



BÁRBARA PEREIRA CHRISTOFARO SILVA

**HYDROPEDOLOGY AS SUPPORT FOR WATER RESOURCES
MANAGEMENT IN AN EXPERIMENTAL WATERSHED AT
MANTIQUEIRA MOUNTAIN RANGE**

**LAVRAS – MG
2019**

BÁRBARA PEREIRA CHRISTOFARO SILVA

**HYDROPEDOLOGY AS SUPPORT FOR WATER RESOURCES MANAGEMENT IN
AN EXPERIMENTAL WATERSHED AT MANTIQUEIRA MOUNTAIN RANGE**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência do Solo, área de concentração em Recursos Ambientais e Uso da Terra, para a obtenção do título de Doutor.

Prof. Dr. Marx Leandro Naves Silva
Orientador

**LAVRAS-MG
2019**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Silva, Bárbara Pereira Christofaro.

Hydropedology as support for water resources management in
an experimental watershed at Mantiqueira mountain range / Bárbara
Pereira Christofaro Silva. - 2019.

94 p. : il.

Orientador(a): Marx Leandro Naves Silva.

Tese (doutorado) - Universidade Federal de Lavras, 2019.
Bibliografia.

1. Mapeamento digital de solos. 2. Calibração de sensores de
umidade do solo. 3. Séries temporais de umidade do solo. I. Silva,
Marx Leandro Naves. II. Título.

BÁRBARA PEREIRA CHRISTOFARO SILVA

**HYDROPEDOLOGY AS SUPPORT FOR WATER RESOURCES MANAGEMENT IN
AN EXPERIMENTAL WATERSHED AT MANTIQUEIRA MOUNTAIN RANGE**

**HIDROPEDOLOGIA COMO SUPORTE ÀS ANÁLISES DE RECARGA DE ÁGUA EM
SUB-BACIA PILOTO DE SERVIÇOS ECOSSISTÊMICOS NO SUDESTE DO BRASIL**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência do Solo, área de concentração em Recursos Ambientais e Uso da Terra, para a obtenção do título de Doutor.

APROVADA em 22 de março de 2019.

Dr. Bruno Montoani Silva UFLA

Dr. Humberto Ribeiro da Rocha USP

Dr. Marcelo Ribeiro Viola UFLA

Dr. Nilton Curi UFLA

Prof. Dr. Marx Leandro Naves Silva
Orientador

**LAVRAS-MG
2019**

AGRADECIMENTOS

Ao Departamento de Ciência do solo, pelo suporte e conhecimento, à UFLA pela estrutura e oportunidade.

A Coordenação de aperfeiçoamento de pessoal de nível superior - Capes - Código de Financiamento 001, pela bolsa de estudos, ao Programa de excelência acadêmica - Proex (AUXPE 593/201), ao Conselho nacional de desenvolvimento científico e tecnológico - CNPq (Processos 306511-2017-7 e 202938/2018-2) e à Fundação de Amparo a Pesquisa do Estado de Minas Gerais - FAPEMIG (Processos APQ-00802-18, e CAG-APQ 01053-15) pelo apoio e financiamento de pesquisas.

À Prefeitura Municipal de Extrema e à Secretaria de Meio Ambiente, pelo suporte financeiro e logístico e pelo apoio nas atividades de campo.

Aos professores Marx Leandro Naves Silva, Nilton Curi e Humberto Ribeiro da Rocha, pela orientação e pelas relevantes contribuições nesta pesquisa.

Aos demais professores, técnicos e funcionários do DCS/UFLA, por todo o conhecimento transmitido e pela convivência durante estes quatro anos.

Em especial, aos amigos e colegas de trabalho do DCS e a todos os amigos dessa vida, os quais, sem dúvida, foram a força motriz para que eu concluísse esta etapa.

À minha família, pelo apoio incondicional em todas as etapas deste percurso.

Muito obrigada!

“Natureza da gente não cabe em certeza nenhuma”
(João Guimarães Rosa)

RESUMO

A hidropedologia estuda as relações solo-água em escalas espaciais e temporais, a partir da integração entre a pedologia, a física do solo e a hidrologia. Conhecer as propriedades e a distribuição dos solos na paisagem é essencial para o planejamento e gestão dos recursos hídricos, tanto para exercer medidas experimentais eficientes, como para interpretar a dinâmica da água na paisagem. O presente trabalho foi desenvolvido na sub-bacias Posses, sub-bacia piloto pioneira no pagamento por serviços ecossistêmicos no Brasil. Os objetivos deste trabalho contemplam: 1) realizar o levantamento, a classificação e o mapeamento digital dos solos (MDS) da sub-bacia Posses, comparando diferentes algoritmos; 2) desenvolver equações de calibração de sensores de capacitância específicas para as classes de solos e horizontes monitorados na sub-bacia e; 3) levantar informações a respeito do padrão temporal da umidade em seis profundidades de Argissolos, em consonância com os atributos físico-hídricos do solo, em áreas de pastagem e reflorestamento. Para a confecção do mapa digital de solos, 74 perfis foram descritos, amostrados e classificados; três diferentes algoritmos comumente usados no MDS foram comparados com base na validação cruzada. Amostras de solo indeformadas foram coletadas nos horizontes A e B das classes de solo predominantes na sub-bacia para a calibração do sensor de capacitância em laboratório e diferentes modelos de regressão foram investigados. O comportamento temporal da umidade do solo foi monitorado em 4 perfis de Argissolos, sob pastagens e reflorestamento, com sensores PR2/profile probe, do período de 08/2014 a 03/2018. Amostras deformadas e indeformadas foram coletadas nos horizontes A e B dos quatro locais monitorados, para caracterização físico-hídrica. O modelo Random Forest, incluindo amostragem adicional, apresentou o melhor desempenho, e foi utilizado para confecção do mapa de solos da sub-bacia das Posses, onde há forte predominância de Argissolos. Equações de calibração específicas foram desenvolvidas para quatro classes de solo, ajustando modelos exponenciais, com acurácias de $0.02 \text{ m}^3 \text{ m}^{-3}$. A partir das análises das séries temporais da umidade nos perfis dos Argissolos, foi constatado que a umidade do solo foi superior nas camadas de 10 e 20 cm do solo na área de reflorestamento, em relação às pastagens, e uma maior similaridade no padrão de variação da umidade entre os quatro locais com o aumento da profundidade do solo. As maiores diferenças no padrão de variação da umidade foram observadas nos períodos de menor ocorrência de chuvas. Nas profundidades abaixo de 30 cm, a umidade se manteve alta ao longo de todas as séries temporais, reflexo da alta capacidade de retenção de água dos Argissolos da sub-bacia das Posses e da elevada e bem distribuída precipitação.

Palavras-chave: Mapeamento digital de solos. Calibração sensores de umidade do solo. Sensores capacitivos. Séries temporais de umidade.

ABSTRACT

Hydropedology emerges with the aim of improving the studies of soil-water relations at spatial and temporal scales, from the interaction among pedology, soil physics, and hydrology. A key factor in the planning and management of water resources consists of knowledge of the properties and distribution of soils in the landscape, both to perform efficient experimental measures and to interpret the dynamics of water in the landscape. The present work was developed in the Posses sub-basins, a pioneer sub-basin in the payment for ecosystem services in Brazil. The objectives of this work include: 1) to carry out the survey, classification and digital mapping of soil in the sub-basin and compare different algorithms; 2) to develop specific calibration equations of capacitance sensors for the soil classes and horizons monitored in the sub-basin and; 3) to obtain information about the temporal pattern of soil moisture in six depths of Argisols, according to the physic-hydric attributes of the soil, in pasture and reforestation areas. A soil survey was carried out and 74 soil profiles were described, sampled and classified for the production of the digital soil map. Three different algorithms were evaluated based on aggregated data from a proportional 5-fold cross-validation procedure. Undisturbed soil samples were collected from the A and B horizons of the predominant soil classes in the sub-basin for the calibration of capacitance sensors in the laboratory and different regression models were investigated. Soil moisture temporal behavior was monitored in four Argisol profiles, under pasture and reforestation, with PR2 / profile probe sensors, from 08/2014 to 03/2018. Disturbed and undisturbed samples were collected from the A and B horizons of the four sites monitored for physical-hydric characterization. The random forest model including additional sampling showed the best performance among the three tested models and was selected to produce the soil map of the Posses sub-basin, where there is a strong predominance of Argisols. The capacitance sensors were calibrated by adjusting polynomial equations with an accuracy of $0.02 \text{ m}^3 \text{ m}^{-3}$. Based on the analyses of the time series of soil moisture in the Argisol profiles, it was verified that the soil moisture was higher in the 10 and 20 cm soil layers in the reforestation area, when comparing to the pastures, and also that similarities in the soil moisture pattern, among the four sites, were higher as the depth of the soil increases. The greatest differences in the pattern of soil moisture variation were observed in periods of less rainfall. In soil depths below 30 cm, the soil moisture remained high throughout all the time series, reflecting the high water retention capacity of the Argisols of the Posses sub-basin and also the high and well-distributed rainfall.

Keywords: Digital soil mapping. Soil moisture sensor calibration. Capacitive Sensor. Time series of soil moisture.

SUMÁRIO

PRIMEIRA PARTE	10
INTRODUÇÃO	11
REFERÊNCIAS	15
SEGUNDA PARTE – ARTIGOS.....	17
ARTIGO 1 - Digital soil mapping including additional point sampling in Posses ecosystem services pilot watershed, southeastern Brazil	18
ARTIGO 2 - NONLINEAR MODELS FOR SOIL MOISTURE SENSOR CALIBRATION IN TROPICAL MOUNTAINOUS SOILS	42
ARTIGO 3 - Dinâmica temporal da umidade em perfis de Argissolos sob pastagens e reflorestamento em sub-bacia hidrográfica na Serra da Mantiqueira, MG.....	69

PRIMEIRA PARTE – INTRODUÇÃO GERAL

1 INTRODUÇÃO

O solo e a água são elementos fundamentais na busca do equilíbrio entre a necessidade de exploração dos recursos naturais e a sustentabilidade ambiental. As interações existentes entre estes dois elementos são complexas e uma abordagem multidisciplinar é necessária para interpretá-las corretamente. A integração da pedologia, a física do solo e a hidrologia, a fim de melhorar os estudos das relações solo-água em escalas espaciais e temporais, foi formalmente definida como hidropedologia por Lin (2003).

A hidropedologia foi sugerida por Lin (2003) como um ramo entrelaçado da ciência do solo com a hidrologia, que envolvem aproximações interdisciplinares para o estudo da interatividade dos processos pedológicos e hidrológicos na chamada “zona crítica da terra”, que corresponde à zona que vai do topo da vegetação até a base do aquífero (RICHTER JR; MOBLEY, 2009). Este tem se mostrado um campo promissor, com foco no avanço da ciência do solo e da hidrologia, ao orientar a aquisição de dados de campo de forma mais eficaz, integrar o conhecimento e melhorar as previsões de modelos baseados nas relações complexas solo-água-vegetação existentes na paisagem (LIN, 2012).

O solo é o principal meio de transporte e armazenamento de água, envolvido em interações dinâmicas com o reservatório subterrâneo e atmosférico, cujo comportamento hidrológico é reflexo dos seus atributos, posição na paisagem, tipo de vegetação e manejo e condições climáticas (TONG; SHEN, 2010). O aprofundamento das análises pedológicas, em escalas de paisagem, e sua inserção nas teorias de hidrologia, possibilitam o desenvolvimento de modelos hidrológicos mais realistas, fisicamente fundamentados e com menos dependência de parametrização, sendo este um dos desafios mais importantes para o hidrólogo (MELLO; CURI, 2012).

A variabilidade espacial e temporal da resposta hidrológica de uma bacia hidrográfica é atribuível à heterogeneidade da paisagem (TROCH et al., 2009). Consequentemente, é esperado que nossa compreensão da natureza da variabilidade do solo na paisagem aumente nossa capacidade de modelar e prever a resposta hidrológica de uma bacia hidrográfica (LIN, 2012). A variabilidade espacial dos solos e de suas propriedades intrínsecas é reconhecida como tendo influência significativa sobre os processos de partição da precipitação, em infiltração e escoamento superficial, sobre a redistribuição lateral e vertical da água subsuperficial e sobre a

distribuição espacial da umidade do solo (GUNTNER; BRONSTERT, 2004). O levantamento, a classificação e o mapeamento dos solos fundamenta a interpretação do padrão de variação dos solos ao longo da paisagem, ao passo que a descrição de perfis do solo fornece informações fundamentais da estrutura do solo “in situ” e das feições hidromorfológicas presentes, que são assinaturas dos processos hidrológicos ocorrentes no solo. O banco de dados do levantamento de solos fornece uma gama de informações importantes para os hidrólogos, ao passo que a classificação dos solos faculta um sistema hierárquico para organizar, modelar e transferir nosso conhecimento sobre os diferentes tipos de solos (Lin, 2003). Além de fornecer informações imprescindíveis para a aplicação de modelos hidrológicos, o mapeamento do solo também orienta a tomada de medidas experimentais e a escolha dos locais a serem amostrados ou monitorados em uma área de estudo.

Conhecer a distribuição dos solos na paisagem também é essencial para a interpretação da dinâmica espaço-temporal da umidade na paisagem, já que o comportamento hidrológico do solo é fortemente influenciado por suas características intrínsecas, tais como profundidade (MENEZES et al., 2009), textura (LUZ; LIMA, 2008; LIMA et al., 2013) e estrutura (BRONICK; LAL, 2005). Solos de diferentes classes e com características intrínsecas influenciam de maneira distinta a dinâmica da água do solo. Além de orientar a seleção de locais para o monitoramento da umidade do solo, conhecer o padrão de distribuição dos solos na paisagem possibilita que informações pontuais, obtidas em escalas de pedon, sejam utilizadas para inferir os processos que ocorrem em toda a paisagem.

Um dos principais problemas relacionados aos estudos que envolvem a ciência do solo, apontado por Mello e Curi (2012), refere-se ao uso indiscriminado de amostras de solo deformadas ou à preparação de colunas empacotadas com solo, nas quais estudos hidrológicos relacionados ao fluxo da água no perfil do solo são realizados, já que comprometem a estrutura do solo e seu meio físico, químico e biológico. É exatamente nesse contexto que a Hidropedologia se torna necessária, pois enfatiza o significado original da Pedologia e sua interação com o meio geofísico (LIN, 2011). No campo da hidrologia, Lin (2011) aponta que o advento dos computadores e softwares aplicados à hidrologia vem provocando uma corrida ao desenvolvimento de modelos e pouca importância tem sido dada aos dados observados no campo. Como explicado anteriormente, a hidropedologia trabalha com o objetivo de melhorar a previsão dos fenômenos hidrológicos, permitindo a expansão do conhecimento sobre o comportamento

dos atributos do solo relacionados com o fluxo da água em micro escala e as suas relações com o comportamento hidrológico em macro-escala (MELLO; CURI 2012).

Nesse sentido, estudar o comportamento da umidade e sua variabilidade no perfil do solo, através do monitoramento “in situ” do saldo de entrada e de saída de água, auxilia na compreensão dos processos ligados ao balanço hídrico em grandes escalas. Tais informações são fundamentais para modelagem e previsão hidrológica, restauração da vegetação e sustentabilidade do uso do solo (WANG et al., 2014; LI et al., 2015). Métodos não destrutivos, baseados na constante dielétrica do solo, tais como a reflectometria no domínio do tempo (TDR) ou da frequência (FDR) e técnicas de capacitância, têm sido extensivamente utilizados para o monitoramento contínuo da umidade do solo “in situ” e para medir e modelar sua evolução no espaço – tempo (ROMANO, 2014). Cabe aqui ressaltar que avaliações precisas da umidade do solo, a partir de sensores eletromagnéticos, requerem equações de calibração específicas para os solos (MORTL et al. 2011; ROWLANDSON et al. 2013) e horizontes (EVETT; TOLK; HOWELL, 2006), já que o comportamento dielétrico dos solos é inerente às suas propriedades eletromagnéticas.

Para que as informações pontuais da umidade do solo possam ser estendidas para descrever os padrões de umidade do solo em toda a paisagem é essencial que as observações de umidade sejam acompanhadas da caracterização dos atributos do solo (PAN et al., 2012). Os atributos do solo responsáveis pelo armazenamento e redistribuição de água, tais como a textura do solo e a distribuição do tamanho de partícula (BHARALI, 2019), os atributos relacionados à retenção de água (GEROY et al., 2011), a condutividade hidráulica (OJHA et al., 2017) e a profundidade do solo (MENEZES et al., 2009), têm-se mostrado fundamentais na interpretação do comportamento da umidade no perfil do solo e na aplicação de modelos matemáticos na tentativa de descrever e melhor compreender a dinâmica da água no sistema solo - planta - atmosfera (PREVEDELLO et al., 2007).

O presente trabalho foi desenvolvido no contexto do projeto “Conservador das Águas”, no município de Extrema – MG. Com o intuito de assegurar a proteção dos mananciais estratégicos no Brasil, a Agência Nacional de Águas - ANA desenvolveu o “Programa Produtor de Águas” que apoia o projeto municipal “Conservador das águas” na sub-bacia das Posses, em Extrema – MG. Este é o projeto pioneiro no Brasil com o Pagamento por Prestação de Serviços Ambientais,

o qual visa à proteção dos recursos hídricos que fornecem água para o Sistema Cantareira, responsável pelo abastecimento de 50% da população da Região Metropolitana de São Paulo.

A sub-bacia das Posses, local onde o presente estudo foi realizado, teve grande parte de sua vegetação original substituída, principalmente pela pastagem extensiva, promovendo a degradação do solo, modificando as condições de infiltração e favorecendo a formação de processos erosivos, comprometendo a recarga dos aquíferos. Por ser a mais impactada do município, esta sub-bacia foi escolhida como a pioneira na implantação do projeto municipal “Conservador das Águas”. Desde então, esta área tem se tornado de grande apelo ambiental, sendo adotada como unidade de planejamento e gestão ambiental, sobretudo no que tange a conservação do solo e água, com pagamento de serviços ambientais, uma vez que existe uma necessidade da minimização da erosão hídrica e maximização da recarga de água subterrânea visando o abastecimento dos reservatórios do Complexo Cantareira.

Com o intuito de levantar informações físicas e pedológicas para dar suporte aos diversos estudos hidrológicos que estão sendo desenvolvidos na sub-bacia das Posses e para auxiliar na tomada de medidas experimentais eficientes para a gestão dos recursos hídricos, os objetivos deste trabalho foram: 1) Realizar o levantamento, a classificação e o mapeamento digital dos solos da sub-bacias Posses, comparando diferentes algoritmos para mapeamento digital; 2) Desenvolver equações de calibração de sensores de capacitância específicas para as classes de solos e horizontes monitorados na sub-bacia e; 3) Investigar a dinâmica temporal da umidade em várias profundidades de Argissolos, em consonância com os atributos físico-hídricos do solo, em áreas de pastagem e reflorestamento na sub-bacia das Posses.

REFERÊNCIAS

- BHARALI, B. Rate of infiltration for different soil textures using rainfall simulator and Green–Ampt model. **ISH Journal of Hydraulic Engineering**, New York, p. 1-7, 2019.
- BRONICK, C. J.; LAL, R. Soil structure and management: a review. **Geoderma**, Amsterdam, v. 124, n. 1, p. 3-22, 2005.
- EVETT, S. R.; TOLK, J. A.; HOWELL, T. A. Soil Profile Water Content Determination. **Vadose Zone Journal**, Madison, v. 5, p. 894-907, 2006.
- GUNTNER, A.; BRONSTERT, A. Representation of landscape variability and lateral redistribution processes for large-scale hydrological modelling in semi-arid areas. **Journal of Hydrology**, Amsterdam, v. 297, p. 136–161, 2004.
- GEROY, I. J. et al. Aspect influences on soil water retention and storage. **Hydrological Processes**, Chichester, v. 25, p. 3836–3842, 2011.
- LI, X. et al. Landscape-scale temporal stability of soil water storage within profiles on the semiarid Loess Plateau of China. **Journal of Soils and Sediments**, Berlin, v. 15, n. 4, p. 949-961, 2015.
- LIMA, G. C. **Variabilidade espacial dos atributos físicos e químicos e índice de qualidade dos solos da sub-bacia das Posses, Extrema (MG), sob diferentes agroecossistemas**. 2013. (Tese de Doutorado) – Universidade Federal de Lavras, Lavras 2013.
- LIN, H. Hydropedology: bridging disciplines, scales, and data. **Vadose Zone Journal**, Madison, v. 2, n. 1, p. 1-11, 2003.
- LIN, H. Hydropedology: towards new insights into interactive pedologic and hydrologic processes across scales. **Journal of Hydrology**, Amsterdam, v. 406, p. 141-145, 2011.
- LIN, H. **Hydropedology: Synergistic integration of soil science and hydrology**. Waltham: Academic Press, 2012.
- LUZ, L. R. Q. P.; LIMA, S. L. Atributos físicos e hídricos de solos em topossequência de tabuleiros costeiros. **Revista de Energia na Agricultura**, Botucatu, v. 23, n. 1, p. 44-59, 2008.
- MELLO, C. R.; CURI, N. Hydropedology. **Ciência e agrotecnologia**, Lavras, v. 36, n. 2, p. 137-146, 2012.
- MENEZES, M. D., et al. Dinâmica hidrológica de duas nascentes, associada ao uso do solo, características pedológicas e atributos físico-hídricos na sub-bacia hidrográfica do Ribeirão Lavrinha-Serra da Mantiqueira (MG). **Scientia Forestalis**, Piracicaba, v. 37, n. 82, p. 175-184, 2009.

MORTL, A. et al. Calibration of a combined dielectric probe for soil moisture and porewater salinity measurement in organic and mineral coastal wetland soils. **Geoderma**, Amsterdam, v. 161, p. 50–62, 2011.

OJHA, R. et al. Effective Saturated Hydraulic Conductivity for Representing Field-Scale Infiltration and Surface Soil Moisture in Heterogeneous Unsaturated Soils Subjected to Rainfall Events. **Water (Switzerland)**, Basel, v. 9, n. 2, p. 1-17, 2017.

PAN, W. et al. Characterizing Soil Physical Properties for Soil Moisture Monitoring with the North Carolina Environment and Climate Observing Network. **Journal of Atmospheric and Oceanic Technology**, Boston, v. 29, n. 7, p. 933-943, 2012.

PREVEDELLO, C. L. et al. Balanço de água por aquisição automática de dados em cultura de trigo (*Triticum aestivum* L.). **Revista Brasileira de Ciência do Solo**, Viçosa, v. 31, n.1, p. 1-8, 2007.

RICHTER JR., D. B.; MOBLEY, M. L. Monitoring Earth's Critical Zone. **Science**, Washington, v. 326, n. 5956, p. 1067-1068, 2009.

ROMANO, N. Soil moisture at local scale: measurements and simulations. **Journal of Hydrology**, Amsterdam, v. 516, p. 6-20, 2014.

ROWLANDSON, T. L. et al. Evaluation of several calibration procedures for a portable soil moisture sensor. **Journal of Hydrology**, Amsterdam, v. 498, p. 335–344, 2013.

TONG, S. T. Y.; CHEN, W. Modeling the relationship between land use and surface water quality. **Journal of environmental management**, London, v. 66, n. 4, p. 377-393, 2002.

TROCH, P. A. et al. Dealing with landscape heterogeneity in watershed hydrology: a review of recent progress toward new hydrological theory. **Geography Compass**, Hoboken, v. 3, n. 1, p. 375–392, 2009.

WANG, B. et al. Vertical profiles of soil water content as influenced by environmental factors in a small catchment on the hilly-gully loess plateau. **PLoS ONE**, San Francisco, v. 9, n. 10, p. 17-20, 2014.

SEGUNDA PARTE – ARTIGOS

ARTIGO 1 Digital soil mapping including additional point sampling in Posses ecosystem services pilot watershed, southeastern Brazil

*Normas do periódico Scientific Reports (versão preliminar)

Bárbara Pereira Christofaro Silva^{a*}, Marx Leandro Naves Silva^a, Fabio Arnaldo Pomar Avalos^a, Michele Duarte de Menezes^a, Nilton Curi^a

^a Departamento de Ciência do Solo, Universidade Federal de Lavras UFLA, Av. Doutor Sylvio Menicucci, 1001, Kennedy, Lavras, MG, Brasil.

*Corresponding author: barbarapcsilva@gmail.com; +55 35 997037760

This study aimed to evaluate the performance of three spatial association models used in digital soil mapping and the effects of additional point sampling in a steep-slope watershed. A soil survey was carried out and 74 soil profiles were analysed. The tested models were: Multinomial logistic regression (MLR), C5 decision tree (C5-DT) and Random forest (RF). In order to reduce the effects of an imbalanced dataset on the accuracy of the tested models, additional sampling retrieved by photointerpretation was necessary. Accuracy assessment was based on aggregated data from a proportional 5-fold cross validation procedure. Uncertainty was accounted based on the multivariate environmental similarity surface (MESS). The RF model including additional sampling (RF*) showed the best performance among the tested models (overall accuracy = 65 %, kappa index = 0.60). The RF* allowed to link soil mapping units (SMU) and, in the case of less-common soil classes in the watershed, to set specific conditions of occurrence on the space of terrain-attributes. MESS analysis showed reliable outputs for 82.5 % of the watershed. SMU distribution across the watershed was: Typic Rhodudult (56%), Typic Hapludult* (13%), Typic Dystrudept (10%), Typic Endoaquent+Fluventic Dystrudept (10%), Typic Hapludult (9.5%) and Rhodic Hapludox+Typic Hapludox (2%).

Keywords: Terrain attributes, Soil survey, Pedometrics, Multinomial Logistic Regression, Decision tree, Random Forest

Introduction

Knowledge of the geographic distribution of soils allows to assess environment-soil relationships at the landscape level¹. Such information is essential for agronomic assessment, soil and water management and land use planning¹⁻³. Digital soil mapping (DSM) techniques are supported by a well-known and widely accepted model in soil science: the factors of soil formation. Early efforts to bring a quantitative solution to this model could be traced back to the work of Jenny⁴. Currently, with the development of geographic information technology and data processing, a comprehensive digital framework could be applied for the production of digital soil maps^{1,5,6}.

The *scorpan* model, as formalized by McBratney et al.⁵, serves as a route for the production of digital soil maps. It establishes a quantitative model for spatial association between soil forming factors covariate maps and the occurrence of soil classes or properties. However, since the spatial association complexity is highly variable among landscapes, there is still no consensus or a pre-established function or operational model that could relate soilscape features and the occurrence of soil classes, and so the model selection still represents a challenge in DSM studies.

While current algorithms applied in DSM have shown acceptable performances (e.g. Camera et al.⁷; Jeune et al.⁸; Taghizadeh-Mehrjardi *et al.*⁹), there is still a concern related to the occurrence of less-common soil classes in the areas under study. These soil classes can have significant effects on the process of model fitting, model selection, and output accuracies¹⁰. To overcome this issue, different strategies could be adopted, e.g. feature-space oversampling¹¹ or geographic space oversampling¹². Although these data-driven strategies have proved to be useful in specific circumstances¹⁰, some pedological aspects related to the occurrence of certain soil

classes remain involved. Pedologists' knowledge about the study area (mental model) could also be incorporated into the digital mapping process, by identifying characteristic sites in aerial imagery associated to soil profiles previously surveyed¹³, which might be useful to register specific conditions of less-common soil classes. In this way, the qualitative soil-landscape model would be translated into quantitative predictions supported by the spatial association between soil classes occurrence and environmental covariates¹⁴

Different techniques of DSM have been widely assessed in studies in tropical soils (^{15–19}). However, mountainous and complex relief areas still present challenges to any approach to soil mapping, due to the complex and scale dependent interactions among soil formation factors.

Therefore, this study aimed to evaluate the performance of three algorithms used in digital soil mapping and the effects of additional sampling for mapping of less-common soil classes in a steep-slope watershed.

Material and Methods

Study area

This work was carried out at the Posses watershed, southeastern Brazil (Fig. 1). This watershed covers an area of 1,200 ha, has an altitude range of 945 to 1,435 m, and a relief dominated by steep (> 20 %) to very steep slopes (> 60 %). According to Köppen's climate classification system, it presents a Cfb class, i.e., mesothermic with no dry season and a warm summer²⁰. The average annual temperature is 18 °C, the hottest and coldest months have average temperatures of 25.6 °C and 13.1 °C, respectively, and the average annual precipitation is 1,447 mm. The predominant parental materials are alkaline granite and monzonite²¹.




Fig. 1 Location of the study area and the soil survey sampling sites

This watershed is pilot for the Water conservation project, which stands, since 2006, as a pioneering initiative to establish a payment system for ecosystem services in Brazil²². Among the objectives of this project is the promotion of the sustainability of water resources for the Cantareira System, which is the major water supply system for the metropolitan region of São Paulo city.

Soil survey

The location of sampling sites was based on 74 random points (Fig. 1). Every point was visited by means of GPS/GNSS navigation and the coordinates of reached points were registered

again with a nominal accuracy of ~10 m; such location accuracy allowed a spatial resolution mapping of 20 m²³. In each point soil profiles morphological description and collection of samples from horizons were carried out as support for soil taxonomic classification²⁴.

Soil Mapping Units

The soils surveyed in the study area were: Typic Dystrudept, Typic Humudept, Typic Endoaquent, Fluventic Dystrudept, Rhodic Hapludox, Typic Hapludox, Typic Hapludult (yellow), Typic Rhodudult, Rhodic Kandiudult and Typic Hapludult* (red-yellow) (Table 1), which correspond to Haplic Cambisol, Humic Cambisol, Haplic Gleysol, Fluvic Cambisol, Red-Latosol, Red-Yellow Latosol, Yellow Argisol, Red Argisol, Red Nitosol and Red-Yellow Argisol, respectively ²⁵

The dominant soil mapping unit (SMU) was the Typic Rhodudult (49 % of the surveyed locations). Since a high imbalance in the dataset was observed, regarding number of pedons in relation to mapping units (Table 1), additional observations were retrieved by expert knowledge and by means of photointerpretation from high-resolution imagery in Google Earth; by doing this, imbalances higher than 2:1 for less-common soil mapping units were not registered (Fig. 2).




Fig. 2 a) Field (FO) and additional (AO) observations. b) Original and final proportions by soil mapping unit

Model selection and soil map production

The spatial prediction framework was based on the approach proposed by⁵, which is an updated and spatially-explicit implementation of the early concepts of Dokuchaev's soil forming factors and Jenny's quantitative interpretation of them⁴. This technique assumes that a soil property or class is a function of a spatial representation of other soil property (s) or a soil-forming factor, namely: climate (c), organisms and vegetation (o), topography (r), parent material (p), time (a), and geographic location (n).

Climate (c) and parent material (p) proxies are not available at the scale of analysis here (10^1 km), and the coarse resolution of current information does not represent spatial variation that could be used for digital mapping. Therefore, only the available maps of relief (r) and organisms and vegetation (o) factors were assessed.

The relief factor (r) proxy was a digital elevation model (DEM) from ALOS which was downloaded from earth.engine.com. The DEM was hydrologically corrected and resampled to the

earlier mentioned spatial resolution mapping of 20 m. After corrections, a total of 28 terrain attributes, that are commonly tested for digital soil mapping, were derived.

Sentinel 2 imagery data (top of the atmosphere reflectance), downloaded from scihub.copernicus.eu, were assessed as the organisms and vegetation factor (*o*). In addition to reflectance data, normalized difference vegetation index (NDVI)^{26,27} and normalized water difference index (NDWI)²⁸ were calculated and evaluated. Processing of *o* and *r* factors were carried out in SAGA GIS software²⁹ and the model analysis was run on R³⁰.

Aiming to fit the best spatial association model that relates soil-forming factor proxies (scorpan's *r* and *o*) and the occurrence of soil mapping units, three models were tested: Multinomial Logistic Regression (MLR), C5 Decision tree (C5-DT), and Random Forest (RF).

The MLR analysis allows to model categorical responses by fitting linear combinations of a set of covariates (predictors) to the natural logarithm of the odds of every level of a response variable (logit transformation)^{31,32}. MLR has been widely applied and tested for classification and mapping of soil features^{8,33}. Therefore, the set of scorpan's *o* and *r* proxies (soil covariates) were evaluated as predictors of the probability of occurrence of the soil mapping units. MLR analysis has been implemented following the best subset procedure that involved testing every combination of the soil covariates for the prediction of the soil mapping units. The best MLR model was selected on the basis of the Bayesian Information Criterion (BIC), being that the model with the lowest BIC was selected.

Classification and Regression Trees (CART) are non-parametric and rule-based models that have a tree-structure and are based on the mining of relationships between a target variable and the feature-space of a set of covariates³⁴. The C5-DT algorithm (an updated version of C4.5³⁵), in a similar way to other CART methods, uses a recursive process that relies on the

partition of the feature space and the separation of the observed classes until a stopping criterion is met (e.g. Gini index, Shannon entropy³⁴). The performance of C5-DT in soil mapping has been proved as efficient⁹, notably, when non-linear and complex soilscape relationships are intended to be modeled. A C5-DT model was fitted with the default parameters in the C5.0 R's package³⁵.

The RF algorithm is also a CART method that records remarkable performances in DSM^{7,8}; it differentiates from other CART by being an ensemble and bootstrapping method^{36,37}. Since the most sensitive parameter in RF fitting is *mtry*, i.e., the number of candidate covariates tested on each split³⁷, a test was run to find the *mtry* value that produced the lesser out-of-bag classification error. Subsequently, from the most important covariates in RF output, a subset of them was selected based on correlation (Spearman rank correlation): high auto-correlated ($\rho > 0.85$) and the less important covariates were removed in posterior analysis.

Model selection criteria and the effects of additional sampling were supported on accuracy statistics (global accuracy, kappa index and producer's and user's accuracies) aggregated by the mean values from a proportional 5-fold cross-validation procedure, which is recommended for imbalanced and relatively small samples³⁸. Then, the model with best accuracy metrics was applied for the production of the digital soil mapping and further soilscape analysis.

Finally, the uncertainty of the final map was based on the level of representation of the feature-space by the point-samples (level of extrapolation) by calculating the Multivariate Environmental Similarity Surface (MESS), according to Elith *et al.*³⁹.

The flow chart of the soil map production can be seen in Fig. 3.




Fig. 3 Soil map production flow chart

Results and discussion

Accuracy assessment (model performance)

The performance of the models to predict the soil mapping units registered in the Poses watershed is summarized in Table 2. Additional point sampling improved the accuracy of all models.

The models without additional observations were rarely been able to predict less-common soils. This finding is consistent with data presented in other works (e.g. Barthold *et al.*⁴⁰; Brungard *et al.*¹⁰; Jafari *et al.*⁴¹) and it is related to soil classes with very limited presence in the

study area, in comparison with the dominating soil classes that are better represented in geographic and feature spaces. Additional point sampling enabled to capture specific conditions of occurrence of less-common soils and, in consequence, it was registered a substantial gain in classification accuracy of the minority soil classes.

Accuracy statistics from the 5-fold cross-validation demonstrates that the RF* model consistently outperformed the other models (overall accuracy = 65 %, kappa index = 0.60, i.e., moderate agreement, Landis and Koch⁴²), while MLR had the lowest overall accuracy and kappa index (Table 2). For the purposes of digital soil mapping, it has been frequently observed that complex models, such as RF, are better classifiers than generalized linear models such as MLR^{7,10,43}. Regarding to the accuracy rank in Table 2 (RF > C5-DT > MLR), it seems that the most sophisticated model fitted more complex relationships, as suggested by Heung *et al.*⁴³. Since MLR is a generalization of the logistic regression, it is highly dependent on the presumed sigmoidal model for class discrimination³¹, which makes it the less flexible model. The DT-C5 is a data-driven and non-parametric discrimination model, and, considering its single tree structure, it did not fit complex relationships. RF is also a data-driven and non-parametric model, however, its bootstrapping and bagging features have proved to be efficient in revealing consistent and complex patterns⁴³, especially when dealing with complex spatial associations, as occurred in this watershed, helping to explain its performance as the most accurate model.

The spatial association model obtained from RF* had also the highest producer's and user's accuracies. The Typic Hapludult, Typic Rhodudult and Typic Hapludult* showed low values of producer's and user's accuracy (Table 2), reflecting in higher classification errors given the difficulty of the models in separating very similar mapping units⁴⁰, all of them framed as Ultisols.

Analysis of covariates

The most important and the less correlated covariates, as determined by the RF* model and the correlation criterion ($\rho \leq 0.85$), are presented in Fig. 4.




Fig. 4 Importance of selected covariates. TWI: topographic wetness index; DI: direct insolation; NO: negative openness; MRVBF: multi-resolution index of valley bottom flatness

The topography proxy (r factor in *scorpan*), as demonstrated by the importance rank, correlation analysis and classification accuracies, had the best set of predictors, remarkably: SAGA topographic wetness index (TWI), slope, elevation, direct insolation (DI) and the multiresolution index of valley bottom flatness (MRVBF) (Fig. 4).

Regarding the global discrimination of the soil mapping units, the topographic wetness index (TWI) registered the highest importance score (Fig. 4). This terrain attribute is a substitute measure of water flux in the landscape, since it shows the tendency of a site to be water saturated and the possible drainage systems of a watershed⁴⁴. TWI has often been reported as a potential predictor in digital soil mapping^{40,45–48}

The TWI outstands as a specific predictor for the Typic Endoaquent + Fluventic Dystrudept mapping unit. Its influence on the discrimination of this soil mapping unit is verifiable for values above 4.5, where an increase of 10% in probability of occurrence is observed (Fig. 5). The occurrence of Rhodic Hapludox + Typic Hapludox mapping unit is also influenced by TWI. These two soils classes could not be distinguished in the final map because they occur randomly distributed in the same landscape position. Silva *et al.*⁴⁸ also reported the influence of TWI on the distinction of Oxisols in Brazil. Higher TWI values (> 5 , i.e., poorly drained areas), supported also a better discrimination among the Typic Rhodudult, Typic Endoaquent + Fluventic Dystrudept, and Rhodic Hapludox + Typic Hapludox mapping units (Fig. 5).

The slope was the next important covariate for global classification. Flatten slopes are associated with a higher probability of occurrence of Typic Endoaquent + Fluventic Dystrudept mapping unit, which is expected to occur in flat slopes along with high values of TWI³³. These two soil classes could not be separated in the final map due to intricate pattern they occur in the watershed landscape. Slope values around 30 radians influenced the discrimination between Typic Dystrudept and Rhodic Hapludox + Typic Hapludox. The slope covariate also registered the highest importance regarding Typic Hapludult*, where slope values above 30 radians showed an inflection point in the occurrence signature of this soil mapping unit (Fig. 5).

Direct isolation (DI), ranked as third in importance for global classification, stands as a pixel-based calculation for solar radiation⁴⁹. This covariate has not been much investigated in tropical conditions^{50,51}. The DI covariate was a remarkable predictor for Typic Dystrudept. Values above $600 \text{ J cm}^2 \text{ day}^{-1}$ were associated to an increase in the probability of occurrence of this mapping unit, while lower values were associated to the occurrence of the Rhodic Hapludox + Typic Hapludox and Typic Hapludult*. The elevation covariate was relevant for Typic

Hapludult distinction; Fig. 5 presents the occurrence signature of this soil mapping unit, where a distinctive pattern is observed between 1000 and 1200 m range.




Fig. 5 Occurrence signatures of soil mapping units projected on the feature-space of selected covariates. TWI: topographic wetness index; DI: direct insolation; NO: negative openness;

MRVBF: multiresolution index of valley bottom flatness. R-squared values indicate goodness-of-fit between feature and prediction space projections (solid curves)

While the selected spatial association model (RF*) successfully discriminated the soil mapping units, a certain degree of mixture is still present in model outputs (Fig. 5). This could be an effect of the dominant soil and its wide range of occurrence conditions in the watershed. On the other hand, mapping units with a lesser degree of ‘impurity’ are those related to specific conditions across the landscape (Typic Dystrudept and Typic Endoaquent + Fluventic Dystrudept).

The level of detail in the topographic data analyzed, both spatial and informative, allowed the identification of specific relief-soil interactions. Topography, as a surficial hydrologic driver, could also reflect other soil-forming factors that have a larger scale domain, by modifying locally the effects of bioclimate and parent material⁶.

Soil map uncertainty

In Fig. 6 it is possible to see the differences between model training and model prediction data. The MESS measures the similarity of any given point to a reference set of points, with respect to the chosen predictor variables in RF* model. Negative values indicate the presence of at least one variable out of reach of the reference points in feature-space (i.e. uncertainty from point sampling extrapolation), while positive values indicate greater similarity to the set of reference points. The higher the score, the more common the point is and more reliable is the prediction³⁹. The negative values are located in areas of lower accessibility (high altitudes and

sharp slopes) and near to the watershed outlet (17.5 % of the watershed area), whereas 82.5 % of the area registered positive and, therefore, more feasible model outputs.




Fig. 6 Multivariate environmental similarity surface (MESS), extrapolation level increasing along with negative values

The map showing the spatial distribution of the different soil mapping units predicted in the watershed is presented in Fig. 7. The majority of the soils in Posses watershed were predicted as Typic Rhodudult (675 ha), which proportion is in agreement with the distribution derived from the field measurements and additional point sampling. Fig. 7 also displays the uncertainty due to

extrapolation of each soil mapping unit: Typic Dystrudept and Typic Rhodudult mapping units have 27 % and 20 % of their areas in less feasible regions, respectively, while the others soil mapping units do not show an expressive uncertain area ($< 15\%$).




Fig. 7 Soil mapping units distribution in the watershed by the RF* model.




Fig. 8 Uncertainty due to extrapolation of the soil mapping units (lighter colors)

Conclusions

A comparison among different models and the effects of additional point sampling for digital mapping of less-common soil classes, based on the spatial association with soilscape covariates, were performed. Tested models were Multinomial Logistic Regression, C5 Decision-Tree and Random Forest. Additional point sampling retrieved by photointerpretation was necessary to improve the prediction performance of each model. The accuracy metrics was found to be higher for the Random Forest model with additional point sampling method, constituting the best model. At the spatial resolution analysed (20 m), the terrain-attribute covariates (relief data), related to surficial water distribution and direct insolation, were the most efficient to discriminate among soil mapping units and for producing feasible digital soil maps.

References

1. Brevik, E. C. *et al.* Soil mapping, classification, and pedologic modeling: History and future directions. *Geoderma* **264**, 256–274 (2016).
2. Brevik, E. C. & Hartemink, A. E. Early soil knowledge and the birth and development of soil science. *CATENA* **83**, 23–33 (2010).
3. Keys, K., Sterling, S. M. & Guan, Y. Using historic soil survey data to map water erosion hazard for land-use planning in Nova Scotia. *Can. J. Soil Sci.* **95**, 299–304 (2015).
4. Jenny, H. *Factors of Soil Formation: A System of Quantitative Pedology*. (McGraw-Hill, 1941).
5. McBratney, A., Mendonça Santos, M. . & Minasny, B. On digital soil mapping. *Geoderma* **117**, 3–52 (2003).
6. Miller, B. A. & Schaetzl, R. J. History of soil geography in the context of scale. *Geoderma* **264**, 284–300 (2016).
7. Camera, C. *et al.* A high resolution map of soil types and physical properties for Cyprus: A digital soil mapping optimization. *Geoderma* **285**, 35–49 (2017).
8. Jeune, W., Francelino, M. R., Souza, E. De, Fernandes Filho, E. I. & Rocha, G. C. Multinomial Logistic Regression and Random Forest Classifiers in Digital Mapping of Soil Classes in Western Haiti. *Rev. Bras. Ciência do Solo* **42**, 1–20 (2018).
9. Taghizadeh-Mehrjardi, R., Nabiollahi, K., Minasny, B. & Triantafilis, J. Comparing data mining classifiers to predict spatial distribution of USDA-family soil groups in Baneh region, Iran. *Geoderma* **253-254**, 67–77 (2015).
10. Brungard, C. W., Boettinger, J. L., Duniway, M. C., Wills, S. A. & Edwards, T. C. Machine learning for predicting soil classes in three semi-arid landscapes. *Geoderma* **239-240**, 68–83 (2015).
11. Chawla, N. V., Bowyer, K. W., Hall, L. O. & Kegelmeyer, W. P. SMOTE: Synthetic

- Minority Over-sampling Technique. *J. Artif. Intell. Res.* **16**, 321–357 (2002).
12. Millard, K. & Richardson, M. On the Importance of Training Data Sample Selection in Random Forest Image Classification: A Case Study in Peatland Ecosystem Mapping. *Remote Sens.* **7**, 8489–8515 (2015).
 13. Minasny, B. & McBratney, A. B. Digital soil mapping: A brief history and some lessons. *Geoderma* **264**, 301–311 (2016).
 14. Menezes, M. D. de, Silva, S. H. G., Mello, C. R. de, Owens, P. R. & Curi, N. Solum depth spatial prediction comparing conventional with knowledge-based digital soil mapping approaches. *Sci. Agric.* **71**, 316–323 (2014).
 15. Meier, M., Souza, E. de, Francelino, M. R., Fernandes Filho, E. I. & Schaefer, C. E. G. R. Digital Soil Mapping Using Machine Learning Algorithms in a Tropical Mountainous Area. *Rev. Bras. Ciência do Solo* **42**, 1–22 (2018).
 16. Chagas, C. da S. *et al.* Data mining methods applied to map soil units on tropical hillslopes in Rio de Janeiro, Brazil. *Geoderma Reg.* **9**, 47–55 (2017).
 17. Giasson, E., Clarke, R. T., Inda Junior, A. V., Merten, G. H. & Tornquist, C. G. Digital soil mapping using multiple logistic regression on terrain parameters in southern Brazil. *Sci. Agric.* **63**, 262–268 (2006).
 18. Menezes, M. D. De, Silva, S. H. G., Owens, P. R. & Curi, N. Digital soil mapping approach based on fuzzy logic and field expert knowledge. *Ciência e Agrotecnologia* **37**, 287–298 (2013).
 19. Pelegrino, M. H. P. *et al.* Mapping soils in two watersheds using legacy data and extrapolation for similar surrounding areas. *Ciência e Agrotecnologia* **40**, 534–546 (2016).
 20. Alvares, C. A., Stape, J. L., Sentelhas, P. C., de Moraes Gonçalves, J. L. & Sparovek, G. Köppen's climate classification map for Brazil. *Meteorol. Zeitschrift* **22**, 711–728 (2013).
 21. CPRM-Serviço Geológico Regional. Mapa geológico do estado de Minas Gerais <<http://rigeo.cprm.gov.br/jspui/handle/doc/5016>>

22. Pereira, P. H., Cortez, B.A., Trindade, T., Mazochi, M. N. Conservador das Águas, 5 anos. <http://www.extrema.mg.gov.br/conservadordasaguas/Livro-Conservador-20101.pdf>
23. Hengl, T. Finding the right pixel size. *Comput. Geosci.* **32**, 1283–1298 (2006).
24. Staff, S. S. Keys to soil taxonomy. *Usda* **12**, 410 (2014).
25. Silva, M. a. *et al.* Sistema de informações geográficas no planejamento de uso do solo. *Rev. Bras. Ciencias Agrar.* **8**, 316–323 (2013).
26. Rouse, J. W., J., Haas, R. H., Schell, J. A. & Deering, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In *3rd Earth Resource Technology Satellite (ERTS) Symposium* 48–62 (1974).
27. Tucker, C. J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* **8**, 127–150 (1979).
28. Gao, B.-C. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.* **58**, 257–266 (1996).
29. Conrad, O. *et al.* System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. *Geosci. Model Development* 1991–2007 (2015). doi:10.5194/gmd-8-1991-2015
30. R-Core-Team. R: A language and environment for statistical computing
<www.R-project.org>
31. Kempen, B., Brus, D. J., Heuvelink, G. B. M. & Stoorvogel, J. J. Updating the 1:50,000 Dutch soil map using legacy soil data: A multinomial logistic regression approach. *Geoderma* **151**, 311–326 (2009).
32. Lane, P. W. Generalized linear models in soil science. *Eur. J. Soil Sci.* **53**, 241–251 (2002).
33. Campling, P., Gobin, A. & Feyen, J. Logistic Modeling to Spatially Predict the Probability of Soil Drainage Classes. *Soil Sci. Soc. Am. J.* **66**, 1390 (2002).
34. Strobl, C., Malley, J. & Tutz, G. An introduction to recursive partitioning: Rationale,

- application, and characteristics of classification and regression trees, bagging, and random forests. *Psychol. Methods* **14**, 323–348 (2009).
35. Quinlan, J. R. *C4.5: Programs for machine learning*. Morgan Kaufmann **5**, (1993).
 36. Breiman, L. Random forests. *Mach. Learn.* **45**, 5–32 (2001).
 37. Liaw, A. & Wiener, M. Classification and Regression by randomForest. *R News* **2**, 18–22 (2002).
 38. Kuhn, M. & Johnson, K. *Applied predictive modeling*. (Springer, 2013).
 39. Elith, J., Kearney, M. & Phillips, S. The art of modelling range-shifting species. *Methods Ecol. Evol.* **1**, 330–342 (2010).
 40. Barthold, F. K. . *et al.* Land use and climate control the spatial distribution of soil types in the grasslands of Inner Mongolia. *J. Arid Environ.* **88**, 194–205 (2013).
 41. Jafari, A., Khademi, H., Finke, P. A., Van de Wauw, J. & Ayoubi, S. Spatial prediction of soil great groups by boosted regression trees using a limited point dataset in an arid region, southeastern Iran. *Geoderma* **232-234**, 148–163 (2014).
 42. Landis, J. & Koch, G. The measurement of observer agreement for categorical data. *Biometrics* **33**, 159–174 (1977).
 43. Heung, B. *et al.* An overview and comparison of machine-learning techniques for classification purposes in digital soil mapping. *Geoderma* **265**, 62–77 (2016).
 44. Beven, K. & Kirkby, N. A physically based variable contributing area model of basin hydrology. *Hydrol. Sci. Bull.* 43–69 (1979).
 45. Bagheri Bodaghabadi, M. *et al.* Using Canonical Correspondence Analysis (CCA) to identify the most important DEM attributes for digital soil mapping applications. *CATENA* **86**, 66–74 (2011).
 46. Machado, I. R. *et al.* Spatial Disaggregation of Multi-Component Soil Map Units Using Legacy Data and a Tree-Based Algorithm in Southern Brazil. *Rev. Bras. Ciência do Solo*

- 42**, 1–14 (2018).
47. Nauman, T. W. & Thompson, J. A. Semi-automated disaggregation of conventional soil maps using knowledge driven data mining and classification trees. *Geoderma* **213**, 385–399 (2014).
 48. Silva, S. *et al.* Proximal Sensing and Digital Terrain Models Applied to Digital Soil Mapping and Modeling of Brazilian Latosols (Oxisols). *Remote Sens.* **8**, 614 (2016).
 49. Boehner, J. & Antonic, O. in *Geomorphometry - Concepts, Software, Applications* 195–226 (Elsevier, 2009).
 50. Chagas, C. da S., Fernandes Filho, E. I. & Bhering, S. B. Relação entre atributos do terreno, material de origem e solos em uma área no noroeste do estado do Rio de Janeiro. *Soc. Nat.* **25**, 147–162 (2013).
 51. Ferreira, F. P., Azevedo, A. C., Kanieski, A. J., Girelli, D. & Pedrotti, J. Solar Exposure and Soil Properties in Santa Maria – RS. *Rev. Bras. Agrociência* **11**, 377–381 (2005).

Acknowledgements

This research was funded by Coordination of Superior Level Staff Improvement – CAPES – Finance Code 001, National Council of Technological and Scientific Development – CNPq (Process nº306511/2017-7 e 202938/2018-2) and Minas Gerais State Research Foundation – FAPEMIG (Process nºAPQ-00802-18 and CAG-APQ-01053-15). The authors would like to thank the Federal University of Lavras and the Department of Soil Science.

Author Contributions

Marx Leandro Naves Silva managed the activities of the study. Soil survey and sample collection were carried out by Bárbara Pereira Christofaro Silva, Michele Duarte de Menezes

and Nilton Curi. Data analyses were conducted by Fábio Pomar Avalos and Bárbara Pereira Christofaro Silva. All authors reviewed and contributed to the writing of the manuscript.

Additional Information

Competing Interests: The authors declare that they have no conflict of interest.

Table 1 Distribution of pedons per soil mapping unit in Posses watershed

Soil mapping unit	Inclusion	Number of pedons
Typic Dystrudept	Typic Humudept	6
Typic Endoaquent + Fluventic Dystrudept	-	4
Rhodic Hapludox + Typic Hapludox	-	3
Typic Hapludult (yellow)	-	10
Typic Rhodudult	Rhodic Kandiudult	36
Typic Hapludult (red-yellow)	-	15

Table 2 Accuracy statistics from proportional 5-fold cross-validation

Soil mapping unit	C5*	RF*	MLR*	C5 ^b	RF ^c	MLR ^d
Producer's accuracy						
Typic Dystrudept	63	87	68	0	20	10
Typic Endoaquent+Fluventic Dystrudept	95	93	96	20	0	20
Rhodic Hapludox+Typic Hapludox	42	82	55	0	0	0
Typic Hapludult (yellow)	83	77	32	53	7	7
Typic Rhodudult	31	27	30	79	98	47
Typic Hapludult (red-yellow)	44	52	27	54	22	15
User's accuracy						
Typic Dystrudept	73	58	68	0	20	7
Typic Endoaquent+Fluventic Dystrudept	66	75	64	7	0	4
Rhodic Hapludox+Typic Hapludox	49	73	59	0	0	0
Typic Hapludult (yellow)	82	87	40	33	20	20
Typic Rhodudult	38	52	31	61	60	56
Typic Hapludult (red-yellow)	53	42	32	48	47	10
OA(%) ^a	56	65	48	50	58	29
Kappa	0.5	0.6	0.4	0	0	0.1

^a Overall accuracy^b C5 Decision Tree^c Random Forest^d Multinomial logistic regression

* Model including additional point sampling

**ARTIGO 2 NONLINEAR MODELS FOR SOIL MOISTURE SENSOR CALIBRATION
IN TROPICAL MOUNTAINOUS SOILS**
SOIL MOISTURE SENSOR CALIBRATION IN TROPICAL SOILS

*Normas do periódico Soil Science (versão preliminar)

Bárbara Pereira Christofaro Silva^{a*}, Diego Tassinari^a, Marx Leandro Naves Silva^a, Bruno Montoani Silva^a, Nilton Curi^a, Humberto Ribeiro da Rocha^b

^a Departamento de Ciência do Solo, Universidade Federal de Lavras UFLA, Av. Doutor Sylvio Menicucci, 1001, Kennedy, Lavras, MG, Brasil.

[*Corresponding author: barbarapcsilva@gmail.com](mailto:barbarapcsilva@gmail.com)

^b Departamento de Ciências Atmosféricas, Universidade de São Paulo USP, São Paulo, SP, Brasil.

Abstract

Capacitance sensors are widely employed in monitoring soil water content (θ). However, for accurate measurements, site-specific calibrations are needed. This study compares the regression models used for calibration of soil capacitance sensors and investigates the relation between soil attributes and the adjusted parameters of the specific calibration equations. Undisturbed soil samples were collected in the A and B horizons of two Paleudults and two Dystrudepts from the Mantiqueira Range in Southeastern Brazil. After saturation, a capacitance sensor ML2X Theta Probe was used to obtain the soil dielectric constant (ϵ). Several readings were made, ranging from saturation to oven-dry. After each reading, the samples were weighted so that θ ($\text{m}^3 \text{m}^{-3}$) could be calculated. Seventeen regression models (linear, linearized and nonlinear) were adjusted to the calibration data and checked for their residue distribution. The exponential models with three parameters performed the best and were the only ones that met the regression assumptions regarding residue distribution. Stepwise regression was used to obtain multiple linear equations to estimate the adjusted parameters (“a”, “b” and “c”) of the calibration model from soil attributes, with silt and clay content providing the best relations. Both the specific and the general calibrations performed well, with RMSE values of 0.02 and 0.03 $\text{m}^3 \text{m}^{-3}$ respectively. The manufacturer calibration and the equations taken from the literature were much less accurate, reinforcing the need to develop specific calibrations.

Keywords: soil dielectric constant; soil water content; model selection; capacitance sensor

INTRODUCTION

The spatial and temporal patterns of soil water content (θ) at various scales are important to a wide range of applications, such as water dynamics in the vadose zone (Vereecken et al. 2008), hydrological modeling (Brocca et al. 2009), assessment of natural hazards (Tramblay et al. 2010), irrigation planning (Hillel 2013), management of water resources (Dobriyal et al. 2012), soil-plant-atmosphere interactions (Rodriguez-Iturbe et al. 2007), soil classification and mapping (Juhász et al. 2006), among many others. Electromagnetic (EM) sensors for the assessment of soil moisture are now a well established technique and widely available with different working principles, like time-domain reflectometry (TDR), frequency-domain reflectometry (FDR) and capacitance techniques (Mittelbach et al. 2012). Their operation, however, is based on the same fundamental principle, that is the intimate relation between the soil apparent relative permittivity or dielectric constant (ϵ) and water content (Dorigo et al. 2011).

The seminal work by Topp et al. (1980) established the theoretical and practical basis for determining soil moisture from TDR measurements. In their study, Topp et al. (1980) proposed a universal empirical equation to estimate the soil water content from the soil dielectric constant, regardless of the soil class, bulk density, temperature and salinity. Although this equation provides reasonable results for a wide range of soils, it may not work properly in some circumstances, as in soils with low bulk density (Regalado et al. 2003; Silva et al. 2012) and with high contents of clay (Kargas et al. 2013), organic matter (Shibchurn et al. 2005), and iron and aluminum oxides (Kaiser et al. 2010).

Although empirical and semi-theoretical models have been developed to estimate θ from ϵ (Bogena et al. 2015), most of the commercial sensors operate with calibration equations specified by the manufactures. This gives rise to uncertainties in the estimates for different soils, since it

does not consider the specific EM properties inherent to each soil (Kargas et al. 2013; Matula et al. 2016). Numerous studies point out that the accurate assessment of θ requires calibration equations specific to the soils (Mortl et al. 2011; Rowlandson et al. 2013; Stangl et al. 2009) and horizons (Evelt et al. 2006) being monitored. Previous studies with Brazilian soils have focused on the Cerrado region (Silva et al. 2012), the gently rolling hills of the Brazilian Southeast (Tomasella and Bachi 2001) and South (Kaiser et al. 2010), and the semiarid Northeast (Silva et al. 2007). However, there are no calibrations proposed specifically for tropical mountainous soils. These soils usually have a shallow solum in a deep weathering profile, and often present high silt and organic matter contents.

The ThetaProbe (Delta-T Devices, UK) is a commonly used impedance sensor and many research papers have shown a significant improvement on measurement accuracy of the ML2 ThetaProbe when site-specific calibrations are applied on both mineral soils (Holzman et al. 2017; Kargas and Kerkides et al. 2008; Matula et al. 2016; Vaz et al. 2013) and organic soils (Bircher et al. 2016; Kargas and Kerkides et al. 2008). Site-specific calibrations are usually performed by adjusting linear equations, whether by straight lines (Fares et al. 2011; Kaiser et al. 2010; Rowlandson et al. 2013), or second and third degree polynomials (Kaiser et al. 2010; Matula et al. 2016; Mortl et al. 2011; Quinones et al. 2003). Although significant parameters and high R^2 values are usually obtained and may indicate a good fit, analysis of the regression residuals is seldom performed. Checking the residuals and the regression assumptions is critical because if these assumptions are not met, the adjusted models may not be valid (Bates and Watts 1988).

Since the most commonly employed regression models for EM sensors calibration are not checked for the regression assumptions, we aimed with this study to perform a thorough

investigation on the use of linear, linearized and nonlinear models in the calibration of EM sensors. The model which performed the best was used to fit the data from the calibration experiment with four soils of the Brazilian Mantiqueira Range. A general equation for these soils is proposed, which acknowledges the effect of soil attributes on the adjusted parameters of the calibration model.

MATERIAL AND METHODS

Study site and soil sampling

The study region is localized in the Posses watershed, in Extrema-MG, southeastern Brazil (Figure 1), in the southern boundary of the Mantiqueira range. The Posses watershed is a pilot site of the project “Conservador das Águas”, a pioneer initiative established in 2006 to implement payment for ecosystem services in Brazil (Pereira et al. 2010). Several studies are being conducted in this watershed to monitor hydrological phenomena, and a grid of soil moisture sensors (model PR2/6 profile probe, Delta T Devices, UK) has recently been installed, what motivated the present research. The local climate is classified as Cfb (Koppen-Geiger climate classification), mesothermic with no dry season and a warm summer. Ultisols and Inceptisols are dominant soils within the watershed, derived from granulitic orthogneiss (Ultisols and Humic Dystrudept) or recent alluvial sediments weathered and eroded from this same rock (Fluventic Dystrudept). The original vegetation was identified by Yamanoto (2009) as montane ombrophilus forest, a subtype of the Atlantic rainforest, but most of the watershed is now covered with brachiaria-grass pastures (*Urochloa decumbens*).




Figure 1. Location of the Posses watershed.

Soil samples with undisturbed structure were collected within rigid PVC cylinders (10 cm height and 10 cm diameter) in the A and B horizons of the following soil classes, characterized in Table 1: Typic Paleudult, Rhodic Paleudult, Humic Dystrudept and Fluventic Dystrudept (Soil Survey Staff 2010), which correspond to Argissolo Vermelho-Amarelo, Argissolo Vermelho, Cambissolo Húmico and Cambissolo Flúvico (Santos et al. 2013). Most of the sampling sites were located in extensive grazing pastures, the major land use in the Posses watershed, except the Typic Paleudult which was sampled in a reforestation site. At each soil and horizon, four undisturbed samples were taken (4 soils x 2 horizons x 4 replicates = 32 samples).

Table 1. Characterization of the soils and horizons employed in this study.

Soil class	Hz	Clay %	Silt %	Sand %	SOM %	ρ_p Kg m ⁻³	ρ_b Kg m ⁻³	n m ³ m ⁻³
Typic	A	57	20	23	2.1	2.50	1.00	0.60
Paleudult	B	65	17	18	1.4	2.56	0.87	0.66
Rhodic	A	38	14	48	2.0	2.43	1.24	0.49
Paleudult	B	59	9	32	1.1	2.53	1.05	0.58
Humic	A	41	21	38	3.1	2.58	0.85	0.67
Dystrudept	B	34	31	35	3.4	2.68	0.67	0.75
Fluventic	A	8	5	87	0.5	2.67	1.28	0.52
Dystrudept	B	22	43	35	1.6	2.34	0.97	0.58

Hz: horizon; SOM: soil organic matter; ρ_p : particle density; ρ_b : bulk density; n: total porosity.

Calibration procedure

In the laboratory, the exceeding soil from the cylinders was carefully trimmed and a nylon cloth was attached to its bottom to prevent soil loss. The undisturbed samples were put to saturate in plastic trays, gradually filled with water. The calibration procedure for the capacitance sensor began soon after saturation. The capacitance sensor used in this study (model ML2X Theta Probe, Delta-T Devices, UK) generates an electromagnetic signal (100 MHz) which extends to the soil through four metallic rods that are introduced in it. The generated signal suffers impedance that depends mostly on the apparent dielectric constant of the soil (Delta-T Devices 1999). As the dielectric constant of the water (~ 81) is much greater than that of the soil matrix (typically from 3 to 5) and that of air (1), the soil dielectric constant is defined mostly by its water content (Topp 2003).

Beginning at saturation, the ML2X probe was inserted in the soil samples (kept within their PVC containers), and the response signal (in volts) was registered. The probe was inserted and removed from the samples at each reading, a procedure often adopted in calibration studies

(Delta T devices, 1999). The samples were left to dry in the laboratory in order to obtain a wide range of water contents, and periodical readings with the ML2X sensor were taken. In the beginning, while the soil was close to saturation and the gravitational gradient drained rapidly the water more loosely retained, the readings were taken at 12 h intervals. The time-lapse between consecutive readings was gradually augmented as the samples dried and the hydraulic conductivity became smaller. Both water loss and redistribution were rapid during the first readings (gravity-driven flow), but soon evaporation became the main driver of water loss, and the gradient of matrix potential started to account for water redistribution. After each reading, the samples were weighted. After the last reading, the samples were oven-dried in order to determine the mass of dry soil, which allowed calculating the water content, θ (v/v), at each calibration step (thermo-gravimetric method) and the soil bulk density (Blake and Hartge 1986; Klute 1986). The sensor response is provided in volts (V) and was converted to the soil apparent dielectric permittivity (ϵ) by the third degree polynomial provided by the manufacturer (equation 1). The sensor outputs ranged from 0 to 1 V for all of the measurements except for readings on the first day (close to saturation). In this case, the sensor output exceeded 1 V, mainly for the Humic Dystrudept. With this procedure, several ordinate pairs ϵ , θ were obtained for each soil and horizon in order to perform the calibration, as recommended by the manufacturer (Delta-T Devices 1999). The calibration equations proposed herein can also be used with other EM sensors, such as the PR2/6 profile probes installed in the same study area. According to the manufacturer, the measurements provided as voltage for both sensors may differ, but they can be converted to dielectric constant with specific equations for each equipment (Delta-T Devices 1999), like equation 1.

$$\epsilon^{0.5} = 1.07 + 6.4 V - 6.4 V^2 + 4.7 V^3 \quad (1)$$

Calibration equations and statistical analysis

The ML2X sensor has two standard calibrations provided by the manufacturer, indicated by equation 2. Different values for the parameters a_0 and a_1 allow using this calibration equation for mineral soils ($a_0 = 1.6$ and $a_1 = 8.4$), with organic matter content below 7% and bulk density above 1.0 Mg m^{-3} ; and for organic soils ($a_0 = 1.3$ and $a_1 = 7.7$), with organic matter content above 7% and bulk density below 1.0 Mg m^{-3} (Delta-T Devices 1999). In the present study, we only used the calibration parameters for mineral soils, since the soil organic matter content (Table 1) was much lower (up to 34 g kg^{-1}) than the one set by the manufacturer (70 g kg^{-1}).

$$\varepsilon^{0.5} = a_0 + a_1 \times \theta \quad (2)$$

Unlike the procedure set by the manufacturer (equation 2), the calibration equations are here defined as the functional relation that allows transforming ε , provided by the sensor (the sensor actually provides a reading in voltage, that was converted to ε with Equation 1 as justified previously), to θ ($\text{m}^3 \text{ m}^{-3}$); that is, ε is the independent or predictor variable and θ is the dependent or response variable. Seventeen different equations were tested (Table 2), including three linear models (first, second and third degree polynomials); three linear models (first, second and third degree polynomials) with square-root transformation in the predictor variable to stabilize variance (and also because this is a common practice in EM sensor calibration); two linearized models (power and exponential models linearized by log transformations); and nine nonlinear models (power, exponential and hyperbolic models with two or three parameters).

Table 2. Models tested in this study.

Linear, square root transformation and linearized models	Identifier	Nonlinear models	Identifier
		$\theta = a\varepsilon^b$	IX
$\theta = a + b\varepsilon$	I	$\theta = a(1 + \varepsilon)^b$	X
$\theta = a + b\varepsilon + c\varepsilon^2$	II	$\theta = 1 - \frac{1}{(1+a\varepsilon)^b}$	XI
$\theta = a + b\varepsilon + c\varepsilon^2 + d\varepsilon^3$	III	$\theta = a(1 - e^{(b\varepsilon)})$	XII
$\theta = a + b\sqrt{\varepsilon}$	IV	$\theta = a + b(1 - e^{(c\varepsilon)})$	XIII
$\theta = a + b\sqrt{\varepsilon} + c\sqrt{\varepsilon}^2$	V	$\theta = a(1 - b\varepsilon)$	XIV
$\theta = a + b\sqrt{\varepsilon} + c\sqrt{\varepsilon}^2 + d\sqrt{\varepsilon}^3$	VI	$\theta = a + b(1 - c\varepsilon)$	XV
$\ln \theta = a + b\varepsilon$	VII	$\theta = a \frac{\varepsilon}{b+\varepsilon}$	XVI
$\ln \theta = \ln a + b \ln \varepsilon$	VIII	$\theta = \frac{\varepsilon}{a+b\varepsilon}$	XVII

The models were adjusted to the observed data, and the primary analysis aimed to identify if the regression assumptions were met by means of residue analysis with graphical procedures (Bates and Watts 1988). The residues were checked for normality (Q-Q plot), constant variance (plots of square-root of standardized residues x fitted values for the linear and linearized models and standardized residues x fitted values for the nonlinear models) and lack of autocorrelation (residuals x fitted values). The models that best met these criteria were further compared according to their residual standard error. The best model chosen was further investigated in order to relate its adjusted parameters to the soil attributes from Table 1, attempting to enable the use of the specific calibrations obtained in this study in different yet similar conditions (same predominantly kaolinitic clay mineralogy, but with differences in soil texture, organic matter content, structure, among others). This analysis was conducted by forward stepwise regression, starting with the simplest model (with only the intercept) and proceeding to the full model (with all the attributes from Table 1). The soil attributes were kept in the model according to the

Akaike information criteria. All the statistical procedures were performed in R (R Core Team 2017).

RESULTS AND DISCUSSION

Calibration models: quality assessment and model selection

The different models varied greatly regarding their residue distribution (Table 3). The assumption of residue normality was met by most of them (observed in more than 50% of the fitted equations for almost all of the 17 models tested), while constant variance and independency between the residues were criteria more difficult to meet. These assumptions are important for both linear and nonlinear models, because if they are violated, the resultant analysis may not be valid (Bates and Watts 1988). These criteria are related to the assumption of identically and independently distributed residues. The normal distribution is a description of the randomness of these errors and this assumption was more easily met because often only minor deviations were observed in the Q-Q plots. Non-constant variance and autocorrelation indicate that the regression residues are not identically and independently distributed; that is, the magnitude of the errors changes as the predictor variable changes (variance is not constant) or the residues present some sort of structure, with higher or lower values occurring together (thus correlated to each other). The failure to meet these assumptions may indicate an inadequacy of the model to fit the data, for example, for lack of a nonlinear term in a linear model or when fitting a non-asymptotic model (e.g. polynomial) to an asymptotic phenomenon. The exponential models performed the best, followed by the hyperbolic models. Two models stood out from the rest, meeting the criteria in all of the fittings. These were the two exponential models with three parameters. In essence, these two models are equivalent (except in their equation form) and resulted in the same residual

standard error. For no particular reason other than a somewhat simpler form, model XV was preferred over model XIII.

Table 3. Percentage of models that met the assumptions of residue normality, constant variance and lack of autocorrelation.

Models	Identifier	Normality	Constant variance	Lack of autocorrelation
$\theta = a + b\varepsilon$	I	62.5	25.0	0.00
$\theta = a + b\varepsilon + c\varepsilon^2$	II	100.0	25.0	37.5
$\theta = a + b\varepsilon + c\varepsilon^2 + d\varepsilon^3$	III	100.0	25.0	37.5
$\theta = a + b\sqrt{\varepsilon}$	IV	75.0	0.00	0.00
$\theta = a + b\sqrt{\varepsilon} + c\sqrt{\varepsilon}^2$	V	100.0	37.5	37.5
$\theta = a + b\sqrt{\varepsilon} + c\sqrt{\varepsilon}^2 + d\sqrt{\varepsilon}^2$	VI	100.0	12.5	25.0
$\ln \theta = a + b\varepsilon$	VII	50.0	0.00	0.00
$\ln \theta = \ln a + b \ln \varepsilon$	VIII	87.5	0.00	0.00
$\theta = a\varepsilon^b$	IX	62.5	0.00	50.0
$\theta = a(1 + \varepsilon)^b$	X	62.5	0.00	62.5
$\theta = 1 - \frac{1}{(1+a\varepsilon)^b}$	XI	62.5	37.5	62.5
$\theta = a(1 - e^{(b\varepsilon)})$	XII	62.5	50.0	62.5
$\theta = a + b(1 - e^{(c\varepsilon)})$	XIII	100.0	100.0	100.0
$\theta = a(1 - b^\varepsilon)$	XIV	62.5	50.0	62.5
$\theta = a + b(1 - c^\varepsilon)$	XV	100.0	100.0	100.0
$\theta = a \frac{\varepsilon}{b+\varepsilon}$	XVI	75.0	50.0	75.0
$\theta = \frac{\varepsilon}{a+b\varepsilon}$	XVII	75.0	62.5	75.0

Capacitance sensors calibration is usually performed with linear models, with the second and third degree polynomials being the most common (Fares et al. 2011; Matula et al. 2016; Mortl et al. 2011; Vaz et al. 2013). However, in none of the studies reviewed for this paper there is a stated concern to check for the regression assumptions, although sometimes uncertainty analysis or other forms of validation are performed (e.g. Longsdon et al. 2009; Vaz et al. 2013).

As can be seen from table 3, these assumptions are frequently violated by most of the models, indicating the strong need to perform this check after fitting.

Exponential model: interpretation and relevance

Model XV was chosen to perform the calibration, although this model also has its own disadvantage. Since its intercept term (the “a” parameter) frequently resulted in negative values, it would indicate negative water contents for ε values close to zero. Of course this is only a theoretical concern, because the smallest possible value for ε is 1.0 (for vacuum). However, as ε for the soil solids (that is, dry soil) is within the range of 3 to 8 (Hillel 1998, Topp 2003) and the model did not return negative values of θ for these values of ε , there are no practical concerns about physical inadequacies. The only practical consequence of this fact is that this parameter may lack any meaningful interpretation. This was the only parameter with some non-significant values and also presented the highest standard errors, while for the “b” and “c” parameters the standard errors were within the range of 1.7-4.8% and 0.4-1.3% of their estimated values respectively (Table 4). Nevertheless, we believe the inclusion of this intercept term is essential for model performance, as the other exponential models without this term (models XII and XIV) performed more poorly in the residue analysis (Table 3).

Table 4. Estimated parameters (“a”, “b” and “c”) for the chosen exponential model (Table 2, model XV), standard error of the estimated parameters and number of data points from the calibration procedure of the models for each soil class and horizon.

Soil class	H z	“a” parameter		“b” parameter		“c” parameter		Number of data points
		Estimated value	Standard error	Estimated value	Standard error	Estimated value	Standard error	
Typic Paleudult	A	0.090 ^{***}	0.012	0.474 ^{***}	0.008	0.929 ^{***}	0.004	72
	B	-0.003 ^{ns}	0.020	0.546 ^{***}	0.014	0.915 ^{***}	0.006	73
Rhodic Paleudult	A	0.006 ^{ns}	0.029	0.539 ^{***}	0.023	0.936 ^{***}	0.012	72
	B	0.042 [*]	0.021	0.453 ^{***}	0.015	0.912 ^{***}	0.010	72
Humic Dystrudept	A	-0.175 ^{***}	0.042	0.766 ^{***}	0.037	0.895 ^{***}	0.007	54
	B	-0.100 ^{***}	0.026	0.690 ^{***}	0.021	0.911 ^{***}	0.006	51
Fluventic Dystrudept	A	-0.088 ^{**}	0.029	0.545 ^{***}	0.023	0.913 ^{***}	0.010	65
	B	-0.302 ^{***}	0.031	0.868 ^{***}	0.028	0.880 ^{***}	0.005	65

Hz: soil horizon

The parameter “c” controls the curvature of the model: the lower its value (Table 4), the sharper is the model initial ascent (Figure 2), while higher values (closer to one) are related to a smoother rise. The parameter “b” is multiplicative and is related to the rate of change in the response variable for each unitary change in the independent variable. However, it is important to notice that the parameters “b” and “c” are correlated to each other ($r = -0.83$), so it may not be proper to analyze them separately. This does not mean they are redundant, as they obviously perform unique effects in the equation (“c” is for curvature and “b” is multiplicative); but rather that they work together: a smoothest initial rise (higher “c”) is related to a lower rate of change in θ for each increment in ε (lower “b”).




Figure 2. Observed data and adjusted calibration equations for the different soils and horizons. The adjusted parameters of the exponential models are in Table 4.

The models from both of the Dystrudepts presented a sharp initial rise (Figure 2) due to higher values of “b” and lower values of “c” (Table 4). This indicates a rapid change in θ for each increment in ϵ for values of ϵ up to 15-20, when the rate of change decreases. For the other soils, the rate of change in θ for each increment in ϵ is somewhat lower than in the aforementioned models, and starts to decrease at ϵ values of about 20-30. These values of ϵ correspond to θ values close to $0.4\text{--}0.5 \text{ m}^3 \text{ m}^{-3}$, indicating that the departure from a linear trend is more conspicuous when the soil is wetter than this. The manufacturer, however, claims their linear

calibration equation may work for θ as high as $0.55 \text{ m}^3 \text{ m}^{-3}$ (Delta-T Devices 1999), what is clearly not corroborated by our results (the relation departs from linear when θ is actually lower).

The studied soils are located in a catena, with the Rhodic Paleudult in the summit, the Typic Paleudult in the more gently slopes, the Humic Dystrudept in the steep slopes, and the Fluventic Dystrudepts in the footslope. Although they occur close to each other, they presented remarkable differences in their calibration equations (see Table 4 for parameter values and Figure 2 for the models) because of the differences in their soil attributes (Table 1). Additionally, there can be great differences in the calibration equations within the same soil profile, as was the case for the A and B horizons of the Fluventic Dystrudept, very much different in their calibration model (Figure 2), because they are so inherently different in their soil attributes (Table 1). These results are relevant they allow to better understand why specific calibrations are so important, since the relation between θ and ε is soil- and horizon-specific. Another aspect of the calibration equations that becomes very clear is how much they depart from a linear trend. It may be that for a narrow range of water contents this relation could be represented by a straight line, as is the case for the manufacturer calibration (Delta-T Devices 1999). However, a model with such a narrow range would undoubtedly be of little value in soil moisture monitoring, for example, which may range from saturation to almost dry conditions.

Influence of soil attributes in the general calibration model

As the soils and horizons differed in their calibration equations (Figure 2), the relation between these equations and the soil attributes was investigated by stepwise linear regressions in order to develop a more general calibration equation. Although these calibrations are only empirical equations without any clear physical meaning, this approach may help in generalizing

our results to other similar soils. Significant equations were obtained (Table 5), which allow estimating the parameters for the exponential model from the soil attributes. Although the linear equation for the “c” parameter was non-significant, the linear correlation coefficient of 0.62 indicates a fair degree of agreement between the two variables.

The most important soil attribute affecting the exponential model parameters was the silt content as it was the first variable incorporated by the stepwise regression. This is interesting because the manufacturer (Delta-T Devices 1999) and most studies usually point out the effect of organic matter content and bulk density (Jacobsen and Schjonning 1993; Jin et al. 2017; Malicki et al. 1996; Silva et al. 2012). Nevertheless, some recent studies have discussed the effect of soil texture in soil moisture sensors calibration (Kargas et al. 2013; Zanetti et al. 2015), but without acknowledging the role played by silt. Silt content is a very important soil attribute to understand the physical properties and erosion resistance of tropical mountainous soils, being related to the soil water retention capacity (Costa et al. 2013; Reichert et al. 2009) and aggregate stability (Sung 2012). The clay content was the second most important soil attribute in the stepwise regression, reinforcing the importance of soil texture in defining the relation between its moisture and its dielectric constant.

Table 5. Linear equations to estimate the parameters of the exponential model (model XV in Tables 2 and 3) from soil attributes for the general calibration model (using all data).

Parameter	Equation	P-value	R ²	σ
a	$a = -0.086 - 0.006 \cdot \text{Silt} + 0.004 \cdot \text{Clay}$	0.029 [*]	0.756	0.075
b	$b = 0.535 + 0.009 \cdot \text{Silt} - 0.003 \cdot \text{Clay}$	0.019 [*]	0.794	0.080
c	$c = 0.929 - 0.001 \cdot \text{Silt}$	0.102 ^{ns}	0.383	0.015

Silt: silt content (%). Clay: clay content (%). σ: residual standard error

The equation for predicting the parameter “c” performed the worst in terms of its coefficient of determination (0.38, Table 5), but it presented the lowest standard error (0.015 or only 1.6% of the average observed values. Because this parameter presented the smallest amplitude (of only 0.034 with an average value of 0.91), the poor-performance equation from Table 5 was still capable of delivering fair estimates for this parameter (Figure 3). The equation for estimating the parameter “b” presented the highest coefficient of determination (0.79) and also depicted a somewhat low standard error, of only 13% of the average parameter values (standard error of 0.08 and average value of 0.61 for the “b” parameter). The equations from Table 5 usually performed more poorly in the Humic Dystrudept and in the A horizons in general (Figure 3), indicating a possible effect of organic matter or even structure that was not captured by the stepwise regression. Organic matter content and bulk density are also important attributes affecting the calibration and performance of electromagnetic sensors for measuring soil water content (Jacobsen and Schjonning 1993; Jin et al. 2017; Malicki et al. 1996; Silva et al. 2012); and the lack of significance for these parameters may probably be due to the small number of observations, since these parameters came from the eight calibration equations fitted to model XV (one for each soil and horizon).




Figure 3. Prediction of the calibration model parameters from the soil attributes (clay and silt contents), depicting the ordinate pairs of observed (Table 4) and predicted (equations from Table

5) parameter values, the 1:1 lines, and the significant soil attributes for each parameter (the arrows indicate direct or inverse tendencies between the predicted parameter and the attributes).

Accuracy improvements with specific and general calibration models

The specific calibration improved the estimate of θ for all the soils and horizons in comparison to the other equations tested (Table 6). The manufacturer establishes a RMSE value of $0.05 \text{ m}^3 \text{ m}^{-3}$ as a threshold for acceptable calibration error (Delta-T Devices 1999). Only the specific and the general calibrations would be considered valid for all the soils and horizons, with average RMSE values of 0.02 and $0.03 \text{ m}^3 \text{ m}^{-3}$ respectively. According to the values of MBE and RMSE, the performance of the calibrations was as follows: specific > general > Malicki et al. (1996) > Vaz (2008) > Topp et al. (1980) ~ manufacturer. The calibration equation from Malicki et al. (1996) has also outperformed the calibration from Topp et al. (1980) in other studies with tropical soils (Coelho et al. 2006; Teixeira et al. 2003). In a previous study, Jacobsen and Schjonning (1993) had already detected improvements of TDR calibrations with the inclusion of soil bulk density, what explains why the equation from Malicki et al. (1996) outperformed the others. These results reinforce the importance of employing specific calibrations for EM sensors, or at least general calibrations that properly represent the soils in matter. The adequate performance of the specific and general calibrations proposed herein can also be noted by their good coincidence with the 1:1 line (Figure 4), but somewhat less accurate for the A horizons of both the Dystrudepts.

Table 6. Mean biased error (MBE) and root of the mean squared error (RMSE) for the estimation of θ from ε with different calibration equations

Soil class	Hz	Specific calibration		General calibration		Manufacturer		Topp et al. (1980)		Malicki et al. (1996)		Vaz (2008)	
		MBE	RMSE	MBE	RMSE	MBE	RMSE	MBE	RMSE	MBE	RMSE	MBE	RMSE
Typic Paleudult	A	<0.001	0.013	0.003	0.02	-0.12	0.127	-0.11	0.125	-0.06	0.078	-0.10	0.104
	B	<0.001	0.016	0.02	0.03	-0.11	0.117	-0.11	0.115	-0.04	0.055	-0.09	0.094
Rhodic Paleudult	A	<0.001	0.026	0.02	0.034	-0.07	0.078	-0.07	0.076	-0.04	0.05	-0.05	0.054
	B	<0.001	0.023	0.01	0.028	-0.11	0.117	-0.11	0.115	-0.06	0.075	-0.08	0.089
Humic Dystrudept	A	<0.001	0.032	-0.04	0.055	-0.13	0.15	-0.14	0.149	-0.06	0.092	-0.09	0.14
	B	<0.001	0.026	-0.01	0.027	-0.10	0.129	-0.10	0.125	-0.01	0.091	-0.04	0.243
Fluventic Dystrudept	A	<0.001	0.029	-0.01	0.035	-0.03	0.056	-0.02	0.05	0.002	0.046	-0.02	0.037
	B	<0.001	0.014	0.01	0.02	-0.12	0.134	-0.13	0.134	-0.07	0.079	-0.11	0.112

Hz: soil horizon.

The calibrations equations taken from other studies most often underestimated θ , with most of the points remaining below the 1:1 line (Figure 4). This underestimation averaged from 0.02 to 0.14 $\text{m}^3 \text{m}^{-3}$ (Table 6). Several other studies, including with tropical soils, have also shown that the calibration from Topp et al. (1980) usually underestimates θ (Fares et al. 2011; Teixeira et al. 2003; Tommaselli and Bacchi 2001; Silva et al. 2012). The underestimation was found to worsen the lower the soil bulk density (Regalado et al. 2003), what we also observed for the Humic Dystrudept (Figure 4). However, overestimation of θ has also been observed (Huang et al. 2004; Kargas and Kerkides, 2008). These equations were also found to overestimate θ in tropical soils with high iron content (Kaiser et al. 2010), because of its interference in the propagation velocity of electromagnetic waves (Tomaselli and Bacchi 2001).




Figure 4. Relation between the determined soil moisture (θ , v/v) and the values estimated from the different calibration equations.

The calibration equations taken from the literature performed better in the A horizons of both the Rhodic Paleudult and the Fluventic Dystrudept, which present the highest sand contents and the highest bulk densities. Kargas et al. (2013) pointed out that the equation from Topp et al. (1980) was satisfactory only for a material composed entirely of sand. The worst performance of the literature calibrations was observed in the Humic Dystrudept (especially in the A horizon) which is the soil with the lowest bulk density and highest organic matter content. Figure 4 also reinforces another important aspect previously discussed, that the polynomial models may not be fit for electromagnetic sensor calibration. For θ values close to saturation, the literature models,

especially that of Malicki et al. (1996) shifted from underestimating θ to overestimating it. For example, the calibration from Vaz (2008) indicated θ values above $1.00 \text{ m}^3 \text{ m}^{-3}$ in the B horizon of the Humic Dystrudept, and resulted in the highest RMSE value (0.243). The polynomial model is not asymptotic and indicates a continuous growth of the relation between θ and ϵ . The exponential model used in this study is asymptotic and therefore better represents the relation between θ and ϵ when approaching saturation.

CONCLUSION

The exponential model performed better than the other models tested, not only because it more properly meets the regression assumptions about residue distribution, but also because its asymptotic behavior better represents the relation between soil water content and dielectric constant.

The adjusted parameters of the exponential model significantly related to soil attributes. Three linear equations were obtained to predict them from the soil silt and clay contents.

The specific calibration equations performed the best, with an average error of only $0.02 \text{ m}^3 \text{ m}^{-3}$, while the general calibration equation (with the adjusted parameters estimated from the soil attributes) also performed well, with an error of $0.03 \text{ m}^3 \text{ m}^{-3}$. Both accuracy errors are considered below threshold levels.

The calibrations taken from the manufacturer and the literature failed in providing accurate estimates, reinforcing the strong need to perform specific calibrations or applying these general calibrations only to soils similar to those from which they generate.

ACKNOWLEDGEMENTS

This research was funded by Coordination of Superior Level Staff Improvement – CAPES – Finance Code 001, the National Council of Technological and Scientific Development – CNPq (Process n° 306511/2017-7 and 202938/2018-2), Minas Gerais State Research Foundation – FAPEMIG (Process n° CAG-APQ 00802-18, CAG-APQ-01053-15). The authors would like to thank the Federal University of Lavras and the Department of Soil Science, the Projects FAPESP ClimateWise (2015/50682-6), CAPES/ANA/Estimativa de evapotranspiração por sensoriamento remoto para gestão de recursos hídricos no Brasil 88887.144979/2017-00, and CNPq/ANA 446278/2015-7 O regime hidrológico das bacias dos Rios Piracicaba e Paraíba do Sul no clima futuro: avaliação de alta resolução dos padrões, incertezas e impactos do uso da terra

REFERENCES

- Bates, D.M., Watts, D.G., 1988. Nonlinear Regression Analysis and Its Applications. John Wiley, New York.
- Bircher, S., Andreasen, M., Vuollet, J., Vehviläinen, J., Rautiainen, K., Jonard, F., Weihermüller, L., Zakharova, E., Wigneron, J., Kerr, Y.H., 2016. Soil moisture sensor calibration for organic soil surface layers. *Geosci. Instrum. Method. Data Syst.* 5, 109–125.
- Blake, G.R., Hartge, K.H., 1986b. Bulk density, in: Klute, A. (Ed.), *Methods of soil analysis Part 1: Physical and Mineralogical Methods*, second ed. ASA/SSSA, Madison, pp. 363-376.
- Bogena, H.R., Huisman, J.A., Güntner, A., Hübner, C., Kusche, J., Jonard, F., Vey, S., Vereecken, H., 2015. Emerging methods for noninvasive sensing of soil moisture dynamics from field to catchment scale: a review. *Wiley Interdiscip. Rev. Water* 2, 635–647.

- Brocca, L., Melone, F., Moramarco, T., Morbidelli, R., 2009. Antecedent wetness conditions based on ERS scatterometer data. *J. Hydrol.* 364, 73–87.
- Coelho, E.F., Vellame, L.M., Coelho Filho, M.A., Ledo, C.A.S., 2006. Desempenho de modelos de calibração de guias de onda acopladas a tdr e a multiplexadores em três tipos de solos. *Rev. Bras. Ciênc. Solo* 30, 23–30.
- Costa, A., Albuquerque, J.A., Costa, A., Pértile, P., Silva, F.R., 2013. Water retention and availability in soils of the State of Santa Catarina-Brazil: effect of textural classes, soil classes and lithology. *Rev. Bras. Ciênc. Solo* 37, 1535-1548.
- Delta-T Devices, 1999. ThetaProbe soil moisture sensor – ML2x: user manual. Delta - T Devices, Cambridge.
- Dobriyal, P., Qureshi, A., Badola, R., Hussain, S.A., 2012. A review of the methods available for estimating soil moisture and its implications for water resource management. *J. Hydrol.* 458–459, 110–117.
- Dorigo, W.A., Wagner, W., Hohensinn, R., Hahn, S., Paulik, C., Xaver, A., Gruber, A., Drusch, M., Mecklenburg, S., Van Oevelen, P., Robock, A., Jackson, T., 2011. The International Soil Moisture Network: A data hosting facility for global in situ soil moisture measurements. *Hydrol. Earth Syst. Sci.* 15, 1675–1698.
- Evelt, S.R., Tolk, J.A., Howell, T.A., 2006. Soil Profile Water Content Determination. *Vadose Zone J.* 5, 894-907.
- Fares, A., Abbas, F., Maria, D., Mair, A., 2011. Improved calibration functions of three capacitance probes for the measurement of soil moisture in tropical soils. *Sensors* 11, 4858–4874.
- Hillel, D., 1998. *Environmental Soil Physics*. Academic Press, San Diego.

- Hillel, D., 2013. *Advances in irrigation*. Academic Press, San Diego.
- Holzman, M., Rivas, R., Carmona, F., Niclòs, R., 2017. A method for soil moisture probes calibration and validation of satellite estimates. *MethodsX* 4, 243-249.
- Huang, Q., Akinremi, O.O., Sri Rajan, R., Bullock, P., 2004. Laboratory and field evaluation of five soil water sensors. *Can. J. Soil Sci.* 84, 431–438.
- Jin, M.; Zheng, X.; Jiang, T.; Li, X.; Li, X.; Zhao, K., 2017. Evaluation and improvement of SMOS and SMAP soil moisture products for soils with high organic matter over a forested area in Northeast China. *Remote Sens.* 9, 387.
- Jacobsen, O.H., Schjonning, P., 1993. A laboratory calibration of time domain reflectometry for soil water measurement including effects of bulk density and texture. *J. Hydrol.* 151, 147-157.
- Juhász, C.E.P., Cursi, P.R., Cooper, M., Oliveira, T.C., Rodrigues, R.R., 2006. Dinâmica físico-hídrica de uma toposequência de solos sob Savana Florestada (cerradão) em Assis, SP. *Rev. Bras. Ciênc. do Solo* 30, 401–412.
- Kaiser, D.R., Reinert, D.J., Reichert, J.M., Minella, J.P.G., 2010. Dielectric constant obtained from TDR and volumetric moisture of soils in southern Brazil. *R. Bras. Ciênc. Solo* 34, 649–658.
- Kargas, G., Kerkides, P., 2008. Water content determination in mineral and organic porous media by ML2 Theta Probe. *Irrig. and Drain.* 57, 435-449.
- Kargas, G., Ntoulas, N., Nektarios, P.A., 2013. Soil texture and salinity effects on calibration of TDR300 dielectric moisture sensor. *Soil Res.* 51, 330–340.
- Klute, A., 1986. Water retention: laboratory methods, in: Klute, A. (Ed.), *Methods of Soil Analysis part 1: Physical and Mineralogical Methods*. ASA/SSSA, Madison, pp. 635-662.

- Malicki, M.A., Plagge, R., Roth, C.H., 1996. Improving the calibration of dielectric TDR soil moisture determination taking into account the solid soil. *Eur. J. Soil Sci.* 47, 357–366.
- Matula, S., Bát'ková, K., Legese, W.L., 2016. Laboratory performance of five selected soil moisture sensors applying factory and own calibration equations for two soil media of different bulk density and salinity levels. *Sensors* 16, 1912.
- Mittelbach, H., Lehner, I., Seneviratne, S.I., 2012. Comparison of four soil moisture sensor types under field conditions in Switzerland. *J. Hydrol.* 430-431, 39–49.
- Mortl, A., Muñoz-Carpena, R., Kaplan, D., Li, Y., 2011. Calibration of a combined dielectric probe for soil moisture and porewater salinity measurement in organic and mineral coastal wetland soils. *Geoderma* 161, 50–62.
- Pereira, P.H., Cortez, B.A., Trindade, T., Mazochi, M.N., 2010. *Conservador das Águas, 5 anos.* Departamento de Meio Ambiente, Extrema.
- Quinones, H., Ruelle, P., Nemeth, I., 2003. Comparison of three calibration procedures for tdr soil moisture sensors. *Irrig. Drain.* 52, 203–217.
- R Core Team, 2017. *R: A Language and Environment for Statistical Computing.* R Foundation for Statistical Computing, Vienna.
- Regalado, C.M., Muñoz Carpena, R., Socorro, A.R., Hernández Moreno, J.M., 2003. Time domain reflectometry models as a tool to understand the dielectric response of volcanic soils. *Geoderma* 117, 313–330.
- Reichert, J.M., Albuquerque, J.A., Kaiser, D.R., Reinert, D.J., Urach, F.L., Carlesso, R., 2009. Estimation of water retention and availability in soils of Rio Grande do Sul. *Rev. Bras. Ciênc. Solo* 33, 1547-1560.
- Rodriguez-Iturbe, I., D'Odorico, P., Laio, F., Ridolfi, L., Tamea, S., 2007. Challenges in humid

- land ecohydrology: Interactions of water table and unsaturated zone with climate, soil, and vegetation. *Water Resour. Res.* 43, 1–5.
- Rowlandson, T.L., Berg, A.A., Bullock, P.R., Ojo, E.R.T., McNairn, H., Wiseman, G., Cosh, M.H., 2013. Evaluation of several calibration procedures for a portable soil moisture sensor. *J. Hydrol.* 498, 335–344.
- Santos, H.G., Jacomine, P.K.T., Anjos, L.H.C., Oliveira, V.A., Lumbrreras, J.F., Coelho, M.R., Almeida, J.A., Cunha, T.J.F., Oliveira, J.B., 2010. *Sistema Brasileiro de Classificação de Solos*, third ed. Embrapa, Brasília.
- Shibchurn A., Van Geel P.J., Kennedy P.L., 2005. Impact of density on the hydraulic properties of peat and the time domain reflectometry (TDR) moisture calibration curve. *Can. Geotech. J.* 42: 279-286.
- Silva, C.R., Andrade Júnior, A.S.A., Alves Júnior, J., Souza, A.B., Melo, F.B., Coelho Filho, M.A., 2007. Calibration of a capacitance probe in a Paleudult. *Sci. Agric.* 64, 636-640.
- Silva, B.M., Oliveira, G.C., Serafim, M.E., Silva Júnior, J.J., Colombo, A., Lima, J.M., 2012. Acurácia e calibração de sonda de capacitância em Latossolo Vermelho cultivado com cafeeiro. *Pesqui. Agropecu. Bras.* 47, 277–286.
- Soil Survey Staff, 2010. *Keys to Soil Taxonomy*. 11th ed. USDA-NRCS, Washington DC.
- Stangl, R., Buchan, G.D., Loiskandl, W., 2009. Field use and calibration of a TDR-based probe for monitoring water content in a high-clay landslide soil in Austria. *Geoderma* 150, 23–31.
- Sung, C.T.B., 2012. Aggregate Stability of Tropical Soils in Relation to Their Organic Matter Constituents and Other Soil Properties. *Pertanika J. Trop. Agric. Sci.* 35, 135 - 148.
- Teixeira, W.G., Schroth, G., Marques, J.D., Huwe, B., 2003. Sampling and Tdr Probe Insertion in the Determination of the Volumetric soil water content. *Rev. Bras. Ciênc. Solo* 27, 575–582.

- Tommaselli, J.T.G., Bacchi, O.O.S., 2001. Calibração de um equipamento de TDR para medida de umidade de solos. *Pesqui. Agropecu. Bras.* 36, 1145–1154.
- Topp, C., Resource, L., Canada, A., 1980. Electromagnetic Determination of Soil Water Content: Measurements in Coaxial Transmission Lines. *Water Resour. Res.* 16, 574–582.
- Topp, G.C., 2003. State of the art of measuring soil water content. *Hydrol. Process.* 17, 2993–2996.
- Tramblay, Y., Bouvier, C., Martin, C., Didon-Lescot, J.F., Todorovik, D., Domergue, J.M., 2010. Assessment of initial soil moisture conditions for event-based rainfall-runoff modelling. *J. Hydrol.* 387, 176–187.
- Vaz, C.M.P., 2008. Aplicabilidade e limitações da TDR para a medida da umidade em solos brasileiros. Available at <<http://www.alice.cnptia.embrapa.br/alice/handle/doc/31137>>. Accessed September 2017.
- Vaz, C.M.P., Jones, S., Meding, M., Tuller, M., 2013. Evaluation of Standard Calibration Functions for Eight Electromagnetic Soil Moisture Sensors. *Vadose Zone J.* 12, 1-16.
- Vereecken, H., Huisman, J.A., Bogaen, H., Vanderborght, J., Vrugt, J.A., Hopmans, J.W., 2008. On the value of soil moisture measurements in vadose zone hydrology: A review. *Water Resour. Res.* 46, 1–21.
- Yamamoto, L.F., 2018. Florística e fitossociologia de espécies arbóreas ao longo de um gradiente altitudinal no extremo sul da Mantiqueira (Serra do Lopo) - MG/SP. Available at <<http://www.repositorio.unicamp.br/handle/REPOSIP/315283>>. Accessed August 2018.
- Zanetti, S.S., Cecílio, R.A., Silva, V.H., Alves, E.G., 2015. General calibration of TDR to assess the moisture of tropical soils using artificial neural networks. *J. Hydrol.* 530, 657-666.

ARTIGO 3 Dinâmica temporal da umidade em perfis de Argissolos em sub-bacia hidrográfica na Serra da Mantiqueira, MG.

* Norma NBR 6022 (ABNT 2003)

RESUMO

Entender o comportamento da umidade em perfis de solo é importante para descrever processos hidrológicos e para a predição e modelagem da umidade do solo. No Brasil, estudos envolvendo séries temporais longas de umidade em diferentes profundidades do solo ainda são escassos. O objetivo deste estudo foi levantar informações a respeito do padrão temporal da umidade em várias profundidades de Argissolos, em consonância com os atributos físico-hídricos do solo na sub-bacia das Posses em Extrema- MG, sub-bacia piloto de serviços ecossistêmicos no Brasil. Quatro sensores de capacitância do tipo PR2/6 profile probe foram instalados em seis profundidades de Argissolos, em áreas de pastagem e reflorestamento. Os valores de umidade do solo foram calibrados e as séries temporais foram construídas com dados diários de umidade do solo do período entre 08/2014 e 03/2018. O coeficiente de correlação não-paramétrica de Spearman foi utilizado para avaliar a similaridade do padrão temporal da umidade entre as diferentes profundidades do solo. Amostras deformadas e indeformadas foram coletadas nos horizontes A e B dos quatro locais, a fim de dar suporte à interpretação dos padrões de umidade nos perfis dos solos. Foi constatado que a umidade do solo foi superior nas profundidades de 10 e 20 cm do solo na área de reflorestamento, em relação às pastagens. A maior similaridade no padrão da umidade entre os quatro locais ocorreu com o aumento da profundidade do solo e as maiores diferenças foram observadas nos períodos de menor ocorrência de chuvas. Nas profundidades abaixo de 30 cm, a umidade se manteve alta ao longo de todas as séries temporais, reflexo da alta capacidade de retenção de água dos Argissolos da sub-bacia das Posses e da elevada e bem distribuída precipitação. Fortes similaridades temporais entre as diferentes profundidades no perfil solo foram constatadas nos quatro locais de monitoramento.

Palavras-chave: Séries temporais. Sensor de umidade do solo. Atributos físico-hídricos do solo.

1 INTRODUÇÃO

A umidade do solo desempenha um papel importante em muitos processos hidrológicos e ecológicos, como nos processos de infiltração, percolação e escoamento superficial (CORRADINI, 2014), no crescimento e desenvolvimento de plantas e na dinâmica dos ecossistemas (SANDVIG; PHILLIPS, 2006), além de exercer influências sobre o clima e as condições meteorológicas (SENEVIRATNE et al., 2010). Entender o comportamento da umidade do solo é de grande importância para uma ampla gama de disciplinas e aplicações práticas (VERECKEN et al., 2008) de modo que a necessidade de compilação de dados de umidade em diferentes escalas e paisagens tem sido reconhecida há décadas (ROBOCK et al., 2000; WESTERN; GRAYSON, 1998).

Na era do sensoriamento remoto, muitas pesquisas têm sido direcionadas para o monitoramento e modelagem da umidade do solo em grandes escalas espaço – temporais (PETROPOULOS; IRELAND; BARRETT, 2015), no entanto, são restritas às camadas superficiais do solo e envolvem inúmeras fontes de incerteza (BROCA et al., 2017). Informações sobre o comportamento da umidade e sua variabilidade no perfil vertical do solo são fundamentais para modelagem e predição hidrológica, restauração da vegetação e sustentabilidade do uso do solo (WANG et al., 2014; LI et al., 2015). Para tanto, métodos não destrutivos, baseados na constante dielétrica do solo, tais como a reflectometria no domínio do tempo (TDR) ou da frequência (FDR), têm sido extensivamente utilizados para o monitoramento contínuo da umidade do solo “in situ” e para medir e modelar sua evolução no espaço – tempo (ROMANO, 2014).

Muitas variáveis controlam a variação espaço-temporal da umidade do solo, com destaque para os atributos do solo, o clima, a vegetação e a topografia (GEROY et al., 2011; ROSENBAUM et al., 2012; ROMANO, 2014). Nas últimas décadas, muitas pesquisas foram realizadas sobre a variabilidade espaço - temporal da umidade e os fatores de influência em todo o mundo, e resultados contrastantes têm sido revelados. O padrão de comportamento da umidade e a influência dos atributos do solo, da vegetação e da topografia no conteúdo de água no solo parecem ser dependentes das condições climáticas e da sazonalidade dos eventos meteorológicos da região de estudo (JAMES et al., 2003; LAWRENCE; HORNBERGER, 2007; LI; RODELL,

2013). Em regiões áridas e semi-áridas, a variação espaço – temporal da umidade do solo parece ser controlada principalmente pelos atributos do solo e vegetação (CANTON; SOLE-BENET; DOMINGO, 2004; COSH et al., 2008; LI et al., 2015, MELO; MONTENEGRO, 2015). Todavia, Li et al. (2017) observaram que fatores dinâmicos, como a precipitação, exerceram um maior controle na variação da umidade na dimensão temporal em uma região de clima úmido. Kim e Barros (2002) e Oldak, Jackson e Pachepsky (2002) relataram que a variabilidade espacial da umidade do solo foi predominantemente controlada pelos padrões de precipitação sob condições úmidas e pela textura do solo e vegetação sob condições secas. Gao et al. (2011) observaram variações espaciais da umidade induzidas pelas condições de cobertura e características dos solos de uma bacia, no entanto, tal influência foi menos expressiva sobre os padrões temporais da umidade do solo.

A variabilidade da umidade também é controlada pelo conteúdo médio de umidade no solo (FAMIGLIETTI et al., 2008; ROSENBAUM et al., 2012). Muitos estudos mostram maiores variações da umidade à medida que o conteúdo médio de umidade do solo diminui (Ex. FAMIGLIETTI et al., 1999; LAWRENCE; HORNBERGER, 2007), ao passo que também existem relatos de maiores variações à medida que o conteúdo médio de umidade aumenta (Ex. LAWRENCE; HORNBERGER, 2007; MARTÍNEZ-FERNÁNDEZ; CEBALLOS, 2003;). Uma gama de informações variadas a respeito da influência da vegetação (WANG et al., 2014; WANG et al., 2015), do clima (TEULING et al., 2007), dos atributos do solo (MARTINEZ; PACHEPSKY; VEREECKEN, 2014) e da topografia (HAWLEY; JACKSON; MCCUEN, 1983) na dinâmica espaço - temporal da umidade do solo encontram-se disponíveis na literatura.

Para que as informações pontuais da umidade do solo possam ser estendidas para descrever os padrões de umidade do solo em toda a paisagem é essencial que as observações sejam acompanhadas da caracterização dos atributos do solo (PAN et al., 2012). Os atributos do solo relacionados aos processos de armazenamento e redistribuição de água, tais como a textura do solo e a distribuição do tamanho de partícula (BHARALI, 2019), os atributos relacionados à retenção de água (GEROY et al., 2011), a condutividade hidráulica (OJHA et al., 2017) e a profundidade do solo (MENEZES et al., 2009), têm-se mostrado fundamentais na interpretação do comportamento da umidade no perfil do solo e na aplicação de modelos matemáticos na tentativa de descrever e melhor compreender a dinâmica da água no sistema solo - planta - atmosfera (PREVEDELLO et al., 2007).

A interatividade existente entre os diversos fatores na evolução espaço-temporal da umidade do solo reforça a importância da análise dos padrões de umidade no solo em diferentes cenários hidrológicos. Um grande avanço no campo de monitoramento da umidade do solo ocorreu no Brasil nos últimos anos, com pesquisas desenvolvidas em diversas escalas espaço - temporais (ÁVILA et al., 2010a, 2010b, 2011; LEITE et al., 1997; MELO; MONTENEGRO, 2015; PREVEDELLO et al., 2007; SENA et al., 2017). No entanto, são poucas as investigações que envolvem longos períodos de monitoramento contínuo da umidade em diferentes profundidades do solo (ex: BRUNO et al., 2006; JUHÁSZ et al., 2006). Além disso, não existem relatos de pesquisas envolvendo séries temporais longas de umidades em perfis de solos altimontanos no Brasil, como os ocorrentes na Serra da Mantiqueira.


Diante da baixa disponibilidade de informações a respeito dos fatores que afetam o comportamento da umidade em perfis verticais de solos no Brasil, o objetivo deste estudo é investigar a dinâmica temporal da umidade em várias profundidades de Argissolos, em consonância com os atributos físico-hídricos do solo, em áreas de pastagem e reflorestamento na sub-bacia das Posses, sub-bacia piloto pioneira no pagamento por serviços ecossistêmicos no Brasil .

2 MATERIAL E MÉTODOS

2.1 Descrição da área de estudo

A sub-bacia das Posses está localizada no município de Extrema, Minas Gerais. Compreende uma área de 1.200 ha, situada entre as coordenadas UTM 374.500 371.500 E e 7.468.200 7.474.800 S (Datum SAD 69) (FIGURA 1). Esta região encontra-se na porção sul da Serra da Mantiqueira e apresenta relevo declivoso e bastante movimentado, com altitudes que variam de 945 a 1.435 m. De acordo com o sistema de classificação climática de Köppen, o clima é do tipo Cfb, ou seja, mesotérmico sem estação seca e um verão quente (ALVARES et al. 2013). A temperatura média anual é de 18 ° C, os meses mais quentes e mais frios têm temperaturas médias de 25,6 ° C e 13,1 ° C, respectivamente, e a precipitação média anual é de 1,447 mm. O material parental predominante é o granito (CPRM, 2003).

Figura 1 - Mapa de localização da sub-bacia das Posses, município de Extrema, MG.



Fonte: Do autor (2019).

As classes de solo predominantes na sub-bacia das Posses são Argissolo Vermelho e Argissolo Vermelho-Amarelo (SILVA et al., 2019). O relevo acidentado dificulta a prática de atividades agrícolas, de modo que a pecuária leiteira e extensiva é a atividade predominante na sub-bacia das Posses. As pastagens extensivas ocupam cerca de 72% da área (SAAD, 2016) e, desde o ano de 2013, esta cobertura vêm sendo gradativamente substituída pelo reflorestamento com espécies nativas da região. A sub-bacia das Posses é a sub-bacia piloto pioneira no projeto “Conservador das águas”, uma iniciativa estabelecida em 2006 para implementar o pagamento por serviços ecossistêmicos no Brasil (PEREIRA et al. 2010). O objetivo do projeto é garantir recursos hídricos para o Sistema Cantareira, o principal sistema de abastecimento de água da região metropolitana de São Paulo e uma das estratégias adotadas é aumentar a cobertura florestal da bacia hidrográfica do Rio Jaguari.

2.2 Monitoramento da precipitação e da umidade do solo

Para obter uma série completa de precipitação para o período de estudo, a média dos registros de sete pluviômetros que se encontram instalados na sub-bacia das Posses foi utilizada para obter os dados diários de precipitação apresentados adiante.

Quatro sensores de capacitância do tipo PR2/6 profile probe (Delta T Devices, UK) associados a dataloggers foram instalados em Argissolos, os quais registraram a umidade do solo a cada 5 minutos, nas profundidades de 10, 20, 30, 40, 60 e 100 cm do solo. Os sensores foram previamente calibrados em laboratório, para as condições específicas dos solos monitorados, a partir de amostras indeformadas coletados na área de estudo, conforme consta em SILVA et al. (2019). Três dos sensores foram instalados em áreas de pastagens extensivas, e um sensor foi instalado em área de reflorestamento, implantado no ano de 2013, com espécies nativas da região (TABELA 1). As médias diárias de umidade do solo foram utilizadas na construção das séries temporais de umidade. Os sensores de umidade PR2/6 profile probe e os pluviômetros instalados na sub-bacia das Posses pertencem ao Instituto de Astronomia, Geofísica e Ciências atmosféricas da Universidade Federal de São Paulo (USP).

A caracterização dos pontos e o período de monitoramento da umidade na sub-bacia das Posses encontram-se na Tabela 1.

Tabela 1 - Caracterização dos locais e período de monitoramento da umidade do solo na sub-bacia das Posses.

Local	Uso	Classe de solo	Textura		Período monitoramento
			Hz A	Hz B	
h4	reflorestamento	Argissolo VermelhoAmarelo	argilosa	muito argilosa	14/08/2014 - 27/03/2018
h6	pasto	Argissolo Vermelho	argilosa	argilosa	17/09/2014 - 27/03/2018
h7	pasto	Argissolo Vermelho	franco-argilosa	franco-argilosa	02/10/2014 - 31/01/2018
h10	pasto	Argissolo Vermelho	franco-argilosa	argilosa	10/6/2016 - 27/11/2017

Hz A = horizonte A; Hz B = horizonte B.

Para avaliar a similaridade do padrão temporal da umidade entre as diferentes profundidades do solo utilizou-se o coeficiente de correlação não-paramétrica de Spearman (Rs) (VACHAUD et al., 1985), calculado no software R (R CORE TEAM, 2017), conforme a equação 1 :

$$Rs = 1 - \frac{6 \sum_{i=1}^n (R_{ij} - R_{ij'})^2}{n(n^2 - 1)} \quad (1)$$

Onde R_{ij} e $R_{ij'}$ são os valores de umidade do solo observados no tempo i nas profundidades j e j' , respectivamente, e n é o número de observações. Valores de correlação de Spearman próximos a 1 indicam fortes similaridades das séries temporais de umidade entre diferentes profundidades do solo.

2.3 Caracterização físico-hídrica dos pontos monitorados

Amostras deformadas e indeformadas foram coletadas nos horizontes A e B de cada solo monitorado, em um total de três repetições por horizonte, para determinação dos atributos relacionados à dinâmica da água no solo: textura, densidade do solo, matéria orgânica, macro e microporosidade, porosidade total, diâmetro médio geométrico (DMG) de agregados do solo em água e retenção de água no solo, com base em metodologia descrita no manual de métodos de análises (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA, 1997).

Para determinar a umidade na capacidade de campo (10 Kpa) e no ponto de murcha permanente (1500 Kpa) as amostras com estrutura preservada foram inicialmente saturadas e

submetidas às tensões matriciais de 10 kPa, utilizando as unidades de sucção funis de Buchner e de 1500 kPa, no extrator de Richards (EMBRAPA, 1997). Após o equilíbrio, as amostras foram pesadas úmidas e então levadas à estufa a 105° C por 24 horas para determinação do conteúdo de água em cada tensão. A umidade obtida em base gravimétrica foi convertida para base volumétrica, a partir da densidade do solo obtida para cada camada.

A resistência mecânica do solo à penetração (RMSP) foi obtida em campo, próximo aos sensores instalados, por meio de um penetrômetro de Impacto, com três repetições para cada profundidade do solo: 10, 20, 30, 40 e 60 cm. A partir do número de impactos, a resistência dinâmica foi calculada conforme equação 2, proposta por Stolf (1991):

$$\text{RMSP (kgf cm}^{-2}\text{)} = 5,6 + 6,89 * N \quad (2)$$

Onde: RMSP é a resistência mecânica do solo à penetração em kgf cm⁻² e N é o número de impactos do peso metálico. Os resultados foram multiplicados pela constante 0,0980665 para transformação em MPa, conforme Beutler et al. (2001).

A fim de caracterizar os quatro locais monitorados foi realizada a análise de componentes principais (ACP), utilizando todos os atributos físicos hídricos dos horizontes A e B dos solos em questão, com auxílio do software R (R CORE TEAM, 2017).

3 RESULTADOS

3.1 Umidade do solo


Para representar a variação da umidade do solo em toda a série temporal foram utilizados gráficos box-plots, para cada profundidade e estação de monitoramento (FIGURA 2). As linhas extremas representam os valores máximos e mínimos de umidade do solo observados, o 1º e 3º quartil delimitam a caixa, e o traço interno refere-se ao valor médio de umidade do solo.

A maior variação da umidade ocorreu nas camadas superficiais do solo, em todos os locais monitorados, com uma tendência decrescente com a profundidade, o que é frequentemente observado em estudos similares (JIA et al., 2013; LI et al., 2017; NEVES et al., 2017; ROSENBAUM et al., 2012; TAKAGI; LIN, 2011). A maior variação foi registrada na profundidade de 10 cm das estações H6 e H7, com amplitudes de 0,33 e 0,31 $\text{m}^3 \text{m}^{-3}$, respectivamente, enquanto as amplitudes nas estações H4 e H10 foram de 0,25 e 0,17 $\text{m}^3 \text{m}^{-3}$, respectivamente (FIGURA 2). Os dados da estação H10 foram coletados a partir de junho de 2016, período no qual uma menor variação da umidade foi observada em todas as estações.

A umidade média foi menor nas profundidades de 10 e 20 cm, em relação às profundidades de 30, 40, 60 e 100 cm. Nas profundidades 10 e 20 cm do local H4, situado em área de reflorestamento, a umidade média do solo foi superior à umidade média das camadas correspondentes nos locais H6, H7 e H10, situados em áreas de pastagens.

Em profundidades abaixo de 30 cm, as variações de umidade são menores e os valores médios, máximos e mínimos se aproximam entre os quatro locais, com registros de elevados teores de água no solo (FIGURA 2).

Figura 2 – Box Plot da umidade nas diferentes profundidades e locais de monitoramento. As linhas extremas indicam os valores máximo e mínimo, os retângulos indicam os percentis de 25% e 75%, a linha preta no interior do retângulo indica a média.



Fonte: Do autor (2019).

As séries temporais de precipitação e umidade do solo, nas profundidades 10, 20, 30, 40, 60 e 100 cm, e os teores de água nas tensões 10 e 1500 kPa e na condição de saturação, para cada estação de monitoramento, se encontram na Figura 3.

No período de agosto a dezembro de 2014 foram registrados 627 mm de chuva. Precipitações anuais de 1820, 1746 e 1489 mm nos anos de 2015, 2016 e 2017, respectivamente, e 642 mm no período de janeiro a março de 2018. Houve registros de precipitação em todos os meses avaliados, com precipitações mínimas nos meses de julho e agosto e máximas no período de novembro a janeiro.

A variação temporal da umidade do solo seguiu o padrão de variação temporal da precipitação nos quatro locais monitorados, com diferenças nas amplitudes de variação e nos teores de água no solo, especialmente nos períodos de menor ocorrência de chuvas.


A maior heterogeneidade temporal da umidade foi observada nas profundidades de 10 e 20 cm do solo, nos quatro locais monitorados. São nestas profundidades que se observam as

maiores diferenças nos padrões de variação entre as quatro séries temporais, no qual a umidade se manteve mais elevada na área de reflorestamento (H4), em relação à umidade nas áreas de pastagens, durante toda a série temporal, e principalmente durante os períodos de menor ocorrência de chuvas. Durante os períodos de maior ocorrência de chuvas, o teor de água das camadas superficiais dos solos nas áreas de pastagem (H6, H7 e H10) se aproxima dos teores de água do solo na área de reflorestamento.

Nos períodos de menor ocorrência de chuvas, teores de água abaixo do ponto de murcha permanente (PMP) foram registrados nas camadas superficiais dos quatro solos monitorados. No início do monitoramento, durante o período de setembro a novembro de 2014, os locais H6 e H7 permaneceram com valores de umidade abaixo do PMP na profundidade de 10 cm. Teores de água abaixo do PMP voltaram a ser registrados nos períodos de agosto a outubro de 2015, e abril a maio de 2016, nas profundidades de 10 e 20 cm dos solos em áreas de pastagem (H6 e H7). Neste período, a estação H4 também registrou quedas nos valores de umidade nas camadas superficiais, porém sem atingir o PMP. Para exemplificar, em abril de 2016, mês que registrou a precipitação mais baixa da série, a umidade na camada de 10 cm nas estações H6 e H7 diminuiu de 0,42 para 0,23 m^3/m^3 e 0,37 para 0,19 m^3/m^3 , respectivamente, enquanto a umidade na estação H4 diminuiu de 0,5 para 0,36 m^3/m^3 . No período de julho a setembro de 2016, a estação H4 registrou uma queda nos valores de umidade na camada de 10 cm do solo, atingindo o PMP. Neste período, ocorreu uma falha nos registros das estações H6 e H7, no entanto, a estação H10 também registrou valores abaixo do PMP, nas camadas de 10 cm e de 20 cm do solo. No mesmo período do ano de 2017, a umidade na camada de 10 cm atingiu novamente o PMP, nas estações H4, H7 e H10, fato que se prolongou no mês seguinte somente nas estações H7 e H10 (FIGURA 3).

Nas profundidades de 30, 40 e 60 cm, o padrão de variação temporal das camadas é semelhante ao das camadas subjacentes, porém com oscilações mais atenuadas, conforme achados de Mitchell et al. (1993) e Melo e Montenegro (2015). Na profundidade de 100 cm a umidade é praticamente estável ao longo das quatro séries temporais analisadas (FIGURA 3). A partir dos 30 cm, quanto maior a profundidade, maior a semelhança existente entre as quatro séries temporais de umidade do solo analisadas. Em tais profundidades, a umidade do solo se manteve alta ao longo de toda a série temporal, permanecendo próxima ou acima dos teores de água na capacidade de campo (CC), nos quatro locais monitorados.

Figura 3. Séries temporais de precipitação e de umidade do solo nas profundidades 10, 20, 30, 40, 60 e 100 cm do solo para quatro locais de monitoramento na sub-bacia das Posses, Extrema-MG.



Fonte: Do autor (2019).

Na Tabela 2 são apresentados os valores dos coeficientes de correlação de Spearman (R_s) entre as profundidades do solo monitoradas. Os R_s foram estatisticamente significativos ($p < 0.001$) entre quaisquer duas profundidades do solo, nos quatro locais monitorados, indicando fortes similaridades temporais entre as profundidades do solo. Os valores de R_s diminuíram gradualmente com o aumento do intervalo de profundidade, principalmente nos locais H4 e H10.

Tabela 2 - Coeficientes de correlação de Spearman entre a umidade do solo em várias profundidades para os quatro locais de monitoramento.

Prof (cm)	10	20	30	40	60	100	Prof (cm)	10	20	30	40	60	100
H4							H7						
10	1,00	0,88	0,72	0,58	-	0,34	10	1,00	0,90	0,88	0,71	0,79	0,52
20		1,00	0,93	0,82	-	0,56	20		1,00	0,79	0,58	0,66	0,37
30			1,00	0,94	-	0,72	30			1,00	0,76	0,80	0,51
40				1,00	-	0,82	40				1,00	0,92	0,82
60					-	-	60					1,00	0,81
100						1,00	100						1,00
H6							H10						
10	1,00	0,91	0,88	0,77	0,71	0,65	10	1,00	0,94	0,87	0,70	0,46	0,42
20		1,00	0,78	0,67	0,66	0,57	20		1,00	0,92	0,80	0,52	0,40
30			1,00	0,87	0,81	0,80	30			1,00	0,84	0,57	0,56
40				1,00	0,89	0,79	40				1,00	0,82	0,36
60					1,00	0,75	60					1,00	0,39
100						1,00	100						1,00

Todas as correlações foram significativas ($p < 0,001$). Fonte: Do autor (2019).

3.2 Atributos físico-hídricos

Para auxiliar a interpretação do comportamento da umidade no perfil dos Argissolos, atributos físicos relacionados à dinâmica da água foram determinados a partir das amostras coletadas nos horizontes A e B dos quatro locais monitorados (TABELA 3), e utilizados na análise de componentes principais (ACP).

Tabela 3 - Atributos físico-hídricos dos horizontes A e B nos quatro locais de monitoramento da umidade do solo, na sub-bacia das Posses, Extrema-MG.


	Arg	Sil	AG	AF	MO	Micro	Macro	Pt	T10	T1500	AD	DS	RMSP	DMG
local	%.....											Kg dm ⁻³	Mpa	mm
Hz A														
h10	39	27	20	14	1,8	40	16	56	40	31	8,4	1,3	4,6	4,5
h6	41	24	21	13	2,1	38	14	52	37	30	6,9	1,2	6,8	4,8
h7	33	28	27	12	2,8	32	17	49	31	25	6,2	1,3	4,3	4,7
h4	54	22	15	8	5,3	43	23	66	41	32	9	1,1	4,5	4,4
Hz B														
h10	60	20	11	10	0,8	41	11	52	41	34	7	1,2	10,6	3,6
h6	56	20	15	10	0,8	36	19	55	35	29	6,1	1,4	16,1	4,1
h7	39	27	23	10	0,8	34	17	51	33	26	6,8	1,3	7,9	3,7
h4	67	17	10	7	0,9	39	21	60	38	33	5	1	5,7	3,6

Arg:argila; Sil=silte; AG: areia grossa; AF: areia fina; MO: matéria orgânica; DS: densidade do solo; Micro: microporosidade; Macro: macroporosidade; Pt: porosidade total; T10: umidade na tensão 10 Kpa; T1500: umidade na tensão 1500 Kpa; AD: água disponível; DS: densidade do solo; RMSP: resistência do solo à penetração; DMG: diâmetro médio geométrico.

Fonte: Do autor (2019).

Conforme apresentado na Figura 4, o primeiro eixo da ACP explica 47,5% dos dados e apresenta maior influência das variáveis relacionadas à textura do solo (argila, AG, AF e silte) e DS e das variáveis relacionadas à retenção de água no solo (microporosidade, porosidade total, umidades de saturação e umidades nas tensões de 10 e 1500 Kpa). O segundo eixo da ACP explica 25% dos dados e é afetado principalmente pelas variáveis MO, AD e RMSP.

Figura 4 - Análise de componentes principais dos atributos físico-hídricos dos horizontes A e B dos quatro locais monitorados na sub-bacia das Posses, Extrema – MG.



Arg:argila; Sil=silte; AG: areia grossa; AF: areia fina; MO: matéria orgânica; DS: densidade do solo; Micro: microporosidade; Macro: macroporosidade; Pt: porosidade total; T10: umidade na tensão 10 Kpa; T1500: umidade na tensão 1500 Kpa; AD: água disponível; DS: densidade do solo; RMSP: resistência do solo à penetração; DMG: diâmetro médio geométrico; HzA: horizonte A; HzB: horizonte B.

Fonte: Do autor (2019).

A primeira componente discriminou as amostras pertencentes aos horizontes A das amostras pertencentes aos horizontes B. As amostras de horizonte A foram agrupadas nos quadrantes superiores, consequência dos maiores teores de MO e AD, e dos menores valores de RMSP. Já as amostras dos horizontes B foram agrupadas nos quadrantes inferiores, por apresentarem menores teores de MO e AD, e maiores valores de RMSP (FIGURA 4).

As amostras pertencentes ao local H4 foram discriminadas das demais amostras principalmente pela influência positiva do primeiro eixo da ACP, estando localizadas nos quadrantes à direita. As amostras pertencentes ao local H7 tem sua localização nos quadrantes à esquerda pela correlação negativa com a primeira componente. Nos locais H6 e H10, as amostras pertencentes ao horizonte A foram agrupadas no quadrante superior esquerdo, com correlação

negativa com a componente 1 e positiva com a componente 2, e as amostras do horizonte B apresentaram correlações negativas com a componente 2 (FIGURA 4).

4 DISCUSSÃO

A maior heterogeneidade da umidade nas camadas superficiais já é esperada em análises de séries temporais de umidade do solo, dada à maior exposição à evapotranspiração, e a influência direta da precipitação. Embora os padrões de variação temporal entre as diferentes profundidades sejam semelhantes, a resposta mais rápida aos eventos de precipitação e a taxa de secagem do solo propiciam uma variação temporal mais acentuada nas camadas superficiais do solo (MELO; MONTENEGRO, 2015; ROSENBAUM et al., 2012).

A umidade do solo foi mais elevada nas profundidades de 10, 20 cm do solo sob reflorestamento, em relação as áreas de pastagem. A Figura 4 revela os maiores teores de argila e matéria orgânica do horizonte A deste local, atributos que contribuem fortemente para a retenção de água no solo (COSTA et al., 2013). O maior teor de matéria orgânica é resultado do acúmulo de serrapilheira sobre o solo, o que contribui para melhoria das condições físicas e da estrutura do solo (BISWAS; SI, 2011) e, conseqüentemente, para a maior capacidade de retenção de água no solo, a maior taxa de infiltração de água e para os menores valores de densidade do solo e resistência mecânica à penetração (FIGURA 4).

Os teores de água no solo mais elevados na área de reflorestamento, em relação às pastagens, são mais evidentes nas épocas de menor ocorrência de chuvas, onde se observa uma menor redução da umidade (FIGURA 3). No período de julho a outubro os Argissolos monitorados na sub-bacia das Posses se encontram com os menores teores de água, atingindo valores abaixo do PMP, com maior frequência nas áreas de pastagens. James et al. (2003) também observaram valores mais baixos de umidade em solos de pastagens, em relação à solos sob floresta e vegetação arbustiva, em condições secas. Estudos similares também sugerem que a taxa de secagem mais rápida da umidade em áreas de pastagens pode estar relacionada a uma maior demanda dessa vegetação pela umidade do solo nas camadas superficiais (KÖCHY; WILSON 2000; MELO; MONTENEGRO, 2015; WANG et al., 2014). Todavia, nos períodos mais chuvosos, quando os conteúdos de água no solo são maiores, a umidade do solo tende a sofrer um menor impacto da vegetação, ao passo que a umidade não atua como um fator limitante na evapotranspiração (ÁVILA et al., 2011; JAMES et al., 2003; MELO; MONTENEGRO, 2015; ROSENBAUN, 2012).

As amostras pertencentes aos horizontes B dos quatro locais monitorados foram agrupadas de maneira distinta na ACP (FIGURA 4). Apesar das diferenças sugeridas entre os atributos físico-hídricos destes horizontes, principalmente entre os locais H4 e H7, as quatro séries temporais de umidade apresentaram padrões de variação semelhantes a partir dos 30 cm de profundidade, com valores médios de umidade elevados. Coeficientes de variação de umidade menores têm sido relatados em séries espaço - temporais de umidade do solo em regiões úmidas, quando a umidade média do solo é alta (LAWRENCE; HORNBERGER, 2007; NOGUCHI et al. 2014; PETERS-LIDARD; PAN, 2002). Na profundidade de 100 cm, as séries temporais de umidade são praticamente estáveis e são similares nos quatro locais monitorados, durante quase todo o período, devido à menor dependência dos fatores climáticos, biológicos e hidrológicos que determinam a dinâmica da umidade do solo (GAO; SHAO, 2012).

Na maior parte do ano, a umidade do solo se manteve próxima ou acima da capacidade de campo nas camadas abaixo de 30 cm, nos quatro locais monitorados. É importante ressaltar que, apesar das diferenças físico-hídricas sugeridas pela ACP, os quatro Argissolos monitorados apresentam elevada capacidade de retenção de água, que pode ser confirmada pelos valores elevados de umidade na tensão 1500 Kpa (TABELA 3). A textura e a superfície específica dos solos exercem um controle primordial na capacidade de retenção de água no solo (HILLEL, 2003). A textura dos solos em questão varia de franco-argilosa a muito argilosa, e, em geral, quanto maior o teor de argila, maior a capacidade de retenção de água (LUZ; LIMA, 2008).

A alta capacidade de retenção de água dos Argissolos da sub-bacia das Posses, aliada à elevada e bem distribuída taxa de precipitação ao longo do ano na sub-bacia das Posses, resultam em valores médios de umidade elevados, nos quatro locais avaliados, principalmente nas profundidades abaixo de 30 cm (FIGURAS 2 e 3). Apesar dos elevados teores de água ao longo das séries temporais, nenhum local atingiu a condição de saturação. O local H7 foi o único a se aproximar de tal condição na camada de 100 cm, fruto dos menores teores de argila e menor porosidade total, que refletem em um menor teor de água armazenada na condição de saturação (FIGURA 4).

Análises de séries espaço-temporais da umidade do solo em regiões áridas e semi-áridas sugerem que fatores estáticos, tais como textura, densidade e topografia exercem um maior controle na variabilidade da umidade do solo (COSH et al., 2008; LI et al., 2015; MELO; MONTENEGRO, 2015). Todavia, Li et al. (2017), ao analisar séries temporais de umidade em

uma região de clima úmido, observaram que fatores dinâmicos, como a precipitação, exerceram um maior controle na variação da umidade na dimensão temporal. Kim e Barros (2002) e Oldak, Jackson e Pachepsky (2002) também relataram que a variabilidade espacial da umidade do solo foi predominantemente controlada pelos padrões de precipitação sob condições úmidas e pela textura do solo e pelo teor de água da vegetação sob condições secas.

Os resultados deste estudo sugerem que a precipitação é o principal fator de influência na variação temporal da umidade no perfil dos Argissolos da sub-bacia das Posses, porquanto o comportamento temporal da umidade é similar nas camadas abaixo de 30 cm, onde o teor de água é elevado, independente dos atributos do solo e vegetação. Por outro lado, nas profundidades superficiais do solo, onde o teor médio de água é inferior, em relação às camadas mais profundas, os atributos do solo e a vegetação parecem exercer um maior controle na variação temporal da umidade, principalmente durante os períodos de menor ocorrência de precipitação, dado os maiores teores de água na área de reflorestamento.

Os altos coeficientes de correlação de Spearman indicam fortes similaridades temporais entre as profundidades do solo, nos quatro locais monitorados, apesar das diferenças existentes entre os atributos físico-hídricos dos horizontes A e B (FIGURA 4). Solos com textura fina são menos propensos a sofrer o chamado “desacoplamento físico das camadas adjacentes do solo (CAPEHART; CARLSON, 1997), que ocorre quando as taxas de secagem da superfície e subsuperfície divergem, controladas pelas propriedades hidráulicas do solo, pois as mudanças nos teores de umidade são mais suaves nas épocas secas (VEREECKEN et al., 2008). Além disso, sob condições de elevados teores de água no solo, a distribuição de água no perfil atua de forma mais homogênea (JOST et al., 2004). A tendência observada foi de redução nos coeficientes de correlação com o aumento do intervalo de profundidade, conforme achado de outros autores (GAO; SHAO, 2012; JIA et al., 2013; LI et al., 2017), principalmente nos locais H4 e H7, onde ocorrem variações texturais entre os horizontes A e B.

5 CONCLUSÕES

Este estudo analisou séries temporais da umidade em perfis de Argissolos situados em áreas de pastagens e reflorestamento. A umidade do solo foi superior nas camadas de 10 e 20 cm do solo na área de reflorestamento, possivelmente reflexo da melhor estrutura física deste horizonte A, dados os maiores teores de argila e matéria orgânica. Maiores diferenças foram observadas no padrão de variação da umidade nos períodos de menor ocorrência de chuvas, quando as áreas de pastagens atingiram o PMP com maiores frequências que a área de reflorestamento. Nas camadas mais profundas, o padrão de variação da umidade é semelhante nas quatro séries temporais analisadas, independente da vegetação e dos atributos físico-hídricos dos solos monitorados. Nas camadas abaixo de 30 cm, a umidade se manteve alta ao longo de todas as séries temporais, reflexo da alta capacidade de retenção de água dos Argissolos da sub-bacia das Posses e da elevada e bem distribuída precipitação. Fortes similaridades temporais entre as profundidades do solo foram indicadas pelos coeficientes de correlação de Spearman. Em posse da caracterização dos atributos relacionados à dinâmica da água no solo, a elevada taxa de precipitação na região de estudo parece exercer papel primordial no comportamento das séries temporais de umidade do solo no perfil dos Argissolos da sub-bacia das Posses.

AGRADECIMENTOS

Ao departamento de Ciência do solo, pelo suporte e conhecimento, à UFLA pela estrutura. A Coordenação de aperfeiçoamento de pessoal de nível superior - Capes - Código de Financiamento 001, pela bolsa de estudos, ao Programa de excelência acadêmica - Proex (AUXPE 593/201), ao Conselho nacional de desenvolvimento científico e tecnológico - CNPq (Processos 306511-2017-7 e 202938/2018-2), à Fundação de Amparo a Pesquisa do Estado de Minas Gerais - FAPEMIG (Processos APQ-00802-18, e CAG-APQ 01053-15) e à Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP (ClimateWise 2015/50682-6), CAPES/ANA/Estimativa de evapotranspiração por sensoriamento remoto para gestão de recursos hídricos no Brasil 88887.144979/2017-00, e CNPq/ANA 446278/2015-7 O regime hidrológico das bacias dos Rios Piracicaba e Paraíba do Sul no clima futuro: avaliação de alta resolução dos padrões, incertezas e impactos do uso da terra, pelo apoio e financiamento de pesquisas.

REFERÊNCIAS

- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, Stuttgart, v. 22, n. 6, p. 711–728, 2013. doi:10.1127/0941-2948/2013/0507
- ÁVILA, L. F.; DE MELLO, C. R.; DA SILVA, A. M. Continuidade e distribuição espacial da umidade do solo em bacia hidrográfica da Serra da Mantiqueira. **Revista Brasileira de Engenharia Agrícola e Ambiental-Agriambi**, Campina Grande, v. 14, n. 12, p. 1257-1266, 2010.
- ÁVILA, L. F.; MELLO, C. R.; SILVA, A. M. Estabilidade Temporal do Conteúdo de Água em três condições de uso do solo, em uma bacia hidrográfica da região da Serra da Mantiqueira, MG. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 34, n. 6, p. 2001-2009, 2010.
- ÁVILA, L. F. et al. Padrão Espaço-Temporal da Umidade Volumétrica do Solo em uma Bacia Hidrográfica com Predominância de Latossolos. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 35, n. 5, p. 1801-1810, 2011.
- BHARALI, B. Rate of infiltration for different soil textures using rainfall simulator and Green–Ampt model. **ISH Journal of Hydraulic Engineering**, London, p. 1-7, 2019.
- BEUTLER, A. N. et al. Resistência a penetração e permeabilidade de Latossolo Vermelho Distrófico típico sob sistemas de manejo na região dos cerrados. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 25, n. 1 p. 167-177, 2001.
- BISWAS, A.; SI, B. C. Identifying scale specific controls of soil water storage in a hummocky landscape using wavelet coherency. **Geoderma**, Amsterdam, v. 165, p. 50-59, 2011.
- BROCCA, L. et al. Soil moisture for hydrological applications: open questions and new opportunities. **Water**, Basel, v. 9, n. 2, p. 140, 2017.
- BRUNO, R. D.; ROCHA, H. R.; FREITAS, H. C.; GOULDEN, M. L.; MILLER, S. D. Soil moisture dynamics in an eastern Amazonian tropical forest. *Hydrological Processes*, Chichester, v. 20, p. 2477-2489, 2006.
- CANTON, Y.; SOLE-BENET, A.; DOMINGO, F. Temporal and spatial patterns of soil moisture in semiarid badlands of SE Spain. **Journal of Hydrology**, Amsterdam, v. 285, p. 199–214, 2004.
- CAPEHART, W. J.; CARLSON, T. N. Decoupling of surface and near-surface soil water content: a remote sensing perspective. *Water Resources Research*, Washington, v. 33, n. 6, p. 1383–1395, 1997.
- CORRADINI, C. Soil moisture in the development of hydrological processes and its determination at different spatial scales. **Journal of Hydrology**, Amsterdam, v. 516, p. 1–5, 2014.

COSH, M. H.; JACKSON, T.J.; MORAN, S.; BINDLISH, R. Temporal persistence and stability of surface soil moisture in a semi-arid watershed. **Remote Sensing of Environment**, New York, v. 112, n. 2, p. 304-313, 2008.

COSTA, A. da. et al. Water retention and availability in soils of the State of Santa Catarina-Brazil: effect of textural classes, soil classes and lithology. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 37, n. 6, 2013.

CPRM - SERVIÇO GEOLÓGICO DO BRASIL (2003). Mapa geológico do estado de Minas Gerais. Belo Horizonte: CPRM, 2003.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Centro Nacional de Pesquisa de Solos. **Manual de métodos de análise de solo**. 2. ed. Rio de Janeiro: Ministério da Agricultura; EMBRAPA/CNPQ, 1997. 212 p.

FAMIGLIETTI, J. S. et al. Ground-based investigation of soil moisture variability within remote sensing footprints during the Southern Great Plains 1997 (SGP97) Hydrology Experiment. **Water Resources Research**, Washington, v. 35, p. 1839 – 1851, 1999. doi:10.1029/1999WR900047.

FAMIGLIETTI, J. S. et al. Field observations of soil moisture variability across scales, **Water Resources Research**, Washington, v. 44, p. 1-16, 2008. doi:10.1029/2006WR00580

GAO, X. D. et al. Estimating spatial mean soil water contents of sloping jujube orchards using temporal stability. **Agricultural Water Management**, Amsterdam, v. 102, p. 66–73, 2011.

GAO, L.; SHAO, M. Temporal stability of shallow soil water content for three adjacent transects on a hillslope. **Agricultural Water Management**, Amsterdam, v. 110, p. 41–54, 2012. doi:10.1016/j.agwat.2012.03.012

GEROY, I. J. et al. Aspect influences on soil water retention and storage. **Hydrological Processes**, Chichester, v. 25, p. 3836–3842, 2011.

HAWLEY, M. E.; JACKSON, T. J.; MCCUEN, R. H. Surface soil moisture variation on small agricultural watersheds. **Journal of Hydrology**, Amsterdam, v. 62, p. 179–200, 1983.

HILLEL, D. **Introduction to environmental soil physics**. Cambridge: Ed. Academic press, 2003.

JAMES, S. E. et al. Temporal heterogeneity of soil in grassland and forest. **Journal of Ecology**, London, v. 91, n. 2, p. 234-239, 2003.

JIA, X. X. et al. Hillslope scale temporal stability of soil water storage in diverse soil layers. **Journal of Hydrology**, Amsterdam, v. 498, n. 18, p. 254-264, 2013.

JOST, G.; SCHUME, H.; HAGER, H. Factors controlling soil water- recharge in a mixed European beech (*Fagus sylvatica* L.)-Norway spruce [*Picea abies* (L.) Karst.] stand. **European Journal of Forest Research**, v. 123, p. 93–104, 2004.

JUHÁSZ, C. E. P. et al. Dinâmica físico-hídrica de uma topossequência de solos sob Savana Florestada (Cerradão) em Assis, SP. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 30, p. 401-402, 2006.

KIM, G.; BARROS, A. P. Space-time characterization of soil moisture from passive microwave remotely sensed imagery and ancillary data. **Remote Sensing of Environment**, New York, n. 81, p. 393–403, 2002.

KÖCHY, M.; WILSON, S. D. Competitive effects of shrubs and grasses in prairie. **Oikos**, Copenhagen, v. 91, p. 385–395, 2000.

LAWRENCE, J. E.; HORNBERGER, G. M. Soil moisture variability across climate zones. **Geophysical Research Letters**, Washington, v. 34, n. 20, p. 1-5, 2007.

LEITE, F. P. et al. Regime hídrico do solo sob povoamento de eucalipto, floresta nativa e pastagem, na região de Guanhães-MG. **Revista Árvore**, Viçosa, v. 21, n. 4, p. 455-462, 1997.

LI, B; RODELL, M. Spatial variability and its scale dependency of observed and modeled soil moisture over different climate regions. **Hydrology and Earth System Sciences**, v. 17, p. 1177–1188, 2013.

LI, X. Z. et al. Landscape-scale temporal stability of soil water storage within profiles on the semiarid loess plateau of china. **Journal of Soils and Sediments**, Berlin, v. 15, n. 4, p. 949-961, 2015.

LI, X. Z. et al. Similarity of the temporal pattern of soil moisture across soil profile in karst catchments of southwestern China. **Journal of Hydrology**, Amsterdam, v. 555, p. 659–669, 2017.

LUZ, L. R. Q. P.; LIMA, S. L. Atributos físicos e hídricos de solos em topossequência de tabuleiros costeiros. **Revista de Energia na Agricultura**, Botucatu, v. 23, n. 1, p. 44-59, 2008.

MARTINEZ-FERNANDEZ, J.; CEBALLOS, A. Temporal stability of soil moisture in a large-field experiment in Spain. **Soil Science Society of America Journal**, Madison, v. 67, p. 1647–1656, 2003.

MARTINEZ, G.; PACHEPSKY, Y. A.; VEREECKEN, H. Effect of soil hydraulic properties on the relationship between the spatial mean and variability of soil moisture. **Journal of Hydrology**, Amsterdam, v. 516, p. 154–160, 2014.

MELO, R. O.; MONTENEGRO, A. A. A. Dinâmica temporal da umidade do solo em uma bacia hidrográfica no semiárido Pernambucano. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 20, p. 430-441, 2015.

MENEZES, M. D., et al. Dinâmica hidrológica de duas nascentes, associada ao uso do solo, características pedológicas e atributos físico-hídricos na sub-bacia hidrográfica do Ribeirão Lavrinha-Serra da Mantiqueira (MG). **Scientia Forestalis**, Piracicaba, v. 37, n. 82, p. 175-184, 2009.

MITCHELL, R. J. et al. Spatial and temporal variation in competitive effects on soil moisture and pine response. **Ecological Applications**, Tempe, v. 3, p. 167-174, 1993.

NEVES, H. H. et al. Spatial and temporal patterns of soil water content in an agroecological production system. **Scientia Agricola**, Piracicaba, v. 74, n. 5, p. 383-392, 2017.

OJHA, R. et al. Effective Saturated Hydraulic Conductivity for Representing Field-Scale Infiltration and Surface Soil Moisture in Heterogeneous Unsaturated Soils Subjected to Rainfall Events. **Water (Switzerland)**, Basel, v. 9, n. 2, p. 1-17, 2017.

OLDAK, A.; JACKSON, T. J.; PACHEPSKY, Y. Using GIS in passive microwave soil moisture mapping and geostatistical analysis. **International Journal of Geographical Information Science**, London, v. 16, n. 7, p. 681-698, 2000.

PAN, W. et al. Characterizing Soil Physical Properties for Soil Moisture Monitoring with the North Carolina Environment and Climate Observing Network. **Journal of Atmospheric and Oceanic Technology**, Boston, v. 29, n. 7, p. 933-943, 2012.

PETROPOULOS, G. P.; IRELAND, G.; BARRETT, B. Surface soil moisture retrievals from remote sensing: Current status, products & future trends. **Physics and Chemistry of the Earth**, Oxford, v. 83-84, p. 36-56, 2015.

PEREIRA, P. H. et al. **Conservador das Águas, 5 anos**. Extrema: Departamento de Meio Ambiente, 2010.

PETERS-LIDARD, C. D.; PAN, F. Re-thinking the contradictions of soil moisture spatial variability, **Eos Transactions American Geophysical Union**, Washington, v. 83, 2002. Fall Meet. Suppl., Abstract NG12C-1042.

PREVEDELLO, C. L. et al. Balanço de água por aquisição automática de dados em cultura de trigo (*Triticum aestivum* L.). **Revista Brasileira de Ciência do Solo**, Viçosa, v. 31, n.1, p. 1-8, 2007.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Viena: R Foundation for Statistical Computing, 2017.

ROBOCK, A. et al. The Global Soil Moisture Data Bank. **Bulletin of the American**

Meteorological Society, Boston, v. 81, p. 1281–1299, 2000.

ROMANO, N. Soil moisture at local scale: measurements and simulations. **Journal of Hydrology**, Amsterdam, v. 516, p. 6-20, 2014.

ROSENBAUM, U. et al. Seasonal and event dynamics of spatial soil moisture patterns at the small catchment scale. **Water Resources Research**, Washington, v. 48, n. 10, 2014.

SAAD, S. I. Modelagem e valoração dos serviços ambientais hidrológicos na recuperação da vegetação no Ribeirão das Posses, Extrema, MG. 2016. 169 p. Tese (Doutorado em Ciência Ambiental) – Universidade de São Paulo, São Paulo, 2016.

SANDVIG, R. M.; PHILLIPS, F. M. Ecohydrological controls on soil moisture fluxes in arid to semiarid vadose zones. **Water Resources Research**, Washington, v. 42, n. 8, 2006.

SENA, A. G. et al. Multivariate analysis of soil moisture data. **Journal of Hyperspectral Remote Sensing**, Recife, v. 7, p. 432-438, 2017.

SENEVIRATNE, S. I. et al. *Investigating soil moisture–climate interactions in a changing climate: a review*. **Earth-Science Reviews**, Amsterdam, v. 99, p. 99–174, 2010.

SILVA, B. P. C. Hydropedology as support for water resources management in an experimental watershed at Mantiqueira mountain range. 2019. 92 p. Tese (Doutorado em Ciência do Solo) – Universidade Federal de Lavras, Lavras, 2019.

STOLF, R. Teoria e teste experimental de fórmulas de transformação dos dados de penetrômetro de impacto em resistência do solo. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 15, p. 249-252, 1991.

TAKAGI, K.; LIN, H. S. Temporal dynamics of soil moisture spatial variability in the shale hills critical zone observatory. **Vadose Zone Journal**, Madison, v. 10, p. 832–842, 2011.

TEULING, A. J. et al. Climate variability effects on spatial soil moisture dynamics. **Geophysical Research Letters**, Washington, v. 34, n. 6, p. 2-5, 2007.

VACHAUD, G. et al. Temporal stability of spatially measured soil water probability density function. **Soil Science Society America Journal**, Madison, v. 49, p. 822–828, 1985.

VERECKEN, H. et al. On the value of soil moisture measurements in vadose zone hydrology: a review. **Water Resources Research**, Washington, v. 46, n. 4, p. 1-21, 2008.

VAN GENUCHTEN, M. T. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. **Soil Science Society America Journal**, Madison, v. 44, p. 892-898, 1980.

WANG, B. et al. Vertical profiles of soil water content as influenced by environmental factors in a small catchment on the hilly-gully Loess Plateau. **PLoS One**, San Francisco, v. 9, n. 10, p. 17-20, 2014.

WANG, Y. Q. et al. Vertical distribution and temporal stability of soil water in 21-m profiles under different land 568 uses on the loess plateau in china. **Journal of Hydrology**, Amsterdam, v. 527, p. 543-554, 2015.

WESTERN, A. W.; GRAYSON, B. The Tarrawarra data set: Soil moisture patterns, soil characteristics, and hydro- logical flux measurements. **Water Resources Research**, Washington, v. 34, p. 2765– 2768, 1998.