



Desenvolvimento e Validação Local de Funções de Pedotransferência para Parâmetros Hídricos na Bacia Hidrográfica do Rio Una (SP): Uma Abordagem Comparativa entre Modelos Lineares e Redes Neurais

Desarrollo y Validación Local de Funciones de Pedotransferencia para Parámetros Hídricos del Suelo en la Cuenca Hidrográfica del Río Una (SP): Un Enfoque Comparativo entre Modelos Lineales y Redes Neuronales Artificiales

Local Development and Validation of Pedotransfer Functions for Soil Hydraulic Parameters in the Una River Watershed (SP): A Comparative Approach between Linear Models and Artificial Neural Networks

Ingrid Larissa Gomes Barbosa¹

Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba, Brasil.
ingrid.barbosa@unesp.br | 0000-0002-5470-050X

Bruna Henrique Sacramento²

Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba, Brasil.
bruna.sacramento@unesp.br | 0000-0003-3230-5944

Arthur Pereira dos Santos³

Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba, Brasil.
arthur.p.santos@unesp.br | 0000-0002-1913-3562

¹ Engenheira Ambiental pela Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia de Sorocaba, Brasil.

² Doutora e Mestra em Ciências Ambientais pela Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia de Sorocaba, na linha de pesquisa em Geoprocessamento e Modelagem Matemática Ambiental. Engenheira Ambiental pela Universidade Tecnológica Federal do Paraná (UTFPR), campus Londrina.

³ Doutor em Ciências Ambientais pelo Programa de Pós-Graduação em Ciências Ambientais da Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia de Sorocaba, atuando na linha de pesquisa em Geoprocessamento e Modelagem Matemática Ambiental. Mestre em Meio Ambiente e Qualidade Ambiental pela Universidade Federal de Uberlândia (UFU) (2020), na linha de pesquisa em Gestão e Monitoramento Ambiental. Engenheiro Ambiental e Sanitarista pela Universidade do Oeste Paulista (2018), com especialização em Engenharia de Produção pela Universidade Federal de Juiz de Fora (UFJF) (2024).



Alessandro Xavier da Silva Junior⁴

Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba, Brasil.
alessandro.junior@unesp.br | 0009-0005-5592-7684

⁵ Darllan Collins da Cunha e Silva⁵

Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba, Brasil.
darllan.collins@unesp.br | 0000-0003-3280-0478

Para citar este artigo: Barbosa, I., Sacramento, B., Santos, A., Silva Junior, A. e Silva, D. (2026). Desenvolvimento e Validação Local de Funções de Pedotransferência para Parâmetros Hídricos na Bacia Hidrográfica do Rio Una (SP): Uma Abordagem Comparativa entre Modelos Lineares e Redes Neurais. *Entorno Geográfico*, (31), e20615086. <https://doi.org/10.25100/eg.v0i31.15086>

Resumo

A previsão da Capacidade de Campo (CC) e do Ponto de Murcha Permanente (PMP) é fundamental para o manejo eficiente do solo e para a sustentabilidade agrícola, como na Bacia Hidrográfica do Rio Una (BHRU), localizada no estado de São Paulo, Brasil, e destaque pela presença da agricultura irrigada, exigindo manejo adequado às suas particularidades. Este estudo avalia a eficiência de Funções de Pedotransferência (FPT) geradas por Regressão Múltipla Linear (RML) e Redes Neurais Artificiais (RNAs) na estimativa de CC e PMP a partir de frações granulométricas e teor de Matéria Orgânica (MO). Analisou-se 35 amostras de solo (0–20 cm) e os modelos foram implementados em ambiente Python. A RML destacou-se pela simplicidade e eficiência, com R^2 de até 0,59 para CC e 0,87 para PMP, exigindo menor número de variáveis e menor custo computacional. Já as RNAs atingiram R^2 de até 0,73 para CC, com maior complexidade computacional e uso de bases de dados mais consistentes. Os resultados demonstram que ambas as metodologias oferecem soluções adaptáveis para a estimativa de parâmetros hídricos do solo, e a incorporação dessas ferramentas nos sistemas de manejo agrícola é estratégica para aumentar a eficiência no uso da água e promover práticas sustentáveis.

Palavras-chave: sustentabilidade agrícola, mudanças climáticas, agricultura irrigada, segurança alimentar e Python

⁴ Mestrando em Ciências Ambientais pelo Programa de Pós-Graduação em Ciências Ambientais da Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia de Sorocaba, na linha de pesquisa em Geoprocessamento e Modelagem Matemática Ambiental. Engenheiro Ambiental pela Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia de Sorocaba (2024), e Técnico em Meio Ambiente pelo Instituto Federal de São Roque (2019).

⁵ Professor Assistente Doutor na Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia de Sorocaba, Brasil.

Resumen

La predicción de la Capacidad de Campo (CC) y el Punto de Marchitez Permanente (PMP) es fundamental para el manejo eficiente del suelo y la sostenibilidad agrícola, como en la Cuenca Hidrográfica del Río Una (CHRU), ubicada en el estado de São Paulo, Brasil, destacada por su agricultura irrigada, que requiere un manejo adaptado a sus particularidades. Este estudio evalúa la eficiencia de Funciones de Pedotransferencia (FPT) generadas por Regresión Lineal Múltiple (RLM) y Redes Neuronales Artificiales (RNA) en la estimación de CC y PMP a partir de fracciones granulométricas y contenido de Materia Orgánica (MO). Se analizaron 35 muestras de suelo (0–20 cm), y los modelos se implementaron en entorno Python. La RLM destacó por su simplicidad y eficiencia, con R^2 de hasta 0.59 para CC y 0.87 para PMP, requiriendo menos variables y menor costo computacional. Por otro lado, las RNA alcanzaron R^2 de hasta 0.73 para CC, pero con mayor complejidad computacional y necesidad de bases de datos más extensas. Los resultados demuestran que ambas metodologías ofrecen soluciones adaptables para la estimación de parámetros hídricos del suelo, y su incorporación en sistemas de manejo agrícola es estratégica para aumentar la eficiencia en el uso del agua y promover prácticas sostenibles.

Palabras clave: sostenibilidad agrícola, cambio climático, agricultura de riego, seguridad alimentaria y Python

Abstract

The prediction of Field Capacity (FC) and Permanent Wilting Point (PWP) is essential for efficient soil management and agricultural sustainability, as in the Una River Watershed (URW), located in the state of São Paulo, Brazil, a region notable for its irrigated agriculture, which requires management tailored to its specific conditions. This study evaluates the efficiency of Pedotransfer Functions (PTFs) generated by Multiple Linear Regression (MLR) and Artificial Neural Networks (ANNs) in estimating FC and PWP from granulometric fractions and Organic Matter (OM) content. We analyzed 35 soil samples (0–20 cm), and the models were implemented in a Python environment. MLR stood out for its simplicity and efficiency, achieving R^2 values of up to 0.59 for FC and 0.87 for PWP, requiring fewer variables and lower computational costs. Meanwhile, ANNs reached R^2 values of up to 0.73 for FC but demanded greater computational complexity and more larger datasets. The results demonstrate that both methodologies provide adaptable solutions for estimating soil hydraulic parameters, and their integration

into agricultural management systems is strategic for improving water-use efficiency and promoting sustainable practices.

Keywords: agricultural sustainability, climate change, irrigated agriculture, food security and Python

Recebido: 6 de julho de 2025

Avaliado: 25 de fevereiro de 2026

Aceito: 9 de março de 2026

Publicado: 20 de março de 2026

1. Introdução

A intensificação das atividades agrícolas nas últimas décadas tem elevado a demanda por práticas de manejo sustentável que assegurem a manutenção da capacidade produtiva dos solos, respeitando suas limitações intrínsecas e potencialidades edafoclimáticas (Al-Shammary et al., 2024; Zhang et al., 2020).

Nesse sentido, a conservação dos recursos naturais e o uso racional da terra assumem papel central, especialmente em regiões submetidas a uso intensivo e a impactos ambientais significativos (Gomes et al., 2025). Nesse viés, destaca-se a importância do manejo do solo como prática conservacionista fundamental para mitigar processos degradativos como erosão hídrica, transporte superficial de nutrientes e assoreamento de corpos d'água, diretamente influenciados pelas condições geoambientais das áreas agrícolas (Du et al., 2022; Santos et al., 2025a; Xiong et al., 2018).

Convém ressaltar que a irrigação, embora indispensável para a agricultura intensiva, representa aproximadamente 70% do consumo global de água doce, posicionando-se como o maior vetor de influência negativa sobre os recursos hídricos de (Food and Agriculture Organization of the United Nations [FAO], 2020). Ademais, a crescente variabilidade climática e a frequência de eventos de seca prolongada agravam esse cenário, reforçando a necessidade de estratégias que otimizem a eficiência hídrica na agricultura. Assim, a caracterização precisa das propriedades físico-hídricas do solo torna-se um fator determinante para a sustentabilidade do uso da água (Abebaw, 2025).

Diante do exposto, destaca-se a Água Disponível (AD), definida como a diferença entre a Capacidade de Campo (CC) e o Ponto de Murcha Permanente (PMP), que corresponde à fração de umidade efetivamente acessível às plantas (Lankford e Orr, 2022). A CC

representa o teor de água retido após o escoamento gravitacional, enquanto o PMP delimita o limite inferior da disponibilidade hídrica para as raízes.

A precisão na estimativa desses parâmetros é imprescindível para o planejamento agrícola, dimensionamento de sistemas de irrigação e manejo eficiente dos cultivos (Amsili et al., 2024; Liu e Ma, 2024). Contudo, a determinação laboratorial direta desses atributos apresenta custos elevados e limitações logísticas, sobretudo em estudos de larga escala (Farooq et al., 2024).

Diante dessa limitação, Funções de Pedotransferência (FPT) surgem como alternativa eficiente, possibilitando a estimativa indireta de propriedades físico-hídricas a partir de atributos de fácil mensuração, como granulometria e teor de Matéria Orgânica (MO) (Silva et al., 2023a). Essa abordagem reduz custos e tempo, além de viabilizar a obtenção de dados essenciais para o manejo edafoclimático (Ramos et al., 2023). Todavia, para o desenvolvimento dessas funções, métodos estatísticos são fundamentais. Entre esses, a Regressão Múltipla Linear (RML) destaca-se pela capacidade de modelar variáveis resposta a partir de múltiplos preditores (Chen et al., 2022).

O conceito de FPT foi formalmente introduzido por Bouma (1989), ao propor o uso de dados de levantamento de solos para avaliações quantitativas da terra. Desde então, modelos clássicos baseados em regressão têm sido utilizados para estimar propriedades hidráulicas a partir de atributos básicos do solo, como textura e MO, conforme demonstrado por Rawls et al. (1982) e Saxton et al. (1986).

Posteriormente, bases de dados estruturadas, como *Hydraulic Properties of European Soils* (HYPRES), desenvolvidas por Wösten et al. (1999), consolidaram a aplicação de FPTs em escala continental, reforçando a importância de modelos regionalizados frente à variabilidade pedológica.

No entanto, dada a complexidade e não linearidade das relações entre propriedades do solo, técnicas de Inteligência Artificial (IA), como as Redes Neurais Artificiais (RNAs), especialmente os modelos *Multilayer Perceptron* (MLP), vêm obtendo destaque pela maior capacidade preditiva, ainda que exijam maior volume de dados e recursos computacionais para calibração (Mozaffari et al., 2024; Pacheco et al., 2021).

A evolução metodológica das FPTs culminou na transição de modelos empíricos tradicionais para sistemas de inferência baseados em aprendizado de máquina, conforme

discutido por McBratney e Minasny (2004). Segundo esses autores, as FPTs modernas passaram a integrar estatística multivariada e técnicas de IA, ampliando a capacidade de modelar relações não lineares complexas presentes nos sistemas pedológicos.

Além disso, Weber et al. (2024) destacam que, considerando a heterogeneidade edafoclimática regional, a transferência direta de modelos desenvolvidos em outras áreas pode comprometer a acurácia das estimativas, o que torna indispensável a calibração e validação local dessas funções.

Nesse cenário, a Bacia Hidrográfica do Rio Una (BHRU), situada no estado de São Paulo (SP), destaca-se pela alta variabilidade textural do solo e pela predominância da agricultura irrigada, com significativas influência antrópicas sobre os recursos naturais (Silva, 2016). Tal contexto torna a BHRU um local propício para o desenvolvimento e aplicação de FPT calibradas localmente, visando aprimorar o monitoramento e planejamento agrícola sustentável.

Portanto, este estudo objetiva estimar a CC e o PMP na BHRU a partir de propriedades físico-químicas e texturais do solo, empregando FPT geradas por RML associada à Análise de Componentes Principais (PCA) e por RNA do tipo MLP, de forma a aumentar a eficiência das estimativas hidrofísicas em ambientes tropicais, contribuindo para a gestão racional dos recursos hídricos e o manejo sustentável do solo, essenciais para a resiliência agroambiental frente às mudanças climáticas e ao uso intensivo do solo.

2. Material e Métodos

2.1 Área de estudo

A BHRU, inserida na Unidade de Gerenciamento de Recursos Hídricos do Sorocaba Médio Tietê (UGRHI 10), abrange uma área de aproximadamente 97 km², localizada integralmente no município de Ibiúna (Figura 1), estado de São Paulo (SP), com população de aproximadamente 75 mil habitantes (Instituto Brasileiro de Geografia e estatística [IBGE], 2025).

A região é caracterizada por forte predominância da atividade agrícola, com destaque para a olericultura, impulsionada pela expressiva população rural do município (Comitê da Bacia Hidrográfica Sorocaba-Médio Tietê, 2024; Santos, 2024).

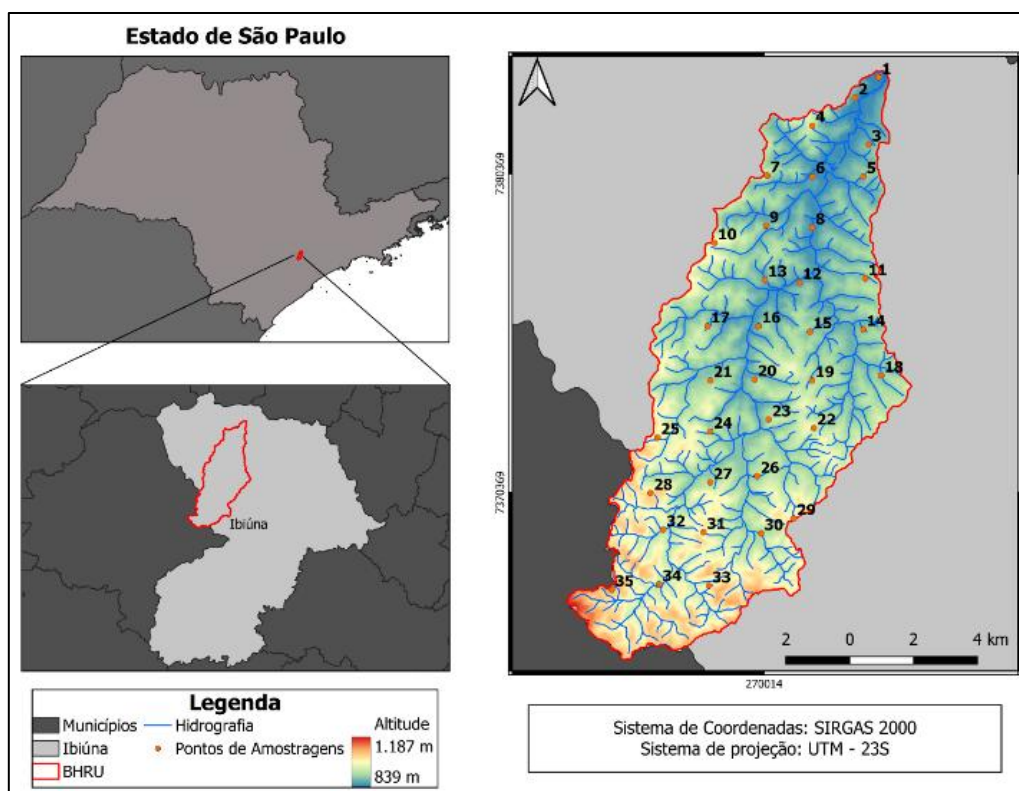


Figura 1. Área de estudo

Fonte: Elaborado pelos autores

O clima predominante na bacia hidrográfica, segundo a classificação de Köppen, é do tipo Cwa (tropical de altitude com verão chuvoso e inverno seco), apresentando temperatura média anual de 19,1 °C, com mínimas de 8,5 °C e máximas de 27,6 °C (Dubreuil et al., 2017).

A precipitação média mensal é de 112,18 mm, com maior concentração pluviométrica em janeiro (218,51 mm) e menor em agosto (40,07 mm), conforme dados da normal climática de 1986–2021 (Departamento de Águas e Energia Elétrica [DAEE], s.d.; Silva et al., 2023b).

Quanto aos aspectos edafológicos, predominam os Argissolos e Latossolos, enquanto, hidrológicamente, o Rio Una desempenha papel estratégico no abastecimento do reservatório de Itupararanga, responsável por suprir parte significativa da demanda hídrica da região de Ibiúna e de municípios adjacentes, como Sorocaba (Silva et al., 2018).

3. Metodologia

3.1. Levantamento e Organização dos dados de campo

A delimitação da BHRU foi realizada a partir de dados altimétricos, incluindo curvas de nível e pontos cotados extraídos de cartas topográficas do Instituto Geográfico e Cartográfico (IGC), na escala 1:10.000, digitalizadas no *software* ArcGIS 10.1. A base de dados utilizada foi desenvolvida por Silva (2016).

A coleta de amostras de solo foi realizada em 35 pontos distribuídos uniformemente na área da bacia, com georreferenciamento obtido por receptor GPS *Garmin Etrex Vista*, com precisão nominal de 15 m, auxiliado por mapas planialtimétricos da região. As amostras foram coletadas na camada de 0 a 20 cm, conforme recomendação do Boletim Técnico 100 do Instituto Agrônomo de Campinas (De Camargo et al., 2009).

A determinação da CC e do PMP foi realizada segundo os procedimentos físico-químicos estabelecidos no Boletim Técnico 106 do Instituto Agrônomo de Campinas (De Camargo et al., 2009), e os dados laboratoriais foram organizados em planilhas no *software* Microsoft Excel (versão 2006), garantindo sua adequada sistematização para as análises subsequentes.

3.2. Análise Exploratória dos Dados (AED)

Antes da etapa de modelagem, foi conduzida uma Análise Exploratória de Dados (AED) com o objetivo de caracterizar a distribuição, dispersão e a presença de valores discrepantes nas variáveis hidrofísicas e granulométricas avaliadas ($n = 35$).

Para tal, foram construídos diagramas de caixa (boxplots) das variáveis CC, PMP, frações texturais (argila, silte e areia) e MO, apresentados na Figura 2 e que permitiram avaliar a mediana, a amplitude interquartílica e a ocorrência de valores atípicos, subsidiando a verificação da adequação dos dados às técnicas estatísticas empregadas e a mitigação de potenciais riscos de *overfitting*, particularmente em modelos não lineares como RNAs.

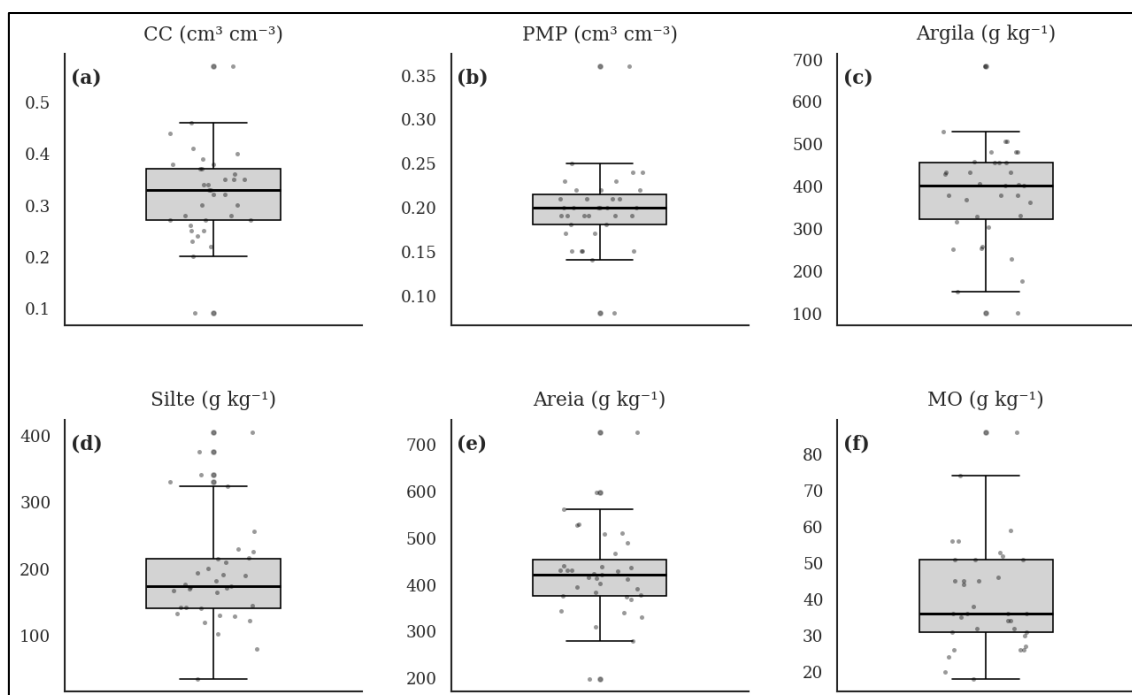


Figura 2. Diagramas de caixa das variáveis hidrofísicas (CC (a) e PMP (b)) e granulométricas (argila (c), silte (d), areia (e) e MO (f)) das 35 amostras da BHRU

Fonte: Elaborado pelos autores

O PMP apresentou menor amplitude interquartil e menor dispersão relativa em comparação à CC, indicando menor variabilidade intrínseca dessa variável. Tal comportamento é consistente com sua definição sob potencial matricial de -1500 kPa, condição que tende a reduzir a variabilidade dentro de classes texturais semelhantes. Essa característica pode favorecer ajustes lineares mais estáveis, o que auxilia na interpretação do desempenho superior da RML para essa variável.

A análise também permitiu identificar a presença pontual de valores extremos, especialmente em variáveis granulométricas e de MO, os quais foram mantidos por representarem a variabilidade natural da área de estudo.

3.3. Estimativa de parâmetros do solo

Para a modelagem dos dados pedológicos da BHRU, foram utilizados dois ambientes integrados de desenvolvimento: *Google Colaboratory* e *Spyder*, acessado via interface gráfica do *Anaconda Navigator*. A linguagem de programação adotada foi Python, devido

à sua ampla aplicação em análises estatísticas, modelagens preditivas e aprendizado de máquina, conforme El Behairy et al. (2024), Hill et al. (2024) e Padarian et al. (2020).

Inicialmente, foi construída uma matriz de correlação de Pearson, com nível de significância de 5%, para explorar relações lineares entre os atributos do solo. A interpretação seguiu uma escala de -1 a 1, identificando interações relevantes entre as variáveis.

Com base nos teores de areia, silte, argila e MO coletados, foram elaboradas Funções de Pedotransferência para estimar umidade na CC (10 kPa) e no PMP (1500 kPa). Para tanto, adotaram-se duas abordagens metodológicas: RLM associada à PCA e RNAs, conforme Rehman et al. (2024) e Štrbac et al. (2024).

A PCA foi empregada para redução da dimensionalidade e eliminação de redundâncias, facilitando a identificação dos principais fatores que influenciam os parâmetros hídricos, técnica adequada para variáveis físico-químicas correlacionadas (Mansour et al., 2024; Sadeghi et al., 2024; Tang, 2024).

Embora regressões penalizadas como *Ridge Regression* (Hoerl e Kennard, 1970; Tibshirani, 1996), sejam reconhecidas por sua eficiência no tratamento de multicolinearidade em bases reduzidas, optou-se neste estudo pela aplicação da PCA por sua capacidade de preservar a estrutura de variância global dos dados e reduzir dimensionalidade antes da modelagem. Contudo, reconhece-se que abordagens penalizadas representam alternativa promissora para investigações futuras.

As variáveis independentes consideradas foram areia, silte, argila e MO, enquanto as dependentes corresponderam às umidades estimadas na CC e PMP. Os dados processados pela PCA foram submetidos à RLM com seleção *stepwise*, método consistente e parcimonioso para construção das FPTs (Veloso et al., 2024; Ziviani et al., 2024). A divisão da base foi de 80% para treinamento e 20% para teste, garantindo equilíbrio entre predição e generalização (Abbasimaedeh, 2024; Abdullah et al., 2024; Bahmed et al., 2024; Raja et al., 2024).

Como alternativa, as RNAs foram aplicadas pelo seu alto poder de aprendizado não linear e adaptabilidade (Georgiou e Elkady, 2024). As variáveis de entrada foram padronizadas para média zero e desvio padrão um, utilizando a biblioteca *Scikit-Learn*, essencial para estabilidade numérica e mitigação de problemas de gradiente (Kurnaz et al., 2024).

Para as RNAs, adotou-se a divisão 67% treinamento e 33% teste, conforme Qiao et al. (2019), visando maior variabilidade durante o aprendizado. A arquitetura baseou-se em modelo MLP com camada de entrada implícita, camada oculta (variando de 3 a 20 neurônios com ativação ReLU) e camada de saída com ativação linear para regressão contínua (Hammad, 2024; Horuz, 2025). O treinamento contemplou de 1.000 a 20.000 épocas, com otimização dos hiperparâmetros (taxa de aprendizado e momento) pelo algoritmo Adam, reconhecido pela eficiência em redes profundas (Okewu et al., 2020; Yang e Long, 2024).

3.4. Avaliação dos modelos

A avaliação do desempenho dos modelos gerados pelas abordagens PCA/RLM e RNA foi realizada por meio de métricas estatísticas de estimativa de erro. Para esse fim, foram calculados e analisados o Erro Médio Absoluto (MAE), o Erro Quadrático Médio (MSE), a Raiz do Erro Quadrático Médio (RMSE) e o Coeficiente de Determinação (R^2), conforme expressos nas Equações 1, 2, 3 e 4, respectivamente.

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

$$MSE = \left[\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \right] \quad (2)$$

$$RMSE = \left[\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \right]^{\frac{1}{2}} \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (4)$$

Onde:

y_i é o valor observado;

\hat{y}_i é o valor estimado;

\bar{y} é a média do valor observado;

N são os números de amostras.

Por fim, para o cálculo dessas métricas de avaliação, empregaram-se os ambientes de desenvolvimento integrados *Google Colaboratory* e *Spyder*, por meio da linguagem de programação Python.

4. Resultados e Discussão

A Tabela 1 apresenta os valores de argila, silte, areia, CC, PMP, fator de erodibilidade (fator K) e MO obtidos nos 35 pontos de coleta. A Figura 3 exibe a matriz de correlação de Pearson entre CC, PMP e as demais variáveis da base da BHRU, evidenciando as relações estatísticas entre os atributos pedológicos analisados.

Tabela 1. Características pedológicas dos pontos de coleta na BHRU

Ponto	CC	PMP	AD	Argila	Silte	Areia	Fator K	MO
1	0,37	0,18	0,19	328,00	256,00	416,00	0,02	36,00
2	0,36	0,23	0,13	368,00	323,00	309,00	0,02	26,00
3	0,32	0,23	0,09	683,00	120,00	197,00	0,00	18,00
4	0,38	0,20	0,18	151,00	341,00	508,00	0,06	51,00
5	0,33	0,25	0,08	434,00	182,00	384,00	0,01	46,00
6	0,40	0,24	0,16	480,00	190,00	330,00	0,01	32,00
7	0,41	0,21	0,20	506,00	215,00	279,00	0,01	26,00
8	0,37	0,20	0,17	480,00	145,00	375,00	0,01	31,00
9	0,30	0,15	0,15	379,00	191,00	430,00	0,02	20,00
10	0,34	0,19	0,15	432,00	194,00	374,00	0,01	44,00
11	0,35	0,17	0,18	455,00	133,00	412,00	0,01	34,00
12	0,39	0,19	0,21	482,00	141,00	377,00	0,01	34,00
13	0,35	0,18	0,16	402,00	177,00	421,00	0,01	31,00

Desenvolvimento e Validação Local de Funções de Pedotransferência para Parâmetros Hídricos na Bacia Hidrográfica do Rio Una (SP): Uma Abordagem Comparativa entre Modelos Lineares e Redes Neurais

14	0,44	0,20	0,24	456,00	142,00	402,00	0,01	35,00
15	0,35	0,24	0,11	362,00	171,00	467,00	0,02	74,00
16	0,38	0,21	0,17	429,00	142,00	429,00	0,01	45,00
17	0,57	0,36	0,21	257,00	375,00	368,00	0,03	86,00
18	0,26	0,20	0,06	432,00	129,00	439,00	0,01	56,00
19	0,24	0,19	0,05	455,00	122,00	423,00	0,01	45,00
20	0,27	0,20	0,07	379,00	131,00	490,00	0,02	53,00
21	0,30	0,22	0,08	405,00	165,00	430,00	0,01	52,00
22	0,22	0,15	0,07	506,00	80,00	414,00	0,01	24,00
23	0,28	0,20	0,09	457,00	103,00	440,00	0,01	45,00
24	0,34	0,19	0,15	330,00	330,00	340,00	0,02	38,00
25	0,09	0,08	0,02	101,00	173,00	726,00	0,09	51,00
26	0,23	0,14	0,08	303,00	170,00	527,00	0,02	36,00
27	0,25	0,17	0,08	402,00	167,00	431,00	0,01	27,00
28	0,28	0,19	0,08	254,00	216,00	530,00	0,03	56,00
29	0,20	0,15	0,05	176,00	226,00	598,00	0,05	36,00
30	0,27	0,19	0,08	229,00	210,00	561,00	0,03	59,00
31	0,27	0,15	0,11	316,00	174,00	510,00	0,02	51,00
32	0,46	0,21	0,25	252,00	404,00	344,00	0,03	30,00
33	0,25	0,22	0,04	379,00	230,00	391,00	0,02	32,00
34	0,33	0,21	0,11	404,00	201,00	395,00	0,01	36,00

Fonte: Adaptado de Silva (2016)




Figura 3. Matriz de correlação de Pearson entre CC, PMP e demais atributos pedológicos da BHRU

Fonte: Elaborado pelos autores

Os resultados indicam que a CC apresentou correlação negativa com a fração de areia (-0,6) e positiva com o silte (0,5) e o fator K (-0,4), enquanto o PMP relacionou-se negativamente com a areia (-0,6) e positivamente com a MO (0,4) e o fator K (-0,4). Tendo em vista essas associações, evidencia-se que tanto a composição textural quanto a erodibilidade do solo são determinantes fundamentais para a dinâmica da retenção hídrica na BHRU, conforme apontado por Silva Junior (2025) em área similar.

Neste contexto, é importante destacar que a textura do solo influencia diretamente a estrutura do perfil, impactando a formação de poros e a distribuição da água, o que é corroborado por estudos que demonstram como a heterogeneidade granulométrica condiciona a porosidade efetiva e, conseqüentemente, a disponibilidade hídrica (Smagin, 2025; Wang et al., 2025; Santos et al., 2025b).

A correlação negativa entre areia e os parâmetros de umidade reforça a premissa de que solos com maior fração arenosa apresentam macroporosidade elevada e menor área

superficial específica, reduzindo a capacidade de adsorção e retenção hídrica, conforme destacado por Santos et al. (2025a) e Ye et al. (2024).

De maneira complementar, o fator K está condicionado à interação das frações granulométricas, que modulam a coesão e estabilidade estrutural do solo (Wang et al., 2024a). Esse aspecto é especialmente relevante, pois solos com menor estabilidade estrutural tendem a apresentar maior risco de erosão e perda de propriedades físicas favoráveis à retenção de água, comprometendo o equilíbrio hidrológico local (Lin et al., 2025; Wang et al., 2024b).

A fração argila, embora não tenha apresentado correlação direta expressiva com a CC no presente estudo, exerce papel crucial por meio da formação e manutenção dos agregados estáveis que influenciam a permeabilidade e o movimento da água no perfil, conforme destacado por Piccoli et al. (2024) e Abdulraheem et al. (2024).

Importa destacar que o efeito moderador do silte sobre a argila pode reduzir a influência direta desta última na retenção hídrica, o que explica a menor associação estatística observada, em consonância com as evidências de Tisdall e Oades (1982). Outro ponto relevante é a correlação positiva da CC com o silte, sugerindo que a presença desse componente favorece a retenção hídrica pela formação de poros intermediários, que equilibram a capacidade de armazenamento e a movimentação da água no solo. Essa relação é reforçada por Gee e Bauder (1986) e Hou et al. (2021), que reconhecem o silte como um importante regulador hidráulico, por seu tamanho de partícula intermediário.

Além disso, a MO destacou-se como o principal atributo correlacionado positivamente com o PMP, indicando sua influência determinante na retenção hídrica em potenciais mais elevados (Fernandes et al., 2025; Lima et al., 2025). Vale destacar que a MO contribui para a melhoria da estrutura do solo, aumentando a capacidade de retenção de água em microporos e promovendo maior disponibilidade hídrica em condições de seca (Piccolo et al., 2025), o que evidencia sua importância para o manejo sustentável dos solos na BHRU.

Ademais, a predominância de Latossolos na área de estudo, reconhecidos pela sua estruturação favorável, elevado grau de intemperismo e alta porosidade, reforça a importância da composição textural e da estabilidade estrutural na dinâmica hídrica regional. Esses atributos conferem aos Latossolos um potencial agrícola elevado, porém

também requerem atenção quanto à sua suscetibilidade à erosão, que está diretamente ligada ao fator K e às interações granulométricas (Santos et al., 2025a; Silva, 2016).

Por fim, estudos recentes têm ressaltado a necessidade de incorporar variáveis adicionais, além das frações granulométricas amplas, para aprimorar a modelagem do fator K e a predição da umidade do solo, dado que a complexidade das interações físicas do solo demanda abordagens multifatoriais (Corral-Pazos-de-Provens et al., 2018; Ke et al., 2021). Esse entendimento é fundamental, e recomendado, para o desenvolvimento de modelos hidrológicos e de conservação do solo mais com maior consistência estrutural e confiabilidade preditiva (Santos et al., 2025a), especialmente em bacias hidrográficas com características ambientais complexas como a BHRU.

A Tabela 2 demonstra o desempenho dos modelos para estimativa da CC utilizando RML combinada com PCA.

Tabela 2. Desempenho dos modelos analisados para estimativas de CC a partir de RML/PCA e dados pedológicos.

Modelo	n	Dados de entrada	MSE	MAE	RMSE	R ²
1	2	ARE + SLT + ARG	0,01	0,06	0,07	0,49
2	3	ARE + SLT + ARG	0,01	0,06	0,07	0,49
3	2	ARE + SLT + Fator K	0,01	0,06	0,07	0,49
4	3	ARE + SLT + Fator K	0,01	0,06	0,07	0,49
5	2	ARE + SLT + MO	0,01	0,07	0,08	0,36
6	3	ARE + SLT + MO	0,01	0,07	0,08	0,59
7	2	ARE + SLT + ARG + MO	0,01	0,07	0,08	0,31
8	3	ARE + SLT + ARG + MO	0,00	0,05	0,06	0,59

n – Número de componentes, MSE - erro quadrático médio, MAE - erro médio absoluto, RMSE - raiz do erro quadrático médio, R² – Coeficiente de determinação.

Fonte: Elaborado pelos autores

Quando consideradas apenas duas variáveis nos modelos 1, 3, 5 e 7, observou-se o R^2 variando entre 0,31 e 0,49, indicando uma correlação fraca, e RMSE entre 0,07 e 0,08. Por outro lado, nos modelos que utilizaram três componentes (modelos 2, 4, 6 e 8), o R^2 aumentou para a faixa entre 0,49 e 0,59, com RMSE entre 0,06 e 0,07.

Vale destacar o desempenho do modelo 6, que apresentou o melhor desempenho ($R^2 = 0,59$), o que evidencia uma correlação moderada obtida com apenas três variáveis de entrada (areia, silte e MO), com destaque para a relevância da MO associada à textura para a previsão da CC.

Em relação ao PMP, os modelos que utilizaram dois componentes e entre três e quatro variáveis (modelos 9, 11, 13 e 15) apresentaram resultados de R^2 que variaram amplamente, entre 0,02 e 0,58, e RMSE entre 0,03 e 0,04. O modelo 11, com três variáveis (areia, silte e fator K) e dois componentes, foi o que obteve melhor correlação moderada ($R^2 = 0,58$).

Entretanto, os modelos que utilizaram três componentes (modelos 10, 12, 14, 16) apresentaram resultados superiores, com R^2 variando de 0,50 a 0,87, sendo que os modelos 14 e 16 atingiram o maior valor de R^2 (0,87), configurando uma correlação forte para a predição do PMP. Para esses modelos, o RMSE variou entre 0,02 e 0,04, indicando maior precisão. A Tabela 3 apresenta o desempenho dos modelos analisados para estimativas de PMP a partir de RML/PCA e dados pedológicos.

Tabela 3. Desempenho dos modelos analisados para estimativas de PMP a partir de RML/PCA e dados pedológicos.

Modelo	n	Dados de entrada	MSE	MAE	RMSE	R^2
9	2	ARE + SLT + ARG	0,00	0,02	0,03	0,50
10	3	ARE + SLT + ARG	0,00	0,02	0,03	0,50
11	2	ARE + SLT + Fator K	0,00	0,02	0,03	0,58
12	3	ARE + SLT + Fator K	0,00	0,02	0,03	0,55
13	2	ARE + SLT + MO	0,00	0,03	0,04	0,09
14	3	ARE + SLT + MO	0,00	0,01	0,02	0,87
15	2	ARE + SLT + ARG + MO	0,00	0,03	0,04	0,02

16	3	ARE + SLT + ARG + MO	0,00	0,01	0,02	0,87
----	---	----------------------	------	------	------	------

n – Número de componentes, MSE - erro quadrático médio, MAE - erro médio absoluto, RMSE - raiz do erro quadrático médio, R² – Coeficiente de determinação.

Fonte: Elaborado pelos autores

Convém interpretar com cautela o elevado coeficiente de determinação observado para o PMP (R² = 0,87). O PMP é definido em potencial matricial fixo (-1500 kPa), condição que tende a reduzir sua variabilidade intrínseca dentro de classes texturais semelhantes, sobretudo quando a fração argila exerce papel dominante na retenção de água sob altas tensões.

Essa menor amplitude de variação favorece ajustes lineares mais estáveis e estatisticamente consistentes, elevando naturalmente os valores de R² em modelos paramétricos. Nesse contexto, o desempenho superior da RML em relação às RNAs para o PMP sugere que a complexidade adicional introduzida por modelos não lineares pode não resultar em ganhos preditivos substantivos quando as relações físico-hídricas subjacentes são predominantemente lineares.

Assim, os resultados indicam que a escolha do método de modelagem deve considerar não apenas métricas estatísticas de ajuste, mas também a coerência física do fenômeno modelado e o grau de variabilidade estrutural da variável resposta, conforme abordado por Goodfellow et al. (2016).

A comparação dos resultados para CC e PMP evidencia que a inclusão de três componentes melhora significativamente o ajuste dos modelos em ambas as variáveis. Para CC, o destaque do modelo 6 reforça a importância da MO aliada à textura do solo para a previsão da capacidade de retenção de água, enquanto para PMP, a elevada correlação do modelo 14, que utiliza a mesma composição de variáveis, demonstra que as propriedades físicas e químicas do solo são determinantes para a retenção mínima de água disponível para as plantas.

A função *stepwise* indicou que a microporosidade é um preditor eficiente para CC, ao passo que PMP depende também do carbono orgânico total, sugerindo que a complexidade na retenção de água disponível às plantas requer a integração de variáveis físicas e químicas do solo.

Com base nessa abordagem, a Tabela 4 resume os desempenhos dos modelos de RNA para a variável CC, enquanto a Tabela 5 apresenta as respostas obtidas para o PMP.

Tabela 4. Desempenho das análises de RNAs para estimar a CC.

Modelo	Épocas	Neurônios	Dados de entrada	MSE	MAE	RMSE	R²
17	1000	20	ARE + SLT + MO	0,007	0,07	0,08	0,47
18	1000	20	ARE + SLT + Fator K	0,009	0,07	0,10	0,24
19	1000	20	ARE + SLT + ARG + MO	0,004	0,05	0,07	0,65
20	10000	3	ARE + SLT + ARG + MO	0,003	0,05	0,06	0,68
21	20000	3	ARE + SLT + ARG + MO	0,003	0,04	0,06	0,73

MSE - erro quadrático médio, MAE - erro médio absoluto, RMSE - raiz do erro quadrático médio, R² – Coeficiente de determinação.

Fonte: Elaborado pelos autores.

Tabela 5. Desempenho das análises de RNAs para estimar o PMP

Modelo	Épocas	Neurônios	Dados de entrada	MSE	MAE	RMSE	R²
22	1000	20	ARE + SLT + ARG	0,003	0,04	0,06	0,17
23	1000	20	ARE + SLT + MO	0,003	0,03	0,05	0,28
24	1000	20	ARE + SLT + ARG + MO	0,002	0,04	0,05	0,44

MSE - erro quadrático médio, MAE - erro médio absoluto, RMSE - raiz do erro quadrático médio, R² – Coeficiente de determinação.

Fonte: Elaborado pelos autores.

Os resultados obtidos pela RNA são promissores para a predição de CC e PMP. Para CC, o modelo 21, que empregou 20.000 épocas e três neurônios com as variáveis areia, silte, argila e MO, apresentou o melhor desempenho, com R² = 0,73 e RMSE = 0,06, superando os modelos de RML em capacidade preditiva. Já para PMP, o modelo 24, com 1000 épocas, apresentou R² = 0,44 e RMSE = 0,05, evidenciando maior dificuldade na predição dessa variável mesmo com redes neurais.

Resultados encontrados por Qiao et al. (2019) corroboram que a predição de CC e PMP é sensível à quantidade e qualidade das variáveis de entrada, uma vez que utilizaram RNA e RML com variáveis limitadas (areia, argila e densidade do solo) e obtiveram R^2 em torno de 0,30 a 0,33 para CC e PMP, respectivamente.

Esse fato enfatiza a necessidade de integrar múltiplas propriedades físicas e químicas do solo para melhorar a acurácia preditiva. Kwon et al. (2025) e Qi et al. (2025) demonstraram que a ampliação do número de variáveis de entrada e do volume amostral resulta em melhora substancial na performance dos modelos, porém esse ganho deve ser ponderado em função do aumento dos custos laboratoriais e do tempo computacional requerido.

No contexto da BHRU, onde cerca de 28% da área total é destinada à atividade agrícola e o setor agropecuário desempenha papel relevante na dinâmica socioeconômica regional (Silva, 2016), observa-se a predominância de cultivos olerícolas, cuja produção depende do uso de irrigação (Santos et al., 2025a). Diante disso, a predição acurada de atributos físico-hídricos do solo, como a CC e o PMP, configura-se como um instrumento estratégico para a gestão racional dos recursos hídricos voltados ao setor produtivo rural.

Considerando a intensificação da agricultura irrigada e os efeitos crescentes das mudanças climáticas globais, evidencia-se a necessidade de ferramentas que subsidiem o uso racional dos recursos hídricos. A adoção de técnicas preditivas, como a RML e as RNAs, demonstrou-se eficaz na modelagem dos parâmetros hídricos, especialmente em áreas com dados pedológicos disponíveis, mas com limitações no monitoramento hidrológico direto.

No contexto geral, os resultados obtidos demonstram que ambas as abordagens apresentaram desempenhos consistentes na estimativa de CC e PMP, a partir de variáveis texturais e MO. Além do mais, a capacidade dessas metodologias de generalizar padrões complexos permite sua aplicação em regiões com características edafoclimáticas diversas, contribuindo não apenas para a melhoria do manejo da irrigação, mas também para a formulação de estratégias de mitigação e adaptação frente aos cenários de instabilidade climática.

Dessa forma, o presente trabalho contribui para o avanço das ferramentas de apoio à tomada de decisão em áreas agrícolas, reforçando a importância da integração entre modelagem estatística, ciência do solo e planejamento territorial, e os desdobramentos

desses resultados têm potencial para subsidiar ações voltadas à segurança hídrica e ao desenvolvimento de políticas públicas voltadas à sustentabilidade da produção agrícola em bacias hidrográficas com alta vulnerabilidade ambiental.

Ressalta-se que o presente estudo não realizou estratificação prévia por classes texturais dominantes (como Latossolos e Argissolos), o que pode reduzir a sensibilidade dos modelos ao comportamento hidráulico específico de cada grupo pedológico. Todavia, investigações futuras poderão incorporar essa segmentação para avaliar ganhos adicionais de desempenho e maior representatividade física dos modelos.

5. Conclusão

Os resultados deste estudo evidenciam que técnicas de modelagem preditiva, como a RML e as RNAs, apresentam eficácia na estimativa da CC e do ponto de PMP a partir de atributos físico-químicos do solo. A RML destacou-se por alcançar R^2 de até 0,59 para CC e 0,87 para PMP, mesmo com número reduzido de variáveis de entrada e base amostral limitada. Essa característica reforça seu potencial para aplicações locais, sobretudo em contextos com restrições de recursos computacionais e laboratoriais.

Do ponto de vista operacional, a RML apresenta vantagem adicional por fornecer coeficientes explícitos, possibilitando integração direta em planilhas eletrônicas e sistemas de suporte à decisão agrícola de baixo custo. Em contraste, a implementação de RNAs requer infraestrutura computacional mais estruturada, bibliotecas especializadas e rotinas de normalização, o que pode elevar custos técnicos sem necessariamente gerar ganhos proporcionais de acurácia em todas as variáveis analisadas.

Em contraponto, as RNAs demonstraram maior capacidade preditiva, atingindo R^2 de até 0,73 para CC, especialmente quando alimentadas com bases de dados mais amplas e maior complexidade computacional. Esse desempenho indica que as RNAs são ferramentas mais indicadas para estudos em escalas maiores, que demandam maior consistência estatística e recursos computacionais, embora isso implique em custos operacionais e técnicos superiores.

Apesar das diferenças observadas, é importante destacar que ambos os métodos vão além da simples predição quantitativa, permitindo identificar os principais atributos do solo que influenciam a dinâmica hídrica, como a MO e as frações granulométricas, os quais

são essenciais para a estabilidade estrutural e a retenção de água. Esse entendimento amplia a aplicabilidade dos modelos para subsidiar decisões de manejo e conservação do solo.

Considerando o cenário atual, a incorporação dessas metodologias em programas de monitoramento e planejamento agrícola pode contribuir para a adoção de práticas mais eficientes e sustentáveis. No entanto, observa-se que a precisão dos modelos está condicionada à qualidade e à abrangência dos dados disponíveis, o que sugere a necessidade de ampliação das bases amostrais e da diversificação dos atributos analisados em futuras pesquisas, especialmente em regiões com heterogeneidade pedológica elevada.

Por fim, a utilização dessas ferramentas representa um avanço estratégico para enfrentar os desafios impostos pelas mudanças climáticas e pela crescente influência antrópica sobre os recursos naturais. Assim, contribui para o desenvolvimento de sistemas produtivos mais resilientes, que conciliem a produtividade agrícola com a conservação ambiental, promovendo a sustentabilidade a longo prazo.

6. Reprodutibilidade e Disponibilização de Código

O código completo desenvolvido em Python para processamento dos dados, aplicação da PCA, modelagem por RML e treinamento das RNAs será disponibilizado em repositório público como material suplementar, garantindo transparência, reprodutibilidade e validação independente dos resultados obtidos.

7. Declarações finais

Contribuições de cada autor:

Ingrid Larissa Gomes Barbosa: conceituação, metodologia, curadoria de dados, análise formal, investigação, software, validação, visualização, redação (rascunho original); Bruna Henrique Sacramento: análise formal, investigação, software, validação, redação (rascunho original); Arthur Pereira dos Santos: análise formal, investigação, software, validação, redação (rascunho original), redação (revisão do rascunho e edição/correção); Alessandro Xavier da Silva Junior: supervisão, redação (revisão do rascunho e edição/correção); Darllan Collins da Cunha e Silva: conceituação, aquisição de recursos,

metodologia, administração do projeto, recursos, supervisão, redação (revisão do rascunho e edição/correção).

Financiao:

Os autores declaram que não receberam recursos para a redação ou publicação deste artigo.

Conflito de interesses: Os autores declaram não haver conflitos de interesse na redação ou publicação deste artigo.

Implicações éticas:

Os autores não têm implicações éticas que devam ser declaradas na redação ou publicação deste artigo.

Declaração sobre o Uso de Inteligência Artificial:

Os autores declaram que não utilizaram inteligência artificial.

7. Referências bibliográficas

Abbasimaedeh, P. (2024). Soil liquefaction in seismic events: pioneering predictive models using machine learning and advanced regression techniques. *Environmental Earth Sciences*, 83(7), 189. <https://doi.org/10.1007/s12665-024-11480-x>

Abebaw, S. (2025). A Global Review of the Impacts of Climate Change and Variability on Agricultural Productivity and Farmers' Adaptation Strategies. *Food Science & Nutrition*, 13(5), e70260. <https://doi.org/10.1002/fsn3.70260>

Abdullah, G., Ahmad, M., Babur, M., Badshah, M., Al-Mansob, R., Gamil, Y. e Fawad, M. (2024). Boosting-based ensemble machine learning models for predicting unconfined compressive strength of geopolymer stabilized clayey soil. *Scientific Reports*, 14, 2323. <https://doi.org/10.1038/s41598-024-52825-7>

Abdulraheem, M., Chen, H., Li, L., Moshood, A., Zhang, W., Xiong, Y., Zhang, Y., Taiwo, L., Farooque, A. e Hu, J. (2024). Recent Advances in Dielectric Properties-Based Soil Water Content Measurements. *Remote Sensing*, 16(8), 1328. <https://doi.org/10.3390/rs16081328>

Amsili, J., van Es, H. e Schindelbeck, R. (2024). Pedotransfer Functions for Field Capacity, Permanent Wilting Point, and Available Water Capacity Based on Random Forest Models for Routine Soil Health Analysis. *Communications in Soil Science and Plant Analysis*, 55(13), 1967–1984. <https://doi.org/10.1080/00103624.2024.2336573>

Al-Shammary, A., Al-Shihmani, L., Fernández-Gálvez, J. e Caballero-Calvo, A. (2024). Optimizing sustainable agriculture: A comprehensive review of agronomic practices and their impacts on soil attributes. *Journal of Environmental Management*, 364, 121487. <https://doi.org/10.1016/j.jenvman.2024.121487>

Bahmed, I., Khatti, J. e Grover, K. (2024). Hybrid soft computing models for predicting unconfined compressive strength of lime stabilized soil using strength property of virgin cohesive soil. *Bulletin of Engineering Geology and the Environment*, 83, (46). <https://doi.org/10.1007/s10064-023-03537-1>

Bouma, J. (1989). Using Soil Survey Data for Quantitative Land Evaluation. Em Stewart, B. (Ed.), *Advances in Soil Science* (Vol. 9, pp. 177–213). Springer. https://doi.org/10.1007/978-1-4612-3532-3_4

Chen, S., Arrouays, D., Mulder, V., Poggio, L., Minasny, B., Roudier, P., Libohova, Z., Lagacherie, P., Shi, Z., Hannam, J., Meersmans, J., Richer-de-Forges, A. e Walter, C. (2022). Digital mapping of GlobalSoilMap soil properties at a broad scale: A review. *Geoderma*, 409, 115567. <https://doi.org/10.1016/j.geoderma.2021.115567>

Comitê da Bacia Hidrográfica do Rio Sorocaba e Médio Tietê. (2024). *Relatório de Situação 2024. Ano base 2023*. <https://tinyurl.com/yt6f6d4e>

- Corral-Pazos-de-Provens, E., Domingo-Santos, J. e Rapp-Arrarás, Í. (2018). Estimating the very fine sand fraction for calculating the soil erodibility K-factor. *Land Degradation & Development*, 29(10), 3595–3606. <https://doi.org/10.1002/ldr.3121>
- De Camargo, O., Moniz, A., Jorge, J. e Valadares, J. (2009). *Métodos de análise química, mineralógica e física de solos do Instituto Agronômico de Campinas* (Boletim Técnico, 106). Instituto Agronômico. <https://tinyurl.com/35634trp>
- De Lima, M., Freire, F., Almeida, D., Almeida, B., Santos, R. e Marangon, L. (2025). Soil properties influence tree fall in a fragment of Atlantic Forest in Recife, Pernambuco, Brazil. *Southern Forests: A Journal of Forest Science*, 87(1–2). 69–81. <https://doi.org/10.2989/20702620.2024.2444218>
- Departamento de Águas e Energia Eléctrica (DAEE). (s.d.). Banco de Dados Hidrológicos [Conjunto de dados]. <https://tinyurl.com/3p3srys9>
- Du, X., Jian, J., Du, C. e Stewart, R. (2022). Conservation management decreases surface runoff and soil erosion. *International Soil and Water Conservation Research*, 10(2), 188–196. <https://doi.org/10.1016/j.iswcr.2021.08.001>
- Dubreuil, V., Pechutti, K., Planchon, O. e Neto, J. (2017). Les types de climats annuels au Brésil: une application de la classification de Köppen de 1961 à 2015. *EchoGéo*, (41). <https://doi.org/10.4000/echogeo.15017>
- El Behairy, R., El Arwash, H., El Baroudy, A., Ibrahim, M., Mohamed, E., Rebouh, N. e Shokr, M. (2024). An Accurate Approach for Predicting Soil Quality Based on Machine Learning in Drylands. *Agriculture*, 14(4), 627. <https://doi.org/10.3390/agriculture14040627>
- Farooq, U., Ajmal, M., Li, S., Yang, J. e Ullah, S. (2024). Evaluation of Pedotransfer Functions to Estimate Soil Water Retention Curve: A Conceptual Review. *Water*, 16(17), 2547. <https://doi.org/10.3390/w16172547>

Fernandes, J., Portela, J., da Silva, E., Mota, P., Vieira, W., Cunha, W., Gomes, D., Fernandes, B., Silva, M., Dantas, M., Neitzke, P. e Antunes, L. (2025). Soil functioning and interrelations with hydrophysical attributes and organic and microstructural fractions in soils under land uses in the Brazilian Semiarid. *Environmental Monitoring and Assessment*, 197, 730. <https://doi.org/10.1007/s10661-025-14151-x>

Food and Agriculture Organization of the United Nations (FAO). (2020). *The State of Food and Agriculture: Overcoming water Challenges in agriculture*. <https://doi.org/10.4060/cb1447en>

Gee, G. e Bauder, J. (1986). Particle-size Analysis. Em A. Klute (Ed.), *Methods of Soil Analysis: Part 1 Physical and Mineralogical Methods* (2nd ed., pp. 383–411). <https://doi.org/10.2136/sssabookser5.1.2ed.c15>

Georgiou, G. e Elkady, A. (2024). ANN-Based Model for Predicting the Nonlinear Response of Flush Endplate Connections. *Journal of Structural Engineering*, 150(5), 04024034. <https://doi.org/10.1061/JSENDH.STENG-13119>

Goodfellow, I., Bengio, Y. e Courville, A. (2016). *Deep learning*. MIT press.

Gomes, G., Nery, L., Nicomedes, N., dos Santos, A. Toniolo, B., da Costa, R. e Silva, D. (2025). Impact of land use and land cover changes on sensible heat variability in a fragment of the Atlantic Forest biome. *International Journal of Remote Sensing*, 46(23), 9258–9284. <https://doi.org/10.1080/01431161.2025.2580584>

Hammad, M. (2024). Deep Learning Activation Functions: Fixed-Shape, Parametric, Adaptive, Stochastic, Miscellaneous, Non-Standard, Ensemble. *arXiv*, 2407.11090 <https://doi.org/10.48550/arXiv.2407.11090>

Hill, C., Du, L., Johnson, M. e McCullough, B. (2024). Comparing programming languages for data analytics: Accuracy of estimation in Python and R. *WIREs Data Mining and Knowledge Discovery*, 14(3), e1531. <https://doi.org/10.1002/widm.1531>

- Hoerl, A. e Kennard, R. (1970). Ridge Regression: Biased Estimation for Nonorthogonal Problems. *Technometrics*, 12(1), 55–67.
<https://doi.org/10.1080/00401706.1970.10488634>
- Horuz, C., Kasenbacher, G., Higuchi, S., Kairat, S., Stoltz, J., Pesl, M., Moser, B., Linse, C., Martinetz, T. e Otte, S. (2025). The Resurrection of the ReLU. *arXiv*, 2505.22074. <https://doi.org/10.48550/arXiv.2505.22074>
- Hou, C., Yi, Y., Song, J. e Zhou, Y. (2021). Effect of water-sediment regulation operation on sediment grain size and nutrient content in the lower Yellow River. *Journal of Cleaner Production*, 279, 123533. <https://doi.org/10.1016/j.jclepro.2020.123533>
- Instituto Brasileiro de Geografia e estatística (IBGE). (2025). *Cidades*. <https://tinyurl.com/547ww6xn>
- Ke, Z., Ma, L., Jiao, F., Liu, X., Liu, Z. e Wang, Z. (2021). Multifractal parameters of soil particle size as key indicators of the soil moisture distribution. *Journal of Hydrology*, 595, 125988. <https://doi.org/10.1016/j.jhydrol.2021.125988>
- Kurnaz, T., Erden, C., Dağdeviren, U., Demir, A. e Kökçam, A. (2024). Comparison of machine learning algorithms for slope stability prediction using an automated machine learning approach. *Natural Hazards*, 120, 6991–7014. <https://doi.org/10.1007/s11069-024-06490-8>
- Kwon, H., Son, J., Kim, D., Tamang, S. e Park, H. (2025). Optimizing thermal performance in internal passage cooling with extended rib: Applying response surface method with artificial neural networks. *Applied Thermal Engineering*, 258, 124570. <https://doi.org/10.1016/j.applthermaleng.2024.124570>
- Lankford, B. e Orr, S. (2022). Exploring the Critical Role of Water in Regenerative Agriculture; Building Promises and Avoiding Pitfalls. *Frontiers in Sustainable Food Systems*, 6, 891709. <https://doi.org/10.3389/fsufs.2022.891709>

- Lin, S., Zou, Y., He, Y., Xue, S., Zhu, L. e Ye, C. (2025). A Spatiotemporal Dynamic Evaluation of Soil Erosion at a Monthly Scale and the Identification of Driving Factors in Hainan Island Based on the Chinese Soil Loss Equation Model. *Sustainability*, 17(6), 2361. <https://doi.org/10.3390/su17062361>
- Liu, L. e Ma, X. (2024). Prediction of Soil Field Capacity and Permanent Wilting Point Using Accessible Parameters by Machine Learning. *AgriEngineering*, 6(3), 2592–2611. <https://doi.org/10.3390/agriengineering6030151>
- Mansour, R., Halwani, J., El-Dakdouki, M. e Mina, S. (2024). Seasonal assessment of surface water and sediments pollution in Rachiine River, Northern Lebanon, using multivariate statistical analysis. *Heliyon*, 10(19). <https://doi.org/10.1016/j.heliyon.2024.e39016>
- McBratney, A. e Minasny, B. (2004). Soil inference systems. *Developments in Soil Science*, 30, 323–348. [https://doi.org/10.1016/S0166-2481\(04\)30018-8](https://doi.org/10.1016/S0166-2481(04)30018-8)
- Mozaffari, H., Moosavi, A. e Nematollahi, M. (2024). Predicting saturated and near-saturated hydraulic conductivity using artificial neural networks and multiple linear regression in calcareous soils. *PLOS ONE*, 19(1), e0296933. <https://doi.org/10.1371/journal.pone.0296933>
- Okewu, E., Misra, S. e Lius, F. (2020). Parameter Tuning Using Adaptive Moment Estimation in Deep Learning Neural Networks. Em O. Gervasi, et al. (Eds), *Computational Science and Its Applications – ICCSA 2020* (pp. 261–272). Springer. https://doi.org/10.1007/978-3-030-58817-5_20
- Pacheco, V., Bragagnolo, L. e Thomé, A. (2021). Artificial neural networks applied for solidified soils data prediction: a bibliometric and systematic review. *Engineering Computations*, 38(7), 3104–3131. <https://doi.org/10.1108/EC-10-2020-0576>
- Padarian, J., Minasny, B. e McBratney, A. (2020). Machine learning and soil sciences: a review aided by machine learning tools. *Soil*, 6(1), 35–52. <https://doi.org/10.5194/soil-6-35-2020>

- Piccoli, I., Camarotto, C., Squartini, A., Longo, M., Gross, S., Maggini, M., Cabrera, M. e Morari, F. (2024). Hydrogels for agronomical application: from soil characteristics to crop growth: a review. *Agronomy for Sustainable Development*, 44, 22. <https://doi.org/10.1007/s13593-024-00958-4>
- Piccolo, A. e Drosos, M. (2025). The essential role of humified organic matter in preserving soil health. *Chemical and Biological Technologies in Agriculture*, 12, 21. <https://doi.org/10.1186/s40538-025-00730-0>
- Qi, J., Cheng, P., Zhou, J., Zhang, M., Gao, Q., He, P., Li, L., Muga, F. e Guo, L. (2025). A Novel Model for Soil Organic Matter and Total Nitrogen Detection Based on Visible/Shortwave Near-Infrared Spectroscopy. *Land*, 14(2), 329. <https://doi.org/10.3390/land14020329>
- Qiao, J., Zhu, Y., Jia, X., Huang, L. e Shao, M. (2019). Pedotransfer functions for estimating the field capacity and permanent wilting point in the critical zone of the Loess Plateau, China. *Journal of soils and sediments*, 19, 140–147. <https://doi.org/10.1007/s11368-018-2036-x>
- Raja, M., Abdoun, T. e El-Sekelly, W. (2024). Exploring the Potential of Machine Learning in Stochastic Reliability Modelling for Reinforced Soil Foundations. *Buildings*, 14(4), 954. <https://doi.org/10.3390/buildings14040954>
- Ramos, T., Darouich, H. e Gonçalves, M. (2023). Development and functional evaluation of pedotransfer functions for estimating soil hydraulic properties in Portuguese soils: Implications for soil water dynamics. *Geoderma Regional*, 35, e00717. <https://doi.org/10.1016/j.geodrs.2023.e00717>
- Rawls, W., Brakensiek, D. e Saxton, K. (1982). Estimation of Soil Water Properties. *American Society of Agricultural and Biological Engineers*, 25(5), 1316–1320. <https://doi.org/10.13031/2013.33720>

- Rehman, M., Abd Rahman, N., Ibrahim, A., Kamal, N. e Ahmad, A. (2024). Estimation of soil erodibility in Peninsular Malaysia: A case study using multiple linear regression and artificial neural networks. *Heliyon*, 10(7). <https://doi.org/10.1016/j.heliyon.2024.e28854>
- Sadeghi, M., Casey, P., Carranza, E. e Lynch, E. (2024). Principal components analysis and K-means clustering of till geochemical data: Mapping and targeting of prospective areas for lithium exploration in Västernorrland Region, Sweden. *Ore Geology Reviews*, 167, 106002. <https://doi.org/10.1016/j.oregeorev.2024.106002>
- Santos, A. (2024). Integração de parâmetros ambientais e machine learning na modelagem do solo para agricultura sustentável [Tese de Doutorado, Universidade Estadual Paulista]. Repositório institucional - Universidade Estadual Paulista.
- Santos, A., Silva Junior, A., Nery, L., Gomes, G., Toniolo, B., Silva, D. e Lourenço, R. (2025a). Random forest algorithm applied to model soil textural classification in a river basin. *Environmental Monitoring and Assessment*, 197, 330. <https://doi.org/10.1007/s10661-025-13786-0>
- Santos, A., Nery, L., Tondato Arantes, L., Toniolo, B., Silva, D. e Lourenço, R. (2025b). Performance of Random Forest in predicting soil loss based on values calculated by USLE. *Earth Sciences Research Journal*, 29(4), 379–386. <https://tinyurl.com/4tcmv95h>
- Saxton, K., Rawls, W., Romberger, J. e Papendick, R. (1986). Estimating Generalized Soil-water Characteristics from Texture. *Soil Science Society of America Journal*, 50(4), 1031–1036. <https://doi.org/10.2136/sssaj1986.03615995005000040039x>
- Silva, D. (2016). *Proposta metodológica para elaboração de um índice espacial de sustentabilidade ambiental aplicado a bacias hidrográficas* [Tese de Doutorado, Universidade Estadual Paulista]. Repositório institucional - Universidade Estadual Paulista.

- Silva, D., Filho, J., de Oliveira, R. e Lourenço, R. W. (2018). Proposta metodológica para análise espacial de nutrientes do solo em bacias hidrográficas. *Sociedade & Natureza*, 30(3), 85–107. <https://doi.org/10.14393/SN-v30n3-2018-5>
- Silva, L., Amorim, R., Filho, E., Bocuti, E. e da Silva, D. (2023a). Pedotransfer functions and machine learning: Advancements and challenges in tropical soils. *Geoderma Regional*, 35, e00720. <https://doi.org/10.1016/j.geodrs.2023.e00720>
- Silva, D., Oliveira, R., Simonetti, V., Toniolo, B., Sales, J. e Lourenço, R. (2023b). Creation of an environmental sustainability index for water resources applied to watersheds. *Environment, Development and Sustainability*, 25, 11285–11305. <https://doi.org/10.1007/s10668-022-02527-9>
- Silva Junior, A., Santos, A. e Silva, D. (2025). Aplicações do Geoprocessamento na Gestão e Conservação do Solo: Análise Integrada da Granulometria do solo e do Fator K em Sub-Bacias Hidrográficas. *Ateliê Geográfico*, 19(3), 349–376. <https://doi.org/10.5216/ag.v19i3.81589>
- Smagin, A. (2025). A physically based model for the entire soil water retention curve. *Soil Science Society of America Journal*, 89(2), e70054. <https://doi.org/10.1002/saj2.70054>
- Štrbac, S., Stojić, N., Lončar, B., Pezo, L., Čurčić, L., Prokić, D. e Pucarević, M. (2024). Heavy metal concentrations in the soil near illegal landfills in the vicinity of agricultural areas—artificial neural network approach. *Journal of Soils and Sediments*, 24, 373–389. <https://doi.org/10.1007/s11368-023-03637-1>
- Tang, L. (2024). Extraction study of soil mineral ions and microbial influences on phosphorus and sulfur cycling based on principal component analysis. *Journal of Combinatorial Mathematics and Combinatorial Computing*, 127b, 6405–6419. <https://doi.org/10.61091/jcmcc127b-351%20%20%20%20>

- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267–288. <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>
- Tisdall, J. e OADES, J. (1982). Organic matter and water-stable aggregates in soils. *Journal of Soil Science*, 33(2), 141–163. <https://doi.org/10.1111/j.1365-2389.1982.tb01755.x>
- Veloso, M., Rodrigues, L. e Filho, E. (2024). Pedotransfer functions for estimating hydraulic conductivity and soil moisture in the Cerrado biome. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 28(12), e278960. <https://doi.org/10.1590/1807-1929/agriambi.v28n12e278960>
- Wang, C., Wu, Y., Xie, L., Yang, Z., Tian, J., Yu, F., Ren, J. e Li, S. (2025). Estimating Soil-Water Characteristic Curve From the Particle Size Distribution With a Novel Granular Packing Model. *Water Resources Research*, 61(2), e2024WR037262. <https://doi.org/10.1029/2024WR037262>
- Wang, L., Guo, M., Chen, Z., Zhang, X., Zhou, P., Liu, X., Qi, J., Wan, Z., Xu, J. e Zhang, S. (2024a). Quantifying the contributions of factors influencing the spatial heterogeneity of soil aggregate stability and erodibility in a Mollisol watershed. *Catena*, 239, 107941. <https://doi.org/10.1016/j.catena.2024.107941>
- Wang, K., Zhou, J., Tan, M. L., Lu, P., Xue, Z., Liu, M. e Wang, X. (2024b). Impacts of vegetation restoration on soil erosion in the Yellow River Basin, China. *Catena*, 234, 107547. <https://doi.org/10.1016/j.catena.2023.107547>
- Weber, T., Weihermüller, L., Nemes, A., Bechtold, M., Degré, A., Diamantopoulos, E., Fatichi, S., Filipović, V., Gupta, S., Hohenbrink, T., Hirmas, D., Jackisch, C., de Jong van Lier, Q., Koestel, J., Lehmann, P., Marthens, T., Minasny, B., Pagel, H., van der Ploeg, M... Bonetti, S. (2024). Hydro-pedotransfer functions: a roadmap for future development. *Hydrology and Earth System Sciences*, 28(14), 3391–3433. <https://doi.org/10.5194/hess-28-3391-2024>

- Wösten, J., Lilly, A., Nemes, A. e Le Bas, C. (1999). Development and use of a database of hydraulic properties of European soils. *Geoderma*, 90(3–4), 169–185. [https://doi.org/10.1016/S0016-7061\(98\)00132-3](https://doi.org/10.1016/S0016-7061(98)00132-3)
- Xiong, M., Sun, R. e Chen, L. (2018). Effects of soil conservation techniques on water erosion control: A global analysis. *Science of the Total Environment*, 645, 753–760. <https://doi.org/10.1016/j.scitotenv.2018.07.124>
- Yang, J. e Long, Q. (2024). A modification of adaptive moment estimation (adam) for machine learning. *Journal of Industrial and Management Optimization*, 20(7), 2516–2540. <https://doi.org/10.3934/jimo.2024014>
- Ye, C., Zheng, G., Tao, Y., Xu, Y., Chu, G., Xu, C., Chen, S., Liu, Y., Zhang, X. e Wang, D. (2024). Effect of Soil Texture on Soil Nutrient Status and Rice Nutrient Absorption in Paddy Soils. *Agronomy*, 14(6), 1339. <https://doi.org/10.3390/agronomy14061339>
- Zhang, J., Miao, Q., Xue, Y., Li, Z. e Cui, Z. (2020). Managing soils and crops for sustainable agricultural intensification in coastal saline zones. *Agronomy Journal*, 112(4), 3076-3088. <https://doi.org/10.1002/agj2.20249>
- Ziviani, M., Costa, E., Alves, A., Pinto, L., Pereira, M. e dos Anjos, L. (2024). Pedotransfer Functions in the Assessment of Fragile Mountainous Areas: Carbon and Nitrogen Stocks in Mountains in Southeastern Brazil. *Revista de Gestão Social e Ambiental*, 18(8), e06052. <https://doi.org/10.24857/rgsa.v18n8-018>