



Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Classificação e mapeamento da textura superficial do solo a partir de dados de sensoriamento remoto e análise discriminante, na região de Volta Grande do Rio Uruguai – Brasil

Sandra Cristina Deodoro*¹, Marcos Antônio Timbó Elmiro², Ricardo Alexandrino Garcia³, Plínio da Costa Temba⁴, William Zanete Bertolini⁵

¹Programa de Mestrado em Análise e Modelagem de Sistemas Ambientais. Universidade Federal de Minas Gerais (UFMG). Instituto de Geociências. Avenida Antônio Carlos, 6627, Pampulha, Belo Horizonte, Minas Gerais. CEP: 31270-901; ² Professor do Departamento de Cartografia. Instituto de Geociências. UFMG; ³ Professor do Departamento de Geografia e de Cartografia. Instituto de Geociências. UFMG; ⁴ Professor do Departamento de Cartografia. Instituto de Geociências. UFMG; ⁵ Professor de Geografia Física. Universidade Federal da Fronteira Sul (Campus Chapecó). Rodovia SC 484 - Km 02, Fronteira Sul. Chapecó, Santa Catarina. CEP 89815-899

*email para correspondência: sdeodoro@hotmail.com

Artigo submetido em 30/08/2020 e aceite em 16/12/2020

RESUMO

Medir e avaliar componentes e propriedades de solo são, geralmente, procedimentos que envolvem custo e consumo de tempo. A escassez de amostragem de dados em campo é geralmente compensada por resultados de predição e modelagem cujos procedimentos são conhecidos como mapeamento preditivo de solo. O conhecimento da granulometria do solo (proporção das frações granulométricas) e sua distribuição em um espaço geográfico torna-se importante, principalmente das camadas superficiais as quais são as primeiras a serem erodidas. Além disso, a granulometria constitui importante característica devido à sua relação com outras propriedades do solo tais como estrutura, porosidade, permeabilidade, fertilidade, química e conteúdo de umidade. O objetivo deste trabalho é obter um mapa da textura superficial do solo na região de Volta Grande do Rio Uruguai (SC/RS-Brasil) por meio de amostragem granulométrica (44 pontos), reflectância espectral do solo (141 pontos) no sensor MSI (Sentinel-2), modelagem estatística preditiva (Análise Discriminante) e interpolação pelo método *Inverse Distance Weighting* (IDW). A metodologia aplicada baseia-se na obtenção de funções discriminantes para aplicação de um classificador estatístico que, a partir dos dados espectrais de solo, seja capaz de discriminar a textura em areia, silte e argila. Os resultados da análise discriminante mostraram que (i) a textura do solo foi classificada no modelo a uma acurácia de 71% conforme Índice de Kappa; (ii) as frações silte e areia mostraram-se próximas tanto em termos do comportamento da assinatura espectral obtida por sensor remoto orbital como em termos de teores (g/kg) obtidos em laboratório de análise de solo; (iii) houve predomínio de argila corroborando a característica litológica de área basáltica. Por permitir a verificação de quais variáveis independentes (reflectância) mais contribuíram para a resposta da variável dependente (granulometria) – variáveis espectrais ou bandas B3, B4, B8 e B11 –, este método pode ser útil para indicar as faixas espectrais que podem ser usadas na aplicação de uma técnica de regressão para predição granulométrica.

Palavras-chave: estatística multivariada, espectral, granulometria, Sentinel-2, interpolação.

Classification and Mapping of the surface-based soil texture through Remote Sensing Data and Discriminant Analysis in the region of Volta Grande do Rio Uruguai – Brazil

ABSTRACT

Measuring and evaluating soil components and properties are often costly and time-consuming procedures. Prediction and modelling, whose procedures are known as predictive soil mapping, are useful for solving the lack of field data sampling. The objective of this work is to map the surface-based soil texture in the region of Volta Grande do Rio Uruguay (SC / RS-Brazil) by using soil particle-size sampling (44 points) or soil granulometry, soil spectral reflectance (141 points) in the MSI sensor (Sentinel-2), predictive statistical modelling (Discriminant Analysis) and

IDW interpolation. The methodology aims to find discriminant functions to obtain a statistical classifier that, based on soil spectral data, is able to discriminate the soil texture (surface-based) in terms of sand, silt and clay. The results showed that (i) the statistical model classified the soil texture at an accuracy of 71% according to the Kappa Index; (ii) silt and sand were similar both in terms of spectral signature and of content (g/kg); (iii) there was a predominance of clay corroborating the lithological characteristic of the basaltic area. Discriminant Analysis provides a basis to identify which independent variables (reflectance) contribute most to the response of the dependent variable (soil texture). Thus, the studied method can be useful to indicate the spectral ranges in regression models for predicting soil texture at locations not sampled.

Keywords: multivariate statistics, spectral, soil particle size, Sentinel-2, interpolation.

Introdução

O mapeamento e a identificação da textura do solo inserem-se no contexto de coberturas superficiais pedogenizadas que constituem um recurso ambiental importante em diferentes abordagens. Dentre elas, citam-se: (i) as vulnerabilidades intrínsecas e suas relações com processos erosivos; (ii) a potencialidade de sofrerem o primeiro impacto da ocupação antrópica; (iii) o fornecimento de informações para o entendimento das dinâmicas de esculturação da paisagem e de trabalho fluvial; (iv) como subsídios para o estudo de ocupações humanas pretéritas (tempo geológico) de um território com a datação de seus sedimentos; (v) como capacidade do solo para manter carbono orgânico, uma vez que esta é influenciada pelo conteúdo de argila e silte (Hassink, 1997; Bationo *et al.*, 2007).

Além disso, a textura do solo é uma importante característica devido às suas relações com outras propriedades pedológicas tais como estrutura, porosidade, permeabilidade, fertilidade, química e umidade (Brady e Weil, 2007; Demattê *et al.*, 2016). Ela é obtida por meio da distribuição da composição relativa do tamanho das partículas no solo.

Medir e avaliar componentes e propriedades de solo e mapear estas informações em escala compatível com o objetivo do trabalho são, geralmente, procedimentos que envolvem custo e consumo de tempo (Fongaro *et al.*, 2018), além de requerer trabalhos laboratoriais subsequentes (McBratney, Santos e Minasny, 2003). A escassez de amostragem de dados é geralmente compensada por resultados de predição e modelagem cujos procedimentos, conhecidos como mapeamento preditivo de solo, são especialmente desenvolvidos para estimar distribuição espacial de variáveis do solo (Kovačević, Bajat e Gajić, 2010). A maioria deles é baseada em modelos numéricos ou estatísticos de relação entre variáveis ambientais e propriedades de solo. São aplicados à base de dados geográficos para criar mapa preditivo ou derivar valores de propriedades de solo a partir de dados coletados de campo, em locais sem medição (Burrough, Van

Gaans e Hootsmans, 1997; Scull *et al.*, 2003; Kovačević, Bajat e Gajić, 2010).

As covariáveis ambientais normalmente utilizadas para predição são altimetria e declividade oriundas de modelos digitais de elevação (McBratney *et al.*, 2000), dados de sensoriamento remoto (Odeh e McBratney, 2000; Fongaro *et al.*, 2018; Dotto *et al.*, 2020), atributos físicos e químicos obtidos através de análises laboratoriais de amostras de solo, tipo de solo (Mayr, Palmer e Cooke, 2008), atributos de relevo (Fongaro, 2015; Fongaro *et al.*, 2018) e da associação de variáveis espectrais, de relevo e climáticas (Dotto *et al.*, 2020).

A Análise Discriminante, uma das técnicas de modelagem estatística utilizada em estudos de predição de variáveis, apresenta potencial utilidade em mapeamento de variáveis ambientais, incluindo características do solo, quando combinada com métodos geoestatísticos (Kravchenko *et al.*, 2002; Nanni, Demattê e Fiorio, 2004).

Espectroscopia do solo vem ganhando importância na obtenção e análise dos atributos do solo, conforme mostrado por Silva *et al.* (2019) e por Demattê *et al.* (2019) em um trabalho de implantação da Biblioteca Espectral de Solos do Brasil a qual tem a finalidade de padronizar e avaliar espectros na faixa de comprimentos de onda (λ) entre 350 nm e 2500 nm dos solos brasileiros e estimar atributos importantes do solo, como argila, areia, carbono orgânico do solo, capacidade de troca catiônica, pH e saturação de base. A resposta espectral dos solos tem o potencial de ser utilizada para separar classes de solos por ser uma característica individualizadora (Nanni, Demattê e Fiorio, 2004; Dotto *et al.*, 2020).

O satélite Sentinel-2, apesar de seu lançamento relativamente recente (2015) vem apresentando potencial de aplicação para predição e análise de atributos do solo com base em reflectâncias espectrais deste elemento obtidas pelo sensor MSI (*Multi-Spectral Instrument*). Gholizadeha *et al.* (2018) compararam resultados obtidos do Sentinel-2 no monitoramento e mapeamento de carbono orgânico e textura do solo (argila, silte e areia) com os obtidos por sensor

hiperespectral aerotransportado e medições de espectrorradiômetro de laboratório (FieldSpec) em quatro áreas agrícolas na República Tcheca. As conclusões do estudo apontam que (i) todas as plataformas mostraram um padrão geral semelhante e aceitável para carbono e argila; e (ii) houve mais dispersões na previsão de silte e areia utilizando imagens do Sentinel-2. Bousbih *et al.* (2019) desenvolveram uma abordagem para estimativas do teor de argila do solo superficial (topsoil), com base em dados espectrais do radar a bordo do Sentinel-1 e do MSI a bordo do Sentinel-2 e nos métodos *Support Vector Machine* e *Random Forest* para classificar e mapear teores de argila em uma área semi-árida na Tunísia. O estudo concluiu que (i) as classificações com melhor desempenho foram obtidas usando o indicador de umidade do solo derivado dos dados Sentinel-1 e Sentinel-2 combinados, com precisão geral de 63% e 65% para as classificações *Support Vector Machine* e *Random Forest*, respectivamente; (ii) os resultados mostraram que o sensoriamento remoto é uma ferramenta eficiente, que pode ser usada para gerar mapas de textura do solo em escala de campo.

O objetivo geral deste trabalho é obter um mapa da textura superficial do solo na região de Volta Grande do Rio Uruguai (SC/RS-Brasil). Os objetivos específicos são obter funções discriminantes estatísticas capazes de separar a granulometria do solo em areia, silte e argila; subsidiar a escolha das variáveis independentes (bandas espectrais) que podem ser utilizadas na modelagem estatística preditiva para classificar as granulometrias.

Metodologia

Área de estudo

A área de estudo desta pesquisa (214 km²) localiza-se na alta bacia do rio Uruguai, no trecho conhecido como Volta Grande (um meandro do rio Uruguai), nas proximidades da Usina Hidrelétrica Foz do Chapecó (Figura 1). Geologicamente, a área da Volta Grande é parte da Formação Serra Geral da Província Magmática do Paraná. A litologia dominante é o basalto (IBGE, 2018) e apresenta relação direta com a textura do solo em função do intemperismo deste tipo litológico que, em geral, resulta em materiais argilosos. Análises mineralógicas (difratometria de raio-X) de amostras de sedimentos coletados na área de estudo apontaram predomínio de caulinita, seguido por illita e quartzo (Santos, 2018). Almeida, Corrêa e Schmitt (2018) também identificaram predominância de caulinita em uma topossequência localizada no oeste de Santa Catarina, sobre solos férteis e de alta atividade da fração argila. Do ponto de vista geomorfológico a área de Volta Grande insere-se no domínio do Planalto Meridional, em unidade com características de vales profundos e desníveis pronunciados, regionalmente, denominada Planalto Dissecado do rio Uruguai (IBGE, 2018). O uso e cobertura do solo é caracterizado por pastagem e cultivos agrícolas, resultando em uma paisagem predominantemente rural



Figura 1. Localização da área de estudo.

Trabalho de campo

Trabalhos de campo foram realizados nos meses de maio (dias 15 e 16) e outubro (dias 19 e 23) do ano de 2019 para amostragem de solo para análise granulométrica. O total de pontos amostrados é de 44 (Figura 2), sendo 24 pontos sobre solo exposto (Figura 3) – utilizados para obtenção das reflectâncias espectrais e na modelagem estatística – e 20 pontos sobre alguma cobertura vegetal, utilizados para verificação do

resultado da interpolação realizada após a etapa da modelagem. Foram feitas amostras simples, utilizando GPS modelo Garmim Etrex. No caso de solo exposto, foram escolhidos os talhões onde houvesse pelo menos 5m² desprovidos de cultivo ou de cobertura vegetal. Importante mencionar que o pixel do sensor MSI do Satélite Sentinel-2 possui 10m de resolução espacial nas bandas utilizadas neste trabalho (B2, B3, B4, B8, B11 e B12).

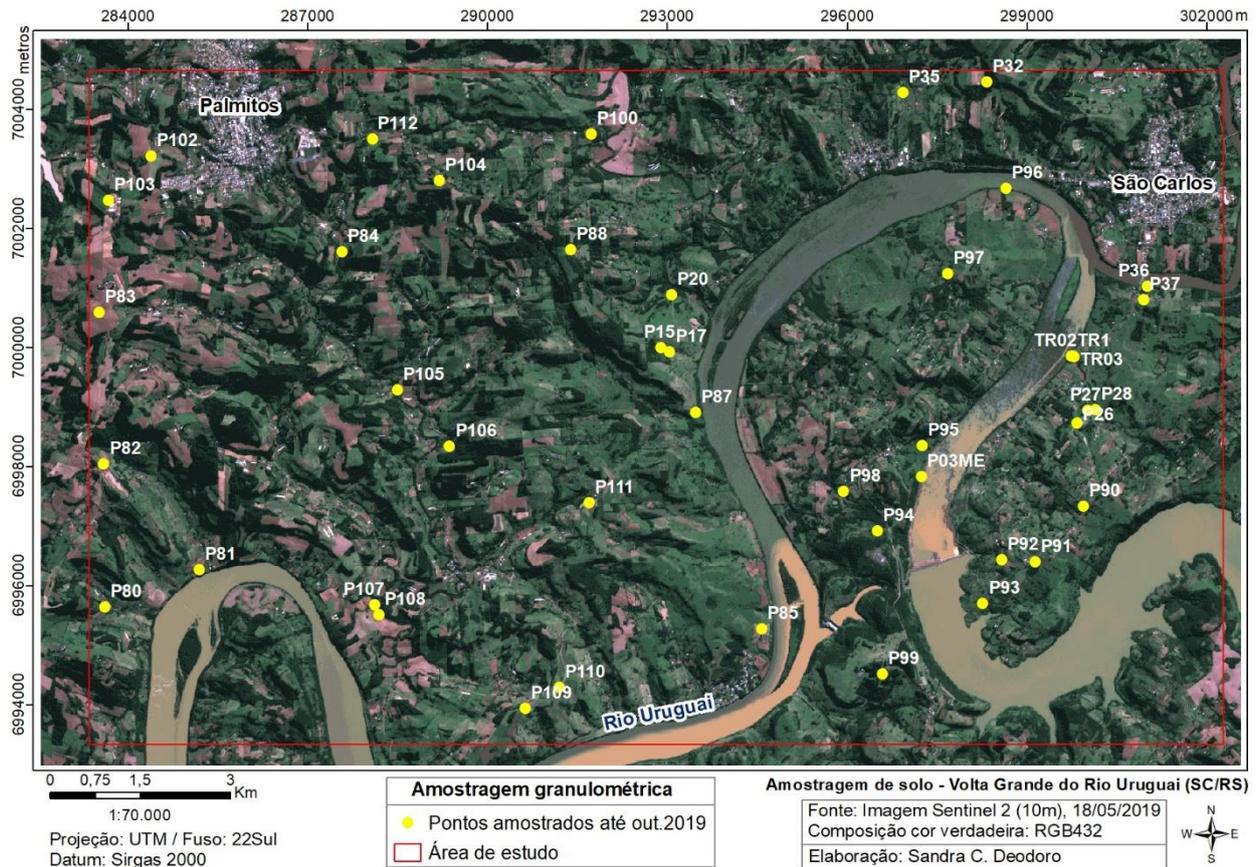


Figura 2. Locais de amostragem granulométrica.



Figura 3. Exemplo de solo exposto em campo.

Análise granulométrica

A amostragem granulométrica do solo (44 pontos), para análise e classificação *a priori* das suas reflectâncias espectrais, foi realizada na camada superficial (profundidade 0-10 cm) uma vez que sensores remotos orbitais passivos como o Sentinel-2 recebem a energia refletida dos alvos (no caso solo) que estão expostos na superfície terrestre. No caso dos solos, o horizonte superficial A exposto é o horizonte que interage com a energia eletromagnética (Meneses, Almeida e Baptista, 2019).

As análises granulométricas foram feitas no laboratório de geologia da Universidade Federal da Fronteira Sul (UFFS), campus Chapecó (SC), pelo método da pipeta (Teixeira *et al.*, 2017). Os cálculos foram feitos conforme Ruiz (2005). A classificação granulométrica em laboratório serviu como referência de terreno na obtenção e avaliação das estimativas por imagem. Este dado serviu de base, também, para a modelagem estatística preditiva como dado de entrada e para a interpolação dos resultados finais com o objetivo de elaboração do mapa da textura superficial do solo.

Imagens ópticas Sentinel-2

Três cenas do satélite Sentinel-2, sensor MSI (fevereiro/2019, maio/2019 e outubro/2019), disponíveis no sítio eletrônico da *European Space Agency* (ESA), foram utilizadas para obter maior quantidade de solo exposto, considerando, também, a proximidade das datas dos trabalhos de campo. As cenas utilizadas possuem nível de processamento 2A, com informações de reflectância da superfície – *Bottom of Atmosphere* (BOA) (ESA, 2015). Esta é uma condição importante para obtenção das respostas ou assinaturas espectrais do solo. Foram utilizadas 10 bandas espectrais (B2, B3, B4, B5, B6, B7, B8, B8A, B11 e B12) – Tabela 1 – cujas faixas são normalmente utilizadas para avaliar propriedades dos solos. O Sentinel-2 foi lançado em 2015 pela ESA. O projeto da resolução espectral do sensor MSI foi desenhado em equivalência às faixas espectrais dos sensores do SPOT e LANDSAT (ESA, 2015), facilitando comparações entre resultados de aplicações dessas imagens.

Tabela 1. Intervalos do espectro eletromagnético das bandas Sentinel-2 utilizadas

Banda	Intervalo espectral (nm)	Posição espectral (nm)
B2	458–523	490
B3	543–578	560
B4	650–680	665
B5	698–713	705
B6	733–748	740
B7	773–793	783
B8	785–900	842
B8A	855–875	865
B11	1565–1655	1610
B12	2100–2280	2190

Fonte: ESA (2015).

Espectrometria do solo – reflectância e assinatura espectral

Os dados espectrais do solo exposto (reflectância) – pontos com amostragem e sem amostragem de campo (Figura 4) – foram extraídos nas dez bandas espectrais correspondentes às faixas do visível (B2, B3 e B4), do infravermelho

próximo (B8) e do infravermelho de ondas curtas SWIR (B5, B6, B7, B8A, B11 e B12) – Tabela 1 – sobre as três imagens Sentinel-2, utilizando-se a plataforma de ferramentas (*toolbox*) denominada *Sentinel Application Platform* (SNAP), obtida no sítio eletrônico da Agência Espacial Europeia.

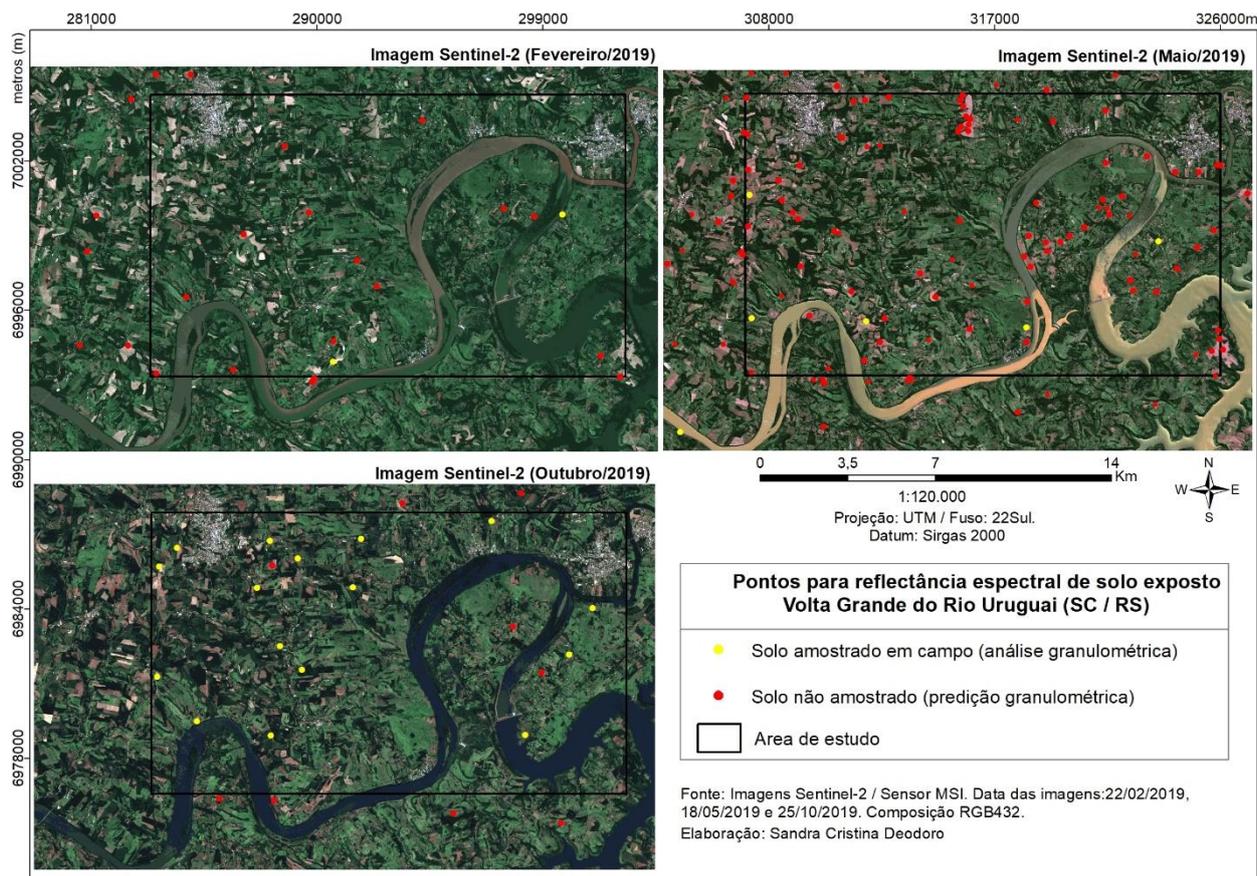


Figura 4. Localização dos pontos de coleta espectral das imagens orbitais.

Para determinação da quantidade de pontos de solo exposto, uma vez que eles constituem os dados de modelo e de interpolação, foi adotado o planejamento amostral proposto por Congalton e Green (2009) para classificação de pixels com base em dados espectrais. Como a amostragem é dependente também das condições de solo exposto do pixel foi obtido um total de 141 amostras de solo exposto (24 de campo e 117 experimentais sem amostragem em campo).

Para a confirmação da condição de solo exposto dos pixels, composições coloridas, cor verdadeira (RGB432) e falsa cor (RGB483 e RGB843) foram executadas e analisadas (Figura 5). Para evitar locais com mistura por alguma vegetação que não pode ser detectada apenas visualmente pelas composições de cores RGB, foram aplicados o índice de vegetação *Soil Adjust Vegetation Index* (SAVI) (Huete, 1988) – Equação 1 – e o índice que relaciona as bandas do infravermelho de ondas curtas (SWIR1 e SWIR2) – Equação 2 – sendo útil para discriminar palhada (restos de cultivo em decomposição) – e solo exposto (Fongaro, 2015; Poppiel, 2016). Na presente pesquisa, a faixa considerada como solo exposto para este índice foi entre 0 e 0,12. Gallo

(2015), Fongaro (2015) e Poppiel (2016) definiram valores entre 0 e 0,19 para estudo de caso na região de Piracicaba (SP), Araraquara (SP) e Brasília-DF, respectivamente, portanto, sob diferentes condições climáticas, litológicas e pedológicas. O SAVI relaciona as bandas do infravermelho próximo e vermelho (Equação 1), indicando que, quanto mais próximo de 1 há indicativo de vegetação e, mais próximo de 0, solo exposto. Neste estudo, considerou-se solo exposto a faixa entre 0 e 0,09. Ambos são índices diferenciais normalizados (Normalized Difference-ND) – variam de 0 a 1.

$$SAVI = (1 + L) * (NIR - RED) / (L + NIR + RED) \quad (1)$$

onde:

L = 1 baixa densidade de vegetação
 L = 0,5 média densidade de vegetação
 L = 0,25 alta densidade de vegetação
 NIR = banda do infravermelho próximo
 RED = banda do vermelho
 Neste estudo, adotou-se L = 0,5.

$$ND_{SWIR1,SWIR2} = (SWIR1 - SWIR2) / (SWIR1 + SWIR2) \quad (2)$$

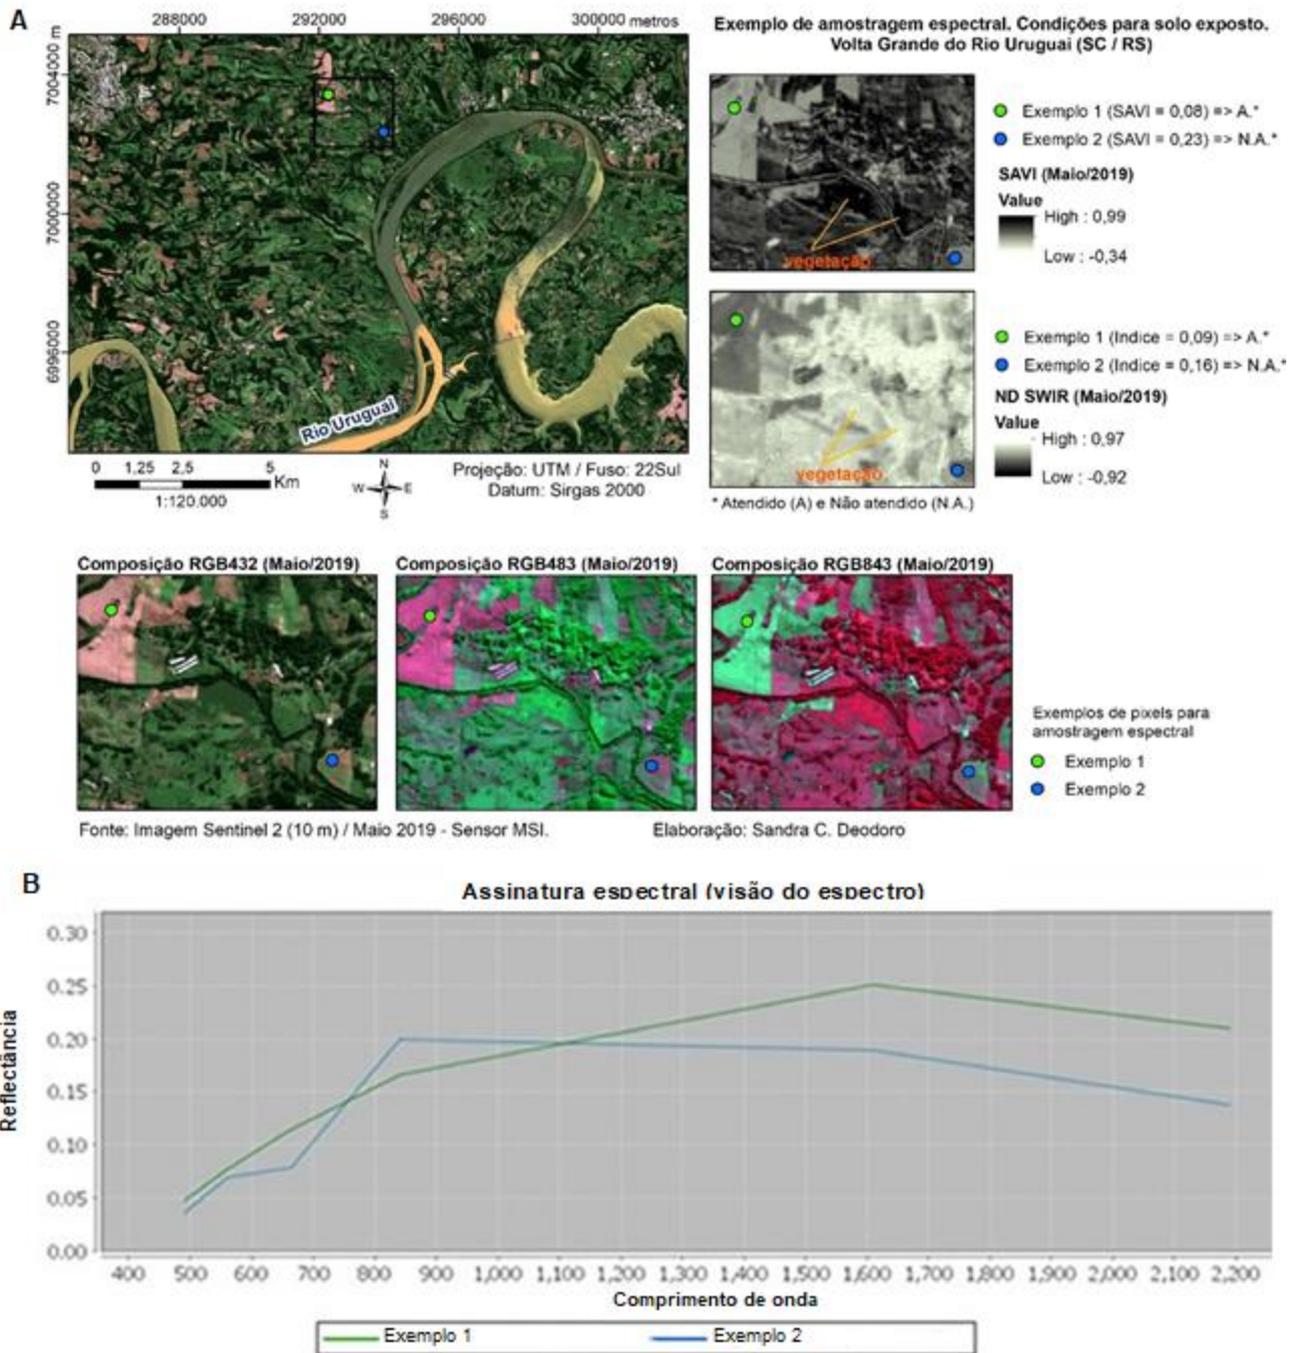


Figura 5. Exemplo de verificação de pixels de solo exposto. A: sobre imagem resultante de composições RGB e índices espectrais solo-vegetação. B: por meio de suas respectivas assinaturas espectrais. Gráfico espectral obtido na plataforma (software) SNAP-ESA.

Modelagem estatística

Preliminarmente à modelagem das funções discriminantes das classes texturais do solo, análises estatísticas descritivas entre as classes granulométricas (variáveis dependentes) e as bandas espectrais (variáveis independentes) foram realizadas com os dados de campo (dados observados ou dados de entrada do modelo). Foram calculadas as médias, os desvios padrões e as covariâncias dos dados espectrais. Para evitar a colinearidade entre as variáveis independentes e o

consequente efeito da redundância (duas variáveis correlacionadas explicando a variável dependente) análise de correlação também foi aplicada. Análise de normalidade multivariada também foi realizada por meio dos testes *Kolmogorov-Smirnov* e *Shapiro-Wilk* para verificar se as variáveis independentes seguem distribuição normal, uma característica importante dos dados uma vez que, se violada, pode prejudicar interpretação dos resultados. O teste Shapiro-Wilk pode ser sensível ao tamanho da amostra e foi originalmente restrito

ao tamanho de amostra menor que 50 (Razali e Wah, 2011). Toda esta etapa inicial da análise discriminante foi executada no software SPSS®.

Análise discriminante foi aplicada aos dados de reflectância espectral dos pontos de campo – e classificados *a priori* em laboratório – para verificar quais faixas do espectro (ou bandas do sensor MSI do satélite Sentinel 2) discriminam melhor os grupos granulométricos e que possam ser usadas no modelo estatístico preditivo para obter as funções discriminantes e classificar os pontos não amostrados em campo (117 pontos).

De acordo com Khattree e Naik (2000) a Análise Discriminante é uma técnica da estatística multivariada que estuda a separação de objetos de uma população (no caso, textura do solo) em duas ou mais classes (no caso, argila, silte e areia). A vantagem desta estatística que também pode ser considerada um tipo de regressão pelo seu poder preditivo, é o fato de ser aplicada em casos onde a variável dependente é categórica ou qualitativa (não métrica) e as variáveis independentes quantitativas (métricas). Daí a escolha deste método para a classificação preditiva das classes texturais do solo neste trabalho. Como a variável dependente não-métrica possui três clusters (grupos ou categorias) foi utilizada a Análise Discriminante Múltipla. A função discriminante utilizada para determinar a variável estatística para análise discriminante (Equação 3) é semelhante à regressão múltipla (HAIR JR. et al., 2009) e é expressa por:

$$Z_{jk} = W_1X_{1k} + W_2X_{2k} + \dots + W_nX_{nk} \quad (3)$$

onde:

Z_{jk} = escore Z discriminante da função discriminante j para o objeto k;

W_i = peso discriminante para a variável independente i;

X_{ik} = variável independente i para o objeto k.

O peso W ou autovalores (*eigenvalues*) das variáveis das funções discriminantes são estimados de modo que a variabilidade seja máxima entre os grupos e mínima nos grupos. Testes de normalidade multivariada e análise de covariância foram realizados para verificar o comportamento dos dados e, previamente, o tipo da função discriminante (se linear ou se quadrática), ao nível de significância de 5%.

Teste de igualdade de médias dos grupos para cada variável explicativa foi realizado. Para este procedimento adotou-se o teste lambda de Wilks que varia de 0 a 1 – valores elevados indicam ausência de diferença entre os grupos (Fávero et al, 2009), ou seja, não discrimina bem o grupo. Foram

testados o poder de discriminação dos valores de reflectância das bandas do sensor MSI utilizadas neste trabalho.

Para obtenção das funções discriminantes, foram utilizados 24 pontos (solo exposto) como dados de entrada do modelo (valores observados), os quais correspondem aos valores de reflectância dos pontos de campo classificados a priori em laboratório. Os resultados foram validados a partir da matriz de confusão, que compara os níveis de acertos de classificação do método e o cálculo do coeficiente de concordância de Kappa. Os valores preditos foram também submetidos a avaliações com amostras de treinamento (50% e 70%) e de teste (50% e 30%) escolhidas aleatoriamente em um total de 20 experimentos. Após validação do modelo, as 117 amostras espectrais (sem amostragem de campo) foram aplicadas nas equações discriminantes de cada classe, sendo que o maior valor resultante foi classificado na classe da função correspondente. Os procedimentos de análise discriminante foram realizados no software SPSS®.

Mapeamento da textura superficial do solo

Para obtenção de um mapa contínuo da textura do solo, uma interpolação foi realizada com os dados classificados em laboratório e os dados classificados no modelo estatístico. A interpolação baseia-se na consideração de que os valores dos atributos tendem a ser similares em locais mais próximos do que em locais mais distantes (Tobler, 1970). Essa técnica também “fundamenta a base das relações espaciais entre fenômenos geográficos, utilizando a correlação espacial como meio de diferença dos atributos estimados” (Câmara e Medeiros, 1998; Jakob e Young, 2006).

A textura do solo na área de estudo, fenômeno a ser interpolado, possui pouca variação em termos de ocorrência no espaço geográfico, sendo predominante a granulometria argila e, de maneira pontual a fração silte. Além disso, com base em observações de campo, mesma granulometria pode ocorrer tanto em superfície de topo como em fundo de vale, em áreas planas e declivosas, a exemplo das frações argila e areia.

Em função dessas considerações, optou-se pelo método de interpolação denominado Distância Inversa Ponderada (*Inverse Distance Weighted – IDW*), um estimador determinístico local que calcula os valores das células não amostradas por meio de uma combinação linear ponderada de um conjunto de pontos da amostra (Smith et al, 2018). O peso é uma função do inverso da distância significando que quanto maior for a distância, menor será a influência de um ponto sobre o valor

estimado (Equação 4). O IDW utiliza os valores amostrados na sua vizinhança que possuem maior peso do que os valores mais distantes.

$$z_i = \frac{\sum_{j=1}^n w_{ij} z_j}{\sum_{j=1}^n w_{ij}} \quad (4)$$

onde:

z_i é o valor estimado de um ponto i qualquer da grade;

z_j é o valor de uma amostra j vizinha do ponto i da grade;

w_{ij} é um fator de ponderação

No caso da área de estudo do presente trabalho, este método de interpolação foi aplicado para estimar valores nas áreas sem amostragem as quais correspondem, principalmente, àquelas com cobertura vegetal (sem amostragem espectral). O número de pontos de referência para o interpolador IDW foi de 141 acrescidos dos 20 pontos amostrados em campo sob condição de solo com cobertura vegetal (e que não entraram na modelagem da Análise Discriminante), totalizando 161 pontos. A Figura 6 apresenta o resumo dos procedimentos metodológicos.

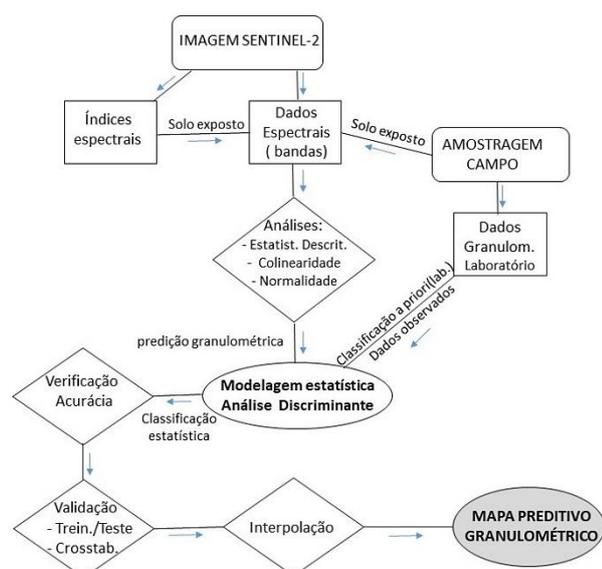


Figura 6. Fluxograma dos procedimentos metodológicos.

Resultados e discussão

Do total de pontos amostrados em campo e classificados em laboratório (Tabela 2), houve predominância da característica argilosa (Figura 7)

refletindo o resultado do intemperismo químico em domínio litológico basáltico.

As assinaturas espectrais de solo exposto dos pontos de campo (Figura 8) mostram um aspecto ascendente no visível (até próximo a 665 nm) com um pico na banda B11 (1610 nm) que corresponde ao infravermelho de ondas curtas. Este comportamento resultante corrobora o disposto na literatura a qual informa que as bandas espectrais que contribuem para a identificação de solos encontram-se nas faixas do infravermelho próximo (700 nm – 1300 nm) e infravermelho médio (1300 nm – 2600 nm) onde se tem uma curva de reflectância fortemente ascendente ao sair das faixas do visível (400nm-650nm) (Florenzano, 2008; Jensen, 2005). Os valores de reflectância das bandas B2, B3, B4, B8, B11 e B12 ficaram próximos à média exibida para solos de litologia ígnea como o basalto (0,31), em conformidade com Demattê *et al.* (2019) para a Biblioteca Espectral de Solos do Brasil.

Nas faixas do infravermelho, ocorreu uma menor absorção dos constituintes do solo e maior reflectância, com destaque para os comprimentos de onda 842 nm (infravermelho próximo) e 1610 nm (infravermelho de ondas curtas). O comportamento geral destes espectros segue o padrão geral de solos, que exibe menores reflectâncias no intervalo das faixas do visível e maiores reflectâncias no intervalo do infravermelho.

Normalmente, há uma aproximação da assinatura espectral (feições de absorção e influência no albedo) entre silte e argila – textura média a fina (Dalmolin et al, 2005), entretanto, isso não ocorreu. A aproximação mostrou-se entre silte e areia (Figura 7). Uma possível explicação é que, sendo o silte uma fração granulométrica intermediária entre argila e areia, ele pode exibir características de ambas. Este resultado concorda com o encontrado por Cezar et al. (2012) ao estudar o comportamento espectral das frações silte, areia e argila obtidos por espectroscopia de reflectância difusa e avaliar a possibilidade de quantificação desses atributos a partir de modelos de regressão individuais gerados para cada elemento. Esses estudos mostraram que, ao contrário do obtido nas frações argila e areia, a fração silte não apresentou comportamento espectral linear, e sim curvilíneo (hiperbólico).

Tabela 2. Classificação granulométrica laboratorial -Volta Grande do Rio Uruguai – SC/RS

Ponto de amostragem	Teores (g/Kg)		
	Areia	Silte	Argila
TR01	215,5	357,7	426,8
TR02	102,1	422,6	475,3
TR03*	342,0	81,5	576,5
P77*	271,4	297,5	431,1
P73	360,2	315,5	324,3
P03ME	177,7	380,6	441,7
P15	282,1	427,3	290,6
P17	495,7	331,1	173,2
P20	260,6	207,5	531,9
P26*	351,4	320,2	328,4
P27*	305,3	501,3	193,4
P28	250,3	228,4	521,3
P32	465,2	275,0	259,8
P35*	351,1	200,6	448,3
P36	125,4	324,6	550,0
P37*	278,5	327,0	394,5
P80*	474,5	268,2	257,3
P81*	217,5	335,3	447,2
P82*	335,6	272,2	392,2
P83*	79,0	261,1	659,9
P84*	275,2	198,2	526,6
P85*	373,9	293,9	332,2
P87	425,8	221,6	352,6
P88*	205,6	412,0	382,4
P90	255,2	259,3	485,5
P91	331,7	204,2	464,1
P92	434,2	237,0	328,8
P93*	340,0	222,3	437,7
P94	334,5	246,6	418,9
P95	279,5	329,8	390,7
P97	197,6	370,9	431,4
P98	289,8	325,3	384,9
P99	274,4	357,0	368,6
P100*	273,4	462,8	263,8
P102*	105,0	270,9	624,2
P103*	72,3	247,7	680,0
P104*	166,4	234,6	599,0
P105*	274,0	206,5	519,5
P106*	307,8	287,4	404,8
P107*	146,4	270,2	583,4
P108*	97,7	347,4	554,9
P109*	244,1	279,1	476,8
P110	235,5	192,2	572,4
P111	107,6	298,2	594,2
P112*	208,7	217,5	573,8

* Pontos da modelagem estatística. Amostragem de solo exposto.
Elaboração: Sandra Deodoro (2020).

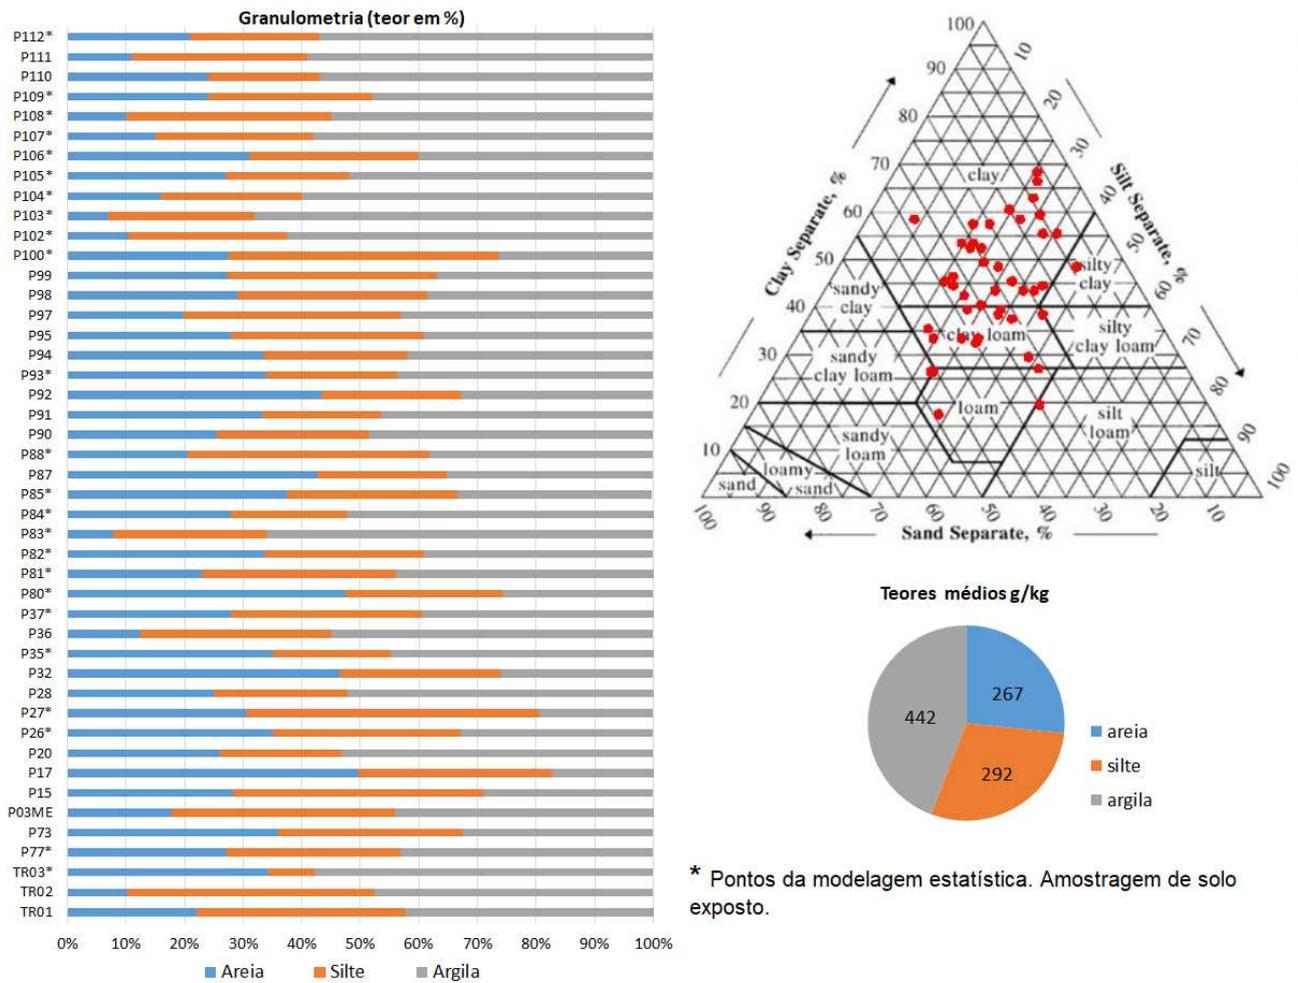


Figura 7. Resultado da análise e classificação granulométrica das amostras coletadas e diagrama textural do solo. Nomenclatura Embrapa: clay = argila; sandy clay = argila arenosa; silty clay = argila siltosa; sandy clay loam = franco argilo-arenosa; clay loam = franco argilosa; silty clay loam = franco argilo-siltosa; sand = areia; loamy sandy = areia franca; sandy loam = franco arenosa; loam = franca; silt loam = franco siltosa; silt = silte.

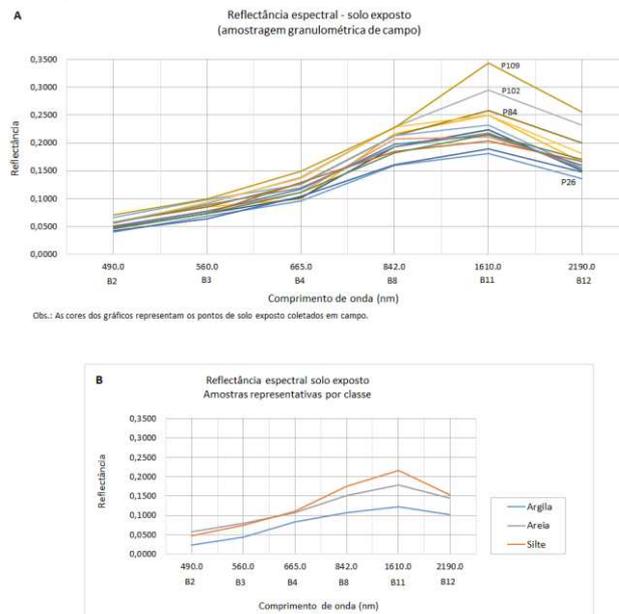


Figura 8. Respostas espectrais obtidas a partir das imagens Sentinel-2 para as amostras de solo coletadas em campo. A – Assinatura e reflectância de cada ponto, destacando os pontos com maior e menor reflectância no comprimento de onda 1610 nm (Banda 11). B – Reflectância conforme a classe textural.

Nos resultados das análises destas três frações em laboratório também houve aproximação dos teores (g/kg) entre silte e areia mais do que entre silte e argila. Além disso, em relação à fração areia, as análises mostraram maiores teores na fração areia fina – mais próxima, portanto, do tamanho da fração silte –, do que para areia grossa. Pode-se dizer, com isso, que o resultado do comportamento espectral das frações granulométricas – que no caso da Volta Grande, os espectros entre padrões argilosos e siltosos foram diferentes, distinguindo-se entre si – é consoante ao dos resultados de laboratório.

O comportamento espectral das amostras de solo exposto coletadas sobre as imagens do Sentinel-2, mas sem amostragem de campo, total de 117 (Figura 9), apresentou as mesmas feições das assinaturas das amostras granulométricas em campo. Comportamento semelhante das respostas espectrais foi encontrado por Poppiel (2016) em amostras de solo exposto sobre imagens do LANDSAT-TM5, no Distrito Federal, em área de ocorrência de Latossolo Vermelho. A semelhança ocorreu, inclusive quanto à máxima reflectância (0,4).

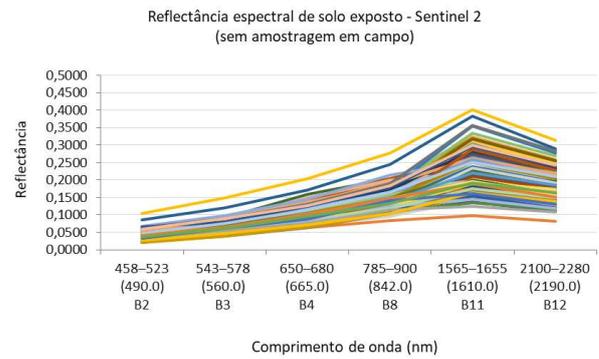


Figura 9. Reflectâncias e assinaturas de solo exposto sobre imagens do Sentinel-2, utilizadas como variáveis previstas no modelo estatístico.

Considerando-se as premissas da análise discriminante, os resultados do teste de normalidade multivariada indicaram que a maior parte das variáveis independentes (explicativas) possuem normalidade univariada (Tabela 3), ou seja, a maior parte dessas variáveis segue distribuição normal. Com este resultado, o tipo de função discriminante para a classificação dos dados espectrais em grupos granulométricos é a linear. O teste Shapiro-Wilk mostrou-se mais restritivo sendo que para duas variáveis (B2 e B3) rejeita-se a hipótese de normalidade. Devido à sua sensibilidade ao tamanho da amostra (< 50), parecendo melhor aplicável aos dados deste estudo. Em um trabalho de comparação de métodos de teste de normalidade de dados, Razali e Wah (2011) concluíram, por meio dos resultados, que o teste Shapiro-Wilk apresentou maior poder de verificação da normalidade dos dados.

Tabela 3. Teste de normalidade multivariada

Variável	Testes de normalidade					
	Kolmogorov-smirnov ^a			Shapiro-Wilk		
	Resultado	G1	Sig.	Result.	df	Sig.
B2	0,233	24	0,002	0,677	24	0,000
B3	0,222	24	0,040	0,764	24	0,000
B4	0,132	24	0,200*	0,944	24	0,200
B8	0,109	24	0,200*	0,924	24	0,073
B11	0,136	24	0,200*	0,957	24	0,381
B12	0,189	24	0,026	0,944	24	0,196

a. Lilliefors Significance Correction.; G1: Gaus de liberdade. Sig.: Significância. * Limite inferior da verdadeira significância.

O teste de igualdade de médias indicou que as médias dos grupos são iguais, ao nível de significância de 0,05 não havendo diferença

significativa entre as médias dos grupos capaz de separar as reflectâncias nas classes estabelecidas. Isto pode ser devido à própria natureza dos dados

de reflectância que possuem dados dimensionalmente pequenos, estando próximos entre si numericamente. O teste também indicou

Na análise de colinearidade, ainda na fase da estatística descritiva, os resultados para as bandas ou variáveis B5, B6, B7 e B8A não foram satisfatórios nesta primeira etapa, apresentando alta correlação entre as demais bandas. Trata-se de bandas detalhadas do espectro vermelho, denominadas *red edge*. Suas características físicas e espectrais podem ter apresentado alguma semelhança com as demais bandas, influenciando os resultados nesta etapa. Como não passaram no teste de colinearidade, elas foram excluídas da análise. As variáveis B2, B3, B4, B8, B11 e B12 foram consideradas em um novo teste, entretanto, ainda apresentaram alguma correlação (> 0,9), representada pelas bandas B2 e B3; B11 e B12. Desta forma, optou-se por desconsiderar as variáveis B2 e B12 do modelo preditivo (para evitar as más classificações causadas por redundância de variáveis que forçam seu poder ou peso preditivo) baseando-se, também, nas assinaturas espectrais que mostraram pouca influência destas bandas nas reflectâncias (em ordem crescente de reflectância B2 > B3 > B4 > B8 > B11 > B12).

Como são três grupos, duas funções discriminantes foram obtidas cujos autovalores (*eigenvalues*) indicara que a primeira função discrimina melhor os grupos a uma porcentagem de

que a banda 8 contribui melhor para a separação das classes por estar dentro do nível de significância.

variância de 68,6 (Tabela 4). Desta forma, os coeficientes relativos a esta função foram adotados na modelagem estatística.

Tabela 4. Autovalores (*Eigenvalues*)

Função	Autovalor	Variância (%)	Correlação canônica
1	0,559	68,6	0,599
2	0,255	31,4	0,451

A partir dos coeficientes da função de classificação (Tabela 5) obtidos para a função discriminante linear de Fisher, o modelo estatístico classificatório das granulometrias foi configurado. Este foi representado pelas funções discriminantes (Equações 5, 6 e 7) nas quais classifica-se uma determinada amostra de reflectância espectral de solo conforme o maior valor encontrado.

Tabela 5. Coeficientes da função de classificação linear de Fisher

Variável (bandas)	Coeficientes		
	Argila	Silte	Areia
B3	862,154	1101,865	752,354
B4	649,735	530,359	509,899
B8	186,697	203,582	134,678
B11	75,999	69,011	124,347
(Constante)	-50,350	-61,700	-36,645

$$Z_{argila} = -50,350 + (862,154 * B3) + (649,735 * B4) + (186,697 * B8) + (75,999 * B11) \quad (5)$$

$$Z_{silte} = -61,700 + (1101,865 * B3) + (530,359 * B4) + (203,582 * B8) + (69,011 * B11) \quad (6)$$

$$Z_{areia} = -36,645 + (752,354 * B3) + (509,899 * B4) + (134,678 * B8) + (124,347 * B11) \quad (7)$$

Como resultado final, a Análise Discriminante classificou 87,5% das amostras corretamente (Tabela 6) indicando uma acurácia de

71% pelo coeficiente de concordância de Kappa. Argila, sendo a classe textural de maior ocorrência na área de estudo, obteve acerto de 84,2%.

Tabela 6. Matriz de confusão* entre os resultados observados e preditos e o Valor do Coeficiente de Concordância de Kappa

Cenário	Granulometria	Associação prevista no grupo			Total
		Argila	Silte	Areia	
Contagem original	Argila	16	2	1	19
	Silte	0	2	0	2
	Areia	0	0	3	3
Acerto %	Argila	84,2	10,5	5,3	100,0
	Silte	0,0	100,0	0,0	100,0
	Areia	0,0	0,0	100,0	100,0
Medida de acordo - Kappa		0,714			

*87,5% dos casos originais foram corretamente classificados.

Os dados preditos da classificação foram submetidos a avaliações com amostras de

treinamento (50% e 70%) e de teste (50% e 30%) escolhidas aleatoriamente em um total de 20

treinamentos. Os resultados mostraram média de acerto de 92,67% para as amostras de validação e de 58,64% para as amostras de teste (Tabela 7).

Tabela 7. Resultado dos testes de treinamento

Validação	N. amostras			% casos válidos do total		Resultado (%)*	
	Treinamento	Teste	Total	Treinamento	Teste	Treinamento	Teste
Aleatória 1	17	7	24	70,8	29,2	82,4	57,1
Aleatória 2	17	7	24	70,8	29,2	88,2	71,4
Aleatória 3	15	9	24	62,5	37,5	100,0	44,4
Aleatória 4	17	7	24	70,8	29,2	88,2	71,4
Aleatória 5	15	9	24	62,5	37,5	86,7	66,7
Aleatória 6	12	12	24	50,0	50,0	100,0	50,0
Aleatória 7	16	8	24	66,7	33,3	100,0	50,0
Aleatória 8	14	10	24	58,3	41,7	100,0	60,0
Aleatória 9	17	7	24	70,8	29,2	82,4	57,1
Aleatória 10	15	9	24	62,5	37,5	93,3	55,6
Aleatória 11	16	8	24	66,7	33,3	87,5	75,0
Aleatória 12	16	8	24	66,7	33,3	87,5	100,0
Aleatória 13	15	9	24	62,5	37,5	93,3	44,4
Aleatória 14	16	8	24	66,7	33,3	100,0	62,5
Aleatória 15	17	7	24	70,8	29,2	88,2	71,4
Aleatória 16	12	12	24	50,0	50,0	91,7	41,7
Aleatória 17	12	12	24	50,0	50,0	91,7	25,0
Aleatória 18	13	11	24	54,2	45,8	100,0	63,6
Aleatória 19	13	11	24	54,2	45,8	92,3	45,5
Aleatória 20	14	10	24	58,3	41,7	100,0	60,0
Média	14,95	9,05	24	62,29	37,71	92,67	58,64

*Casos corretamente classificados.

Após a validação do modelo, as 117 amostras espectrais (sem coleta em campo) foram aplicadas nas equações discriminantes de cada classe, sendo que o maior valor resultante foi classificado na classe da função correspondente. A partir das funções classificadoras (Equações 5, 6 e 7), o resultado destas novas amostras de solo exposto inseridas no modelo ($n = 117$), indicou maior classificação para a granulometria argila e menor em silte, ficando coerente com a tendência do comportamento da distribuição textural do solo das amostras de entrada do modelo.

O método de interpolação utilizado – IDW – apresentou como resultado distribuições

proporcionais às classes granulométricas de ocorrência na área de estudo, ou seja, predominância de argila e menor ocorrência de silte (Figura 10) para os horizontes superficiais, seguindo o comportamento natural da região para a predominância dessa fração granulométrica, conforme apontado na etapa da caracterização da área de estudo. A textura areia ficou distribuída em manchas esparsas tanto próximas ao rio Uruguai (associação de dinâmica fluvial) como mais afastadas a esse rio, associadas às porções altas das vertentes (relevo).

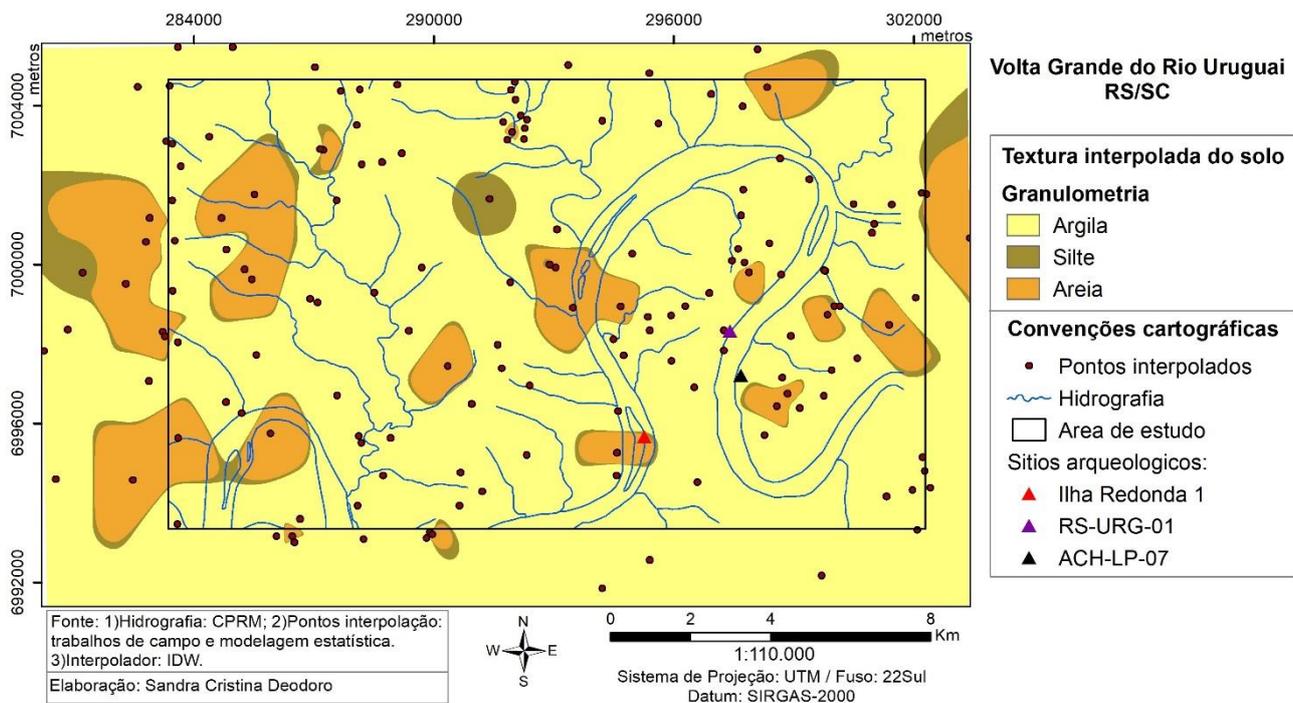


Figura 10 – Distribuição espacial da textura do solo interpolada por IDW.

Conclusões

1. O mapa resultante da modelagem estatística e da interpolação mostrou a predominância de argila.
2. Dos resultados obtidos pela modelagem estatística da Análise Discriminante, o que mais chamou atenção foi a ocorrência das areias em posição diferenciada na paisagem. Este resultado requer outras análises para melhor entendimento dos ambientes de ocorrência, a exemplo da morfoscopia da fração areia e difratogrametria de raio X da fração argila.
3. Os resultados demonstraram que os procedimentos adotados para a modelagem da Análise Discriminante neste estudo – por tamanho de grupo e covariâncias separadas por grupo – foram importantes para alcançar, ao nível de significância de 0,05%, a tendência do comportamento textural do solo da área de estudo, de ambiente basáltico. A Análise Discriminante forneceu subsídios para a escolha das variáveis de entrada do modelo estatístico (variáveis espectrais ou bandas B3, B4, B8 e B11), quanto às faixas espectrais, confirmado, também pelas assinaturas espectrais.

Agradecimentos

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de Mestrado (processo CAPES-DS número 1823396) e ao CNPq pelo apoio financeiro ao Projeto de Pesquisa *Reconstituição paleoambiental quaternária no alto*

vale do rio Uruguai – Oeste de Santa Catarina, edital 01/2016, aos quais este artigo faz parte.

Referências

- Almeida, J. A. de.; Corrêa, J.; Schmitt, C., 2018. Clay mineralogy of basaltic hillsides soils in the western State of Santa Catarina. *Revista Brasileira de Ciência do Solo* [on line] 42. Disponível: <https://doi.org/10.1590/18069657rbc20170086>. Acesso 15 dez. 2020.
- Bationo, A., Kihara, J.; Vanlauwe, B.; Waswa, B.; Kimetu, J., 2007. Soil organic carbon dynamics, functions and management in West African agroecosystems. *Agricultural Systems* [on line] 94. Disponível: <https://doi.org/10.1016/j.agsy.2005.08.011>. Acesso 15 dez. 2020.
- Bousbih, S.; Zribi, M.; Pelletier, C.; Gorrab, A.; Lili-Chabaani, Z.; Baghdadi, N.; Aissa, N.B.; Mougenot, B., 2019. Soil Texture Estimation Using Radar and Optical Data from Sentinel-1 and Sentinel-2. *Remote Sensing* [on line] 11. Disponível: <https://doi.org/10.3390/rs11131520>. Acesso: 15 dez. 2020.
- Brady, N. C; Weil, R. R., 2007. *The nature and properties of soil*, 14 ed. Pearson Prentice Hall, New Jersey.
- Burrough, P.A., Van Gaans, P.F.M., Hootsmans,

- R., 1997. Continuous classification in soil survey: spatial correlation, confusion and boundaries. *Geoderma* [on line] 77. Disponível: [https://doi.org/10.1016/S0016-7061\(97\)00018-9](https://doi.org/10.1016/S0016-7061(97)00018-9). Acesso: 15 dez. 2020.
- Câmara, G.; Medeiros, J. S., 1998. Princípios básicos em geoprocessamento, in: Assad, E. D.; Sano, E. E. (Eds.), *Sistemas de informações geográficas: aplicações na agricultura*. Embrapa SPI-CPAC, Brasília-DF, pp.3-11.
- Cezar, E.; Nanni, M. R.; Chicati, M. L.; Junior, I. G. S.; Costa, A.C.S., 2012. Avaliação e quantificação das frações silte, areia e argila por meio de suas respectivas refletâncias. *Revista Brasileira de Ciência do Solo* [on line] 36. Disponível: <http://dx.doi.org/10.1590/S0100-06832012000400010>. Acesso: 14 mai. 2020.
- Congalton, R. G.; Green, K., 2009. *Assessing the Accuracy of Remotely Sensed Data. Principles and Practices*, 2 ed, CRC Press, Boca Raton.
- Dalmolin, R. S. D. Gonçalves, C. N.; Klamt, E.; Dick, D. P., 2005. Relação entre os constituintes do solo e seu comportamento spectral. *Ciencia Rural* [on line] 35. Disponível em: <http://dx.doi.org/10.1590/S0103-84782005000200042>. Acesso: 15 dez. 2020.
- Demattê, J. A. M.; Alves, M. R.; Terra, F. S.; Bosquilia, R. W. D.; Fongaro, C. T.; BARROS, P. P. S., 2016. Is it possible to classify yopsoil texture using a sensor located 800 km away from the surface? *Revista Brasileira de Ciência do Solo* [on line]. Disponível: <http://dx.doi.org/10.1590/18069657rbcs20150335>. Acesso: 10 set. 2020.
- Dotto, A. C., Demattê, J. A. M., Viscarra Rossel, R. A., Rizzo, R., 2020. Soil environment grouping system based on spectral, climate, and terrain data: a quantitative branch of soil series. *SOIL* [on line] 6. Disponível: <https://doi.org/10.5194/soil-6-163-2020>. Acesso: 10 out. 2020.
- ESA. European Space Agency, 2015. *Sentinel-2 User Handbook*. Paris.
- Fávro, Luiz Paulo; Belfiore, Patrícia; Silva, Fabiana Lopes da; Chan, Betty Lilian., 2009. *Análise de dados – Modelagem multivariada para tomada de decisões*, 1 ed. Elsevier, Rio de Janeiro.
- Florenzano, T. G., 2008. *Geomorfologia: conceitos e tecnologias atuais*, 1 ed. Oficina de Textos, São Paulo.
- Fongaro, C. T., 2015. *Mapeamento granulométrico do solo via imagens de satélite e atributos de relevo*. Dissertação (Mestrado). Piracicaba, Universidade de São Paulo.
- Fongaro, C. T. et al., 2018. Improvement of Clay and Sand Quantification Based on a Novel Approach with a Focus on Multispectral Satellite Images. *Remote Sensing* [on line] 10. Disponível: <https://doi.org/10.3390/rs10101555>. Acesso: 15 dez. 2020.
- Gallo, B. C., 2015. *Imagens multitemporais do Landsat TM como estratégia no apoio ao levantamento pedológico*. Dissertação (Mestrado). Piracicaba, Universidade de São Paulo.
- Gholizadeha, A; Žižala, D.; Aberioon, M.; C, Borůvka, L., 2018. Soil organic carbon and texture retrieving and mapping using proximal, airborne and Sentinel-2 spectral imaging. *Remote Sensing of Environment* [on line] 218. Disponível: <https://doi.org/10.1016/j.rse.2018.09.015>. Acesso: 20 ago. 2019.
- Hair JR, J. F. et al., 2009. *Análise multivariada de dados*, 6 ed. Bookman, Porto Alegre.
- Hassink, J., 1997. The capacity of soils to preserve organic C and N by their association with clay and silt particles. *Plant Soil* [on line] 191. Disponível: <https://doi.org/10.1023/A:1004213929699>. Acesso: 10 set. 2020.
- IBGE. Instituto Brasileiro de Geografia e Estatística, 2018. Folha SG.22 Curitiba, parte da folha SG.21 Asunción e folha SG.23 Iguape: geologia, geomorfologia, pedologia, vegetação, uso potencial da terra. IBGE: Rio de Janeiro. Disponível: <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101617>. Acesso: em 06 dez. 2020.
- Jakob, A. A. E.; Young, A. F., 2006. O uso de métodos de interpolação espacial de dados nas analyses sociodemográficas. ABEP, Caxambu. Disponível: <http://www.abep.org.br/publicacoes/index.php/anais/article/view/1530/1494>. Acesso: 15 dez. 2020.
- Jensen, J. R., 2005. *Introductory Digital Image Processing: a remoting sensing perspective*, 3 ed. Prentice Hall. California.
- Khattree, R. e Naik, D.N., 2000. *Multivariate data reduction and discrimination with SAS software*. SAS Institute Inc. Cary, NC, USA

- Kovačević, M.; Bajat, B.; Gajić, B., 2010. Soil type classification and estimation of soil properties using support vector machines. *Geoderma* [on line] 154. Disponível: <https://doi.org/10.1016/j.geoderma.2009.11.005>. Acesso: 15 dez. 2020.
- Kravchenko, A.N.; Bollero, G.A.; Omonode, R.A.; Bullock, D.G., 2002. Quantitative mapping of soil drainage classes using topographical data and soil electrical conductivity. *Soil Science Society of America Journal* [on line] 66. Disponível: <https://doi.org/10.2136/sssaj2002.2350>. Acesso: 10 set. 2020.
- Mayr, T.R., Palmer, R.C.; Cooke, H. J., 2008. Digital soil mapping using legacy data in the Eden valley, UK, in: Ahartemink, A.E.; McBratney, A. B.; Mendonça Santos, M. D. L. (eds). *Digital soil mapping with limited data*. Springer, London. pp. 291–301.
- McBratney, A.B., Odeh, I.O.A.; Bishop, T. F. A.; Dunbar, M. S.; Shatar, T.M., 2000. An overview of pedometric techniques for use in soil survey. *Geoderma* [on line] 97. Disponível: [doi:10.1016/S0016-7061\(00\)00043-4](https://doi.org/10.1016/S0016-7061(00)00043-4). Acesso: 20 ago. 2019.
- McBratney, A.B.; Mendonça Santos, M.L.; MINASNY, B., 2003. On digital soil mapping. *Geoderma* [on line] 117. Disponível: [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4). Acesso: 20 ago. 2019.
- Meneses, P. R.; Almeida, T.; Baptista, G. M. M. (orgs.), 2019. *Reflectância dos materiais terrestres – análise e interpretação*, 1 ed. Oficina de textos.
- Nanni, M.R., Demattê, J.A.M., Fiorio, P.R., 2004. Análise discriminante dos solos por meio da resposta espectral no nível terrestre. *Pesquisa Agropecuária Brasileira* 39, 995-1006.
- Odeh, I.O.A., McBratney, A.B., 2000. Using AVHRR images for spatial prediction of clay content in the lower Namoi valley of eastern Australia. *Geoderma* [on line] 97. Disponível: [doi:10.1016/S0016-7061\(00\)00041-0](https://doi.org/10.1016/S0016-7061(00)00041-0). Acesso: 12 set. 2019.
- Poppiel, R. R., 2016. Mapeamento pedológico por meio de série histórica Landsat-5 TM e biblioteca espectral na bacia do Rio Jardim. Dissertação (Mestrado). Brasília-DF, Universidade de Brasília.
- Razali, N. M.; Wah, Y. B., 2011. Power comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling Tests. *Journal of Statistical Modeling and Analytics* [on line] 2. Disponível: http://www.de.ufpb.br/~ulisses/disciplinas/normality_tests_comparison.pdf. Acesso: 7 dez. 2020.
- Ruiz, Hugo A., 2005. Incremento da exatidão da análise granulométrica do solo por meio da coleta da suspensão (silte + argila). *Revista Brasileira de Ciência do Solo*. Nota técnica. 29, 297-300.
- Scull, P., Franklin, J., Chadwick, O.A., McArthur, D., 2003. Predictive soil mapping: a review. *Progress in Physical Geography* 27, 171–197.
- Santos, M. C. P., 2018. *Geoarqueologia da área da Volta Grande do Alto Rio Uruguai, Sul do Brasil: morfoestratigrafia, geocronologia e sequência arqueológica da Foz do rio Chapecó*. Tese (Doutorado). Itália. Università Degli Studi de Ferrara.
- Silva, E.B; Giasson, E.; Dotto, A.C; Ten Caten, A.; Demattê, J.A.M.; Bacic, I.L.Z.; Veiga, M., 2019. A regional legacy soil dataset for prediction of sand and clay content with VIS-NIR-SWIR in Southern Brazil. *Revista Brasileira de Ciência do Solo* [on line] 43. Disponível: <https://doi.org/10.1590/18069657rbc20180174>. Acesso: 12 setembro 2019.
- SMITH, M. J. de; GOODCHILD, M. F.; LONGLEY, A., 2018. *Geospatial Analysis – A Comprehensive Guide to Principles Techniques and Software Tools*. 6th edition, Disponível: https://www.spatialanalysisonline.com/HTML/index.html?surface_and_field_analysis.htm. Acesso: 06 dez. 2020.
- Teixeira, P.C.; Donagemma, G.K.; Fontana, A.; Teixeira, W.G. (eds.), 2017. *Manual de Métodos de Análise de Solo*, 3 ed. EMBRAPA Disponível: <https://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1085209>. Acesso: 03 ago. 2020.
- Tobler, W. R. 1970. A Computer Movie Simulating Urban Growth in the Detroit Region. *Economic Geography*. Commission on Quantitative Methods, 46, 234–240. DOI:10.2307/143141.