

Arthur Costa Bittar

Previsão de Irrigação com Machine Learning na Agricultura de Precisão

Uberlândia, MG

2026

Arthur Costa Bittar

Previsão de Irrigação com Machine Learning na Agricultura de Precisão

Trabalho de Conclusão de Curso da Engenharia de Controle e Automação da Universidade Federal de Uberlândia - UFU - Campus Santa Mônica, como requisito para a obtenção do título de Graduação em Engenharia de Controle e Automação.

Universidade Federal de Uberlândia - UFU
Faculdade de Engenharia Elétrica - FEELT

Orientador Prof. Dr. Josué Silva de Moraes

Uberlândia, MG

2026

Agradecimentos

Agradeço, primeiramente, a Deus, por me conceder força, sabedoria e perseverança ao longo de toda esta caminhada. Foi por meio da fé que encontrei tranquilidade nos momentos de incerteza e coragem para continuar diante das dificuldades, até a conclusão desta etapa tão importante da minha vida.

À minha mãe, Márcia, deixo minha mais profunda gratidão por todo o amor, cuidado e incentivo que sempre me ofereceu. Sua presença constante, sua preocupação e sua confiança em mim foram fundamentais para que eu permanecesse firme, mesmo nos períodos mais cansativos e desafiadores. Agradeço por cada gesto de carinho, por cada palavra de apoio e por sempre acreditar que eu seria capaz de chegar até aqui.

Ao meu pai, Rafael, agradeço pelos ensinamentos, pelos valores transmitidos e pelo exemplo que representa em minha vida. Sua dedicação, responsabilidade e a maneira leve de levar a vida contribuíram diretamente para minha formação pessoal e profissional. Levarei comigo tudo o que aprendi ao seu lado, especialmente a importância do esforço, da honestidade e da persistência.

Ao meu irmão, Murilo, agradeço por todo o apoio, pela amizade e pela parceria que sempre tivemos. Dividir um apartamento e a rotina diária tornou nossa relação ainda mais próxima, fazendo com que ele fosse, além de irmão, meu companheiro nos desafios e nas experiências dessa etapa. Sou grato pelas conversas, pelos momentos de descontração, pela ajuda nos dias mais difíceis e por tornar nossa convivência mais leve e especial.

À minha namorada, Paula, agradeço por estar ao meu lado, principalmente nos momentos em que o cansaço, a ansiedade e as dificuldades pareciam maiores. Sua paciência, seu carinho e suas palavras de incentivo foram essenciais para que eu recuperasse a confiança e continuasse seguindo em frente. Obrigado por me ouvir, por compreender minhas ausências e por sempre me lembrar da importância de acreditar em mim mesmo.

À minha cachorrinha, Amora, que partiu há alguns anos, deixo também uma lembrança especial. Durante o tempo em que esteve comigo, foi uma fonte constante de carinho, companhia e alegria. Mesmo após sua partida, continuo sentindo que sua presença me acompanha e que, de alguma forma, ela se tornou meu anjo da guarda. Sua memória permanece viva em meu coração e faz parte desta conquista.

Aos meus amigos que conheci na faculdade, Gabriel, Bruno e Lucas, agradeço pela companhia, pelas conversas e pelos momentos de descontração que trouxeram leveza a essa trajetória. Cada memória construída durante a graduação, contribuiu de alguma forma para tornar esse caminho mais significativo e feliz.

Aos professores, manifesto minha gratidão pelos conhecimentos compartilhados, pela dedicação ao ensino e pela contribuição para minha formação acadêmica e profissional. Cada disciplina, orientação e conselho deixou aprendizados que ultrapassam os limites da universidade e que levarei comigo ao longo de minha carreira.

Por fim, agradeço a todos que, direta ou indiretamente, contribuíram para que esta etapa fosse concluída. Cada palavra de incentivo, gesto de apoio e demonstração de confiança teve importância ao longo dessa caminhada.

Resumo

A disponibilidade de água no solo exerce influência direta sobre o desenvolvimento das culturas agrícolas, tornando o monitoramento da umidade uma atividade importante para o planejamento da irrigação. Entretanto, decisões baseadas apenas em observações pontuais podem não representar adequadamente a evolução das condições hídricas do solo. Nesse contexto, este trabalho apresenta o desenvolvimento de um sistema para monitoramento e previsão da umidade do solo, voltado ao apoio à tomada de decisão na irrigação de cafezais.

O sistema integra um protótipo de aquisição de dados baseado em Arduino, um sensor de umidade do solo e uma aplicação desenvolvida em Python para o armazenamento e o processamento das medições. A partir do histórico coletado, são aplicados os algoritmos de aprendizado de máquina Random Forest Regressor e Gradient Boosting Regressor, com o objetivo de estimar o comportamento futuro da umidade. Informações meteorológicas também são incorporadas ao sistema como apoio complementar à decisão, permitindo considerar a possibilidade de precipitação antes da recomendação de irrigação.

Além da previsão, foi desenvolvida uma lógica de controle capaz de relacionar as condições atuais e futuras do solo às ações de irrigar, aguardar ou continuar o monitoramento. Dessa forma, o trabalho propõe a integração entre sensoriamento, análise de dados, aprendizado de máquina e informações meteorológicas em uma ferramenta de apoio ao manejo hídrico. A proposta busca contribuir para decisões de irrigação mais planejadas, auxiliando no uso racional da água e demonstrando o potencial de tecnologias acessíveis na agricultura de precisão.

Palavras-chave: agricultura de precisão; irrigação; aprendizado de máquina; umidade do solo; previsão; cafeicultura.

Abstract

Soil water availability directly influences crop development, making moisture monitoring an important activity for irrigation planning. However, decisions based solely on isolated observations may not adequately represent the evolution of soil water conditions. In this context, this study presents the development of a system for monitoring and forecasting soil moisture, aimed at supporting irrigation decision-making in coffee plantations.

The system integrates an Arduino-based data acquisition prototype, a soil moisture sensor, and a Python application for storing and processing measurements. Based on the collected historical data, the Random Forest Regressor and Gradient Boosting Regressor machine learning algorithms are applied to estimate the future behavior of soil moisture. Meteorological information is also incorporated into the system as complementary decision support, allowing the possibility of rainfall to be considered before an irrigation recommendation is made.

In addition to forecasting, a control logic was developed to relate current and future soil conditions to the actions of irrigating, waiting, or continuing the monitoring process. Therefore, this work proposes the integration of sensing, data analysis, machine learning, and meteorological information into a decision-support tool for water management. The proposed approach seeks to contribute to more planned irrigation decisions, support the rational use of water, and demonstrate the potential of accessible technologies in precision agriculture.

Key-words: precision agriculture; irrigation; machine learning; soil moisture; forecasting; coffee production.

Lista de ilustrações

Figura 1 – Fluxo metodológico do sistema de monitoramento, previsão e apoio à irrigação.	25
Figura 2 – Comportamento temporal da unidade volumétrica e eventos de irrigação.	37
Figura 3 – Comparação entre a unidade observada e a unidade prevista pelo modelo selecionado.	41
Figura 4 – Painel de acompanhamento desenvolvido em Streamlit.	43

Lista de tabelas

Tabela 1	–	Hiperparâmetros utilizados nos modelos.	32
Tabela 2	–	Caracterização da base experimental.	36
Tabela 3	–	Eventos de acionamento da irrigação.	37
Tabela 4	–	Desempenho dos modelos no conjunto de teste.	40

Lista de abreviaturas e siglas

ADC	<i>Analog-to-Digital Converter</i> – Conversor Analógico-Digital
CS12	Designação do modelo do sensor de umidade do solo utilizado
CSV	<i>Comma-Separated Values</i> – Valores Separados por Vírgulas
FAO	<i>Food and Agriculture Organization of the United Nations</i> – Organização das Nações Unidas para a Alimentação e a Agricultura
JSON	<i>JavaScript Object Notation</i> – Notação de Objetos JavaScript
MAE	<i>Mean Absolute Error</i> – Erro Absoluto Médio
RMSE	<i>Root Mean Squared Error</i> – Raiz do Erro Quadrático Médio
UNESCO	<i>United Nations Educational, Scientific and Cultural Organization</i> – Organização das Nações Unidas para a Educação, a Ciência e a Cultura
VWC	<i>Volumetric Water Content</i> – Conteúdo Volumétrico de Água

Lista de símbolos

ADC_{lido}	Leitura instantânea fornecida pelo conversor analógico-digital
ADC_{saturado}	Leitura de referência do sensor na condição de solo saturado
ADC_{seco}	Leitura de referência do sensor na condição de solo seco
ET_0	Evapotranspiração de referência
ET_c	Evapotranspiração da cultura
$f(\mathbf{x})$	Função de previsão ajustada pelo modelo de aprendizado de máquina
$F_m(\mathbf{x})$	Modelo de Gradient Boosting após a adição da etapa m
$h_m(\mathbf{x})$	Árvore de decisão adicionada na etapa m do Gradient Boosting
i	Índice de uma observação no conjunto de dados
K_c	Coefficiente de cultura, adimensional
m	Índice da etapa de construção do modelo Gradient Boosting
n	Número total de observações utilizadas no cálculo de uma métrica
R^2	Coefficiente de determinação, adimensional
t	Índice associado ao instante de uma medição
U_{norm}	Umidade normalizada entre as condições seca e saturada, adimensional
$\mathbf{x}$	Vetor de variáveis de entrada do modelo de aprendizado de máquina
y	Valor observado da variável-alvo
y_i	Valor observado da variável-alvo na observação i
$\hat{y}$	Valor previsto pelo modelo de aprendizado de máquina
$\hat{y}_i$	Valor previsto pelo modelo para a observação i
$\bar{y}$	Média dos valores observados da variável-alvo
y_t	Variável-alvo associada ao instante t
η	Taxa de aprendizado do modelo Gradient Boosting

ϕ	Porosidade de referência do solo (m^3/m^3)
θ_v	Umidade volumétrica do solo (m^3/m^3)
$\theta_{\min}$	Limite inferior de umidade volumétrica para acionamento da irrigação (m^3/m^3)
$\theta_{\max}$	Limite superior de umidade volumétrica para desligamento da irrigação (m^3/m^3)
θ_{filtrada}	Umidade volumétrica obtida após a aplicação da média móvel (m^3/m^3)
θ_{t+48}	Umidade volumétrica observada 48 registros após o instante t (m^3/m^3)

Sumário

1	INTRODUÇÃO	13
1.1	Justificativa	14
1.2	Objetivos	15
1.2.1	Objetivo geral	15
1.2.2	Objetivos específicos	15
2	REFERENCIAIS TEÓRICOS	17
2.1	Importância da irrigação e monitoramento da umidade do solo	17
2.2	Sensoriamento da umidade do solo	18
2.3	Aquisição de dados com sistemas embarcados	19
2.4	Aprendizado de máquina aplicado à previsão da umidade do solo	19
2.4.1	Treinamento, teste e generalização	20
2.4.2	Variáveis temporais	20
2.4.3	Random Forest Regressor	21
2.4.4	Gradient Boosting Regressor	21
2.4.5	Avaliação de modelos de regressão	22
2.5	Informações meteorológicas no apoio à decisão	23
2.6	Supervisão e visualização dos dados	24
3	METODOLOGIA	25
3.1	Escopo do estudo	25
3.2	Desenvolvimento do protótipo	26
3.3	Conversão da leitura analógica	26
3.4	Filtragem e controle local da irrigação	27
3.5	Aquisição e armazenamento das medições	28
3.6	Obtenção das informações meteorológicas	29
3.7	Preparação da base de dados	29
3.8	Construção das variáveis de entrada	30
3.9	Definição da variável-alvo	31
3.10	Treinamento dos modelos	31
3.11	Divisão temporal e avaliação	31
3.12	Lógica preditiva de apoio à decisão	32
3.13	Supervisão e visualização	33
4	RESULTADOS E DISCUSSÕES	35
4.1	Validação funcional do sistema	35

4.2	Caracterização da base experimental	35
4.3	Comportamento temporal da umidade	36
4.4	Avaliação do controle da irrigação	37
4.5	Seleção dos modelos de aprendizado de máquina	38
4.5.1	Random Forest Regressor	38
4.5.2	Gradient Boosting Regressor	39
4.6	Desempenho preditivo dos modelos	40
4.7	Interpretação da previsão em 24 horas	41
4.8	Integração meteorológica e tomada de decisão	42
4.9	Visualização e acompanhamento	42
4.10	Potencial de aplicação e expansão	43
4.11	Limitações e possibilidades de melhoria	44
4.12	Síntese dos resultados	45
5	CONCLUSÃO	46
	REFERÊNCIAS BIBLIOGRÁFICAS	47

1 Introdução

O crescimento da produção agrícola precisa ocorrer de forma compatível com a disponibilidade dos recursos naturais, especialmente diante da variabilidade climática e da crescente demanda pelo uso da água. Em escala global, a agricultura representa aproximadamente 70% das retiradas de água doce, evidenciando a importância do desenvolvimento de estratégias que contribuam para um manejo hídrico mais eficiente (UNESCO, 2024). No Brasil, a área equipada para irrigação tem apresentado expansão contínua e ainda possui elevado potencial de crescimento, tornando o planejamento do uso da água um fator relevante para a produtividade e para a sustentabilidade do setor agrícola (Agência Nacional de Águas e Saneamento Básico, 2017). Nesse contexto, iniciativas de monitoramento e mapeamento da agricultura irrigada auxiliam na compreensão da distribuição espacial e temporal da irrigação no país, contribuindo para o planejamento e para a adoção de tecnologias mais eficientes (MapBiomas Brasil, 2024).

O manejo da irrigação está diretamente relacionado ao conhecimento das condições hídricas do solo e da demanda atmosférica. Métodos tradicionais utilizam parâmetros como a evapotranspiração de referência, os coeficientes de cultura e o balanço hídrico para estimar a necessidade de água das culturas Allen et al. (1998). Embora esses métodos constituam referências importantes para o planejamento agrícola, as condições locais do solo, as variações meteorológicas e as particularidades de cada área podem dificultar a definição do momento adequado para irrigar. Dessa forma, o uso de sensores de umidade permite acompanhar diretamente a condição hídrica do solo e fornecer informações mais próximas da realidade da área monitorada.

A obtenção contínua de dados também possibilita a aplicação de técnicas de aprendizado de máquina para identificar padrões e estimar o comportamento futuro da umidade. Diferentemente de métodos baseados exclusivamente em valores instantâneos, os modelos preditivos podem considerar o histórico das medições, as tendências de secagem do solo e as condições meteorológicas observadas. Essa abordagem permite antecipar situações em que a umidade poderá alcançar níveis críticos, oferecendo maior suporte ao planejamento da irrigação.

Entre os algoritmos aplicáveis a dados tabulares, destacam-se o *Random Forest Regressor* e o *Gradient Boosting Regressor*. O Random Forest utiliza um conjunto de árvores de decisão e combina suas previsões, apresentando capacidade de representar relações não lineares e relativa robustez diante de variações nos dados (BREIMAN, 2001). O Gradient Boosting, por sua vez, constrói modelos sequencialmente, de modo que cada nova árvore busque reduzir os erros produzidos pelas anteriores (FRIEDMAN, 2001). Essas

características tornam os dois algoritmos adequados para a comparação no problema de previsão da umidade do solo.

Neste trabalho, propõe-se o desenvolvimento de um sistema para monitoramento e previsão da umidade do solo, voltado ao apoio à tomada de decisão na irrigação de cafezais. O sistema integra um protótipo de aquisição de dados baseado em Arduino, um sensor de umidade do solo e uma aplicação desenvolvida em Python para o recebimento, o processamento e o armazenamento das medições. Os registros obtidos são organizados em uma série temporal e combinados com informações meteorológicas, possibilitando a aplicação dos modelos de aprendizado de máquina.

A previsão meteorológica é empregada como uma camada complementar à previsão da umidade. Assim, após a estimativa realizada pelo modelo, o sistema considera a possibilidade de precipitação para definir se a irrigação deve ser recomendada, adiada ou se o monitoramento deve continuar. Essa separação busca manter o processo decisório compreensível, permitindo identificar tanto a contribuição do modelo preditivo quanto a influência das condições meteorológicas.

O desempenho dos modelos é analisado por meio de métricas de regressão que avaliam a diferença entre os valores previstos e observados, bem como a capacidade dos algoritmos de representar a variabilidade dos dados. Além da avaliação preditiva, o trabalho analisa o funcionamento integrado do protótipo, o armazenamento das medições e a lógica utilizada para apoiar a decisão de irrigação. Dessa forma, busca-se demonstrar a viabilidade da integração entre sensoramento, programação, aprendizado de máquina e informações meteorológicas em uma solução acessível para a agricultura de precisão.

1.1 Justificativa

A relevância deste trabalho está relacionada à necessidade de melhorar o uso da água na agricultura e de tornar as decisões de irrigação mais fundamentadas em informações do próprio ambiente monitorado. A participação expressiva da agricultura no consumo de água doce e o crescimento da área irrigada no Brasil reforçam a importância da adoção de tecnologias capazes de apoiar um manejo mais eficiente (UNESCO, 2024; Agência Nacional de Águas e Saneamento Básico, 2017).

Decisões baseadas apenas em calendários fixos ou em observações isoladas podem não acompanhar adequadamente as mudanças na umidade do solo. A utilização de sensores permite registrar continuamente essas variações, enquanto os modelos de aprendizado de máquina possibilitam analisar o histórico das medições e prever tendências futuras. Dessa forma, o sistema pode antecipar a aproximação de uma condição crítica, em vez de atuar somente após o limite de umidade ser atingido.

A incorporação da previsão meteorológica também é relevante, pois uma recomendação de irrigação pode ser revista diante da possibilidade de precipitação. Essa abordagem pode evitar acionamentos desnecessários e tornar a decisão mais coerente com as condições esperadas para o período seguinte. Ao mesmo tempo, a utilização da previsão meteorológica em uma camada externa mantém a lógica de decisão transparente e facilita a interpretação dos resultados.

Outro aspecto que justifica o desenvolvimento da proposta é a utilização de tecnologias acessíveis, como Arduino, sensores de umidade e ferramentas de programação de código aberto. A combinação desses recursos permite desenvolver um sistema de menor complexidade, com possibilidade de adaptação e expansão. Portanto, o trabalho contribui para a investigação do uso de sensoriamento, análise de dados e aprendizado de máquina como ferramentas de apoio ao manejo hídrico na agricultura de precisão.

1.2 Objetivos

1.2.1 Objetivo geral

Desenvolver e avaliar um sistema para monitoramento, previsão e visualização da umidade do solo, integrando dados obtidos por sensor, modelos de aprendizado de máquina e informações meteorológicas como apoio à tomada de decisão na irrigação de cafezais.

1.2.2 Objetivos específicos

- Desenvolver um protótipo de aquisição de dados utilizando Arduino e sensor de umidade do solo;
- Implementar uma aplicação em Python para receber, processar e armazenar as medições em uma base de dados temporal;
- Integrar as medições de umidade do solo com informações meteorológicas observadas e previstas;
- Preparar e organizar as variáveis utilizadas no treinamento dos modelos de aprendizado de máquina;
- Treinar e comparar os algoritmos Random Forest Regressor e Gradient Boosting Regressor para a previsão da umidade futura do solo;
- Avaliar o desempenho dos modelos por meio das métricas erro absoluto médio, raiz do erro quadrático médio e coeficiente de determinação;
- Desenvolver uma lógica de apoio à decisão que considere a umidade atual, a umidade prevista e a possibilidade de precipitação;

- Desenvolver um painel interativo em Streamlit para a visualização das medições, das previsões, das informações meteorológicas e das recomendações de irrigação.

2 Referenciais Teóricos

2.1 Importância da irrigação e monitoramento da umidade do solo

A disponibilidade de água no solo exerce influência direta sobre o desenvolvimento das culturas agrícolas. Tanto a deficiência quanto o excesso de água podem comprometer o crescimento das plantas, a absorção de nutrientes e a produtividade. Nesse contexto, a irrigação constitui uma ferramenta importante para complementar a precipitação e reduzir os efeitos da variabilidade climática.

Em escala global, a agricultura representa a maior parcela das retiradas de água doce, o que reforça a necessidade de práticas que promovam maior eficiência no uso dos recursos hídricos (UNESCO, 2024). No Brasil, a área equipada para irrigação tem apresentado crescimento, tornando o planejamento do uso da água um fator relevante para a produtividade e para a sustentabilidade da atividade agrícola (Agência Nacional de Águas e Saneamento Básico, 2017). O mapeamento das áreas irrigadas também contribui para a compreensão da evolução dessa atividade e para o direcionamento de tecnologias de manejo mais precisas (MapBiomas Brasil, 2024).

O manejo hídrico tradicional pode utilizar a evapotranspiração de referência (ET_0) e o coeficiente de cultura (K_c) para estimar a evapotranspiração da cultura, conforme apresentado na Equação 2.1:

$$ET_c = K_c \cdot ET_0, \quad (2.1)$$

em que ET_c representa a evapotranspiração da cultura Allen et al. (1998). Esses parâmetros permitem estimar a demanda hídrica atmosférica e realizar o balanço de água no solo. Entretanto, a estimativa indireta pode ser complementada por medições locais, possibilitando acompanhar as condições efetivamente observadas na região monitorada.

A umidade volumétrica do solo, normalmente representada por θ_v , expressa a relação entre o volume de água e o volume total de solo. Sua unidade pode ser representada por m^3/m^3 . O monitoramento dessa grandeza permite identificar processos de secagem, aumento de umidade provocado por precipitação ou irrigação e aproximação de condições consideradas críticas para a cultura (HILLEL, 2004).

Uma estratégia comum de controle consiste na definição de uma faixa operacional delimitada por um limite inferior, $\theta_{\min}$, e um limite superior, $\theta_{\max}$. Quando a umidade se

aproxima do limite inferior, a irrigação pode ser iniciada. O desligamento ocorre somente após a umidade alcançar o limite superior.

Essa diferença entre os limites é denominada histerese e contribui para evitar acionamentos e desligamentos sucessivos provocados por pequenas oscilações da medição. A lógica geral pode ser representada por:

$$\begin{cases} \theta_v \leq \theta_{\min} & \Rightarrow \text{acionar a irrigação,} \\ \theta_v \geq \theta_{\max} & \Rightarrow \text{interromper a irrigação.} \end{cases} \quad (2.2)$$

Os valores específicos dos limites dependem das características do solo, da cultura, da profundidade monitorada e dos critérios adotados no sistema. Por essa razão, sua definição e aplicação são apresentadas posteriormente na metodologia do trabalho.

2.2 Sensoriamento da umidade do solo

Sensores de umidade do solo permitem transformar alterações relacionadas à presença de água em sinais elétricos que podem ser medidos por um sistema eletrônico. Dependendo do princípio de funcionamento, esses sensores podem responder a mudanças na resistência, na capacitância ou em outras propriedades elétricas do meio.

A utilização de sensores de baixo custo facilita o desenvolvimento de protótipos para monitoramento agrícola. Entretanto, a leitura elétrica fornecida pelo sensor não corresponde diretamente à umidade volumétrica. Para que o valor adquirido seja interpretado, torna-se necessário estabelecer uma relação entre a saída do sensor e condições conhecidas de umidade.

Uma forma simplificada de calibração consiste em utilizar uma leitura de referência para a condição seca, ADC_{seco} , e outra para a condição saturada, ADC_{saturado} . Quando a resposta do sensor diminui à medida que a umidade aumenta, uma medida normalizada pode ser calculada por:

$$U_{\text{norm}} = \frac{ADC_{\text{seco}} - ADC_{\text{lido}}}{ADC_{\text{seco}} - ADC_{\text{saturado}}}, \quad (2.3)$$

em que ADC_{lido} representa a leitura instantânea. O resultado deve ser limitado ao intervalo entre zero e um, evitando valores fora da faixa de calibração.

A conversão para umidade volumétrica pode ser realizada por uma função de calibração definida experimentalmente. Essa função pode ser linear ou não linear, dependendo do sensor e das características do solo. Dessa forma, os valores de calibração devem ser associados ao sensor e ao meio em que ele será utilizado, não sendo recomendada sua generalização para qualquer condição de campo.

Além da calibração, sensores de baixo custo podem apresentar oscilações provocadas por ruídos elétricos, contato com o solo e variações locais. Uma alternativa para reduzir a influência de uma leitura isolada é utilizar filtros simples, como a média móvel, calculada a partir de um conjunto recente de medições.

2.3 Aquisição de dados com sistemas embarcados

Sistemas embarcados são dispositivos eletrônicos programáveis desenvolvidos para executar tarefas específicas. Em aplicações de monitoramento, eles podem realizar a leitura de sensores, processar sinais e controlar atuadores.

O Arduino Uno é uma plataforma de prototipagem baseada em microcontrolador, capaz de receber sinais analógicos e convertê-los em valores digitais. Seu conversor analógico-digital apresenta resolução de 10 bits, resultando em valores inteiros entre 0 e 1023 ([Arduino](#),). Essa característica permite que a variação da saída elétrica de um sensor seja representada numericamente e posteriormente processada.

A comunicação serial permite transmitir as leituras do microcontrolador para um computador. Nesse tipo de arquitetura, o sistema embarcado fica responsável pela aquisição do sinal e pelo controle básico dos componentes físicos, enquanto uma aplicação externa pode realizar tarefas que exigem maior capacidade de armazenamento e processamento.

O fluxo geral de aquisição pode ser representado por:

sensor $\longrightarrow$ microcontrolador $\longrightarrow$ comunicação serial $\longrightarrow$ aplicação computacional. (2.4)

No computador, as medições podem ser associadas a um carimbo de data e hora e armazenadas em arquivos tabulares, como o formato CSV. Esse formato apresenta estrutura simples e pode ser utilizado por diferentes ferramentas de análise de dados e aprendizado de máquina.

A separação entre aquisição física e processamento computacional também favorece a manutenção do sistema. Alterações nos modelos preditivos, nas regras de decisão ou na visualização podem ser realizadas no software sem a necessidade de modificar todo o circuito de aquisição.

2.4 Aprendizado de máquina aplicado à previsão da umidade do solo

O aprendizado de máquina compreende métodos computacionais capazes de identificar relações a partir de dados e utilizar essas relações para realizar previsões em novas

observações (MITCHELL, 1997). Em um problema supervisionado, cada exemplo do conjunto de treinamento contém variáveis de entrada e uma resposta-alvo conhecida.

No contexto deste trabalho, a resposta-alvo corresponde a um valor contínuo de umidade do solo em um instante futuro. Portanto, o problema é caracterizado como uma tarefa de regressão. As variáveis de entrada podem incluir as medições atuais, valores anteriores de umidade, médias móveis, taxas recentes de variação e informações meteorológicas observadas.

O objetivo do treinamento é encontrar uma função capaz de aproximar a relação entre as variáveis de entrada, $\mathbf{x}$, e o valor futuro da umidade, y , conforme:

$$\hat{y} = f(\mathbf{x}), \quad (2.5)$$

em que $\hat{y}$ representa a previsão produzida pelo modelo.

2.4.1 Treinamento, teste e generalização

Durante o treinamento, os parâmetros internos do modelo são ajustados para reduzir a diferença entre os valores previstos e observados. Entretanto, um bom desempenho nos dados de treinamento não garante que o modelo produza previsões adequadas para novas observações.

A capacidade de apresentar bom desempenho em dados não utilizados durante o treinamento é denominada generalização (BISHOP, 2006; HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Modelos excessivamente simples podem não representar relações importantes, situação associada ao subajuste. Em sentido oposto, modelos muito complexos podem memorizar características particulares da base de treinamento, apresentando sobreajuste.

Por essa razão, a base deve ser dividida em conjuntos distintos de treinamento e teste. No caso de séries temporais, essa separação deve respeitar a ordem cronológica, utilizando registros mais antigos para treinamento e registros posteriores para avaliação. A divisão aleatória poderia utilizar informações futuras para prever períodos anteriores, produzindo uma estimativa inadequada da capacidade preditiva do modelo (HYNDMAN; ATHANASOPOULOS, 2018).

2.4.2 Variáveis temporais

A umidade do solo apresenta dependência temporal, pois seu valor atual está relacionado às condições anteriores. Para representar essa característica em modelos tabulares, podem ser criadas variáveis derivadas da própria série.

Entre as variáveis temporais utilizadas nesse tipo de problema destacam-se:

- valores defasados da umidade;
- médias móveis;
- valores mínimos e máximos em janelas recentes;
- diferenças entre medições consecutivas;
- taxas de aumento ou redução da umidade;
- hora do dia e período do ciclo diário;
- variáveis meteorológicas observadas.

Esses atributos permitem que algoritmos de regressão recebam informações sobre a evolução recente da série sem a necessidade de utilizar diretamente uma rede neural recorrente.

2.4.3 Random Forest Regressor

O Random Forest é um método de conjunto baseado em árvores de decisão (BREIMAN, 2001). Durante o treinamento, diferentes árvores são construídas a partir de amostras e subconjuntos das variáveis disponíveis. A previsão final de regressão é normalmente obtida pela média das previsões individuais.

O uso de várias árvores reduz a dependência de uma única estrutura e pode diminuir a variância do modelo. O algoritmo apresenta capacidade de representar relações não lineares e interações entre variáveis, sem exigir que essas relações sejam previamente definidas.

Entre suas características estão a relativa robustez diante de oscilações dos dados, a possibilidade de paralelização do treinamento e a obtenção de medidas de importância das variáveis. Em contrapartida, conjuntos com grande quantidade de árvores podem exigir maior armazenamento e tempo de execução.

Os principais hiperparâmetros incluem o número de árvores, a profundidade máxima, o número mínimo de amostras por folha e a quantidade de variáveis consideradas em cada divisão.

2.4.4 Gradient Boosting Regressor

O Gradient Boosting também utiliza árvores de decisão, porém sua construção ocorre de forma sequencial (FRIEDMAN, 2001). Cada nova árvore é ajustada para reduzir os erros produzidos pelo conjunto anterior, fazendo com que o modelo seja aprimorado progressivamente.

Esse processo pode ser representado de maneira simplificada por:

$$F_m(\mathbf{x}) = F_{m-1}(\mathbf{x}) + \eta h_m(\mathbf{x}), \quad (2.6)$$

em que F_m representa o modelo após a adição da árvore m , h_m representa a nova árvore e η corresponde à taxa de aprendizado.

A taxa de aprendizado controla o quanto cada nova árvore contribui para o modelo. Valores menores podem produzir um aprendizado mais gradual, geralmente associado à necessidade de uma quantidade maior de árvores.

O Gradient Boosting possui capacidade de representar relações complexas em dados tabulares e pode apresentar bom desempenho quando seus hiperparâmetros são adequadamente ajustados. Entretanto, por ser construído sequencialmente, pode ser mais sensível a ruídos e ao sobreajuste. Entre seus principais hiperparâmetros estão a quantidade de estimadores, a taxa de aprendizado, a profundidade das árvores e a função de perda.

2.4.5 Avaliação de modelos de regressão

A avaliação dos modelos deve considerar métricas capazes de representar diferentes aspectos do erro preditivo. Neste trabalho, são consideradas o erro absoluto médio, a raiz do erro quadrático médio e o coeficiente de determinação.

O erro absoluto médio, ou MAE, é calculado por:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (2.7)$$

em que y_i representa o valor observado, $\hat{y}_i$ o valor previsto e n a quantidade de observações. O MAE expressa a magnitude média dos erros e mantém a mesma unidade da variável prevista. Valores menores indicam previsões mais próximas dos valores observados.

A raiz do erro quadrático médio, ou RMSE, é dada por:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (2.8)$$

Como os erros são elevados ao quadrado, o RMSE atribui maior peso aos desvios de grande magnitude. Assim, essa métrica complementa o MAE ao evidenciar a presença de erros maiores.

O coeficiente de determinação, representado por R^2 , é calculado por:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (2.9)$$

em que $\bar{y}$ representa a média dos valores observados. O R^2 indica a proporção da variabilidade dos dados representada pelo modelo. Valores mais próximos de um indicam maior capacidade de acompanhar as variações da variável analisada. Valores próximos de zero indicam desempenho semelhante ao uso da média, enquanto valores negativos representam desempenho inferior a essa referência.

A análise conjunta das três métricas permite avaliar o erro médio, a ocorrência de desvios maiores e a capacidade do modelo de representar a variabilidade da umidade.

2.5 Informações meteorológicas no apoio à decisão

A dinâmica da umidade do solo está relacionada não apenas aos eventos de irrigação, mas também às condições atmosféricas. Temperatura do ar, umidade relativa, precipitação e evapotranspiração influenciam a entrada e a retirada de água do sistema solo-planta-atmosfera.

A precipitação representa uma entrada de água, enquanto a evapotranspiração está associada à perda de água pela evaporação do solo e pela transpiração das plantas. Temperaturas mais elevadas, baixa umidade relativa, radiação solar e vento podem aumentar a demanda atmosférica, embora seus efeitos dependam da interação entre diferentes variáveis ambientais [Allen et al. \(1998\)](#).

Informações meteorológicas observadas podem ser utilizadas para caracterizar as condições associadas às medições de umidade. Já as previsões meteorológicas podem apoiar a decisão sobre a necessidade de irrigação. Caso a umidade futura estimada se aproxime de um limite crítico, mas exista previsão de precipitação, o sistema pode recomendar uma nova avaliação antes do acionamento.

Neste trabalho, a previsão meteorológica é tratada como uma camada externa ao modelo principal de aprendizado de máquina. O modelo realiza a previsão da umidade a partir do histórico disponível, enquanto uma regra posterior combina essa estimativa com a possibilidade de chuva.

Essa separação apresenta duas vantagens. A primeira é manter clara a função de cada componente do sistema. A segunda é evitar que informações meteorológicas futuras indisponíveis no instante da previsão sejam utilizadas indevidamente durante o treinamento.

De forma geral, a camada decisória pode produzir três recomendações:

- irrigar, quando a condição crítica já foi atingida ou é prevista sem expectativa de precipitação;

- aguardar e reavaliar, quando existe possibilidade de chuva antes que a condição se torne crítica;
- continuar monitorando, quando a umidade permanece em condição adequada.

2.6 Supervisão e visualização dos dados

A visualização de dados tem como objetivo transformar registros numéricos em informações compreensíveis para o acompanhamento do sistema. Em aplicações de monitoramento da umidade, gráficos de séries temporais permitem observar tendências de secagem, aumentos provocados por chuva ou irrigação e aproximações dos limites operacionais.

Um painel pode reunir diferentes informações, como:

- valor atual da umidade;
- histórico das medições;
- limites de acionamento e desligamento;
- eventos de irrigação;
- dados meteorológicos;
- modelo utilizado na previsão;
- valor futuro estimado;
- recomendação produzida pelo sistema.

O Streamlit é uma biblioteca de código aberto que permite desenvolver aplicações web interativas utilizando Python ([Streamlit](#),). Sua utilização possibilita integrar tabelas, indicadores e gráficos ao mesmo ambiente empregado para o processamento dos dados.

A apresentação das medições em um painel não substitui a análise dos dados, mas facilita a interpretação do comportamento do sistema. Além disso, o registro das previsões e recomendações permite verificar posteriormente quais informações estavam disponíveis no momento de cada decisão.

Dessa forma, a visualização constitui a última camada do fluxo medir–processar–prever–decidir, reunindo os resultados produzidos pelos sensores, pelos modelos de aprendizado de máquina e pelas regras de apoio à irrigação.


3 Metodologia

A metodologia deste trabalho foi estruturada de forma sequencial, abrangendo o desenvolvimento do protótipo, a aquisição das medições, a organização da base de dados, o treinamento dos modelos de aprendizado de máquina e a elaboração da lógica de apoio à decisão de irrigação.

O sistema foi desenvolvido para monitorar a umidade do solo em uma área destinada ao cultivo de café. A arquitetura proposta integra um sensor de umidade do solo, um Arduino Uno, um circuito de acionamento da irrigação, uma aplicação desenvolvida em Python, informações meteorológicas e modelos de aprendizado de máquina.

A Figura 1 apresenta o fluxo geral adotado no desenvolvimento do sistema.

Figura 1 – Fluxo metodológico do sistema de monitoramento, previsão e apoio à irrigação.



Fonte: Autoria própria (2026).

3.1 Escopo do estudo

O estudo foi desenvolvido considerando um ponto de monitoramento da umidade do solo em uma área de cultivo de café. O solo foi considerado de textura média, e o sensor foi posicionado na camada definida para o experimento, buscando representar a região de interesse para o acompanhamento da disponibilidade hídrica.

A aquisição foi realizada em intervalos regulares de 30 minutos. Essa frequência foi escolhida por permitir o acompanhamento das mudanças graduais da umidade sem produzir uma quantidade excessiva de registros.

O desenvolvimento foi dividido em cinco etapas principais:

1. montagem e programação do protótipo eletrônico;
2. aquisição e armazenamento das medições;
3. obtenção e integração das informações meteorológicas;
4. preparação da base e treinamento dos modelos;
5. geração das previsões e recomendações de irrigação.

O trabalho foi direcionado à identificação do momento adequado para irrigar, não abrangendo o dimensionamento hidráulico completo do sistema nem o cálculo da lâmina de água aplicada.

3.2 Desenvolvimento do protótipo

O protótipo foi composto por um Arduino Uno, um sensor de umidade do solo CS12, um módulo relé e uma bomba de água de vazão fixa. O sensor foi conectado a uma entrada analógica do Arduino, enquanto o módulo relé foi empregado para controlar a alimentação da bomba.

O Arduino Uno foi responsável pela leitura do sinal analógico, pelo processamento inicial da medição, pela aplicação da lógica local de controle e pela transmissão das informações ao computador.

A saída analógica do sensor foi conectada ao pino A0, enquanto o módulo relé foi controlado pelo pino digital 7. A comunicação com o computador foi realizada por meio da interface serial, com taxa de transmissão de 9600 bits por segundo.

Para reduzir pequenas oscilações instantâneas, cada medição registrada pelo Arduino foi obtida pela média de 15 leituras consecutivas do conversor analógico-digital, realizadas com pequenos intervalos entre si.

3.3 Conversão da leitura analógica

O conversor analógico-digital do Arduino Uno apresenta resolução de 10 bits, produzindo valores inteiros entre 0 e 1023. Para a conversão das leituras do sensor, foram adotados os seguintes valores de referência:

$$ADC_{\text{seco}} = 800 \quad \text{e} \quad ADC_{\text{saturado}} = 300. \quad (3.1)$$

Como a leitura diminui com o aumento da umidade, a umidade relativa normalizada foi calculada por:

$$U_{\text{norm}} = \frac{ADC_{\text{seco}} - ADC_{\text{lido}}}{ADC_{\text{seco}} - ADC_{\text{saturado}}}, \quad (3.2)$$

em que ADC_{lido} representa o valor obtido pelo Arduino.

O resultado da Equação 3.2 foi limitado ao intervalo entre zero e um. Em seguida, a umidade volumétrica do solo foi estimada por:

$$\theta_v = U_{\text{norm}} \cdot \phi, \quad (3.3)$$

em que θ_v representa a umidade volumétrica e ϕ corresponde à porosidade de referência adotada no trabalho, igual a $0,472 \text{ m}^3/\text{m}^3$.

Dessa forma, as leituras foram representadas em m^3/m^3 , permitindo a comparação entre os registros obtidos ao longo do tempo.

3.4 Filtragem e controle local da irrigação

Além da média das leituras analógicas realizadas em cada medição, foi aplicada uma média móvel das três últimas estimativas de umidade. Como o intervalo de aquisição foi de 30 minutos, essa janela representou aproximadamente uma hora de monitoramento.

A média filtrada foi utilizada para reduzir o efeito de oscilações isoladas antes do acionamento da bomba. O controle foi implementado por meio de dois limites distintos:

$$\begin{cases} \theta_{\text{filtrada}} \leq 0,25 & \Rightarrow \text{ligar a bomba,} \\ \theta_v \geq 0,30 & \Rightarrow \text{desligar a bomba.} \end{cases} \quad (3.4)$$

A utilização de limites diferentes introduziu uma histerese no sistema, evitando acionamentos e desligamentos sucessivos próximos de um único valor.

Após o acionamento, a bomba permaneceu em funcionamento até que uma das seguintes condições fosse atendida:

- a umidade atingisse o limite superior estabelecido;
- o tempo máximo de funcionamento de 30 minutos fosse alcançado.

O limite temporal foi incluído como uma condição adicional de segurança, evitando que a bomba permanecesse ligada indefinidamente em caso de falha na leitura ou de resposta insuficiente da umidade.

3.5 Aquisição e armazenamento das medições

Após cada ciclo de aquisição, o Arduino transmitiu uma mensagem ao computador seguindo o formato:

```
MEDICAO;adc;umidade_vwc;umidade_filtrada;bomba;estado
```

A mensagem continha a leitura analógica, a umidade calculada, a umidade filtrada, o estado da bomba e a condição de operação do sistema.

Uma aplicação desenvolvida em Python realizou a leitura contínua da porta serial. O programa foi configurado para identificar automaticamente a porta associada ao Arduino, validar as mensagens recebidas e descartar registros incompletos ou com valores fora da faixa de 0 a 1023.

O computador foi responsável por adicionar a data e a hora de recebimento de cada medição. Os registros válidos foram acrescentados a um arquivo CSV, preservando as medições anteriores e formando uma série temporal contínua.

As principais variáveis armazenadas foram:

- data e hora da medição;
- identificação do ponto monitorado;
- leitura ADC;
- umidade percentual;
- umidade volumétrica;
- umidade filtrada;
- estado da bomba;
- estado operacional do sistema;
- origem do registro.

O programa também foi desenvolvido para tentar restabelecer automaticamente a comunicação em caso de desconexão temporária do Arduino. As ocorrências durante a aquisição foram registradas em um arquivo de log.

3.6 Obtenção das informações meteorológicas

As informações meteorológicas foram obtidas por meio da plataforma Open-Meteo, considerando a região de Uberlândia, Minas Gerais. Foram coletadas as seguintes variáveis:

- temperatura do ar;
- umidade relativa do ar;
- precipitação;
- evapotranspiração de referência.

Os dados foram obtidos em resolução horária e armazenados em arquivos CSV. Além da previsão atual, foi mantido um histórico das consultas realizadas, permitindo registrar as informações disponíveis ao longo do desenvolvimento do sistema.

A base de medições do sensor e a base meteorológica foram consolidadas pela proximidade entre os registros de data e hora. Para cada medição do sensor, foi associado o registro meteorológico mais próximo, utilizando-se uma tolerância máxima de 90 minutos.

As informações meteorológicas observadas foram utilizadas na caracterização da evolução da umidade e na construção das variáveis de entrada dos modelos. A previsão futura de precipitação foi mantida separada do treinamento e utilizada somente na etapa posterior de apoio à decisão.

Essa separação teve como objetivo evitar que informações futuras, ainda indisponíveis no momento original de uma medição, fossem utilizadas indevidamente durante o treinamento dos modelos.

3.7 Preparação da base de dados

A base experimental foi formada pelas medições obtidas pelo sistema de aquisição e pelas informações meteorológicas correspondentes. Inicialmente, os registros foram ordenados cronologicamente, e as datas foram convertidas para um formato padronizado.

Foram removidos registros com data inválida e duplicidades de horário, mantendo-se a observação mais recente em situações de repetição. As variáveis numéricas foram convertidas para um formato compatível com o processamento em Python.

Não foi aplicada imputação extensa de valores ausentes. Após a criação das variáveis temporais, foram utilizadas somente as linhas que apresentavam todas as informações necessárias para o treinamento.

3.8 Construção das variáveis de entrada

Como a umidade do solo apresenta dependência temporal, foram criadas variáveis derivadas das medições anteriores. Essas variáveis permitiram que os modelos baseados em árvores recebessem informações sobre o comportamento recente da série.

Foram utilizadas defasagens de:

$$1, 2, 3, 6, 12, 24 \text{ e } 48 \quad (3.5)$$

registros. Considerando o intervalo de 30 minutos, essas defasagens representaram períodos entre 30 minutos e 24 horas.

Para cada defasagem, foram calculados o valor anterior da umidade e a diferença entre a umidade atual e a medição correspondente.

Também foram construídas janelas móveis de:

$$3, 6, 12, 24 \text{ e } 48 \quad (3.6)$$

registros, a partir das quais foram calculados:

- média;
- desvio padrão;
- valor mínimo;
- valor máximo.

As informações de hora do dia e dia da semana foram convertidas em componentes senoidais e cossenoidais. Essa transformação foi utilizada para representar a característica cíclica do tempo, evitando que o final de um dia fosse interpretado como distante do início do dia seguinte.

Para as variáveis meteorológicas, foram incluídos o valor atual, uma defasagem e uma média recente. Para precipitação e evapotranspiração, também foram calculados acumulados referentes às janelas temporais anteriores.

O estado atual da bomba e a ocorrência de acionamento em um período recente também foram incluídos como variáveis descritivas da operação do sistema.

3.9 Definição da variável-alvo

O problema foi formulado como uma tarefa de regressão, na qual os modelos estimam um valor contínuo de umidade volumétrica.

Foi adotado um horizonte de previsão de 24 horas. Como as medições foram realizadas a cada 30 minutos, esse horizonte correspondeu a 48 registros.

A variável-alvo foi definida por:

$$y_t = \theta_{t+48}, \quad (3.7)$$

em que y_t representa a umidade prevista a partir do instante t e θ_{t+48} representa a umidade observada 48 medições depois.

Portanto, a saída dos modelos corresponde ao valor pontual estimado para a umidade 24 horas após a medição atual. Essa previsão não representa necessariamente o menor valor de umidade dentro da janela de 24 horas, mas o valor esperado ao final desse horizonte.

3.10 Treinamento dos modelos

Foram treinados somente os dois algoritmos selecionados para o desenvolvimento do trabalho:

- Random Forest Regressor;
- Gradient Boosting Regressor.

Os modelos foram implementados em Python por meio da biblioteca *scikit-learn*. Como ambos são baseados em árvores de decisão, não foi necessária a normalização das variáveis de entrada.

Os hiperparâmetros empregados são apresentados na Tabela 1.

A semente aleatória foi mantida fixa para favorecer a reprodutibilidade dos resultados.

3.11 Divisão temporal e avaliação

A separação entre treinamento e teste respeitou a ordem cronológica das medições. Os primeiros 80% dos registros válidos foram utilizados para treinamento, enquanto os 20% finais foram reservados para teste.

Tabela 1 – Hiperparâmetros utilizados nos modelos.

Hiperparâmetro	Random Forest	Gradient Boosting
Número de estimadores	400	300
Profundidade máxima	14	3
Número mínimo de amostras por folha	2	3
Taxa de aprendizado	Não se aplica	0,03
Fração de amostras	Amostragem padrão do modelo	0,90
Função de perda	Erro quadrático interno	Huber
Semente aleatória	42	42

Essa estratégia impediu que informações de períodos futuros fossem utilizadas para prever observações anteriores. Diferentemente da divisão aleatória, a separação temporal reproduziu de forma mais próxima a aplicação do sistema, na qual um modelo treinado com dados passados é empregado para prever condições posteriores.

O desempenho foi avaliado pelas métricas apresentadas na Seção 2.4.5:

- erro absoluto médio;
- raiz do erro quadrático médio;
- coeficiente de determinação.

O modelo selecionado foi aquele que apresentou o menor erro absoluto médio no conjunto de teste. As outras métricas foram utilizadas como indicadores complementares da qualidade preditiva.

As previsões foram limitadas ao intervalo entre zero e a porosidade de referência, evitando a geração de valores fisicamente incompatíveis com a escala adotada.

Após o treinamento, os modelos foram armazenados no formato `joblib`. Também foram registrados arquivos contendo as métricas, as previsões do conjunto de teste, as variáveis utilizadas e os metadados do treinamento.

3.12 Lógica preditiva de apoio à decisão

Após o treinamento, o modelo selecionado foi utilizado para estimar a umidade 24 horas à frente. A escolha automática entre os dois algoritmos foi realizada com base no menor MAE obtido no conjunto de teste.

A recomendação final considerou três informações:

- umidade atual do solo;

- umidade prevista pelo modelo;
- precipitação acumulada prevista para as 24 horas seguintes.

A lógica utilizada foi definida da seguinte forma:

1. Quando a umidade atual fosse igual ou inferior ao limite mínimo, a recomendação seria irrigar imediatamente;
2. Quando a umidade prevista fosse igual ou inferior ao limite mínimo e a precipitação prevista fosse inferior ao valor de referência, a recomendação seria irrigar;
3. Quando a umidade prevista fosse igual ou inferior ao limite mínimo, mas houvesse precipitação suficiente prevista, a recomendação seria aguardar e realizar uma nova avaliação;
4. Quando as umidades atual e prevista permanecessem acima do limite mínimo, a recomendação seria continuar o monitoramento.

Foi adotada uma precipitação acumulada de 1 mm nas 24 horas seguintes como valor de referência para a decisão de aguardar. Nessa situação, foi definido um intervalo de seis horas para uma nova avaliação.

A previsão meteorológica não cancelou a recomendação de irrigação quando a umidade atual já havia atingido o limite crítico. Nesse caso, a condição medida pelo sensor teve prioridade sobre a previsão de chuva.

A recomendação preditiva funcionou como uma camada de apoio à decisão. O controle local implementado no Arduino permaneceu responsável pelo acionamento e desligamento seguro da bomba com base nas medições efetivamente observadas.

3.13 Supervisão e visualização

Foi desenvolvida uma aplicação em Streamlit para apresentar as informações do sistema em um painel interativo.

O painel reuniu:

- umidade atual;
- histórico das medições;
- limites de acionamento e desligamento;
- eventos relacionados à bomba;

- informações meteorológicas;
- modelo utilizado;
- umidade prevista;
- recomendação produzida pelo sistema.

A visualização permitiu acompanhar a evolução da umidade, relacionar alterações com eventos de irrigação ou precipitação e consultar a recomendação mais recente.

As recomendações foram armazenadas em arquivo JSON e em um histórico no formato CSV, contendo o instante de geração, o modelo utilizado, a umidade atual, a umidade prevista, a precipitação esperada e o motivo da decisão.

4 Resultados e Discussões

Este capítulo apresenta e discute os resultados obtidos durante o desenvolvimento do sistema de monitoramento e previsão da umidade do solo. Foram avaliados o funcionamento integrado do protótipo, o comportamento temporal das medições, o controle da irrigação, o desempenho dos modelos de aprendizado de máquina e a utilização de informações meteorológicas como apoio à tomada de decisão.

O sistema desenvolvido integrou o sensor de umidade do solo, o Arduino Uno, a comunicação serial, o armazenamento das medições em arquivo CSV, os algoritmos de aprendizado de máquina e o painel de visualização. Os resultados permitiram avaliar tanto o funcionamento dos componentes individuais quanto a capacidade da arquitetura de operar de forma conjunta.

4.1 Validação funcional do sistema

A montagem física foi realizada utilizando o Arduino Uno como unidade de aquisição e controle, o sensor CS12 para o monitoramento da umidade do solo, um módulo relé e uma bomba de água de vazão fixa.

Durante os testes, verificou-se que o Arduino realizou adequadamente a leitura analógica do sensor e transmitiu os registros ao computador por meio da comunicação serial. A aplicação desenvolvida em Python recebeu as mensagens, validou os dados e acrescentou as medições ao arquivo CSV, preservando o histórico anteriormente registrado.

Também foi validado o acionamento da bomba pelo módulo relé. Dessa forma, o sistema foi capaz de executar o fluxo completo entre a identificação da condição de umidade, o processamento da leitura e a atuação sobre a irrigação.

A validação funcional demonstrou que a arquitetura adotada foi suficiente para realizar a aquisição periódica, o armazenamento estruturado e o acionamento da bomba. O resultado é relevante porque confirma a compatibilidade entre os componentes físicos e computacionais que formam o sistema.

4.2 Caracterização da base experimental

A base analisada compreendeu o período entre 10 de junho e 10 de julho de 2026. As medições foram realizadas em intervalos de 30 minutos, totalizando 1488 registros ao longo de 31 dias.

Além da umidade volumétrica, foram armazenadas a leitura analógica do sensor, a umidade filtrada, o estado da bomba, o estado operacional do sistema e as variáveis meteorológicas correspondentes.

A Tabela 2 apresenta uma síntese da base experimental.

Tabela 2 – Caracterização da base experimental.

Característica	Resultado
Período analisado	10/06/2026 a 10/07/2026
Intervalo entre medições	30 minutos
Quantidade de registros	1488
Limite inferior de controle	0,25 m ³ /m ³
Limite superior de controle	0,30 m ³ /m ³
Quantidade de acionamentos da bomba	5
Menor leitura registrada	0,2483 m ³ /m ³
Maior leitura registrada	0,3000 m ³ /m ³

Embora a base contenha uma quantidade significativa de registros, as observações consecutivas possuem dependência temporal. Assim, os 1488 registros não representam 1488 condições ambientais completamente independentes. Além disso, foram observados somente cinco ciclos de irrigação, o que limita a variedade de situações apresentadas aos modelos durante o treinamento.

4.3 Comportamento temporal da umidade

A Figura 2 apresenta a evolução da umidade volumétrica ao longo do período analisado. O limite inferior indica a condição de acionamento da irrigação, enquanto o limite superior representa a condição esperada para o encerramento do ciclo.

Entre os eventos de irrigação, observou-se uma redução gradual da umidade. Essa redução não ocorreu de forma perfeitamente linear, sendo identificadas pequenas ondulações e alterações na inclinação da curva.

Essas variações são compatíveis com a mudança da demanda atmosférica entre os períodos diurno e noturno. Durante o dia, a presença de radiação solar e temperaturas mais elevadas tende a aumentar a evapotranspiração. Durante a noite, a redução da radiação e da temperatura, associada geralmente ao aumento da umidade relativa do ar, diminui a demanda atmosférica e reduz a velocidade de perda de água [Allen et al. \(1998\)](#).

Por essa razão, a curva apresenta trechos de secagem mais acentuada durante determinados períodos do dia e trechos de menor variação durante a noite. As pequenas ondulações observadas não representam necessariamente falhas no sensor, mas a combinação entre a dinâmica ambiental, a redistribuição da água no solo e pequenas variações naturais da medição.




Figura 2 – Comportamento temporal da umidade volumétrica e eventos de irrigação.

Fonte: Autoria própria (2026).

Também foram observados comportamentos semelhantes entre diferentes ciclos, pois a irrigação elevou a umidade para uma região próxima ao limite superior e o processo de secagem foi reiniciado em condições semelhantes.

4.4 Avaliação do controle da irrigação

A lógica de controle utilizou dois limites distintos, formando uma histerese entre o acionamento e o desligamento da bomba. A média das três últimas medições foi utilizada para confirmar a condição de acionamento, reduzindo a influência de uma leitura isolada.

Durante o período analisado, foram registrados cinco eventos de irrigação, apresentados na Tabela 3.

Tabela 3 – Eventos de acionamento da irrigação.

Evento	Data e hora	Umidade	Umidade filtrada
1	19/06/2026 13:30	0,2483	0,2494
2	23/06/2026 21:00	0,2497	0,2498
3	29/06/2026 17:00	0,2492	0,2498
4	03/07/2026 20:30	0,2499	0,2500
5	07/07/2026 17:00	0,2492	0,2496

Os acionamentos ocorreram quando a umidade filtrada atingiu a região definida como limite inferior. Após cada evento, observou-se a recuperação da umidade até a região do limite superior, indicando que a bomba e a lógica de controle atuaram conforme o comportamento esperado.

As leituras individuais apresentaram valores ligeiramente inferiores a $0,25 \text{ m}^3/\text{m}^3$. Essa pequena ultrapassagem está relacionada ao intervalo de 30 minutos entre as medições e ao uso da média móvel. O sistema somente confirma a condição após considerar as leituras recentes, de modo que uma medição individual pode ultrapassar discretamente o limite antes do acionamento.

Portanto, não seria tecnicamente correto afirmar que a umidade nunca ficou abaixo do limite. Entretanto, não foi observada permanência prolongada ou uma redução expressiva abaixo da condição mínima. Após a identificação da condição crítica, o sistema acionou a irrigação e restabeleceu a umidade.

A utilização da média móvel e da histerese produziu um equilíbrio entre sensibilidade e estabilidade. Um acionamento baseado em uma única leitura poderia responder mais rapidamente, porém estaria mais sujeito a ruídos. Por outro lado, uma janela muito longa poderia atrasar excessivamente a irrigação.

O intervalo entre os eventos variou aproximadamente entre quatro e seis dias, demonstrando que o acionamento não ocorreu segundo um calendário fixo, mas de acordo com a evolução da umidade. Essa característica representa uma vantagem em relação a estratégias que desconsideram as condições efetivamente medidas no solo.

4.5 Seleção dos modelos de aprendizado de máquina

Durante a etapa exploratória, foram considerados métodos com diferentes níveis de complexidade, incluindo Regressão Linear, modelo de persistência, Extra Trees Regressor, Random Forest Regressor e Gradient Boosting Regressor.

A Regressão Linear foi considerada como uma alternativa de menor complexidade, mas sua estrutura pode ser limitada diante de relações não lineares entre a umidade, seu histórico e as condições ambientais. O modelo de persistência foi utilizado como uma referência simples, considerando que a umidade futura seria igual à umidade atual. Embora útil como comparação, esse método não aprende as mudanças observadas na série.

O Extra Trees Regressor também foi considerado na etapa exploratória. No entanto, para tornar o escopo final mais objetivo, decidiu-se concentrar a comparação em dois algoritmos baseados em árvores que apresentam mecanismos de aprendizado complementares: Random Forest Regressor e Gradient Boosting Regressor.

4.5.1 Random Forest Regressor

O Random Forest combina diversas árvores de decisão construídas a partir de diferentes amostras da base. A previsão final é obtida pela média das previsões individuais, reduzindo a dependência de uma única árvore (BREIMAN, 2001).

Entre as vantagens do modelo para esta aplicação destacam-se:

- capacidade de representar relações não lineares;
- relativa resistência a ruídos e oscilações;
- estabilidade produzida pela combinação de várias árvores;
- possibilidade de avaliar a importância das variáveis;
- possibilidade de paralelizar parte do treinamento.

Como limitações, o modelo pode exigir maior armazenamento quando utiliza muitas árvores e tende a apresentar dificuldade para extrapolar condições muito diferentes daquelas observadas no treinamento. Além disso, a média das árvores pode suavizar mudanças mais rápidas da série.

4.5.2 Gradient Boosting Regressor

O Gradient Boosting constrói as árvores sequencialmente, fazendo com que cada nova árvore procure reduzir os erros deixados pelo conjunto anterior ([FRIEDMAN, 2001](#)).

Suas principais vantagens são:

- capacidade de representar relações não lineares;
- bom desempenho em bases tabulares;
- correção progressiva dos erros;
- controle da aprendizagem por meio da taxa de aprendizado;
- possibilidade de ajustar a complexidade do conjunto.

Por outro lado, o modelo pode ser mais sensível à seleção dos hiperparâmetros e ao sobreajuste. Como as árvores são construídas sequencialmente, o treinamento também apresenta menor possibilidade de paralelização quando comparado ao Random Forest.

A escolha dos dois modelos permitiu comparar duas estratégias distintas. O Random Forest busca estabilidade por meio da média de diversas árvores independentes, enquanto o Gradient Boosting busca melhorar progressivamente a previsão pela correção dos erros anteriores.

4.6 Desempenho preditivo dos modelos

Os modelos foram treinados utilizando os registros iniciais da série temporal, enquanto os registros mais recentes foram reservados para o teste. Essa separação preservou a ordem cronológica e evitou a utilização de informações futuras durante o treinamento.

A Tabela 4 apresenta o desempenho obtido.

Tabela 4 – Desempenho dos modelos no conjunto de teste.

Modelo	MAE	RMSE	R^2
Random Forest Regressor	0,003061	0,007165	0,709127
Gradient Boosting Regressor	0,002861	0,007090	0,715241

O Gradient Boosting apresentou o menor MAE e o menor RMSE, além do maior valor de R^2 . Dessa forma, foi selecionado automaticamente pelo sistema como o modelo com melhor desempenho na execução analisada.

O MAE de 0,002861 m^3/m^3 indica que as previsões do Gradient Boosting apresentaram, em média, uma diferença de aproximadamente 0,0029 m^3/m^3 em relação aos valores observados. No Random Forest, essa diferença média foi de aproximadamente 0,0031 m^3/m^3 .

Apesar da seleção do Gradient Boosting, os resultados dos dois modelos foram próximos. A diferença no MAE foi de aproximadamente 6,5% em favor do Gradient Boosting, não sendo suficiente para concluir que um dos algoritmos será superior em qualquer período ou condição ambiental.

O RMSE foi superior ao MAE nos dois modelos. Esse comportamento indica a existência de algumas previsões com erros maiores do que o erro médio, pois o RMSE atribui maior penalização aos desvios de maior magnitude.

Os coeficientes de determinação ficaram próximos de 0,71. Isso significa que os modelos conseguiram representar uma parcela relevante da variabilidade da umidade no conjunto de teste, embora aproximadamente 29% dessa variabilidade não tenha sido explicada pelas variáveis e configurações utilizadas.

Portanto, os resultados podem ser considerados promissores para o período analisado, mas ainda existe espaço para melhoria. A proximidade entre os dois modelos também indica que a seleção definitiva pode variar quando forem adicionados novos períodos e condições ambientais à base.

A Figura 3 deve apresentar a comparação temporal entre os valores observados e previstos pelo modelo selecionado.

A curva prevista acompanhou de forma satisfatória a tendência geral da umidade observada ao longo do conjunto de teste, embora não tenha reproduzido com a mesma

precisão todas as oscilações locais. As maiores diferenças entre os valores observados e previstos ocorreram nas proximidades dos eventos de irrigação, especialmente nos momentos de elevação rápida da umidade. Esse comportamento está relacionado ao fato de que a irrigação produz alterações mais abruptas na série, enquanto o processo de secagem ocorre de maneira mais gradual e previsível.




Figura 3 – Comparação entre a umidade observada e a umidade prevista pelo modelo selecionado.

Fonte: Autoria própria (2026).

4.7 Interpretação da previsão em 24 horas

O valor produzido pelo modelo corresponde à umidade estimada exatamente 24 horas após o instante atual. Dessa forma, a previsão pode, em determinados momentos, ser superior à umidade presente.

Esse comportamento pode ocorrer quando o histórico indica a possibilidade de um evento de irrigação ou de precipitação dentro do horizonte analisado. Por exemplo, a umidade pode reduzir até o limite inferior, provocar o acionamento da bomba e retornar a uma condição mais elevada antes do término das 24 horas.

Portanto, uma previsão superior à umidade atual não significa necessariamente que o modelo esteja incorreto. Ela representa a condição estimada ao final do horizonte, considerando os padrões aprendidos na base.

Entretanto, essa característica também constitui uma limitação para o apoio à decisão. A umidade pode atingir o limite mínimo durante o intervalo e voltar a aumentar antes do final das 24 horas. Nesse caso, apenas o valor previsto ao final do horizonte pode ocultar uma condição crítica intermediária.

Uma possibilidade de melhoria consiste em desenvolver um segundo alvo para prever a menor umidade esperada ao longo das 24 horas seguintes. A utilização conjunta da umidade pontual futura e da menor umidade prevista no período poderia fornecer uma avaliação mais completa do risco hídrico.

4.8 Integração meteorológica e tomada de decisão

A previsão meteorológica foi utilizada em uma camada externa aos modelos de aprendizado de máquina. Dessa forma, o modelo permaneceu responsável por estimar a umidade futura, enquanto uma regra posterior avaliou a possibilidade de precipitação.

A lógica adotada permitiu produzir três recomendações:

- irrigar, quando a umidade atual já havia atingido o limite mínimo ou quando a previsão indicava condição crítica sem chuva esperada;
- aguardar e reavaliar, quando a umidade prevista se aproximava da condição crítica e havia precipitação prevista;
- continuar monitorando, quando as condições atual e futura permaneciam acima do limite mínimo.

A separação entre previsão da umidade e previsão meteorológica tornou a decisão mais transparente. Foi possível identificar se uma recomendação resultava da condição medida, da previsão realizada pelo modelo ou da expectativa de chuva.

Quando a umidade atual atingiu a condição mínima, a leitura do sensor teve prioridade sobre a previsão meteorológica. Essa decisão foi adotada porque uma chuva prevista pode não ocorrer na intensidade, no local ou no horário esperado.

4.9 Visualização e acompanhamento

O painel desenvolvido em Streamlit reuniu as informações produzidas pelas diferentes etapas do sistema. Foram apresentados o valor atual da umidade, o histórico das medições, os limites operacionais, os eventos de irrigação, os dados meteorológicos, o modelo selecionado e a recomendação mais recente.

A Figura 4 apresenta a interface desenvolvida.

A visualização facilitou a identificação da tendência de secagem, dos momentos de acionamento da bomba e das alterações provocadas pela irrigação. O registro das recomendações também permitiu manter a rastreabilidade das decisões produzidas pelo sistema.



Figura 4 – Painel de acompanhamento desenvolvido em Streamlit.

Fonte: Autoria própria (2026).

4.10 Potencial de aplicação e expansão

Embora o experimento tenha sido realizado em um único ponto de monitoramento, a arquitetura apresenta potencial de expansão para áreas com maior quantidade de pontos ou talhões.

Em propriedades maiores, o acompanhamento manual de diferentes áreas pode se tornar complexo. Cada talhão pode apresentar comportamento distinto em razão do tipo de solo, topografia, exposição solar, idade das plantas e histórico de manejo. Nesse cenário, um sistema de previsão pode auxiliar na organização das prioridades de irrigação.

A aplicação em múltiplos talhões poderia permitir:

- identificar quais áreas se aproximam primeiro da condição crítica;
- antecipar a demanda de irrigação dos períodos seguintes;
- priorizar a utilização de bombas, válvulas e equipes;
- comparar o comportamento hídrico entre diferentes regiões;
- registrar o histórico das decisões de cada área.

O valor operacional da ferramenta tende a crescer com a quantidade de áreas monitoradas, pois aumenta também a dificuldade de acompanhar manualmente todas as condições. Entretanto, não se pode afirmar, com base no presente experimento, que o sistema terá automaticamente maior eficácia em áreas maiores.

A expansão exigiria sensores representativos para cada zona de manejo, calibração local, infraestrutura de comunicação e validação dos modelos em condições diferentes. Assim, a aplicação em múltiplos talhões constitui uma possibilidade de desenvolvimento futuro, e não um resultado já comprovado.

4.11 Limitações e possibilidades de melhoria

Os resultados obtidos demonstraram o funcionamento do sistema e apresentaram desempenho preditivo promissor. Entretanto, algumas limitações devem ser consideradas na interpretação.

A principal limitação foi o período de aproximadamente um mês. Embora tenham sido obtidos 1488 registros, foram observados somente cinco ciclos de irrigação e uma faixa limitada de condições meteorológicas. Dessa forma, os modelos não foram expostos a toda a variabilidade que pode ocorrer ao longo de uma safra.

Uma base mais longa poderia incluir:

- períodos secos e chuvosos;
- diferentes temperaturas e demandas atmosféricas;
- precipitações de diferentes intensidades;
- maior quantidade de ciclos de irrigação;
- possíveis mudanças na resposta do sensor;
- diferentes estádios de desenvolvimento da cultura.

Em aprendizado de máquina, uma quantidade maior de dados tende a favorecer a generalização quando esses dados possuem qualidade e representam adequadamente as condições futuras de aplicação. Portanto, não é apenas a quantidade de registros que deve ser ampliada, mas também a diversidade das situações presentes na base.

Outra limitação está relacionada ao uso de um único ponto de monitoramento. A umidade do solo pode variar espacialmente, e uma única medição pode não representar toda uma área agrícola. Estudos futuros podem utilizar diferentes pontos e profundidades para avaliar essa variabilidade.

Também podem ser realizadas melhorias no treinamento, como:

- otimização sistemática dos hiperparâmetros;
- validação temporal em múltiplas janelas;

- avaliação em diferentes épocas do ano;
- inclusão de novas variáveis ambientais;
- análise da importância das variáveis;
- estimativa da incerteza das previsões;
- comparação entre diferentes horizontes de previsão;
- previsão da menor umidade dentro do horizonte futuro.

Os limites de controle e a calibração do sensor também devem ser avaliados em diferentes condições de solo. Os valores adotados foram adequados ao experimento, mas não devem ser generalizados diretamente para qualquer área ou cultura.

4.12 Síntese dos resultados

O sistema apresentou funcionamento integrado entre aquisição, armazenamento, controle, previsão e visualização. As medições foram registradas em intervalos regulares, e a lógica de irrigação respondeu aos momentos em que a umidade atingiu a região crítica.

A histerese e a média móvel evitaram acionamentos sucessivos provocados por pequenas oscilações. Durante o período analisado, não houve permanência prolongada da umidade abaixo do limite mínimo, e os eventos de irrigação restabeleceram a umidade para a região superior de controle.

Na avaliação preditiva, o Random Forest e o Gradient Boosting apresentaram resultados próximos. O Gradient Boosting obteve desempenho ligeiramente superior nas três métricas e foi selecionado pelo menor MAE. Entretanto, os valores de R^2 e a diferença entre MAE e RMSE indicam que ainda existem variações e erros que podem ser reduzidos.

A integração da previsão meteorológica adicionou contexto à recomendação, permitindo considerar a expectativa de chuva sem retirar a prioridade da medição atual quando a condição crítica já havia sido atingida.

De forma geral, os resultados demonstram a viabilidade da arquitetura desenvolvida para monitorar a umidade, estimar seu comportamento futuro e apoiar a decisão de irrigação. A ampliação do período experimental e a incorporação de maior diversidade de condições são os principais passos para aumentar a confiabilidade e avaliar a aplicação do sistema em uma escala maior.

5 Conclusão

Os resultados obtidos permitiram concluir que o sistema desenvolvido foi capaz de acompanhar a evolução da umidade do solo e apoiar a decisão de irrigação de forma coerente com os limites estabelecidos. Durante o período analisado, a lógica de controle respondeu aos momentos de redução da umidade, acionando a irrigação e evitando que o solo permanecesse por períodos prolongados abaixo da condição mínima adotada.

Os modelos Random Forest Regressor e Gradient Boosting Regressor apresentaram desempenhos próximos e resultados satisfatórios para a previsão da umidade. O Gradient Boosting obteve desempenho ligeiramente superior, embora essa diferença não permita afirmar que ele será sempre o modelo mais adequado em outras condições. A utilização da previsão meteorológica também contribuiu para tornar a recomendação mais completa, ao permitir que a possibilidade de chuva fosse considerada antes da decisão final.

Dessa forma, considera-se que o objetivo proposto foi atingido, demonstrando a viabilidade da integração entre monitoramento, previsão e apoio à irrigação. Entretanto, o período de aproximadamente um mês e o uso de um único ponto de medição limitaram a diversidade de situações avaliadas. A ampliação da coleta, com diferentes períodos climáticos, ciclos de irrigação e pontos de monitoramento, poderá aumentar a capacidade de generalização dos modelos e permitir uma avaliação mais abrangente da aplicação do sistema em áreas agrícolas maiores.

Referências Bibliográficas

- Agência Nacional de Águas e Saneamento Básico. *Atlas Irrigação: uso da água na agricultura irrigada*. Brasília, 2017. 86 p. Disponível em: <https://www.ana.gov.br/arquivos/institucional/sge/CEDOC/Catalogo/2017/AtlasIrrigacaousodaAguaAgriculturaIrigada.pdf>. Citado 3 vezes nas páginas 13, 14 e 17.
- ALLEN, R. G. et al. *Crop Evapotranspiration: Guidelines for computing crop water requirements*. Rome: FAO, 1998. (FAO Irrigation and Drainage Paper, 56). Disponível em: <https://www.fao.org/4/x0490e/x0490e00.htm>. Citado 4 vezes nas páginas 13, 17, 23 e 36.
- Arduino. *analogRead()*. <https://docs.arduino.cc/language-reference/en/functions/analog-io/analogRead/>. Acesso em: 26 jul. 2026. Citado na página 19.
- BISHOP, C. M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006. Citado na página 20.
- BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 2001. Citado 3 vezes nas páginas 13, 21 e 38.
- FRIEDMAN, J. H. Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, v. 29, n. 5, p. 1189–1232, 2001. Citado 3 vezes nas páginas 13, 21 e 39.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2. ed. New York: Springer, 2009. Citado na página 20.
- HILLEL, D. *Introduction to Environmental Soil Physics*. Amsterdam: Elsevier Academic Press, 2004. Citado na página 17.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: Principles and Practice*. 2. ed. Melbourne: OTexts, 2018. Disponível em: <https://otexts.com/fpp2/>. Citado na página 20.
- MapBiomas Brasil. *Irrigation — Appendix, Collection 9*. 2024. Technical appendix for annual irrigation mapping in Brazil. Disponível em: <https://brasil.mapbiomas.org/wp-content/uploads/sites/4/2024/08/Irrigation-Appendix-C9.docx.pdf>. Citado 2 vezes nas páginas 13 e 17.
- MITCHELL, T. M. *Machine Learning*. New York: McGraw-Hill, 1997. Citado na página 20.
- Streamlit. *Streamlit Documentation*. <https://docs.streamlit.io/>. Acesso em: 26 jul. 2026. Citado na página 24.
- UNESCO. *Statistics | UN World Water Development Report 2024*. 2024. Global freshwater withdrawals by sector and related indicators. Disponível em: <https://www.unesco.org/reports/wwdr/en/2024/s>. Citado 3 vezes nas páginas 13, 14 e 17.