

## 22ª Semana Nacional de Ciência e Tecnologia do IFBA - 2025

*Do Sertão ao Mar: Conexões entre Territórios, Saberes e Águas*  
21 a 25 de Outubro de 2025 - BA - Brasil

### Aprimoramento do Módulo de Inteligência Artificial do sistema Aquamind

Autores

Ivan da Silva Bispo Junior<sup>1</sup>

Daniel dos Anjos Costa<sup>2</sup>

Flavio Pereira da Silva<sup>3</sup>

**Área Temática:** Ciências Exatas da Terra.

**Palavras-chave:** Irrigação Inteligente, Internet das Coisas, Inteligência Artificial

### RESUMO

A Caatinga Nordestina enfrenta sérios desafios hídricos devido à escassez e irregularidade das chuvas, tornando crucial a gestão eficiente da água na agricultura. Para enfrentar esse problema, o presente projeto desenvolveu um sistema de irrigação modular com capacidade de tomar decisões sobre tempo de irrigação artificial com base nos dados ambientais locais e meteorológicos coletados via Internet das Coisas (IoT). A solução utiliza IoT para coletar dados do ambiente e Inteligência Artificial (IA) para calcular com precisão o tempo de rega necessário. No seu desenvolvimento foi realizado um estudo comparativo entre diferentes modelos de aprendizado de máquina. Por seu desempenho superior, alto alcance e acurácia com um coeficiente de determinação ( $R^2$ ) de 93,63%, o algoritmo CatBoost foi selecionado para compor o sistema. O projeto demonstra ser uma contribuição tecnológica viável e eficaz para uma agricultura mais sustentável e produtiva com foco direto nas necessidades de pequenos e médios produtores.

### 1. INTRODUÇÃO

No Brasil, a agricultura é responsável por aproximadamente 70% do consumo de água tratada, sendo o setor que mais contribui para o desperdício de recursos hídricos (Globo Ecologia, 2013). Além disso, estudos do Instituto Trata Brasil (2022) e do Neowater (2024) apontam que as perdas no sistema de abastecimento para a agricultura superam 40%. No caso da agricultura de sequeiro, a vulnerabilidade é ainda maior devido às variações climáticas que afetam diretamente a

---

<sup>1</sup> Esp. Ivan da Silva Bispo Junior; IFBA-Campus Santo Amaro, [ivanbispojr@gmail.com](mailto:ivanbispojr@gmail.com).

<sup>2</sup> Prof. Me. Daniel dos Anjos Costa; IFBA-Campus Santo Amaro, [daniel.anjos@ifba.edu.br](mailto:daniel.anjos@ifba.edu.br).

<sup>3</sup> Prof. Dr. Flavio Pereira da Silva; IFBA-Campus Santo Amaro, [flavio.pereira@ifba.edu.br](mailto:flavio.pereira@ifba.edu.br).

produção (Ana; IBGE, 2023). Os métodos tradicionais de irrigação, baseados em cronogramas fixos, muitas vezes desconsideram fatores ambientais como a umidade do solo, a umidade relativa do ar e as previsões meteorológicas, resultando em baixo rendimento e elevado desperdício de água (Embrapa, 2024). A umidade do solo é essencial para a fertilidade agrícola, regulando a atividade microbiana e a disponibilização de nutrientes. Nesse contexto, torna-se necessário o desenvolvimento de soluções que conciliem eficiência hídrica e acessibilidade econômica. O projeto propõe uma abordagem inovadora ao integrar Internet das Coisas (IoT) e Inteligência Artificial (IA), utilizando dados de umidade do ar e solo, temperatura e luminosidade, para otimizar o uso da água. Esse artigo apresenta o aprimoramento do módulo de IA do Sistema de Irrigação Aquamind, descrevendo sua infraestrutura baseada em microsserviços, os mecanismos de segurança, a resiliência a falhas e o seu ciclo contínuo de aprendizado, que permite à IA adaptar-se progressivamente ao ambiente monitorado.

## **2. FUNDAMENTAÇÃO TEÓRICA**

Para a construção do modelo preditivo, foram avaliados diversos algoritmos de regressão para garantir uma ampla exploração do espaço de soluções. Foram selecionados modelos que representam diferentes abordagens, desde a Regressão Linear clássica até ensembles avançados como Random Forest, XGBoost, LightGBM, CatBoost e Redes Neurais. Após a análise teórica e a fase de experimentação prática, a escolha do modelo foi consolidada. Dentre os algoritmos de alta performance, o CatBoost destacou-se como o modelo com o melhor equilíbrio entre precisão, robustez e custo computacional. Na fase de experimentação, ele apresentou o menor Erro Quadrático Médio (MSE) e o maior Coeficiente de Determinação ( $R^2$ ), justificando sua escolha como o modelo final a ser implementado no sistema (Bispo Junior, et. al. 2025).

## **3. METODOLOGIA**

A metodologia adotada para o desenvolvimento e avaliação do sistema foi estruturada em quatro frentes principais: definição do ambiente de desenvolvimento, geração e preparação de dados e experimentação do modelo de inteligência artificial e implementação da infraestrutura do sistema baseada em microsserviços. Essa abordagem visou garantir robustez, escalabilidade e confiabilidade no monitoramento e na tomada de decisão para irrigação em regiões semiáridas.

O desenvolvimento foi realizado em um ambiente com processador Intel Core i5 de 12ª Geração, 32 GB de RAM e GPU NVIDIA GeForce GTX 3050, utilizando Python com bibliotecas como Pandas, Scikit-learn e Matplotlib.

Para o treinamento, foi gerado um dataset sintético de 30.000 registros, simulando cenários agronômicos e climáticos diversos, com base em dados da Embrapa (2020). As variáveis de entrada (12 no total) incluíram parâmetros de Clima/Ambiente (Umidade do Solo/Ar, Temperatura, Luminosidade), Chuva e Previsão (Previsão de Chuva, Chuva 24h/72h), Variáveis Temporais (Hora, Dia do Ano, Estação) e Cultura e Fases (Tipo de Cultura, Fase da Planta).

A preparação dos dados envolveu a limpeza e a transformação de variáveis categóricas (Estação, Cultura, Fase) em formato numérico através da técnica de One-Hot Encoding, utilizando a biblioteca Pandas.

Para a validação, o dataset foi particionado em 80% para treinamento e 20% para teste, garantindo uma avaliação realista da performance do modelo. A comparação entre os algoritmos utilizou as métricas Erro Quadrático Médio (RMSE), Erro Absoluto Médio (MAE) e Coeficiente de Determinação ( $R^2$ ).

## Capacidades do Sistema: O Assistente de Agronomia Digital

Com o modelo de IA integrado, o sistema é capaz de executar três funções de alto nível:

- **Calcular a Irrigação com Precisão:** Recebe 12 tipos de dados e a IA calcula os minutos exatos para a irrigação.
- **Avisar a Hora Certa da Colheita:** Uma rotina diária verifica a idade dos plantios e envia um alerta de "Colheita Pronta!", finalizando o ciclo.
- **Atuar como Consultor de Plantio:** Ao registrar um novo plantio, o sistema cruza as coordenadas geográficas com a época de plantio recomendada e envia sugestões ao agricultor.

## A arquitetura Central: Um Ecossistema de Microserviços

No contexto do projeto, é fundamental compreender que a inteligência artificial (IA) constitui apenas um componente do sistema, não o todo. O arquivo `server.js` atua como controlador principal, gerenciando o fluxo operacional e concentrando a lógica de negócios.

A base do projeto adota uma **arquitetura de microserviços containerizada com Docker**, garantindo isolamento, escalabilidade e portabilidade entre ambientes de desenvolvimento e produção.

**Backend (Node.js/Express):** funciona como ponto de entrada principal. Trata-se de uma API leve e eficiente cuja responsabilidade é autenticar requisições, validar dados e publicá-los em uma fila de mensagens.

**Worker (Node.js):** representa o núcleo operacional do sistema. Ele monitora a fila de mensagens e executa tarefas intensivas em segundo plano, incluindo consultas a serviços externos de clima, interação com a API da Ceres e armazenamento de dados de treinamento no banco de dados.

**API da Ceres (Python/FastAPI):** é o serviço dedicado de Machine Learning. Este componente carrega modelos treinados e expõe um único endpoint /predict, fornecendo previsões precisas de irrigação em tempo real.

**Banco de Dados (PostgreSQL):** armazena todos os dados persistentes do sistema, incluindo leituras de sensores, configurações de dispositivos, versões de modelos e dados para re-treinamento, assegurando integridade e consistência.

**Fila de Mensagens (Redis):** atua como sistema nervoso central da aplicação. O padrão **Publicar/Subscrever** (Pub/Sub) desacopla a API do Worker, permitindo que o sistema continue recebendo dados mesmo quando o processamento está lento ou em manutenção.

**Serviço de Alertas (Node.js):** serviço independente encarregado de enviar notificações (ex.: via Telegram) quando certas condições são atendidas, promovendo automação e monitoramento em tempo real.

## **Arquitetura do Sistema Ceres: Segurança, Resiliência e IA Evolutiva**

O sistema Ceres foi projetado sobre três pilares fundamentais: segurança em camadas para comunicação de dispositivos, alta resiliência para garantir a integridade dos dados e um ciclo de aprendizado contínuo que permite a evolução da sua inteligência artificial.

### **Segurança em Camadas: Autenticação de Dispositivos com JWT**

A segurança do sistema é garantida por um fluxo de autenticação baseado em JSON Web Tokens (JWT), assegurando que apenas sensores autorizados interajam com a API. Ao ser iniciado, cada dispositivo se registra em um endpoint público (/api/register) e recebe um JWT único, assinado e com tempo de expiração predefinido (ex: 30 dias). Este token funciona como uma credencial para todas as requisições futuras. O firmware é projetado para, em caso de expiração do token (erro 401 Unauthorized), descartar o token antigo e iniciar um novo ciclo de registro automaticamente, garantindo a operação contínua e segura. Em ambiente de produção, o segredo do JWT é protegido via Docker Secrets, eliminando a exposição em arquivos ou variáveis de ambiente e reforçando a segurança do ecossistema.

### **Resiliência e Performance: Redis e Operação em Modo Offline**

Para assegurar a confiabilidade e o desempenho, o sistema adota duas estratégias complementares. No backend, o Redis atua como uma fila de mensagens, permitindo que a API principal enfileire um grande volume de requisições e responda aos sensores em milissegundos (202 Accepted), tornando a aplicação resiliente a picos de carga. No sensor (ESP8266), um modo offline é ativado diante de falhas de conexão. As leituras são armazenadas em um log na memória flash local (SPIFFS) e, assim que a rede é restabelecida, um processo de sincronização envia os dados acumulados, garantindo que nenhuma informação seja perdida.

### Ciclo de Aprendizagem Contínua: O Treinamento da IA

A principal característica do Ceres é sua capacidade de aprendizado contínuo, transformando-o de um modelo estático em um sistema vivo e adaptativo. O ciclo funciona da seguinte forma:

1. **Coleta de Dados:** O serviço `worker.js` salva cada decisão de irrigação e seu contexto ambiental correspondente em uma tabela de treinamento no PostgreSQL.
2. **Retreinamento Automatizado:** Periodicamente, um serviço dedicado em Python (`ceres_trainer`), isolado em um container Docker, coleta o novo conjunto de dados e o envia para um job de treinamento na plataforma Huawei ModelArts.
3. **Versionamento e Ativação:** Após o treinamento, o novo modelo (.pkl) é baixado, versionado e registrado no banco de dados. A ativação em produção ocorre de forma dinâmica através de uma rota segura na API (POST `/api/ceres/versions/:id/activate`), que instrui o serviço `api_ia` a carregar a nova versão ativa.

Este ciclo garante que o sistema se aprimore constantemente, tornando-se cada vez mais eficiente e adaptado às particularidades do seu ambiente.

## 4. RESULTADOS E DISCUSSÃO

A avaliação dos modelos foi conduzida em ambiente controlado, com todos os algoritmos treinados sob o mesmo conjunto de dados. A análise revelou uma superioridade dos algoritmos baseados em árvores de decisão (CatBoost, XGBoost, LightGBM e Random Forest) em comparação com a Regressão Linear e a Rede Neural (MLP), o que é corroborado pela literatura para dados tabulares.

**Tabela 1 - Desempenho dos Modelos de Regressão**

Modelo	Erro Médio Quadrático (MSE)	Coefficiente de Determinação (R <sup>2</sup> )
--------	-----------------------------	--

CatBoost	0.4006	0.9363
XGBoost	0.4366	0.9306
LightGBM	0.4408	0.9299
RandomForestRegressor	0.4978	0.9208
Linear	0.4978	0.9208
MLP	0.5705	0.9093

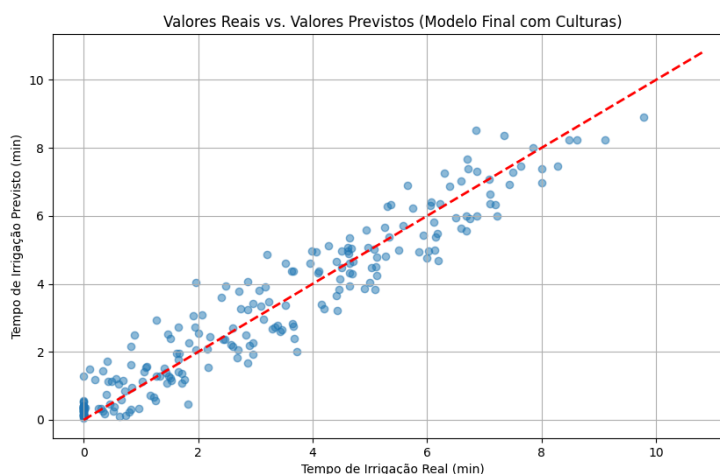
Fonte: Elaboração Própria, 2025.

O modelo **CatBoost** se destacou como o mais preciso. Após validação com o conjunto de teste, a performance final do modelo foi:

- **Erro Médio Quadrático (MSE):** 0,4978, indicando que a média das diferenças quadráticas entre os valores previstos e os reais é muito pequena.
- **Raiz do Erro Médio Quadrático (RMSE):** 0,71, o que equivale a um erro médio de apenas 42 segundos, validando a alta precisão do modelo.
- **Coefficiente de Determinação (R<sup>2</sup>):** 0,9208, significando que o modelo explica 92,08% da variabilidade no tempo de irrigação, indicando um ajuste excelente.

A análise visual dos resultados, apresentada no gráfico de dispersão abaixo, corrobora as métricas. A forte correlação linear entre os valores reais (eixo X) e os previstos (eixo Y), com pontos concentrados ao longo da linha ideal, confirma visualmente a precisão e robustez do modelo.

**Gráfico 1: Dispersão - Valores Reais vs. Valores Previstos**



Fonte: Elaboração Própria, 2025.

Os resultados obtidos confirmam a eficácia do CatBoost para a otimização da irrigação. O sucesso do modelo pode ser atribuído à sua capacidade de lidar com relações não-lineares e interações complexas entre as 30 variáveis de entrada.

## 5. CONCLUSÕES

Sistemas automatizados de irrigação oferecem maior eficiência, mas seu custo limita a adoção por pequenos produtores. Este trabalho enfrentou o desafio da gestão hídrica na agricultura de sequeiro ao desenvolver um sistema de irrigação inteligente, de baixo custo e modular, utilizando IoT e IA. A metodologia culminou na implementação de um modelo preditivo baseado em CatBoost, que alcançou um coeficiente de determinação ( $R^2$ ) de 92,08% e um erro médio de apenas 42 segundos. Tais métricas validam o potencial da solução para gerar economia de água e aumentar a eficiência produtiva. Conclui-se que o projeto apresenta uma solução tecnológica viável, escalável e de baixo custo para a modernização da agricultura. Ele representa um passo concreto em direção a uma produção mais sustentável e resiliente, com potencial para empoderar pequenos e médios produtores. Como trabalhos futuros, o projeto ("Horta Inteligente v2.0") focará em expandir os "sentidos" do sistema, com a geração de relatórios de safra, integração de sensores avançados (Condutividade Elétrica e pH) e uso de visão computacional para detectar estresse na planta e pragas.

## 6. REFERÊNCIAS

Agência Nacional de Águas e Saneamento Básico-ANA/ Instituto Brasileiro de Geografia e Estatística IBGE. 2025. Disponível em: <https://www.gov.br/ana/pt-br/assuntos/noticias-e-eventos/noticias/ana-e-ibge-lancam-levantamento-sobre-uso-da-agua-na-agricultura-de-sequeiro-no-brasil-1>. Acesso em: 30 ago. 2025.

BISPO JÚNIOR, I.S.; SILVA, D.E.P.A.; OLIVEIRA, H.R.; SANTANA, D.F.; COSTA, D.A.; SILVA, F.P. **Desenvolvimento de um Sistema de Irrigação Autônomo e Modular com uso de Inteligência Artificial e ESP8266**. 2025. Disponível em: <https://erbase.sbc.org.br/2025/templates/pesqbase.html>. Acesso em: 30 ago. 2025.

EMBRAPA. *Água na agricultura – sobre o tema*. Empresa Brasileira de Pesquisa Agropecuária, 2024. Disponível em: <https://www.embrapa.br/agua-na-agricultura/sobre-o-tema>. Acesso em: 30 ago. 2025.

\_\_\_\_\_. *Catálogo de Hortaliças*, 2020. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/887213/1/Catalogohortalias.pdf>. Acesso em: 30 ago. 2025.

GLOBO ECOLOGIA. *Agricultura é responsável por 70% do desperdício de água tratada no país*. Rede Globo, 2013. Disponível em: <https://redeglobo.globo.com/globoecologia/noticia/2013/09/agricultura-e-responsavel-por-70-do-desperdicio-de-agua-tratada-no-pais.html>. Acesso em: 30 ago. 2025.

Instituto Nacional do Semiárido - INSA. *Semiárido brasileiro*, 2025. Disponível em: <https://www.gov.br/insa/pt-br/semiariado-brasileiro>. Acesso em: 30 ago. 2025. BISPO JÚNIOR, I.S.; BISPO JÚNIOR, I.S.;

NEOWATER. *Perdas de água 2024*. Neowater, 2024. Disponível em: <https://www.neowater.com.br/post/perdas-de-agua-2024>. Acesso em: 30 ago. 2025.

TRATA BRASIL. *Perdas de água 2022*. Instituto Trata Brasil, 2022. Disponível em: <https://tratabrasil.org.br/perdas-de-agua-2022/>. Acesso em: 30 ago. 2025.