

Simpósio de Integração Acadêmica

“Bicentenário da Independência: 200 anos de ciência, tecnologia e inovação no Brasil e 96 anos de contribuição da UFV”

SIA UFV 2022



PREDIÇÃO DE PROPRIEDADES HIDRÁULICAS DE SOLOS DO ESTADO DE MATO GROSSO

Sannawá da Graça Ferreira - (DEC/UFV) - sannawa.ferreira@ufv.br

Ricardo Santos Silva Amorim (DEA/UFV) - rsamorim@ufv.br

Lucas de Castro Moreira da Silva (DEA/UFV) - lucas.c.moreira@ufv.br

Edwaldo Dias Bocuti (PPGA/UFMT) - edwaldodiasbocuti@gmail.com

Projeto de Pesquisa - Engenharia Agrícola, Ciências agrárias

Palavras-chave: Pedotransferência, Capacidade de água disponível, Solos tropicais

Introdução

Propriedades hidráulicas do solo são informações cruciais para estudos de modelagem agrícola e ambiental. Todavia, a determinação por métodos convencionais é complexa e onerosa⁽¹⁾. Assim, funções de pedotransferência (PTFs) são uma alternativa para estimar essas propriedades por meio de variáveis de obtenção mais simples⁽²⁾. Porém, o desempenho de PTFs em regiões tropicais ainda é modesto, e algoritmos de aprendizado de máquina têm sido utilizados como forma de melhorar a confiabilidade das predições por PTFs⁽³⁾.

Objetivos

Desenvolver PTFs para propriedades hidráulicas (condutividade hidráulica e retenção de água) de solos do estado de Mato Grosso por meio de técnicas de aprendizado de máquina.

Material e Métodos

O banco de dados foi estabelecido a partir de dados extraídos de diferentes trabalhos, abrangendo propriedades físicas, químicas e morfológicas do solo. Sendo realizado um particionamento da base de dados, onde 75% foi particionada para treinamento dos modelos e 25% para teste independente. Utilizou-se três algoritmos de aprendizado de máquina: k- Nearest Neighbors (KNN), Random Forest (RF), Support Vector Machine (SVM), além da convencional Regressão Linear Múltipla (MLR). Para a avaliação da qualidade de ajuste das PTFs utilizou-se os indicadores estatísticos: RMSE, MAE, R^2 . Para a modelagem das propriedades hidráulicas, foram usados 684 registros de capacidade de campo e ponto de murcha permanente e 580 amostras de condutividade hidráulica.

Apoio Financeiro

CAPES e FAPEMIG

Bibliografia

- (1) Botula, Y.-D., Van Ranst, E., Cornelis, W.M., 2014. Pedotransfer functions to predict water retention for soils of the humid tropics: a review. Rev. Bras. Ciência do Solo 38, 679–698. <https://doi.org/10.1590/s0100-06832014000300001>
- (2) Rab, M.A., Chandra, S., Fisher, P.D., Robinson, N.J., Kitching, M., Aumann, C.D., Imhof, M., 2011. Modelling and prediction of soil water contents at field capacity and permanent wilting point of dryland cropping soils. Soil Res. 49, 389–407. <https://doi.org/10.1071/SR10160>
- (3) Patil, N.G., Singh, S.K., 2016. Pedotransfer Functions for Estimating Soil Hydraulic Properties: A Review. Pedosphere 26, 417–430. [https://doi.org/10.1016/S1002-0160\(15\)60054-6](https://doi.org/10.1016/S1002-0160(15)60054-6)

Resultados e Discussão

As variáveis preditoras mais importantes para a capacidade de campo e ponto de murcha permanente foram: areia total, argila e areia fina. Para a condutividade hidráulica foram: densidade, areia e argila. O algoritmo que apresentou melhor desempenho na modelagem da capacidade de campo e do ponto de murcha permanente foi o RF, com valores de $R^2 = 0,81$, $MAE = 0,0267 \text{ m}^3 \text{ m}^{-3}$ (Figura 1A) e $R^2 = 0,86$, $MAE = 0,0185 \text{ m}^3 \text{ m}^{-3}$ (Figura 1B). Para a modelagem do logaritmo da condutividade hidráulica, o melhor algoritmo foi o KNN, com $R^2 = 0,53$ e $MAE = 0,430 \text{ mm h}^{-1}$ (Figura 1C).

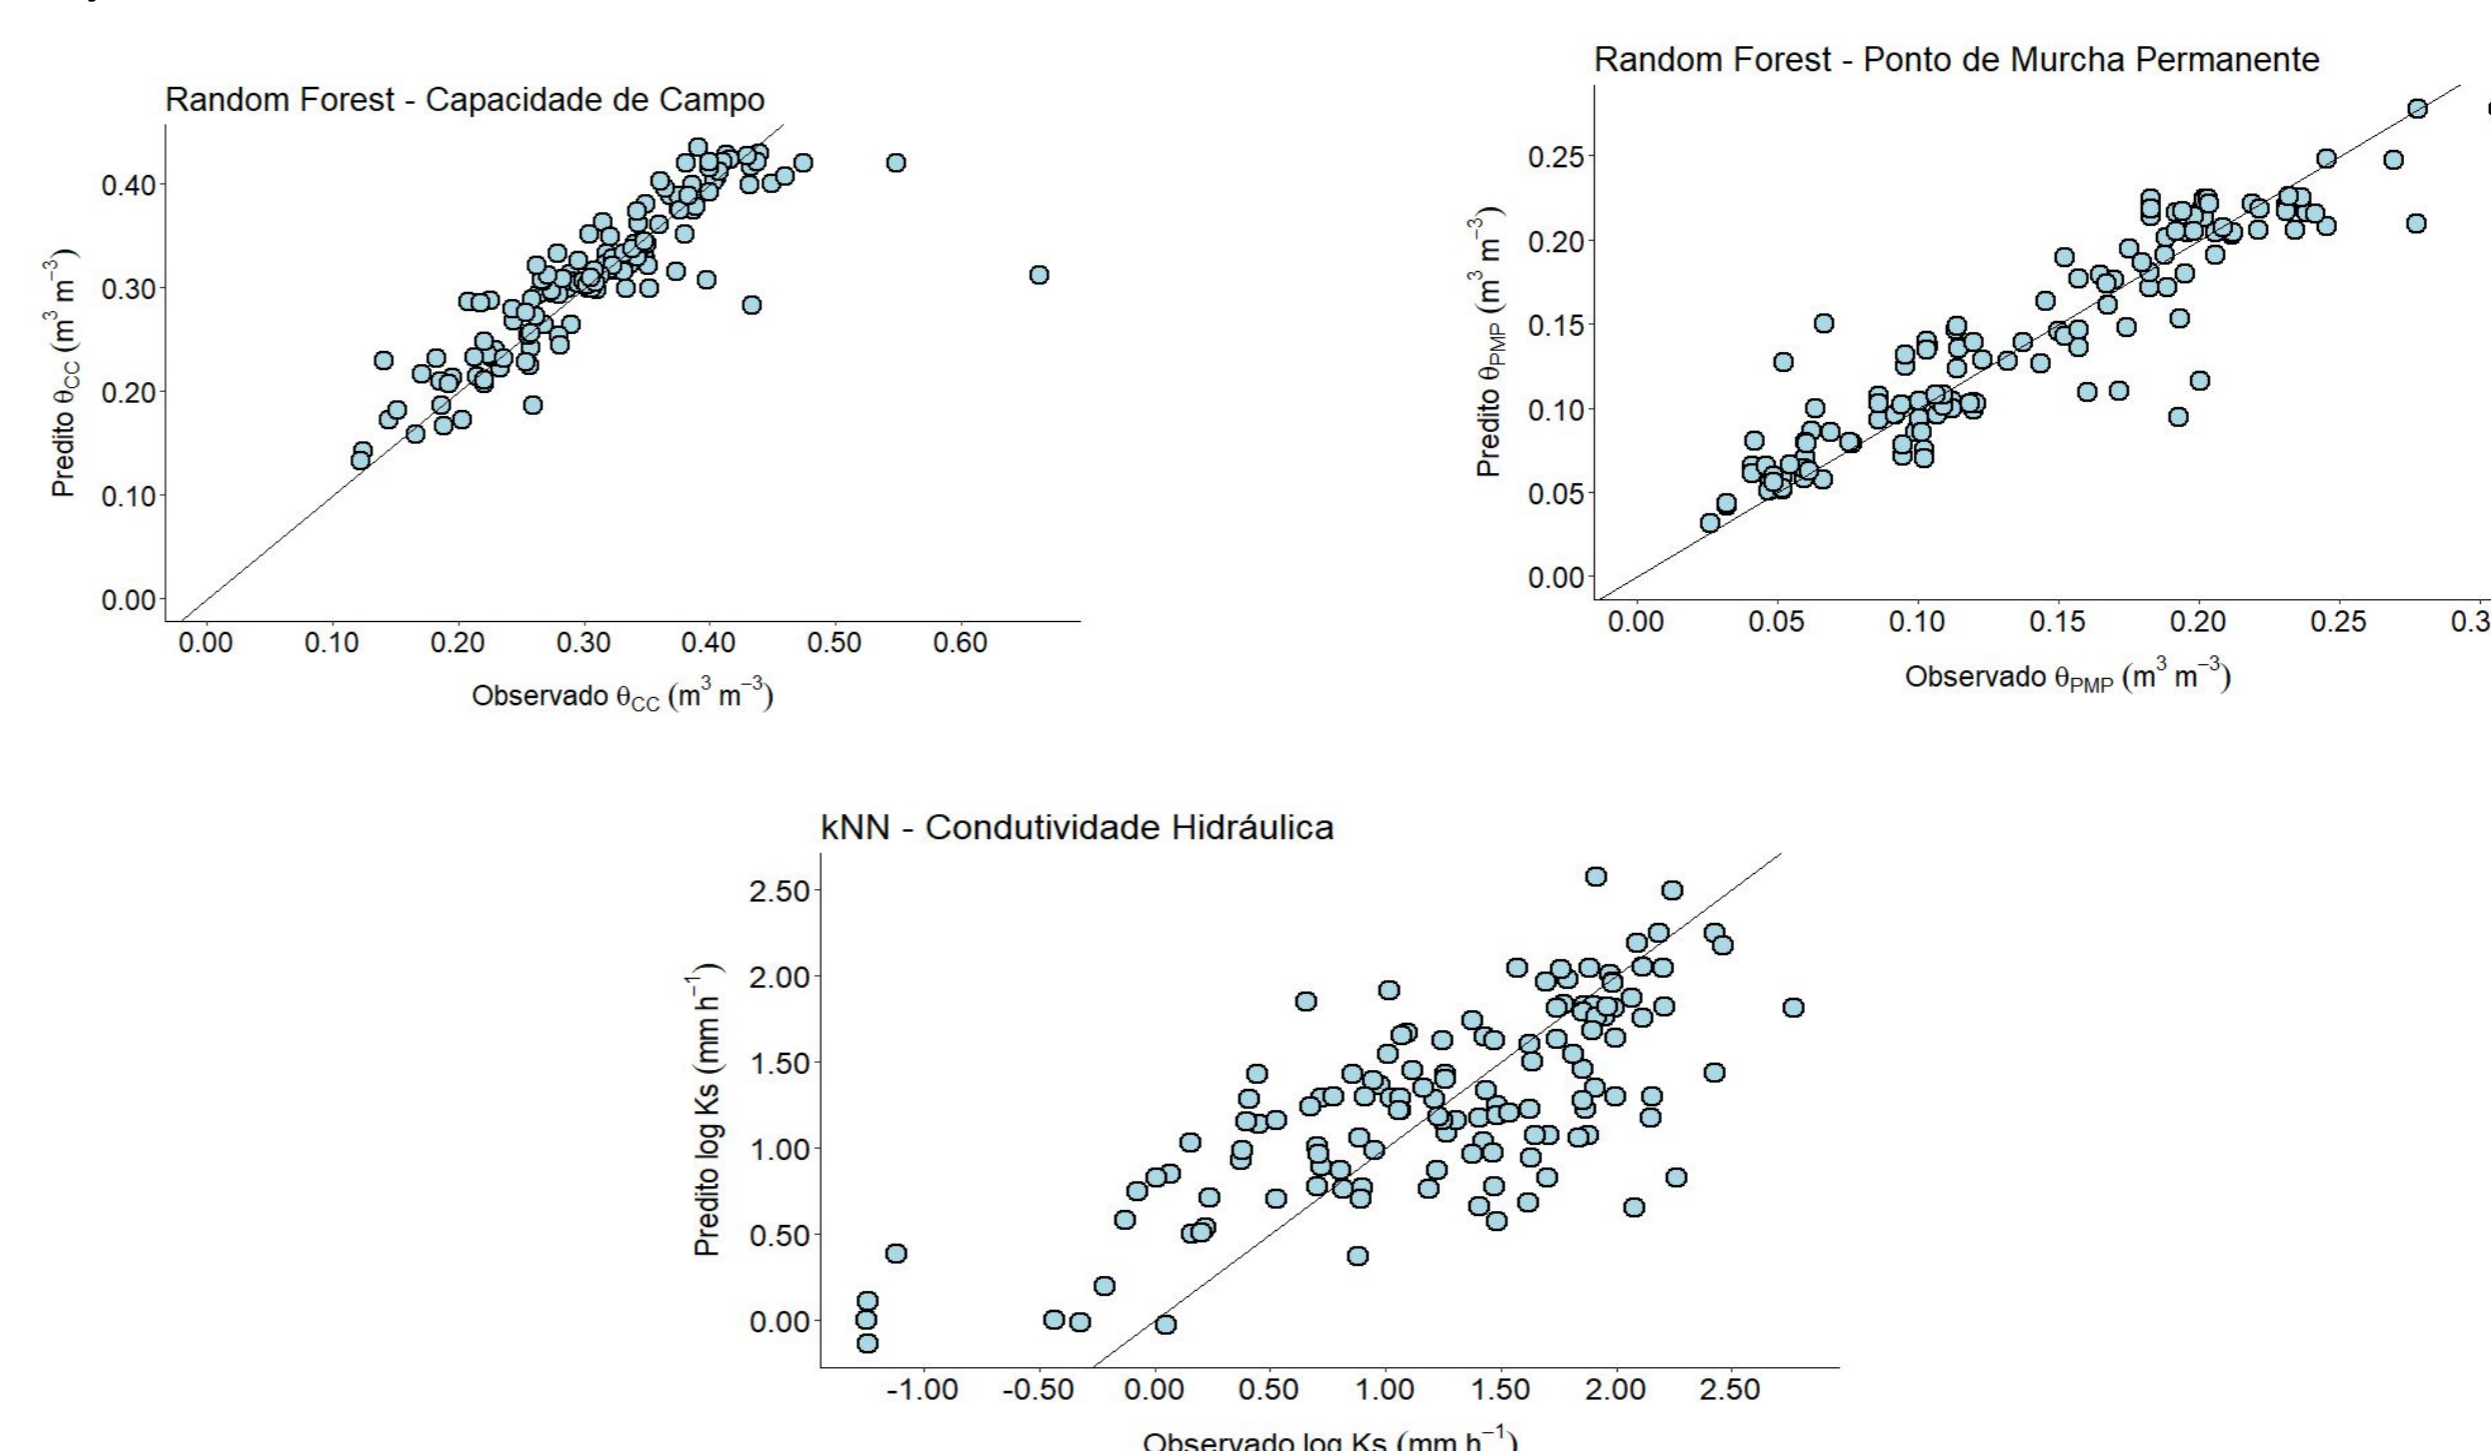


Figura 1. Comparação dos valores de capacidade de campo - θ_{cc} (A), ponto de murcha permanente - θ_{PMP} (B) e condutividade hidráulica - K_s (C) observados e estimados pelos modelos com melhor desempenho.

Conclusões

As PTFs obtidas apresentam bons desempenhos para estimativa dos valores de capacidade de campo, ponto de murcha permanente e condutividade hidráulica.

Não houve um único modelo de aprendizagem de máquina com melhor desempenho para as três variáveis. Sendo que o modelo k-Nearest Neighbors melhor para a K_s e o modelo Random Forest aquele de melhor para a θ_{cc} e o θ_{PMP} .