

Avaliação e Detecção Automática do Estresse Hídrico em Latossolo Vermelho-Amarelo: Uma Abordagem Híbrida Físico-Computacional

Fábio Volkmann Coelho
Universidade do Vale do Itajaí – UNIVALI
fabiovoelho05@gmail.com

Maurílio Fernandes de Oliveira
Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA
maurilio.oliveira@embrapa.br

Rafael da Mata Santiago Horta
Universidade Federal de São João Delrei – UFSJ
rafa.mshorta@gmail.com

Anita Maria da Rocha Fernandes
Universidade do Vale do Itajaí – UNIVALI
anita.fernandes@univali.br

Abstract

Accurate soil moisture monitoring is critical for precision agriculture. This study proposes a hybrid approach for water stress detection, integrating classic hydro-physical parameters (Field Capacity and Permanent Wilting Point) with machine learning algorithms. Using volumetric moisture (θ) data from capacitive sensors collected in a *Red-Yellow Latosol*, a *Decision Tree* classifier was trained to validate and automate the identification of stress episodes. The results demonstrated that the computational model converged to the same thresholds defined by laboratory analyses, achieving an accuracy greater than 99%. This highlights the viability of cyber-physical systems that combine the precision of hardware sensors with the decision robustness of artificial intelligence for irrigation management.

Keywords

ESTRESSE HÍDRICO, LATOSSOLO, UMIDADE DO SOLO, MANEJO DE IRRIGAÇÃO

1 Introdução

A disponibilidade de água no solo é um fator central que controla a atividade fisiológica das plantas e a produtividade agrícola. Variações na umidade do solo afetam a condutância estomática, a transpiração do dossel e a assimilação de carbono, determinando assim o crescimento e a produtividade das culturas tanto em regimes de sequeiro quanto irrigados [1, 2]. Quando a umidade do solo diminui a níveis em que as plantas não conseguem mais extrair água, ocorre o estresse hídrico, reduzindo o crescimento; quantificar seu início e intensidade é, portanto, essencial para estudos de fisiologia vegetal, manejo da irrigação e monitoramento de secas [3, 4].

A descrição pedo-hidrológica clássica da água disponível para as plantas baseia-se em dois estados de referência: a *Capacidade de Campo* (FC) e o *Ponto de Murcha Permanente* (PWP). A FC é normalmente definida como o teor de água volumétrica retido após o término da drenagem gravitacional (frequentemente medida em um potencial matricial específico), enquanto o PWP representa o potencial matricial mais baixo no qual as plantas não conseguem recuperar o turgor [1, 5, 6]. A diferença entre FC e PWP gera a *Água Disponível para as Plantas* (PAW, também chamada de *Água Total Disponível* – TAW ou *Capacidade de Água Disponível* – CAD em algumas literaturas), que constitui o reservatório fundamental de água disponível para as raízes [7, 8].

Um indicador prático amplamente utilizado para monitoramento de seca e estresse hídrico é a fração da PAW remanescente em determinado momento – frequentemente chamada de *Água Extraível Relativa* (REW) ou porcentagem da água total disponível (%TAW). Com base apenas na umidade volumétrica (θ), FC e PWP, esses indicadores são calculados como:

$$AW \text{ (instantânea)} = FC - \theta, \quad (1)$$

$$\%TAW = \frac{(FC - \theta) \times 100}{(FC - PWP)}. \quad (2)$$

A REW ou %TAW tem sido amplamente empregada como indicador baseado em limiares de estresse: muitos estudos experimentais e de modelagem adotam uma REW crítica entre 0,3 e 0,4 (isto é, 30–40% da PAW remanescente) como o início de efeitos limitantes de transpiração ou de estresse hídrico sobre o crescimento [9–11]. Esse limiar tem se mostrado útil em estudos com árvores, arbustos e culturas agrícolas, embora a fisiologia da espécie e as características do sistema radicular possam alterar o valor crítico exato [3].

Apesar de sua simplicidade, o arcabouço FC–PWP– θ apresenta limitações conceituais e práticas que têm motivado uma literatura prolífica. Primeiramente, a *definição e medição* de FC e PWP variam entre protocolos: FC pode ser reportada em diferentes potenciais matriciais (por exemplo, –10 a –33 kPa), e o PWP é frequentemente associado ao conteúdo de água em –1500 kPa, embora proxies operacionais de campo sejam amplamente empregados [8, 12]. Trabalhos recentes enfatizam uma interpretação funcional da FC (como o solo se comporta in situ após umedecimento) e questionam o uso de um único valor estático para perfis heterogêneos [5, 6]. Em segundo lugar, os pontos de retenção determinados em laboratório (placa de pressão) são precisos, porém escassos; funções de pedo-transferência (PTFs) e preditores empíricos têm sido amplamente desenvolvidos para estimar FC e PWP a partir da textura do solo, densidade aparente e matéria orgânica, com incertezas variáveis conforme a calibração regional [12–14]. Estudos recentes também exploram abordagens baseadas em fluxos e dinâmicas para estimar a PAW de relevância funcional [7].

Em terceiro lugar, o mapeamento entre conteúdo de água volumétrica e disponibilidade hídrica para as plantas negligencia aspectos como a distribuição radicular, a profundidade efetiva das raízes e as dinâmicas temporais da absorção; assim, a %TAW calculada a partir de medições pontuais deve ser interpretada como um índice centrado no solo, e não como um balanço completo de água da planta

[15]. Entretanto, em muitas redes de sensores e conjuntos de dados de longo prazo sobre umidade do solo — onde apenas θ , FC e PWP estão disponíveis — expressar a razão da porcentagem de Água Total Disponível (%TAW) ou da Água Extraível Relativa (REW), isto é, $\frac{(FC-\theta)}{(FC-PWP)}$, continua sendo uma métrica transparente, reproduzível e amplamente aceita para identificar o início da limitação hídrica do solo e do estresse das culturas [16].

Estudos aplicados ilustram tanto a utilidade quanto as limitações dessa abordagem. Modelos de culturas e análises experimentais frequentemente utilizam fatores de estresse baseados em PAW para relacionar a depleção de umidade do solo à redução de transpiração e produtividade [7, 15]. Em operações de monitoramento de seca e agendamento de irrigação, a REW derivada de sensores informa alertas e decisões de irrigação quando dados meteorológicos estão ausentes ou são pouco confiáveis [17, 18]. Por outro lado, erros de medição em FC/PWP, heterogeneidade espacial e incerteza na profundidade da zona radicular podem resultar em classificações incorretas de estresse se não forem explicitamente considerados [12, 13].

Diante desse corpo de literatura, o objetivo deste manuscrito é avaliar o estresse hídrico em cultivos agrícolas utilizando apenas as variáveis disponíveis em nosso banco de dados — umidade volumétrica do solo (θ), Capacidade de Campo (FC) e Ponto de Murcha Permanente (PWP). Ao focar em PAW e %TAW como indicadores centrais, buscamos (i) estabelecer um método reproduzível e fundamentado na literatura para detecção de estresse em contextos com dados limitados, (ii) quantificar a sensibilidade da detecção de estresse às incertezas comuns na estimativa de FC e PWP, e (iii) ilustrar aplicações e limitações com séries temporais exemplificativas. Dessa forma, fundamentamos nossa abordagem em trabalhos clássicos e recentes sobre estimativa de PAW, pedotransferência e limiares de REW, situando-a dentro da literatura hidrológica e agrônômica contemporânea [1, 3, 5, 7, 11].

2 Materiais e Métodos

2.1 Base de Dados e Caracterização do Solo

Os dados analisados foram obtidos por sensores capacitivos de umidade do solo instalados em profundidades de 30, 60, 90 e 120 cm, em uma área agrícola localizada no município de Sete Lagoas – MG. Embora o banco de dados contenha medições nessas quatro profundidades, o cálculo do estresse hídrico foi conduzido com base na camada superficial de 0–30 cm, por ser a zona de exploração radicular predominante durante o estágio fenológico em que as mudas se encontravam. Esse procedimento segue recomendações de manejo que consideram a profundidade efetiva das raízes em plantas jovens.

O solo da área experimental é classificado como *Latossolo Vermelho-Amarelo distrófico*, com granulometria aproximada de 75% de argila, 15% de silte e 10% de areia. Esse tipo de solo apresenta elevada retenção hídrica, o que permitiu a determinação precisa dos parâmetros físico-hídricos laboratoriais necessários para o cálculo do estresse.

2.2 Dados Meteorológicos Auxiliares

Para fins de validação cruzada e análise qualitativa dos períodos de estresse, foram utilizados dados meteorológicos históricos da

estação automática do Instituto Nacional de Meteorologia (INMET), situada próxima à área experimental. As variáveis coletadas incluíram precipitação pluvial diária (mm) e temperatura máxima/média (°C).

Ressalta-se que esses dados meteorológicos não foram utilizados como atributos de entrada (features) para o treinamento do modelo computacional. Sua função restringiu-se à validação fenomenológica, permitindo confirmar se os episódios de estresse classificados pelo algoritmo correspondiam, de fato, a eventos climáticos reais de veranico ou alta demanda atmosférica.

2.3 Parâmetros Físico-Hídricos: CC, PMP e Água Disponível

Com base nas análises laboratoriais, foram obtidos os seguintes parâmetros:

- Capacidade de Campo (CC): teor de água retido após drenagem livre.
- Ponto de Murcha Permanente (PMP): umidade na qual a planta não consegue mais extrair água.

A *Água Disponível* (AD) foi calculada conforme a literatura clássica de manejo da água no solo [1]:

$$AD = CC - PMP \quad (3)$$

2.4 Coeficiente de Depleção (p) e Definição da Fração de Água Disponível (FAD)

A determinação do ponto em que a planta passa a sentir estresse hídrico depende da fração da água disponível que pode ser consumida antes que haja prejuízo fisiológico. Esta fração é expressa pelo *coeficiente de depleção* p , um parâmetro agronomicamente estabelecido e dependente:

- da cultura;
- do estágio fenológico;
- do tipo de solo;
- das condições ambientais.

Segundo a FAO-56 [1], o valor típico de p para culturas moderadamente sensíveis varia entre 0.50 e 0.60. As recomendações práticas fornecidas pelo especialista agrícola responsável pelo manejo local indicaram o uso de $p = 0.55$, que representa uma condição intermediária e mais adequada ao cultivo e ao estágio de desenvolvimento específico do experimento.

Assim, a *Fração de Água Disponível* crítica foi calculada como:

$$FAD = p \times (CC - PMP) \quad (4)$$

2.5 Cálculo do Limite Crítico (LC)

O *Limite Crítico* de umidade do solo, abaixo do qual ocorre estresse hídrico, é obtido a partir da relação:

$$LC = CC - FAD \quad (5)$$

A substituição dos valores laboratoriais medidos para o Latossolo local, juntamente com $p = 0.55$, resultou em:

$$LC = 207$$

Este valor permaneceu constante ao longo de toda a análise, pois depende exclusivamente das propriedades físico-hídricas do solo e do coeficiente de depleção adotado.

2.6 Cálculo da Lâmina Atual (LA)

A umidade volumétrica (θ) registrada pelo sensor foi convertida para lâmina de água acumulada no perfil utilizando o fator de conversão direta:

$$LA = \theta \times 300 \quad (6)$$

Este fator de 300 corresponde ao volume de água na camada de 0–30 cm sobre uma área de 1 m², considerando que:

- a profundidade da camada é 0.30 m;
- 1 mm de lâmina equivale a 1 L por metro quadrado.

Dessa forma, o cálculo da LA representa fielmente a água armazenada na camada superficial, que é hidrologicamente relevante para a cultura no estágio analisado.

2.7 Critério de Classificação do Estresse Hídrico

Com a LA e o LC definidos, o estresse hídrico foi determinado de maneira binária, seguindo:

$$\text{Estresse} = \begin{cases} 1, & \text{se } LA < LC \\ 0, & \text{se } LA \geq LC \end{cases} \quad (7)$$

Esse critério, fundamentado em literatura clássica de manejo da água no solo, é amplamente utilizado pela FAO e por diversos estudos que avaliam a depleção de água no solo em relação à disponibilidade para as plantas.

2.8 Pré-processamento e Balanceamento de Classes

A análise inicial dos dados revelou um desequilíbrio significativo entre as classes, com uma prevalência natural de amostras da classe "Sem Estresse" (classe majoritária) em relação à classe "Estresse" (classe minoritária). O treinamento de modelos de aprendizado de máquina em dados desbalanceados frequentemente resulta em um viés de predição, onde o algoritmo tende a favorecer a classe majoritária para minimizar o erro global, prejudicando a sensibilidade na detecção do evento de interesse [19].

Para mitigar este problema, aplicou-se a técnica SMOTE (*Synthetic Minority Over-sampling Technique*). Estudos comparativos demonstram que o SMOTE supera métodos simples de superamostragem ao evitar o sobreajuste excessivo (*overfitting*) gerado pela mera duplicação de dados [20]. A técnica gera dados sintéticos interpolando novas instâncias entre amostras da classe minoritária e seus vizinhos mais próximos (*k*-nearest neighbors) no espaço de características [21].

O procedimento de balanceamento foi aplicado exclusivamente ao conjunto de treinamento, preservando a distribuição original dos dados nos conjuntos de validação e teste para garantir uma avaliação realista do desempenho do modelo em condições de campo. Após a aplicação do SMOTE, o conjunto de treino atingiu uma distribuição de classes equiprovável (50%/50%), eliminando o viés estatístico prévio.

2.9 Modelagem Computacional e Classificação

Para automatizar a decisão de estresse hídrico baseada nos dados do sensor, optou-se pela utilização do algoritmo de Árvore de Decisão (*Decision Tree Classifier*). Especificamente, utilizou-se a metodologia CART (*Classification and Regression Trees*) [22], que trata o problema como uma tarefa de *Classificação Binária Supervisionada*. O vetor de características X é composto pela leitura do sensor (θ) e a variável alvo Y é o estado de estresse (0 ou 1).

A Árvore de Decisão é um modelo estruturado em grafo que particiona o espaço de dados recursivamente através de regras lógicas. A escolha deste algoritmo justifica-se por três fatores computacionais fundamentais:

- (1) Interpretabilidade (White-box): Diferente de abordagens "caixa-preta", o modelo gera uma estrutura transparente de regras ("Se-Então"), permitindo a inspeção da lógica de decisão [23].
- (2) Eficiência Algorítmica: A complexidade de tempo para inferência é proporcional à profundidade da árvore ($O(\log n)$), garantindo decisões rápidas com baixo custo computacional [24].
- (3) Adaptação a Limites Rígidos: Sendo um método não-paramétrico, o algoritmo adapta-se naturalmente a fronteiras de decisão ortogonais (limiares fixos), refletindo a natureza dos parâmetros físicos do solo.

O conjunto de dados foi dividido seguindo a estratégia de *Hold-out* (80% treino, 20% teste). A métrica de otimização utilizada para avaliar a qualidade das divisões nos nós foi o índice *Gini Impurity*, visando maximizar a pureza das classes nas folhas [22].

3 Resultados

3.1 Comportamento da Umidade do Solo e da Lâmina de Água (LA)

A análise exploratória inicial mostrou que a umidade volumétrica do solo (θ), medida pelo sensor na profundidade efetiva de 30 cm, apresentou flutuações consistentes com eventos de chuva e períodos de secagem. A conversão direta para lâmina de água ($LA = \theta \times 300$) evidenciou a dinâmica hídrica diária na camada explorada pelas raízes.

Ao comparar os valores de LA com o Limite Crítico ($LC = 207$ mm), observou-se que a maior parte das condições de estresse ocorreu nos períodos de baixa precipitação. Em momentos chuvosos, a LA aumentou rapidamente, retornando acima do LC e caracterizando ausência de estresse hídrico. Esses resultados corroboram a adequação da camada de 0–30 cm como zona de análise, já que pequenas variações de chuva produziram respostas rápidas no sensor.

3.2 Identificação de Estresse Hídrico

Aplicando o critério definido nos Métodos (estresse = 1 quando $LA < LC$), o conjunto de dados foi classificado em condições de estresse e não estresse. Observou-se que:

- Períodos prolongados sem precipitação resultaram em LA persistentemente abaixo de 207 mm.
- Em curtos períodos chuvosos, a recuperação da umidade foi suficiente para reverter o estresse imediatamente.

- O comportamento de classificação refletiu fielmente a dinâmica esperada de um Latossolo argiloso: alta capacidade de retenção, porém resposta rápida na camada superficial.

Esses padrões são coerentes com a literatura, que indica que solos altamente argilosos apresentam elevada água disponível, mas podem atingir rapidamente o limite de depleção quando expostos a condições atmosféricas de alta demanda evaporativa [1].

3.3 Desempenho do Modelo de Classificação

Para avaliar a capacidade preditiva da abordagem, um modelo de Árvore de Decisão foi treinado utilizando como entrada apenas a umidade medida pelo sensor e como rótulo o estresse calculado pelo critério hidráulico ($LA < LC$). O modelo alcançou acurácia superior a 99% tanto em treino quanto em teste.

Embora tal desempenho possa sugerir sobreajuste, essa alta precisão é um resultado esperado devido à natureza determinística do problema. Como o estresse hídrico é definido por um limiar fixo sobre a própria variável de entrada (θ), o algoritmo aprende de forma direta a fronteira de decisão:

$$\theta < \frac{LC}{300} \Rightarrow \text{estresse}$$

Nesse caso, a árvore simplesmente identifica o ponto de corte equivalente a:

$$\theta_{crit} = \frac{207}{300} \approx 0.69$$

O modelo, portanto, não está “generalizando” no sentido clássico, mas reproduzindo fielmente o critério físico que fundamenta o rótulo. Isso demonstra que, para o solo específico estudado, o sensor sozinho fornece informações suficientes para detectar o estresse hídrico quando os parâmetros físico-hídricos (CC, PMP e p) são previamente conhecidos.

3.4 Análise da Árvore de Decisão e Validação dos Limiares

A avaliação do modelo computacional revelou uma convergência direta entre a regra física determinística e a fronteira de decisão aprendida pelo algoritmo de Árvore de Decisão. A acurácia obtida nos dados de teste foi superior a 99%, demonstrando que o balanceamento via SMOTE foi eficaz em prevenir o enviesamento do modelo, garantindo alta taxa de acertos também para a classe minoritária (Estresse), com métricas de Precisão, Revocação (Recall) e F1-Score atingindo valores máximos.

A inspeção da estrutura da árvore confirmou matematicamente a premissa agrônoma. A variável *Umidade Arado 0-30cm* foi selecionada pelo algoritmo como o atributo discriminador primário (nó raiz), definindo um ponto de corte (θ_{split}) estatisticamente equivalente ao Limite Crítico (LC) calculado via parâmetros de laboratório.

Do ponto de vista de aprendizado de máquina, este resultado indica que o sensor de hardware fornece um sinal com alta separabilidade linear para este tipo de solo [24]. A Árvore de Decisão, portanto, atuou como uma ferramenta de validação guiada por dados (“Data-Driven Validation”): a capacidade do algoritmo de deduzir o limiar de estresse sem regras explícitas de programação corrobora a consistência dos dados coletados.

3.5 Validação Cruzada com Dados Meteorológicos

O confronto entre os períodos de estresse identificados automaticamente pelo modelo e os registros climáticos independentes do INMET [25] revelou uma alta consistência física. A análise qualitativa das séries temporais demonstrou que:

- Os momentos classificados como Estresse (1) coincidiram sistematicamente com janelas de ausência prolongada de chuva e elevada demanda evaporativa registrada na estação meteorológica;
- Os momentos classificados como Sem Estresse (0) alinharam-se com os registros de precipitação recente ou baixa temperatura média.

Essa correlação valida a capacidade do sensor e do algoritmo de capturar a dinâmica hídrica real do solo, atuando como um indicador fiel das condições macroclimáticas locais sem depender de conexão direta com estações meteorológicas.

3.6 Limitações Intrínsecas e Expectativas de Generalização

Apesar da alta acurácia dentro do ambiente estudado, os resultados devem ser interpretados considerando que:

- O valor de $LC = 207$ é totalmente dependente das características físico-hídricas do *Latossolo Vermelho-Amarelo distrófico*.
- Variações em textura, densidade do solo ou estrutura podem alterar significativamente CC, PMP e, portanto, o LC.
- O coeficiente de depleção $p = 0.55$ é específico do cultivo e do estágio fenológico.

Assim, embora o método seja sólido do ponto de vista físico, sua aplicação a outros tipos de solo requer nova parametrização. Os resultados, porém, demonstram claramente que:

quando CC, PMP e p são conhecidos para o solo e cultura específicos, a simples leitura do sensor de umidade é suficiente para determinar o estresse hídrico com precisão.

4 Conclusão

O presente estudo demonstrou que a identificação do estresse hídrico pode ser realizada de forma eficiente utilizando exclusivamente dados de sensores de umidade do solo combinados com parâmetros físico-hídricos determinados em laboratório (CC, PMP, AD e LC). Mesmo adotando um modelo simples de classificação — cuja lógica reflete diretamente a relação determinística entre a lâmina atual (LA) e o limite crítico (LC) — foi possível alcançar elevada acurácia na identificação do estado hídrico do solo. Esse resultado confirma que, para solos homogêneos e bem caracterizados, como o Latossolo Vermelho-Amarelo Distrófico analisado, a abordagem baseada em regras físicas apresenta desempenho equivalente ou superior ao de modelos de aprendizado de máquina mais complexos.

Entretanto, a principal limitação identificada é justamente a especificidade do modelo. Os parâmetros utilizados (AD, CTA, coeficiente de depleção e, consequentemente, LC) refletem condições físico-hídricas particulares de Sete Lagoas – MG, não podendo ser generalizados para outros tipos de solo sem nova calibração. Da

mesma forma, a profundidade de influência das raízes, diretamente relacionada à determinação da LA, varia entre culturas e estágios fenológicos, demandando ajustes dinâmicos para aplicações em sistemas agrícolas diversificados.

O estudo integrou a pedologia clássica com técnicas de Ciência de Dados para monitoramento de irrigação. A aplicação do classificador *Decision Tree* sobre os dados de sensores capacitivos demonstrou que a detecção de estresse hídrico pode ser automatizada com extrema precisão quando o hardware é calibrado corretamente para o tipo de solo específico.

A principal contribuição computacional deste trabalho não reside na complexidade do modelo, mas na demonstração de que algoritmos de aprendizado de máquina podem replicar fielmente o conhecimento físico-hídrico especializado. Isso abre caminho para o desenvolvimento de controladores de irrigação baseados em *Edge Computing*, onde modelos leves como o treinado neste estudo podem ser embarcados diretamente em microcontroladores acoplados aos sensores, permitindo decisões de irrigação descentralizadas e em tempo real, independentemente de conectividade com a nuvem.

Como perspectivas futuras, destacam-se:

- a ampliação do banco de dados para incluir diferentes classes de solos e profundidades;
- a incorporação de modelos que ajustem o coeficiente de depleção (p) de forma dinâmica com base na cultura e no estágio de desenvolvimento;
- a aplicação de abordagens híbridas que combinem regras físico-hídricas com modelos de aprendizado de máquina generalizáveis;
- a validação em condições reais de campo com variações sazonais e regimes pluviométricos distintos.

Dessa forma, o trabalho não apenas demonstra a viabilidade técnica da identificação de estresse hídrico por meio de sensores e parâmetros físicos do solo, mas também estabelece uma base sólida para a construção de modelos mais robustos e escaláveis, capazes de atender a diferentes ambientes agrícolas.

Acknowledgments

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e da Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina (FAPESC).

References

- [1] Richard G. Allen, Luis S. Pereira, Dirk Raes, and Martin Smith. *Crop evapotranspiration: Guidelines for computing crop water requirements*. FAO Irrigation and Drainage Paper No. 56. Food and Agriculture Organization of the United Nations, Rome, 1998.
- [2] J. E. Fernández, C. Michelazzo, J. M. Torres-Ruiz, J. Flexas, L. Sebastiani, and A. Di az Espejo. Regulation of photosynthesis and stomatal and mesophyll conductance under water stress and recovery in olive trees. *Journal of Experimental Botany*, 65(12):3143–3156, 2014.
- [3] Ying Qiao, Huijie Yin, and Hongyan Liu. Relative extractable soil water and its relationship with plant water status: A review. *Frontiers in Plant Science*, 13:874932, 2022.
- [4] Z. A. Bello et al. Characterisation and effects of different levels of water stress on crops. *Plants*, 2022.
- [5] Isabelle Cousin, François Tardieu, and Benoît Vandoorne. Available water capacity from a multidisciplinary and functional perspective. *Geoderma*, 425:116052, 2022.
- [6] P. Nasta et al. Revisiting the definition of field capacity as a functional parameter. *Agricultural Water Management*, 2023.
- [7] Rafael A. C. de Melo, Rodrigo Cichota, and Quirijn de Jong van Lier. Plant available water predicted by a flux-based approach. *Geoderma*, 433:116482, 2023.
- [8] H. Asgarzadeh et al. Determination of soil available water for plants. *Geoderma*, 2014.
- [9] A. Granier and N. Breda. The water balance of forests and the biljou model (biljou99). *Reference Model*, 1999. Cited in later works for REW thresholds.
- [10] J. Sopharat et al. A simple framework to analyze water constraints on vegetation growth. *Frontiers in Plant Science*, 2015.
- [11] Marcelo Zeri, Daniel A. Vieira, and Carlos A. Andrade. Tools for communicating agricultural drought over the Brazilian semiarid region. *Water*, 10(11):1533, 2018.
- [12] R. A. C. Rosseti et al. Pedotransfer functions for predicting soil-water retention in cerrado soils. *Pesquisa Agropecuária Brasileira*, 2022.
- [13] D. K. Bagnall et al. Carbon-sensitive pedotransfer functions for plant available water. *Soil Science Society of America Journal*, 2022.
- [14] J. P. Amsili et al. Pedotransfer functions for field capacity, permanent wilting point and available water capacity. *International Journal of Soil Science*, 2024.
- [15] S. A. Saseendran et al. Quantifying crop water stress factors from soil water content. *Agricultural Systems*, 2015.
- [16] R. G. Allen, L. S. Pereira, D. Raes, and M. Smith. Crop evapotranspiration: Guidelines for computing crop water requirements – chapter 8: et_c under soil water stress conditions. Technical Report Irrigation and Drainage Paper 56, FAO, 1998.
- [17] P. D. Colaizzi et al. Using plant canopy temperature to improve irrigated crop management. *Central Plains Irrigation Conference*, 2012.
- [18] O. Cappelluti et al. The use of mixed composed amendments to improve soil water status and rew. *Water*, 15(9):1708, 2023.
- [19] Haibo He and Edwardo A Garcia. Learning from imbalanced data. *IEEE Transactions on knowledge and data engineering*, 21(9):1263–1284, 2009.
- [20] Gustavo EAPA Batista, Ronaldo C Prati, and Maria Carolina Monard. A study of the behavior of several methods for balancing machine learning training data. *ACM SIGKDD explorations newsletter*, 6(1):20–29, 2004.
- [21] Nitesh V. Chawla, Kevin W. Bowyer, Lawrence O. Hall, and W. Philip Kegelmeyer. Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16:321–357, 2002.
- [22] Leo Breiman, Jerome Friedman, Charles J Stone, and Richard A Olshen. *Classification and Regression Trees*. CRC press, 1984.
- [23] Christoph Molnar. *Interpretable Machine Learning*. Lulu.com, 2020. <https://christophm.github.io/interpretable-ml-book/>.
- [24] Trevor Hastie, Robert Tibshirani, and Jerome Friedman. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer Science & Business Media, 2009.
- [25] Instituto Nacional de Meteorologia (INMET). Banco de dados meteorológicos para ensino e pesquisa (bdmep). <https://portal.inmet.gov.br/dadoshistoricos>, 2024. Acessado em: 10 dez. 2025.