

REDES NEURAIS NA GERAÇÃO DE FUNÇÕES DE PEDOTRANSFERÊNCIAS PSEUDO-CONTINUAS PARA ESTIMAÇÃO DA UMIDADE DO SOLO

GABRIEL ALMEIDA GOMES¹; MIGUEL DAVID FUENTES-GUEVARA²; ULISSES
BRISOLARA CORRÊA³; THIAGO RODRIGUES DA ROSA⁴; RICARDO
MATSUMURA ARAUJO⁵; LUIS CARLOS TIMM⁶

¹Universidade Federal de Pelotas – gagomes@inf.ufpel.edu.br

²Universidade Federal de Pelotas – miguelfuge@hotmail.com

³Universidade Federal de Pelotas – ulissesbcorrea@gmail.com

⁴Universidade Federal de Pelotas – thiagorodrigues2000@outlook.com.br

⁵Universidade Federal de Pelotas – ricardo@inf.ufpel.edu.br

⁶Universidade Federal de Pelotas – lctimm@ufpel.edu.br

1. INTRODUÇÃO

Nas ciências agrárias e ambientais é de fundamental importância o conhecimento sobre o comportamento dos atributos hídricos do solo, tal como o conteúdo de água no solo, pois tal variável é importante para a tomada de decisões e o estabelecimento de boas práticas agrícolas em relação ao manejo da água e do solo (D'EMILIO et al. 2018).

A determinação dessa variável demanda um tempo considerável, sendo de difícil obtenção e precisando de equipamentos caros na sua medição. Portanto, o uso de métodos alternativos para a sua determinação torna-se necessário, como é o caso das funções de pedotransferência (FPT). As FPT são utilizadas por cientistas do solo, pois são uma ferramenta muito útil na determinação de variáveis de difícil obtenção a partir de outras variáveis mais comuns e de fácil aquisição (GUNARATHNA et al. 2019).

Uma das formas de se obter as FPT é por meio de técnicas de inteligência artificial, como por exemplo, as redes neurais artificiais (RNA), que frequentemente apresentam uma estimativa e acurácia melhor do que outros métodos devido a sua alta capacidade de resolver problemas complexos.

As FPT são principalmente utilizadas em escalas de vertentes (área experimental) ou continental, e não em escala de bacia hidrográfica, unidade a qual é importante para o planejamento e gestão de recursos hídricos. Para a estimativa do conteúdo de água no solo em grande escala são necessários atributos do solo que comumente são obtidos a partir de levantamentos pedológicos ou de bancos de dados nacionais ou internacionais. Assim, a exploração e geração de métodos que tenham o potencial em estimar o conteúdo de água no solo em escalas maiores, como o caso das bacias hidrográficas, torna-se necessário (NEBEL et al. 2010). Frente ao anteriormente exposto, o objetivo do presente estudo foi desenvolver uma RNA para a estimativa do conteúdo de água no solo ao longo de uma bacia hidrográfica.

2. METODOLOGIA

As áreas de estudos consideradas em este estudo foram a bacia hidrográfica Arroio Pelotas (BHAP) e a sua sub-bacia de cabeceira Sanga Ellert (SBHSE). As quais foram selecionadas devido as suas importâncias econômica e social para a região Sul do Rio Grande do Sul nos municípios de Pelotas e Canguçu, onde predominam a agricultura familiar. Trabalhou-se a partir de informações de dados de solo previamente coletados e analisados nessas bacias hidrográficas. A partir disso, um banco de dados de solo foi criado, contendo 14

atributos de solo de fácil aquisição e 1 variável de difícil determinação (conteúdo de água no solo).

Os atributos do solo de fácil aquisição no banco de dados e considerados como variáveis de entrada foram: teor de argila, silte, areia, densidade do solo, macroporosidade, microporosidade, carbono orgânico do solo, elevação do terreno, declividade, aspecto do terreno, curvatura do terreno, curvatura do plano, curvatura do perfil e o potencial matricial de retenção de água no solo. Como variável de saída foi considerada o conteúdo de água no solo (θ).

Na estimação do conteúdo de água no solo foi utilizada a metodologia de HAGVERDI et al. (2012) com adaptações para desenvolver uma FPT pseudocontínua através da técnica de RNA, a qual considera o potencial matricial como um parâmetro de entrada na RNA, permitindo ao usuário estimar o conteúdo de água no solo em qualquer potencial matricial desejado. Conseqüentemente, a RNA foi estabelecida com um único parâmetro de saída referente a θ , estimando o θ no predefinido potencial matricial que foi considerado como parâmetro de entrada. Assim, uma ampla faixa de potenciais matriciais foi usada como parâmetros de entrada (0; -1; -6, -10; -33, -100 e -1,500 kPa), permitindo a estimação das correspondentes faixas de umidades que darão origem a uma curva pseudocontínua.

Durante o planejamento para a escolha do algoritmo de aprendizado de máquina (AM) a ser utilizado para a estimação do θ mediante uma FPT pseudocontínua foram realizados diversos testes no software WEKA (EIBE FRANK et al. 2016), explorando diversos algoritmos para selecionar o mais indicado. Dentre os algoritmos proporcionados pelo WEKA, a RNA perceptron multicamadas demonstrou ser o algoritmo com maior potencial para estimar θ .

O banco de dados estabelecido foi seccionado em dois subconjuntos, um contendo 80% dos dados de entrada e saída (conjunto de treinamento) e o outro contendo o 20% restante dos dados (conjunto de teste). Essa separação de conjuntos foi essencial para dar início ao processo de treinamento da RNA e posterior avaliação do modelo gerado. Depois dessa separação dos dados, foi aplicado uma outra separação no conjunto de treinamento, sendo separados 10% dos dados de forma aleatória dentro do conjunto de treinamento, que posteriormente seria utilizado como conjunto de validação durante o treinamento da RNA, teste esse necessário para poder verificar-se a presença de *overfitting* no treinamento, e também para permitir o uso da técnica de *early stopping*.

A partir disso, a arquitetura da RNA perceptron multicamadas foi desenvolvida na linguagem de programação Python, devido à grande quantidade de bibliotecas que a linguagem possui, facilitando a criação de RNAs. A RNA inicial desenvolvida consistiu de 3 camadas principais, sendo elas, uma camada de entrada, uma camada oculta e uma camada de saída, entre essas camadas foi utilizada a função de ativação *Rectified Linear Unit* (ReLU), assim como uma função de *Batch Normalization* com o objetivo de normalizar as entradas da rede. Na otimização da rede, foi utilizado o otimizador *Stochastic Gradient Descent* (SGD), ademais de um *scheduler* para a variação do parâmetro *learning rate* à medida em que o treinamento da rede fosse realizado.

Com o objetivo de encontrar os melhores hiper parâmetros da rede para solução do problema de estimação de θ , foi dado um foco na automatização de treinamento de diversos modelos com hiper parâmetros diferentes. Essa automatização foi realizada de forma em que fossem desenvolvidos diversos treinamentos de modelos, e em cada saída de modelo fosse obtido a função de perda do modelo (função *Loss*), a qual permite avaliar a qualidade do treinamento da rede com base nos erros de estimação nos conjuntos de treinamento e de

validação, a função *Loss* escolhida para a verificação da qualidade do treinamento é a função MSE.

Outros ajustes de hiper parâmetros foram realizados na RNA como o *early stopping*, uma técnica utilizada para a diminuição de *overfitting* no treinamento, visando que a rede obtenha uma melhoria no desempenho de estimação do θ e na velocidade de treinamentos. A avaliação do desempenho da RNA foi realizada mediante análise estatística das estimações de θ em relação aos dados medidos, mediante os índices R^2 , MAE e RMSE.

3. RESULTADOS E DISCUSSÃO

A RNA desenvolvida gerou modelos que seguem o comportamento da série de dados medidos de θ (saída esperada). Além disso, a capacidade do código de gerar diversos modelos da rede com diferentes hiper parâmetros é algo importante de se salientar, pois a geração de dados resultantes dos treinos são úteis para uma futura análise de quais hiper parâmetros são os mais indicados para resolver a problemática.

A figura 1a representa a qualidade de um dos melhores modelos encontrados com base nas métricas estatísticas sobre o conjunto de treinamento com baixos valores de MAE= 0,07, RMSE= 0,09 $\text{cm}^3 \text{cm}^{-3}$ e $r^2= 0,45$. Porém, nota-se também um ótimo acompanhamento da curva de predição em relação à tendência dos valores esperados.

Referente à figura 1b, ela apresenta o comportamento das estimações do modelo desenvolvido pela RNA sobre o conjunto de validação. Observa-se na figura que durante o treinamento da RNA, a mesma não manifestou a existência de *overfitting*, uma vez que as predições acompanham o comportamento dos valores alvo, então pode-se assumir que a presença de *overfitting* na rede é baixa por causa das métricas de erro serem semelhantes às obtidas durante o treinamento.

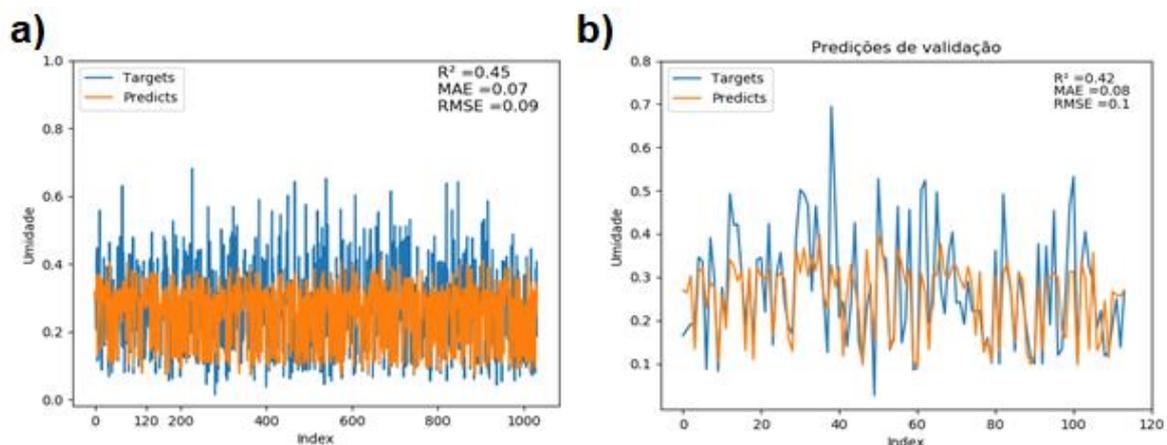


Figura 1. a) Comparação da predição com o conjunto de treinamento e, b) comparação da predição com o conjunto de validação

Na figura 3 observa-se uma representação gráfica do comportamento da função de perda (*Loss*) MSE durante as épocas de treino para o mesmo modelo anteriormente citado, podendo-se assumir que é um comportamento satisfatório, sem grandes oscilações até o final do treinamento.



Figura 3. Acompanhamento do erro MSE durante as épocas de treino sobre o conjunto de treinamento.

Quanto ao conjunto de teste, foi decidido não aplicar ainda nos modelos, pois o projeto ainda se encontra na fase de seleção dos melhores modelos de treino e a procura dos melhores hiper parâmetros.

4. CONCLUSÕES

A RNA desenvolvida demonstrou potencial para a estimação de θ , acompanhando a tendência dos valores esperados. O código desenvolvido para a automatização da troca de hiper parâmetros tem se mostrado muito eficiente, com uma alta velocidade de execução, além de ser de fácil interpretação, manipulação e customização. Contudo, recomenda-se a exploração dos diversos hiper parâmetros que podem influenciar o desempenho da RNA na estimação de θ .

5. REFERÊNCIAS BIBLIOGRÁFICAS

D'EMILIO, A.; AIELLO, R.; CONSOLI, S.; VANELLA, D.; IOVINO, M. Artificial neural networks for predicting the water retention curve of Sicilian agricultural soils. **Water**, v. 10, n.1431, p. 1-13, 2018.

FRANK, E.; HALL, M.A.; WITTEN, I.H. **The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques"**, Morgan Kaufmann, Fourth Edition, 2016.

GUNARATHNA, M; SAKAI, K; NAKANDAKARI, T; MOMII, K; KUMARI, M; AMARASEKARA, M. Pedotransfer functions to estimate hydraulic properties of tropical Sri Lankan soils. **Soil & Tillage Research**, v. 190, p. 109-119, 2019.

HAGHVERDI, A.; CORNELIS, W.M.; GHAHRAMAN, B.A pseudo-continuous neural network approach for developing water retention pedotransfer functions with limited data. **Journal of Hydrology**, v. 442–443, p. 46–54, 2012.

NEBEL, Á.L.C.; TIMM, L.C.; CORNELIS, W.; GABRIELS, D.; REICHARDT, K.; AQUINO, L.A.; PAULETTO, E.A.; REINERT, D.J. Pedotransfer functions related to spatial variability of water retention attributes for lowland soils. **Revista Brasileira de Ciência do Solo**, v. 34, n. 3, p. 669–680, 2010.