 60%	60.5 %	NA	0.0 %	NA	164
	alimenta 80%	20.7 %	NA	6.4 %	NA	111
	alimenta 100%	7.0 %	NA	81.6 %	NA	721
	não alimenta	11.8 %	NA	12.0 %	NA	135
Σ		271	0	860	0	1131

Figura 5. Matriz de confusão algoritmo Naive Bayes.

A figura 6 exibe a matriz de confusão do algoritmo árvore de decisão, o qual obteve o melhor valor de acurácia

		Predicted				Σ
		alimenta 60%	alimenta 80%	alimenta 100%	não alimenta	
Actual	alimenta 60%	100.0 %	0.9 %	0.0 %	0.0 %	164
	alimenta 80%	0.0 %	99.1 %	0.1 %	0.0 %	111
	alimenta 100%	0.0 %	0.0 %	99.9 %	0.0 %	721
	não alimenta	0.0 %	0.0 %	0.0 %	100.0 %	135
Σ		163	111	722	135	1131

Figura 6. Matriz de confusão algoritmo Árvore de Decisão.

A figura 7 apresenta a Árvore de decisão gerada pelo modelo através do Orange Data Mining, que apresenta

resultados semelhantes à tabela 2. A árvore generalizou os dados, criando regras de associação.




Figura 7. Árvore de Decisão do Modelo.

O nó raiz da árvore foi considerado como a temperatura. Em seguida, um nó foi criado no lado direito da árvore, indicando que se a temperatura for maior que 23.9, serão feitas mais duas tomadas de decisão. Se a temperatura for menor ou igual a 29.5, a taxa de alimentação é de 100%. Por outro lado, se a temperatura for maior que 29.5, são gerados mais nós. Se a temperatura for menor ou igual a 31.9, a taxa de alimentação é de 80%. No entanto, se a temperatura for maior que 31.9, não ocorre alimentação.

No lado esquerdo da árvore, outros nós foram criados. O primeiro nó indica que, se a temperatura for menor ou igual a 23.9, são gerados mais dois nós. Se a temperatura for maior que 19.0, a taxa de alimentação é de 80%. O outro nó criado afirma que, se a temperatura for menor ou igual a 19.0, são gerados mais dois nós. Se a temperatura for menor ou igual a 15.9, não ocorre alimentação. Porém, se a temperatura for maior que 15.9, a taxa de alimentação é de 60%.

Após treinamentos e validações, uma base de dados foi desenvolvida para analisar previsões dos algoritmos. Durante testes, diversos algoritmos de aprendizado de máquina foram utilizados.

O algoritmo naive bayes apresentou desempenho inferior, não identificando corretamente algumas porcentagens de alimentação. O modelo reconheceu apenas 60% e 100%, não sendo eficaz para 80% e ausência de alimentação.

Contudo, outros algoritmos apresentaram resultados superiores. A figura 8 apresenta o gráfico com o resultado de previsões do algoritmo árvore de decisão com novos dados simulados de temperatura.

6. CONCLUSÃO

A arquitetura proposta foi testada em laboratório, demonstrando sua eficácia. A ferramenta utilizada para o armazenamento das medições, o InfluxDB, é amigável e proporciona resultados objetivos aos usuários. Os algoritmos de aprendizado de máquina empregados alcançaram bons índices de acurácia. Embora o Naive Bayes tenha apresentado menor assertividade em alguns casos, os demais algoritmos obtiveram resultados satisfatórios e conseguiram prever com precisão a alimentação ideal para os peixes, considerando as condições da água e a temperatura. Os estudos relacionados a esse tema apresentam arquiteturas para monitorar parâmetros como temperatura, turbidez e pH. No entanto, este trabalho vai além, incluindo o parâmetro de oxigênio dissolvido e ainda prevendo a porcentagem ideal de alimentação para a espécie de Tilápia.




Figura 8. Gráfico previsões árvore de decisão.

Dentre os algoritmos utilizados no treinamento, a Árvore de Decisão se destacou como o mais eficaz, apresentando uma alta acurácia de 0.998. Ao analisar a matriz de confusão gerada por esse algoritmo, podemos observar que houve uma taxa de erro de apenas 0.9% na predição de "alimenta 80%" e 0.1% na predição de "alimenta 100%". No entanto considerando os resultados com e sem validação cruzada, podemos afirmar que os algoritmos KNN, Árvore de Decisão e CN2 apresentam um desempenho consistente e confiável na classificação dos dados, independentemente da forma como foram avaliados. Já o algoritmo Naive Bayes pode requerer uma análise mais cuidadosa e possíveis ajustes para melhorar sua capacidade de generalização.

Além disso, pretende-se dar continuidade ao desenvolvimento do projeto, finalizando a implementação da comunicação com o MySQL e, desta vez, considerando a espécie do tambaqui. Serão realizados testes em campo para acompanhar o monitoramento dos parâmetros, implementando agora algoritmos de regressão e utilizando dados do piscicultor, como o peso e a quantidade de biomassa no tanque, para prever a quantidade de ração diária com base no valor da temperatura do tanque. Dessa forma, será possível validar a eficácia da sugestão de alimentação do algoritmo, deixando o protótipo em campo para acompanhar a curva de crescimento dos peixes.

7. AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES-PROEX) - Código de Financiamento 001. Este trabalho foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado do Amazonas - FAPEAM - por meio do projeto POSGRAD 22-23 e pelo Instituto SENAI de Inovação em Microeletrônica.

REFERÊNCIAS

Angani, A., Lee, C.B., Lee, S.M., e Shin, K.J. (2019). Realization of eel fish farm with artificial intelligence part 3: 5g based mobile remote control. In *2019 IEEE International Conference on Architecture, Construction, Environment and Hydraulics (ICACEH)*, 101-104. IEEE.

- Bartz, R.L. et al. (2021). Sensoriamento remoto para análise de parâmetros de qualidade da água aplicado à piscicultura.
- Caldeira, G.A. (2023). Monitoramento de parâmetros físico-químicos através do sensoriamento para a piscicultura.
- de Oliveira, E.G. e Santos, F.J.d.S. (2015). Piscicultura e os desafios de produzir em regiões com escassez de água. In *Embrapa Meio-Norte-Artigo em anais de congresso (ALICE)*. Ciência Animal, v. 25, n. 1, p. 133-154, 2015. Ed. esp.
- dos Santos, M.V.B., Domiciano, C.A.R., da Guia Rocha, F., de Lima, C.J.B., de Jesus, L.A., e Moura, J.R.F. (2018). Desenvolvimento de sistema automático de análise de ph e temperatura da água para aquicultura. *Anais do Computer on the Beach*, 325-333.
- Figueiredo, F.M., da Costa, R.L., da Costa Bomfim, S., Rodrigues, J.F.H., e Bay-Hurtado, F. (2017). Qualidade da água na piscicultura. *Piscicultura e meio ambiente, estudos e perspectivas na Amazônia*, 1.
- Homem, W.L. e Ufes, P.E.M. (2020). Apostila de machine learning. *PET Engenharia Mecânica, UFES*.
- Junior, W.B.L., Landim, N.M.D., Nunes, R.M., e de Araujo, H.X. (2019). Projeto de um sistema de automação para piscicultura utilizando internet das coisas-iot.
- Kubitza, F. (1998). Qualidade da água na produção de peixes—parte iii (final). *Panorama Aquicult*, 8, 35-43.
- Leira, M.H., Cunha, L.d., Braz, M.S., Melo, C.C.V., Botelho, H.A., e Reghim, L.S. (2017). Qualidade da água e seu uso em pisciculturas. *Pubvet*, 11(1), 11-17.
- Lourenço, J.N.d.P., Malta, J.C.d.O., e de Sousa, F.N. (1999). A importância de monitorar a qualidade da água na piscicultura. *Embrapa Amazônia Ocidental-Séries anteriores (INFOTECA-E)*.
- Odakura, A.M., Braz, J.M., Neu, D.H., e Caldara, F.R. (2021). Problemática da piscicultura orgânica. *Revista Multidisciplinar de Educação e Meio Ambiente*, 2(3), 34-34.
- Pantoja-Lima, J., Rocha, M.J.S., Castro, L., Amaral, A., Scherer Filho, C., Paixao, R., Feijo, J., Araujo, H., Aride, P., Oliveira, A., et al. (2021). O estado da piscicultura na amazônia brasileira. *Aquicultura na Amazônia: estudos técnico-científicos e difusão de tecnologias*. Atena, Ponta Grossa, 86-102.
- Ribeiro, P.A.P., Melo, D., Costa, L.S., e Teixeira, E. (2012). Manejo nutricional e alimentar de peixes de água doce. *Belo Horizonte: Universidade Federal de Minas Gerais*.
- Santos, H.G.d., Nascimento, C.F.d., Izbicki, R., Duarte, Y.A.d.O., Chiavegatto Filho, P., e Dias, A. (2019). Machine learning para análises preditivas em saúde: exemplo de aplicação para prever óbito em idosos de são paulo, brasil. *Cadernos de Saúde Pública*, 35, e00050818.
- SENAR (2019). Coleção 263 piscicultura: alimentação. 1-52. SENAR.
- Winter, L. e Mota, S.H.R. (2021). Sistema automatizado de monitoramento e arraçamento aplicado à criação de tilápias em tanques-rede. *Revista Thêma et Scientia*, 11(2), 96-113.