




C A P Í T U L O 1

Irrigação Inteligente Sensível à Espécie baseada em Deep Learning e Dados Ecológicos Globais

 <https://doi.org/10.22533/at.ed.441122601041>

Gabrielly de Queiroz Pereira

Curso de Análise e Desenvolvimento de Sistemas – SENAC
Ponta Grossa – PR – Brasil

Marcos Monteiro Junior

Curso de Análise e Desenvolvimento de Sistemas – SENAC
Ponta Grossa – PR – Brasil

Rodrigo Adamshuk Silva

Curso de Análise e Desenvolvimento de Sistemas – SENAC
Ponta Grossa – PR – Brasil

Marcella S. Ribeiro Martins

Universidade Tecnológica Federal do Paraná (UTFPR)
Ponta Grossa – PR – Brasil

RESUMO: Este trabalho apresenta uma abordagem de irrigação inteligente sensível à espécie, baseada na integração entre atributos ecológicos de plantas e modelos de aprendizado de máquina, visando o uso mais eficiente da água em sistemas agrícolas. Foi desenvolvido um sistema em Python com interface web para estimar a demanda hídrica diária a partir de variáveis ambientais, fase fenológica e características ecológicas das espécies. A base experimental foi composta por 2800 amostras sintéticas geradas a partir de perfis botânicos e climáticos. Foram avaliados algoritmos como regressão Ridge, KNN e redes neurais, utilizando métricas como MAE, RMSE e R2. Os resultados indicaram melhor desempenho dos modelos neurais, com destaque para a shallow MLP, que obteve RMSE de 0,2338 e R2 de 0,9295 no conjunto de teste. Os achados sugerem que a combinação entre dados ecológicos e aprendizado de máquina é promissora para representar diferenças hídricas entre espécies e apoiar sistemas de irrigação mais adaptativos. Apesar do uso de dados sintéticos, a abordagem demonstrou consistência e potencial de aplicação com dados reais.

Species-sensitive smart irrigation based on deep learning and global ecological data

ABSTRACT. This work presents a species-sensitive smart irrigation approach based on the integration of plant ecological attributes and machine learning models, aiming at more efficient water use in agricultural systems. A system was developed in Python with a web interface to estimate daily water demand from environmental variables, phenological stage, and species ecological characteristics. The experimental dataset consisted of 2,800 synthetic samples generated from botanical and climatic profiles. Algorithms such as Ridge regression, KNN, and neural networks were evaluated using metrics including MAE, RMSE, and R2. The results showed that neural models achieved better performance, with the shallow MLP obtaining an RMSE of 0.2338 and an R2 of 0.9295 on the test set. The findings suggest that combining ecological data with machine learning is promising for representing species-specific water requirements and supporting more adaptive irrigation systems. Although synthetic data were used, the approach demonstrated consistency and potential for application with realworld data.

INTRODUÇÃO

A agricultura depende de uma gestão hídrica cada vez mais eficiente, pois a irrigação consome parcela significativa da água disponível e seu uso inadequado compromete a sustentabilidade da produção agrícola [Abioye et al. 2022]. A escassez hídrica, a variabilidade climática e o aumento da demanda por alimentos têm ampliado a necessidade de sistemas de irrigação capazes de ajustar a aplicação de água às condições ambientais e às exigências das culturas [Morchid et al. 2025].

Nesse contexto, a agricultura de precisão tem incorporado sensores, redes IoT e modelos computacionais para monitorar variáveis como umidade do solo, temperatura e umidade do ar, apoiando decisões de irrigação mais adequadas [Sarjerao et al. 2025]. Sistemas inteligentes de irrigação baseados em IoT e aprendizado profundo também têm sido propostos para prever umidade volumétrica do solo, período de irrigação e distribuição espacial da água requerida, com desempenho superior ao de abordagens anteriores em áreas experimentais [Kashyap et al. 2021].

Além da decisão de irrigação em si, a confiabilidade dos sensores físicos constitui um desafio importante, pois falhas e ruídos podem comprometer a qualidade dos dados usados pelo sistema em tempo real [Sami et al. 2022]. Para enfrentar esse problema, abordagens de baixo custo com IoT e inteligência artificial têm empregado autoencoders, GANs e arquiteturas CNN/BiLSTM para detectar anomalias, corrigir leituras e aumentar a confiabilidade dos dados utilizados no manejo da irrigação [Benameur et al. 2024].

A literatura também mostra que modelos de aprendizado de máquina e aprendizado profundo podem ser integrados a características fisiológicas das plantas e a variáveis meteorológicas para prever evapotranspiração e estimar necessidades hídricas em diferentes zonas climáticas [Mghouchi and Udristioiu 2025]. De modo complementar, já foram propostos sistemas que integram irrigação inteligente, IoT e aprendizado de máquina para recomendação de plantas, indicando que a combinação entre atributos da espécie e dados ambientais pode apoiar decisões agrônomicas mais específicas [Tyagi et al. 2024].

Outra linha promissora utiliza visão computacional e aprendizado profundo para inferir classes de textura do solo e necessidade de água sob diferentes condições de iluminação, ampliando as possibilidades de sensoriamento para irrigação inteligente [Kurtulmus, et al. 2022].

Apesar desses avanços, ainda há espaço para investigar modelos que tornem a irrigação mais sensível às particularidades ecológicas das espécies vegetais, combinando dados ambientais e atributos associados às plantas em uma abordagem preditiva.

Diante disso, este trabalho tem como objetivo desenvolver e avaliar um modelo de irrigação inteligente sensível à espécie, baseado em *deep learning* e em dados ecológicos, para apoiar decisões de uso mais eficiente da água em sistemas agrícolas.

MATERIAL E MÉTODOS

A Figura 1 apresenta o fluxo geral do projeto, desde a definição das espécies até a geração da recomendação de irrigação e a avaliação dos modelos.

O sistema foi desenvolvido para estimar a demanda hídrica diária de plantas a partir da espécie vegetal e das condições ambientais. A implementação foi realizada em

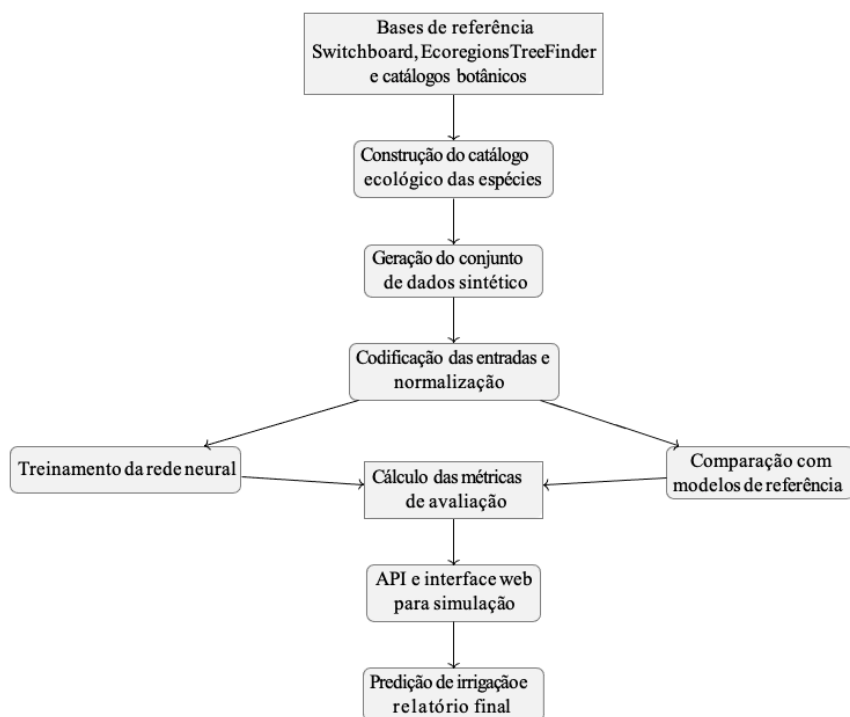


Figura 1. Fluxo metodológico do sistema de irrigação sensível à espécie.

Python, com FastAPI na camada de serviço, NumPy para treinamento dos modelos e interface web em HTML, CSS e JavaScript.

Bases de dados e definição das espécies

A construção dos perfis ecológicos foi orientada por bases voltadas à agrofloresta, restauração ecológica e distribuição vegetal, com destaque para o *Agroforestry Species Switchboard 4.0* e o *EcoregionsTreeFinder*. Essas fontes serviram como referência para atributos botânicos, ecológicos e climáticos das espécies. Como não há, nessas bases, uma variável alvo única de irrigação diária em litros por planta, foi adotada uma estratégia de geração de dados sintéticos baseada em parâmetros ecológicos coerentes com essas fontes.

Foram cadastradas dez espécies de referência, cada uma descrita por nome científico, nome comum, família, bioma, ecorregião, zona climática, tolerância à seca, preferência por umidade, temperatura ótima, precipitação anual, profundidade radicular, densidade de copa e índice hídrico.

Entradas do modelo e geração dos dados

As entradas do sistema incluíram temperatura do ar, umidade relativa, umidade do solo, chuva acumulada em sete dias, radiação solar, velocidade do vento, fase fenológica e atributos ecológicos da espécie. A fase fenológica foi convertida em fator numérico, enquanto a espécie foi codificada por *one-hot encoding*.

O conjunto de dados foi gerado artificialmente com 280 amostras por espécie, totalizando 2800 registros. Para cada amostra, foram sorteados valores ambientais em faixas compatíveis com o perfil da espécie e calculada a variável alvo em litros por dia. Esse cálculo combinou secura do ambiente, pressão hídrica da espécie, efeito climático e uma componente simplificada de evapotranspiração, com adição de ruído aleatório de pequena amplitude.

Modelo principal e treinamento

O modelo principal foi uma rede neural para regressão, implementada em NumPy, com 25 atributos de entrada, três camadas ocultas de 48, 24 e 12 neurônios, função de ativação ReLU e uma saída contínua correspondente ao volume diário de irrigação. Os dados de entrada e a variável alvo foram normalizados por média e desvio padrão antes do treinamento.

O conjunto foi embaralhado com semente fixa e dividido em 82% para treinamento e 18% para teste. O treinamento utilizou taxa de aprendizado de 0,003, 700 épocas e mini-lotes de tamanho 64. Ao final, o modelo treinado e seus parâmetros de normalização foram salvos para reutilização na inferência.

Modelos de comparação e métricas

Além da rede principal, foram avaliados quatro algoritmos de comparação: *mean baseline*, regressão Ridge, KNN e uma rede neural rasa (*shallow MLP*). A comparação foi realizada sobre o mesmo conjunto de treino e teste.

As métricas calculadas foram MAE, MSE, RMSE, R^2 , MAPE, sMAPE, erro absoluto mediano, variância explicada, erro máximo, viés médio e correlação de Pearson. Também foram analisados o ganho percentual de RMSE em relação ao *mean baseline* e o *gap* de generalização, definido como a diferença entre o RMSE de teste e o de treinamento.

Nos experimentos executados, o modelo *shallow MLP* apresentou o menor RMSE no teste (0,2338) e o maior R^2 (0,9295), seguido pela rede profunda *deep species MLP*, com RMSE de 0,2463 e R^2 de 0,9218. A regressão Ridge obteve RMSE de 0,3428, o KNN apresentou 0,6497 e o *mean baseline* 0,8807.

Fluxo de execução do sistema

O funcionamento do sistema ocorreu em sequência: carregamento do catálogo ecológico, geração do conjunto de dados, preparação dos atributos, treinamento e avaliação dos modelos, armazenamento dos artefatos e disponibilização da aplicação web. Na etapa de uso, o usuário informa a espécie e as variáveis ambientais; o sistema então monta o vetor de entrada, executa a predição e retorna o volume diário, o volume semanal e o tempo estimado de irrigação com base na vazão do emissor.

Interface e reprodutibilidade

A interface web foi criada para simular cenários de irrigação e visualizar o perfil ecológico da espécie, o resultado da predição e a comparação entre algoritmos. Para manter a repetibilidade dos experimentos, foram usadas sementes fixas na geração dos dados e no treinamento, e os relatórios de avaliação foram exportados em arquivos JSON e Markdown. Essa organização permite repetir os testes com os mesmos parâmetros e substituir futuramente o conjunto sintético por dados observados em campo.

RESULTADOS E DISCUSSÃO

A aplicação desenvolvida reuniu, em um único ambiente, o cadastro ecológico das espécies, o simulador de cenários, a estimativa de irrigação e o painel de avaliação dos modelos. A tela inicial do sistema, mostrada na Figura 2, apresenta uma síntese do experimento, com destaque para o total de 2800 amostras geradas para treinamento, 10 espécies de referência e desempenho global da rede principal no conjunto de teste, com $R^2 = 0,922$.

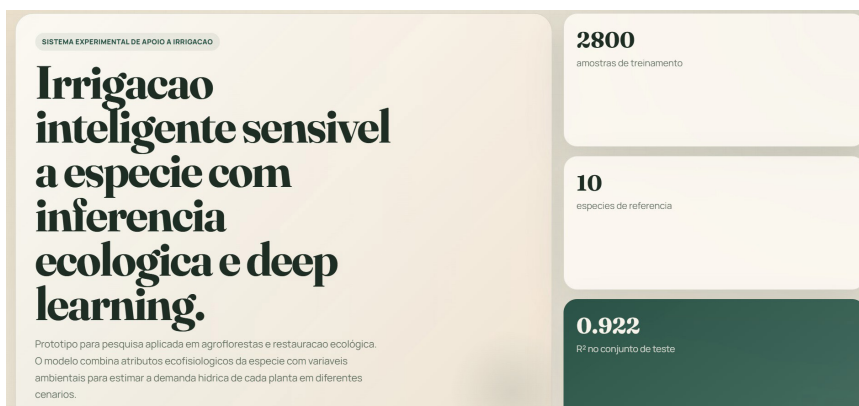


Figura 2. Tela inicial do sistema com resumo do conjunto de dados e do desempenho do modelo.

O conjunto de dados foi composto por 2800 amostras sintéticas, distribuídas entre dez espécies vegetais com perfis ecológicos distintos. Essa composição permitiu representar espécies associadas a ambientes úmidos, como açaí e cacau, e espécies mais adaptadas a ambientes secos, como moringa e cajueiro. O catálogo de espécies, apresentado na Figura 3, mostra essa diversidade ao reunir nome científico, bioma, ecorregião, índice hídrico e tolerância à seca. Essa etapa foi importante para que o modelo aprendesse padrões diferentes de demanda hídrica conforme a espécie e o ambiente considerado.

A interface principal de uso do sistema é apresentada na Figura 4. Nessa tela, o usuário informa espécie vegetal, temperatura, umidade relativa, umidade do solo, chuva acumulada, radiação solar, velocidade do vento, fase fenológica, vazão do emissor e número de plantas. Ao lado do formulário, o sistema exibe o perfil ecológico da espécie selecionada. No exemplo ilustrado, a espécie escolhida foi o açaí, com índice hídrico de

Açaí <i>Euterpe oleracea</i>	Amazonia	Varzea do estuario amazonico	0.86	0.2
Cacau <i>Theobroma cacao</i>	Floresta tropical umida	Florestas umidas do sul da Bahia	0.82	0.25
Inga <i>Inga edulis</i>	Floresta tropical	Florestas riparias neotropicais	0.64	0.45
Moringa <i>Moringa oleifera</i>	Regioes secas tropicais	Bosques tropicais secos	0.3	0.88
Cajueiro <i>Anacardium occidentale</i>	Caatinga e zonas costeiras secas	Caatinga sensu stricto	0.34	0.82
Cafe arabica <i>Coffea arabica</i>	Matas de altitude	Mata Atlantica montana	0.66	0.38
Bananeira <i>Musa acuminata</i>	Tropicis umidos cultivados	Areas tropicais umidas antropizadas	0.92	0.18
Guandu <i>Cajanus cajan</i>	Tropicis sazonais	Savana tropical estacional	0.36	0.72
Goabeira <i>Psidium guajava</i>	Tropical sazonal	Transicao Cerrado-Mata Atlantica	0.52	0.55
Araucaria <i>Araucaria angustifolia</i>	Floresta ombrofila mista	Floresta com araucaria	0.48	0.5

Figura 3. Catálogo de espécies modeladas e respectivos atributos ecológicos resumidos.

0,86, tolerância à seca de 0,20 e pluviosidade anual de 2300 mm, características compatíveis com sua associação a ambientes úmidos e quentes.

Figura 4. Simulador de irrigação com entrada de variáveis ambientais e exibição do perfil ecológico da espécie.

Para avaliar o comportamento preditivo do sistema, foi implementado um painel de validação com métricas e comparação entre algoritmos. A Figura 5 mostra essa área da aplicação. Na rede neural principal, os resultados no conjunto de teste foram MAE de 0,195, RMSE de 0,246 e R^2 de 0,922. Esses valores indicam pequena diferença média entre predição e valor de referência dentro do conjunto utilizado no experimento. No conjunto de treinamento, a mesma rede apresentou MAE de 0,164, RMSE de 0,208 e R^2 de 0,949, o que indica diferença moderada entre treino e teste.

A comparação entre algoritmos mostrou que o problema pode ser parcialmente descrito por modelos mais simples, mas com melhor ajuste nas redes neurais. O *mean baseline* apresentou RMSE de 0,8807 e R^2 próximo de zero, servindo como referência

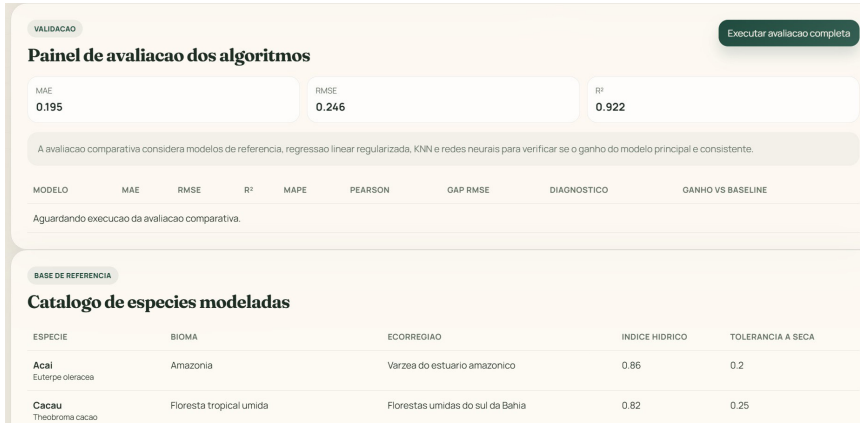


Figura 5. Painel de avaliação dos algoritmos e resumo das métricas do modelo principal.

mínima. A regressão Ridge obteve RMSE de 0,3428 e R^2 de 0,8485, mostrando que há relação linear entre parte das variáveis de entrada e a demanda hídrica. O KNN apresentou RMSE de 0,6497 e R^2 de 0,4557, com desempenho inferior aos demais modelos. Entre as redes neurais, a *shallow MLP* apresentou o melhor resultado, com RMSE de 0,2338 e R^2 de 0,9295, seguida pela *deep species MLP*, com RMSE de 0,2463 e R^2 de 0,9218. Assim, o aumento da profundidade não produziu melhoria adicional no conjunto atual, o que sugere que a formulação das entradas e a estrutura do problema já eram bem capturadas por uma rede menos profunda.

As métricas complementares seguiram a mesma tendência observada em RMSE e R^2 . A rede rasa apresentou MAPE de 4,44%, sMAPE de 4,45% e correlação de Pearson de 0,9646. A rede profunda apresentou MAPE de 4,67%, sMAPE de 4,68% e correlação de 0,9610. Esses valores mostram aproximação elevada entre valores previstos e valores alvo no conjunto de teste. O ganho percentual em RMSE em relação ao *mean baseline* foi superior a 72% nas redes neurais, enquanto a regressão Ridge apresentou ganho de aproximadamente 61%.

A Tabela 1 resume o desempenho dos algoritmos avaliados no conjunto de teste.

Modelo	MAE	RMSE	R^2	MAPE (%)	Pearson	Ganho vs baseline (%)
Mean baseline	0,6941	0,8807	-0,0001	17,23	0,0000	0,00
Ridge regression	0,2705	0,3428	0,8485	6,52	0,9212	61,08
KNN regression	0,5191	0,6497	0,4557	12,66	0,6774	26,22
Shallow MLP	0,1869	0,2338	0,9295	4,44	0,9646	73,46
Deep species MLP	0,1951	0,2463	0,9218	4,67	0,9610	72,04

Tabela 1. Comparação dos algoritmos no conjunto de teste.

O comportamento do sistema pode ser observado em um cenário específico para o cacau, mostrado na Figura 6. Nesse caso, foram informados temperatura de 30 °C, umidade relativa de 62%, umidade do solo de 50%, chuva acumulada de 2 mm em sete dias, radiação solar de 20 MJ/m², velocidade do vento de 3,5 m/s, fase vegetativa, vazão do emissor de 2 L/h e uma planta. O sistema processou essas entradas com base no perfil ecológico da espécie e gerou a recomendação apresentada na Figura 7.

Figura 6. Exemplo de cenário configurado para a espécie cacau.



Figura 7. Perfil ecológico do cacau e resultado da predição para o cenário simulado.

Para o cenário de exemplo com cacau, o sistema estimou volume diário de 6,05 L, volume semanal de 42,37 L e tempo de irrigação de 181,6 min. O perfil ecológico exibido para a espécie indica índice hídrico de 0,82, tolerância à seca de 0,25, temperatura ideal de 26°C e pluviosidade anual de 1800 mm. Como o cenário informado combinou chuva recente baixa e temperatura acima da ideal, a recomendação permaneceu em faixa mais alta, o que está de acordo com a descrição ecológica da espécie no sistema.

De forma geral, os resultados mostram que a proposta foi capaz de integrar atributos ecológicos, variáveis ambientais e aprendizado de máquina em uma aplicação funcional para estimativa de irrigação sensível à espécie. O painel de comparação mostrou que o desempenho do modelo principal não depende apenas de apresentação visual, mas de uma etapa explícita de avaliação frente a algoritmos

de referência. Ao mesmo tempo, deve-se considerar que os experimentos foram realizados sobre dados sintéticos gerados a partir de regras ecológicas e ambientais. Assim, os resultados devem ser interpretados como evidência de viabilidade metodológica e de consistência interna da abordagem. A estrutura implementada permite, em etapas futuras, substituir o conjunto sintético por dados observados em campo, mantendo a mesma organização de treinamento, avaliação e inferência.

CONCLUSÃO

Este trabalho apresentou um sistema de irrigação inteligente sensível à espécie, baseado em atributos ecológicos e modelos de aprendizado de máquina, com interface web para simulação e análise dos resultados. A proposta permitiu integrar informações de espécie, ambiente e fase fenológica em uma estrutura única de predição da demanda hídrica.

Os resultados mostraram que a abordagem foi capaz de produzir estimativas coerentes dentro do conjunto experimental, com bom desempenho das redes neurais em relação aos modelos de referência. A comparação entre algoritmos também indicou que a inclusão de atributos ecológicos contribuiu para diferenciar o comportamento hídrico entre as espécies modeladas.

Como o estudo utilizou dados sintéticos construídos a partir de perfis ecológicos, os resultados devem ser entendidos como uma demonstração de viabilidade da metodologia. Como continuidade, o sistema pode ser ampliado com dados reais de sensores, séries meteorológicas e experimentos de campo, permitindo sua aplicação em cenários agrícolas e agroflorestais com maior aderência às condições observadas.

REFERÊNCIAS

- Abioye, E. A., Hensel, O., Esau, T. J., Elijah, O., Abidin, M. S. Z., Ayobami, A. S., Yerima, O., and Nasirahmadi, A. (2022). Precision irrigation management using machine learning and digital farming solutions. *AgriEngineering*, 4(1):70–103.
- Benameur, R., Dahane, A., Kechar, B., and Benyamina, A. E. H. (2024). An innovative smart and sustainable low-cost irrigation system for anomaly detection using deep learning. *Sensors*, 24(4):1162.
- Kashyap, P. K., Kumar, S., Jaiswal, A., Prasad, M., and Gandomi, A. H. (2021). Towards precision agriculture: lot-enabled intelligent irrigation systems using deep learning neural network. *IEEE Sensors Journal*, 21(16):17479–17491.

Kurtulmus, E., Arslan, B., and Kurtulmus, F. (2022). Deep learning for proximal soil sensor development towards smart irrigation. *Expert Systems with Applications*, 198:116812.

Mghouchi, Y. E. and Udristioiu, M. T. (2025). Enhancing agricultural sustainability through intelligent irrigation using pvt energy applications: Implementing hybrid machine and deep learning models. *Agriculture*, 15(8):906.

Morchid, A., Elbasri, A., Oughannou, Z., Qjidaa, H., Alami, R. E., and Bossoufi, B. (2025). An innovative smart irrigation using embedded and regression-based machine learning technologies for improving water security and sustainability. *IEEE Access*, 13:100731–100751.

Sami, M., Khan, S. Q., Khurram, M., Farooq, M. U., Anjum, R., Aziz, S., Qureshi, R., and Sadak, F. (2022). A deep learning-based sensor modeling for smart irrigation system. *Agronomy*, 12(1):212.

Sarjerao, J. S., Sudhagar, G., and Jadhav, R. N. (2025). Sustainable smart irrigation in precision farming using iot. In *2025 International Conference on Emerging Smart Computing and Informatics (ESCI)*, pages 1–7.

Tyagi, S., Anand, R., Sabharwal, A., and Reddy, S. R. N. (2024). Plant recommendation system using smart irrigation integrated with iot and machine/deep learning. *Communications in Soil Science and Plant Analysis*, 55(16):2488–2508.