

Uso da espectroscopia de reflectância do solo na estimativa da textura para fins de seguro agrícola

Elisângela Benedet da Silva¹, Cristina Pandolfo¹, Gabriel Berenhauer Leite¹ e Élvio Giasson²

Resumo – O Zoneamento Agrícola de Risco Climático é um instrumento importante para a gestão de riscos que utiliza parâmetros do solo para determinar o risco climático associado ao cultivo de determinadas culturas. Este estudo teve como objetivo avaliar a eficácia da espectroscopia de reflectância do solo associada a um modelo de *machine learning* na predição dos teores de argila e areia do solo utilizados na classificação do solo para fins de seguro agrícola. Uma matriz de confusão foi utilizada para a classificação de amostras medidas em laboratório e preditas pelo modelo Cubist. Os resultados mostraram que o Cubist apresentou bom desempenho preditivo para os atributos argila e areia. Na matriz de confusão, a maioria das amostras foi corretamente classificada nos tipos de solo definidos pela IN 02/2008. O estudo demonstra o potencial da espectroscopia combinada com algoritmos de *machine learning* na predição de atributos do solo como técnica complementar na gestão dos riscos agrícolas.

Termos para indexação: Zoneamento Agrícola de Risco Climático; Classes texturais do solo; Água disponível no solo; *Machine learning*.

Use of soil spectral reflectance to estimate texture for agricultural insurance purposes

Abstract – The Agricultural Zoning for Climatic Risk is an important tool for risk management that uses soil parameters to determine the climatic risk associated with cultivating specific crops. This study aimed to evaluate the performance of soil reflectance spectroscopy combined with a machine learning algorithm in predicting soil clay and sand contents for agricultural insurance purposes. A confusion matrix was used to classify samples measured in the laboratory and predicted by the Cubist algorithm. The results showed that Cubist presented good predictive performance for the clay and sand attributes. In the confusion matrix, most samples were correctly classified into the soil types defined by IN 02/2008. The study demonstrates the potential of spectroscopy combined with machine learning algorithms in predicting soil attributes as a complementary technique in agricultural risk management.

Index Terms: Agricultural Zoning for Climatic Risk; Soil textural classes; Soil available water; Machine learning.

Introdução

A agricultura é uma atividade econômica caracterizada por riscos de produção que, além da variação nos preços e no crédito, possui grande vulnerabilidade a eventos adversos de natureza climática ou biológica, que podem gerar perdas significativas na produção dos cultivos agrícolas (OECD-FAO, 2021). Para garantir a produção e reduzir a exposição dos agricultores ao risco, muitos governos utilizam o seguro agrícola como um dos mecanismos mais eficazes de resposta na mediação da relação entre condições meteorológicas extremas e alterações climáticas e os seus impactos econômicos e sociais

(Melser *et al.*, 2024).

No Brasil, o Programa de Garantia da Atividade Agropecuária (Proagro e Proagro Mais) e o Garantia-Safra são programas de apoio governamental que têm como objetivo proteger os agricultores de perdas causadas por eventos extremos de variabilidade climática na produção de alimentos. Entre as safras de 2011-2021, o aumento das perdas agrícolas elevou o número de beneficiários do Proagro, alcançando um total de 110.080 coberturas, com indenizações que somaram 989,45 milhões de reais. A seca foi o principal evento climático responsável por esses prejuízos, representando 86% das coberturas nesse período. Nas safras

seguintes, a seca continuou a ser a principal causa das perdas, com 48% das operações de seguro em 2018-2019, 62% em 2019-2020 e 57% em 2020-2021 (de Carvalho *et al.*, 2020).

O Zoneamento Agrícola de Risco Climático (ZARC) desenvolvido pela Embrapa e adotado pelo Ministério da Agricultura e Pecuária (Mapa) é um dos instrumentos de política agrícola e gestão de riscos na agricultura brasileira. Na metodologia utilizada pelo ZARC os parâmetros do solo utilizados para calcular a capacidade de água disponível (CAD) são a água disponível (AD) e a profundidade efetiva do sistema radicular. A AD é calculada pela diferença entre a capacidade de campo

Recebido em 13/09/2024. Aceito para publicação em 08/11/2024.

Editor de seção: João Frederico Mangrich dos Passos

¹ Eng.-agr. Pesquisadora da Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina - Epagri. Rodovia Admar Gonzaga, 1347, Florianópolis, SC. E-mail: elisangelasilva@epagri.sc.gov.br, cristina@epagri.sc.gov.br, gabriel@epagri.sc.gov.br

² Eng.-agr. Professor da Universidade Federal do Rio Grande do Sul - UFRGS. Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre, RS. E-mail: giasson@ufrgs.br

Doi: <https://doi.org/10.52945/rac.v37i3.1919>

e o ponto de murcha permanente. Até 2021, o ZARC utilizava a Instrução Normativa n. 02/2008 (Brasil, 2008) com apenas três classes de água disponível (AD) para o cálculo da CAD, definidas a partir dos teores de areia total e de argila em três tipos de solos (Tipo 1 teor de argila entre 10% e 15% de argila, Tipo 2 entre 15% e menor do que 35% de argila e Tipo 3 maior ou igual a 35% de argila) e uma profundidade efetiva fixada em 50cm para todas as culturas. Em 2022, a metodologia foi atualizada e entrou em vigor, apenas para a cultura da soja, a IN 01/2022 (Brasil, 2022) que estabelece seis classes de água disponível (AD) no solo (Araújo Filho *et al.*, 2022) definidas por uma função de pedotransferência a partir dos teores de areia total, silte e argila do solo na camada de 0 a 40cm de profundidade. A classificação dos solos em três tipos dada pela IN 02/2008 ainda está vigente, mas será gradualmente substituída pela IN 01/2022, que utiliza seis classes de AD. Ambas coexistirão por um período de transição. A análise granulométrica, com teores de argila, silte e areia, tem alta correlação com a AD (Bortolini e Albuquerque, 2018; Costa *et al.*, 2013), tornando-se essencial para ambas as normativas, sendo ainda mais necessária à medida que a IN 01/2022 substitui a IN 02/2008, já que não há correspondência direta entre os dois sistemas de classificação. Os métodos de referência padrão são utilizados para a determinação da granulometria do solo. Entretanto, esses métodos utilizam reagentes químicos, geram resíduos e consomem recursos financeiros e tempo ao analisar grandes volumes de amostras.

Um método alternativo é o uso da espectroscopia de reflectância difusa que vem sendo aplicado na caracterização e predição de diversas características do solo nos últimos 30 anos com aumento significativo na última década (Demattê *et al.*, 2019a; Thomas *et al.*, 2021; Ahmadi *et al.*, 2021; Demattê *et al.*, 2022). No solo, a resposta espectral na região do visível (VIS), do infravermelho próximo (NIR), do infravermelho de ondas curtas (SWIR)

(350-2500nm) e do infravermelho médio (MIR) (2500-25.000nm) vem sendo usada como padrão espectral para imagens de satélite (Demattê *et al.*, 2018; Mendes *et al.*, 2019), na caracterização e modelagem de predição de atributos físico, químicos e biológicos do solo (Silva *et al.*, 2019; Demattê *et al.*, 2019a; Mendes *et al.*, 2022; Paiva *et al.*, 2022; Demattê *et al.*, 2022; Piccini *et al.*, 2024; Hosseini *et al.*, 2024), impulsionando esforços na criação de bibliotecas espectrais de solos (Demattê *et al.*, 2019a; Baumann *et al.*, 2021; Summerauer *et al.*, 2021 Shepherd *et al.*, 2022). Recentemente desperta atenção de laboratórios em todo o mundo e vem sendo promovida pela Rede Mundial de Laboratórios de Solos (GLOSOLAN) como técnica complementar aos métodos de via úmida (Demattê *et al.*, 2019a; Benedetti e Egmond, 2021; Demattê *et al.*, 2022). A espectroscopia apresenta menor variação nos resultados das análises em comparação aos métodos tradicionais de laboratório, o que indica maior consistência e precisão nas medições (Soriano-Disla *et al.*, 2014; Demattê *et al.*, 2019b; Piccini *et al.*, 2024), aumentando a confiabilidade dos dados e reduzindo a necessidade de repetição das análises. Estudos aplicando espectroscopia de solos são incipientes em Santa Catarina e este é o primeiro trabalho com uso de uma biblioteca espectral regional de solos. Este estudo teve como objetivo avaliar a eficácia da espectroscopia de reflectância do solo associada a um modelo de *machine learning* na predição dos teores de argila e areia do solo utilizados na classificação do solo para fins de seguro agrícola.

Material e métodos

Para o desenvolvimento do estudo foi criada uma biblioteca espectral de solos para avaliar o desempenho da espectroscopia na região do VIS-NIR-SWIR na predição dos teores de argila e areia total através do modelo Cubist. Todas as análises foram realizadas no R (R Core Team, 2021).

Biblioteca Espectral de Solos de SC

Para a criação da biblioteca espectral de solos foi utilizado um banco de 1.533 amostras físicas de solos coletadas em 260 dos 295 municípios do estado de Santa Catarina, SC (Veiga *et al.*, 2012). As curvas espectrais das 1.533 amostras físicas de solos foram obtidas em 2016 utilizando um espectrorradiômetro modelo *FieldSpec 3* (Analytical Spectral Devices, Boulder, EUA) na faixa de 350-2500nm (VIS-NIR-SWIR) do espectro eletromagnético, seguindo o protocolo da Biblioteca Espectral de Solos do Brasil (Romero *et al.*, 2018).

Para cada amostra, aproximadamente 15cm³ de solo foram colocados em uma placa de Petri e nivelados para garantir uma superfície plana para leitura do espectro. O sensor capturou a luz através de um cabo de fibra óptica conectado ao sensor posicionado verticalmente a 8cm da amostra, onde foi medida a luz refletida em uma área de aproximadamente 2cm² no centro da amostra. Como padrão de referência, uma placa Spectralon® branca foi utilizada antes da digitalização e a cada 20 leituras do sensor para calibração radiométrica.

Modelagem por machine learning

O conjunto de dados foi dividido aleatoriamente em um conjunto de treinamento [1.150 amostras ~75%] e um de validação independente [383 amostras ~25%]. Foram aplicadas análises estatísticas descritivas para resumir os dois conjuntos de dados (Tabela S1). O teste de Levene seguido do teste t foi utilizado para verificar a suposição de que as variâncias eram iguais entre os valores de argila e areia total nos grupos de treinamento e validação com nível de significância de 5% e para determinar a existência de diferença estatisticamente significativa entre as médias dos dois grupos não relacionados. O pré-processamento utilizado para correção das curvas espectrais foi o de *multiplicative scatter correction* (MSC) (Silva *et al.*, 2019).

O modelo Cubist foi utilizado para predição dos teores de argila e areia total a partir das curvas espectrais das amostras de solos. A variável resposta foi o teor de argila (%) ou de areia total (%) e as variáveis preditoras foram as 2100 bandas espectrais (350nm a 2500nm). O Cubist é um modelo baseado em uma árvore de decisão que constrói regressão linear multivariada nas folhas terminais da árvore (Holmes; Hall; Prank, 1999), em vez de usar valores discretos em cada folha de uma árvore de decisão. A acurácia do modelo foi avaliada comparando os teores estimados pelo modelo e os teores de referência medidos no laboratório pelo coeficiente de determinação (R^2) e raiz do erro quadrático médio de predição (RMSE).

Neste trabalho, foram apresentadas as estatísticas dos dados de treinamento e validação (Tabela S1), mas os resultados discutidos priorizaram apenas os dados do conjunto de validação. Isso porque esses dados indicam a capacidade do modelo de generalizar para amostras não incluídas no treinamento, ajudando a identificar problemas de *overfitting* e a otimizar os hiperparâmetros, garantindo um melhor desempenho em dados não vistos.

Matriz de confusão

Uma matriz de confusão foi utilizada para descrever a coocorrência dos tipos de solos, utilizando o cálculo da concordância (A) e da concordância global (OA). A IN 02/2008 considera três tipos de solos que variam em função da textura, como segue: Tipo 1 – teor de argila variando de 10% a 15% ou superior a 15% quando areia total menos argila for maior ou igual a 50% (tipo de solo com restrições para apoio financeiro em regiões agrícolas com mais de 20% de risco de seca); Tipo 2 - teor de argila variando de 15% a menos de 35% com areia total menos argila menor que 50% (tipo de solo sem restrições de apoio financeiro); Tipo 3 - teor de argila igual ou superior a 35% (sem restrições de apoio financeiro). Na IN 02/2008, às classes de AD são predefinidas com

base no tipo de solo: tipo 1 ($AD=0,7\text{mm cm}^{-1}$), tipo 2 ($AD=1,1\text{mm cm}^{-1}$) e tipo 3 ($AD=1,5\text{mm cm}^{-1}$). Neste estudo foi considerado um quarto tipo de solo para incluir as amostras de solos com teores de argila menores de 10%: Tipo 0 - teor de argila inferior a 10%. Este tipo de solo é considerado inapto para apoio financeiro pelo Mapa.

Para classificar as amostras na nova metodologia utilizada pelo Mapa (Teixeira *et al.*, 2021), foi aplicada a FTP descrita na IN 01/2022, com os teores medidos e preditos de argila e areia total do conjunto de validação obtidos pelo Cubist. Para maiores informações sobre a FTP utilizada, consultar Teixeira *et al.* (2021). Os teores de argila e areia total medidos e preditos pelo modelo Cubist foram classificados de acordo com os tipos definidos pelas IN de 2008.

Resultados e discussão

Atributos do solo

As 1.533 amostras de solos apresentaram teores de argila variando de 0,0 a 77,0%, com valor médio de 38,25%, teores de areia total variando entre 1,0 e 99,0%, com valor médio de 28,85%, indicando grande variabilidade da distribuição do tamanho das partículas (Tabela S1). As frações texturais apresentaram distribuição próxima da normal, conforme indicado por seu valor médio com assimetria fraca e positiva (Tabela S1). O teor de areia total apresentou os maiores coeficientes de variação e assimetria,

indicando alta dispersão em relação à média.

Caracterização das curvas espectrais

Foi observada grande variação nas características das curvas espectrais das 1.533 amostras de solos. As variações de intensidade de reflectância, forma e características de absorção (profundidade e amplitude) das curvas espectrais das amostras refletem a alta variabilidade encontrada em termos de material de origem e classes texturais dos solos em SC. O aumento do teor de areia total nas amostras dos solos dos tipos 0 e 1 (Figura 1) aumentou a intensidade de reflectância do solo em toda a faixa do VIS-NIR-SWIR, enquanto as amostras com maiores teores de argila tiveram menor intensidade de reflectância na mesma faixa espectral. Em média, os teores medidos de areia total foram de 80%, 60%, 37% e 17% nos tipos de solos 0, 1, 2 e 3, respectivamente. Além disso, pode-se observar uma alteração angular, aspecto ascendente (Figura 1), nas curvas espectrais do tipo de solo 3 para o tipo de solo 0 devido à influência do quartzo na faixa SWIR (de 1.500 a 2.500nm), em concordância com observações de Demattê *et al.* (2019) em solos do bioma Mata Atlântica. O aspecto ascendente mostra um aumento na intensidade e na forma das curvas espectrais no SWIR à medida que a amostra contém maiores teores de areia total. Por outro lado, amostras com grandes teores de argila (solo do tipo 3) na faixa do VIS-NIR-

Tabela 1. Análise estatística descritiva dos teores de argila e areia medidos pelo método de referência e preditos pelo modelo Cubist, no conjunto de validação (383 amostras).

Table 1. Descriptive statistical analysis of clay and sand contents measured by the reference method and predicted by the Cubist model in the validation set (383 samples)

	Método laboratório (%)		Modelo Cubist (%)	
	Argila	Areia Total	Argila	Areia Total
Mínimo	0,00	2,00	1,00	4,00
Mediana	35,00	26,00	35,80	26,50
Média	37,50	29,80	37,80	29,00
Máximo	77,00	97,00	70,60	92,00
Desvio padrão	17,50	20,40	15,08	15,80
Coefficiente de variação	46,80	68,00	40,00	54,00

*Os teores de silte foram calculados por diferença entre os teores de argila e areia.

SWIR apresentaram menor refletância devido à influência dos óxidos de ferro e minerais opacos que absorvem energia nesta faixa (Lacerda *et al.*, 2016) (Figura 1). De acordo com Stevens *et al.* (2013), variações no teor de argila geram grandes diferenças na forma da curva espectral, sendo que com teores de argila mais baixos ocorre aumento da profundidade das feições de absorção relacionadas ao grupo OH e a ligação metal-OH na rede cristalina mineral e o íon OH e a molécula de água (H₂O). Solos argilosos exibem curvas espectrais mais planas em comparação com os solos arenosos, variando de forma semelhante à medida que a intensidade de reflectância aumenta (Demattê *et al.*, 2018). Uma série lógica de reflectância que aumenta do tipo 3 < 2 < 1 < 0 (Figura 1) mostrou uma estreita relação entre características espectrais de refletância do solo e os teores de areia total e argila das amostras de solos coletadas, permitindo a separação em classes texturais distintas, conforme observado em estudos anteriores de Lacerda *et al.* (2016); Dotto *et al.* (2016) e Silva *et al.* (2019).

Performance do modelo Cubist na predição dos teores de argila

O teste de Levene indicou igualdade de variância (p-valor = 0,18) e o teste "t" de Student demonstrou que não houve diferença significativa (p-valor = 0,44), no nível de significância $\alpha = 0,05$, para os teores de argila e a areia total na comparação dos conjuntos de treinamento e validação (Tabela S1). Somente os resultados da predição do conjunto de validação foram apresentados neste trabalho (Tabela 1).

Os resultados do conjunto de validação mostraram bom desempenho preditivo ($R^2=0,81$; $RMSE=7,4\%$; $RPIQ=3,62$ e $R^2=0,73$; $RMSE=10,46\%$; $RPIQ=2,64$) para os teores de argila e areia total, respectivamente (Figura S1). Os trabalhos publicados por, Cezar *et al.* (2019), Jaconi *et al.* (2019) e Ahmadi *et al.* (2021) apresentaram resultados semelhantes na predição de atributos do solo a partir de dados espectrais. Os resultados estão de acordo com os reportados por Zhang *et al.* (2023), que compararam o uso dos algoritmos de regressão por

mínimos quadrados parciais (PLSR), Cubist e Floresta Aleatória (RF) na predição de sete atributos do solo, entre eles, argila, silte e areia a partir de uma biblioteca espectral na região do VIS-NIR-SWIR com 1.430 amostras de solos regionais da China. O Cubist teve melhor performance em relação aos demais algoritmos para a maioria dos atributos do solo com $R^2=0,81$; $RMSE=6,5\%$, $R^2=0,61$; $RMSE=11,8\%$ e $R^2=0,54$; $RMSE=9,5\%$ para argila, areia e silte, respectivamente. Viscarra Rossel e Webster (2012) usaram o Cubist na predição de 24 atributos do solo, incluindo argila, silte e areia total, com um conjunto nacional de dados de solo da Austrália com 21.493 amostras. Eles encontraram $RMSE=8,5\%$ e $RMSE=12,0\%$ para os teores de argila e areia total respectivamente, concluindo que o Cubist prevê bem o teor de areia total e argila, funcionando de forma eficaz com conjuntos de dados grandes e diversos.

Entretanto, em uma revisão sistemática e metanálise realizada por Ahmadi *et al.*, (2021) sobre a capacidade da espectroscopia de reflectância na região do VIS-NIR-SWIR na predição de diversos atributos do solo foi constatado que as melhores predições foram alcançadas para os teores de carbono e nitrogênio e as piores para silte a argila. Os autores destacam que a textura do solo é um atributo mais difícil de ser predito por algoritmos de *machine learning* devido a sua natureza composicional, ou seja, a textura é determinada pelas proporções relativas de todo o solo e devem sempre somar 100%. Para os autores, uma alternativa para melhorar a predição da textura do solo seria modelar simultaneamente as três frações aplicando uma transformação de razão logarítmica nos dados, como sugeriram Jaconi *et al.*, (2019). Estudos mostram que, embora a modelagem composicional traga vantagens em termos de precisão, ela requer técnicas estatísticas específicas e pode ser mais complexa do que a abordagem tradicional que modela os teores separadamente (Zhang; Shi e Xu, 2020).

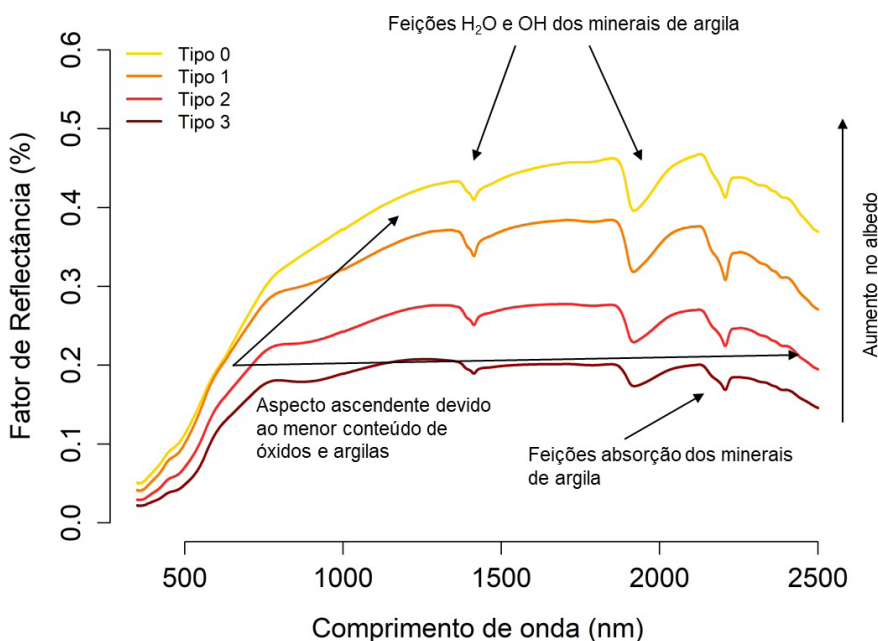


Figura 1. Curvas espectrais de reflectância média do solo das 1533 amostras classificadas segundo a IN 02/2008 do Mapa
 Figure 1. Average soil reflectance spectral curves of the 1533 samples classified according to IN 02/2008 of Mapa

A Figura S1 mostra os gráficos de dispersão dos teores preditos versus teores medidos dos teores de argila e areia total usando o modelo Cubist-MSC para os conjuntos de validação (383 amostras).

Matriz de confusão IN 02/2008

A matriz de confusão determinou o número de amostras corretamente classificadas nos quatro tipos de solos segundo a IN 02/2008 (Tabela 2) ao comparar os tipos de solos com base nos dados de laboratório e tipos de solos classificados pelo Cubist. A maioria das amostras (320/383) foi classificada corretamente nos tipos 0 (73%), 1 (33%), 2 (75%) e 3 (86%) com OA=80% (0.80) (Tabela 2, Figura 2). Resultados semelhantes foram observados por Dotto *et al.* (2016), que utilizaram o VIS-NIR-SWIR para predição dos teores de argila e agruparam o solo nos tipos texturais da IN 02/2008 na bacia hidrográfica do Rio Marombas, SC. Segundo os autores, o melhor desempenho foi encontrado para os solos do tipo 3, seguido pelo tipo 2 e com pior desempenho para o tipo 1.

Na predição com o modelo Cubist, o tipo de solo 0 apresentou boa concordância, com 80,0% para o conjunto de validação (Tabela 3). Este resultado é significativo porque amostras com menos que 10% de argila podem ser excluídas do seguro agrícola, uma vez que culturas estabelecidas em solos com teores de argila inferiores a este percentual não são elegíveis para financiamento agrícola, de acordo com a IN n. 02/2008. Nas predições, o tipo de solo 0 foi confundido com os tipos de solo 1 e 2 em 10% do conjunto de dados (Figura 2, Tabela 3). O erro de alocação do tipo de solo 0 no tipo de solo 2 (10,0%) é um erro importante se considerarmos que solos com essas diferentes texturas são considerados de forma distinta na concessão de seguro agrícola. O tipo de solo 0 possui sérias limitações em termos de retenção de água e menor capacidade de suportar o cultivo sob estresse hídrico, devido

Tabela 2. Matriz de confusão das amostras de solo do conjunto de validação gerada a partir da similaridade entre os tipos de solos: 0, 1, 2 e 3

Table 2. Confusion matrix of the soil samples from the validation set generated based on the similarity between soil types: 0, 1, 2, and 3

Medidos	Preditos				Total
	Conjunto validação (n=383)				
Concordância (%)					
Tipos	0	1	2	3	Total
0	8 (73%)	3	0	0	11
1	4	4 (33%)	4	0	12
2	2	12	114 (75%)	24	152
3	0	0	29	179 (86%)	208
Total	14	19	147	203	383




Figura 2. Gráfico ternário da distribuição granulométrica das 383 amostras medidas em laboratório (esquerda) e preditas pelo Cubist (direita), do conjunto de validação classificadas conforme a IN 02/2008

Figure 2. Ternary plot of the particle size distribution of the 383 samples measured in the laboratory (left) and predicted by the Cubist model (right), from the validation set classified according to IN 02/2008

aos elevados teores de areia (Costa *et al.*, 2013), sendo por isso considerado inapto pela IN 02/2008, enquanto o solo tipo 2 não apresenta restrições. Os principais erros devem-se à superestimação dos tipos de solo 0 e 1. Esses dois tipos de solo representavam uma parte relativamente pequena do conjunto de dados, com apenas 48 e 50 amostras, respectivamente. Essa quantidade limitada de amostras pode ter contribuído para a dificuldade em modelá-los com precisão, resultando na superestimação. Em Santa Catarina, esses solos ocorreram de forma predominante no litoral sul do Estado.

Para o tipo de solo 1, cerca de 77% das amostras foram classificadas incorretamente nos tipos de solo 2 e 0 (Figura 2). Esse erro de classificação é prejudicial, uma vez que o tipo de solo

1 é dominado pela fração areia e o tipo de solo 2 é um solo de textura média. Portanto, o comportamento desses dois solos difere consideravelmente em relação ao manejo e à disponibilidade de água, sendo considerados distintos na concessão do seguro agrícola. O tipo de solo 1 apresenta restrições para apoio financeiro segundo a IN 02/2008 por apresentar menores conteúdos de AD (1,1mm cm⁻¹). A capacidade desse tipo de solo em armazenar água por um determinado período de tempo é menor, aumentando a vulnerabilidade ao risco de perdas dos cultivos por estresse hídrico. A predição do tipo de solo 1 também apresentou acurácia menor que o tipo de solo 0, conforme índice de concordância de 33% (Tabela 2). Esse fraco desempenho não era esperado, uma vez que o teor de argila

é maior para o tipo de solo 1 do que para o tipo de solo 0. Uma possível explicação seria que o erro de predição do modelo (RMSE=7,3%) é maior que o limite da faixa dos teores de argila permitidos para o tipo de solo 1, de 5% ($\geq 10\%$ e $< 15\%$), enquanto que no tipo de solo 0 são inferiores a 10% ($< 10\%$).

Zeng *et al.* (2017) afirmaram que, ao trabalhar com sistemas de classificação, a precisão da alocação do solo depende não apenas da precisão do modelo de predição do atributo alvo, mas dos limites exigidos (intervalo) entre as classes. A arbitragem no estabelecimento de uma pequena faixa do tipo de solo 1 pela regulamentação do Mapa (IN 02/2008) pode prejudicar os enquadramentos dos solos por limitações dos métodos de análise usados em laboratório. Por exemplo, o tipo de solo 1 foi superestimado como tipo de solo 2 em 44% no conjunto de validação (Tabela 2). Para aplicações de seguros, isso pode beneficiar áreas de cultivo com restrições de apoio financeiro, nas quais o comportamento do solo difere consideravelmente do tipo de solo 2 e elevar o risco agrícola. O tipo de solo 2 foi confundido principalmente com o tipo de solo 3 no conjunto de validação (13%), seguida pelo tipo 1 (5%) e tipo 0 (3%). O teor de argila é um atributo que influencia indiretamente os espectros de solo na região do VIS-NIR-SWIR (Vasques *et al.*, 2014) e, portanto, pequenas diferenças no teor de argila provavelmente não foram capturadas pelo modelo Cubist, causando erros de classificação entre os tipos de solo 2 e 3. O tipo de solo 3 foi discriminado dos tipos 0 e 1 em 100% da classificação e foi confundido com o tipo de solo 2 em apenas 10% das predições. Esse resultado está de acordo com Franceschini *et al.* (2013), que obtiveram melhores resultados entre estimativa laboratorial e VIS-NIR-SWIR para classes com altos teores de argila (AO = 69,8%) utilizando um pequeno conjunto de dados de 129 amostras de solo coletadas em diferentes locais da Região Centro-Oeste do Brasil, embora com pouca discriminação para classes com baixos teores de argila.

O sistema de seguro agrícola depende da classificação dos tipos de solo, já que solos com maior teor de argila, como os tipos 2 e 3, têm maior capacidade de retenção de água e, portanto, oferecem menor risco agrícola. Por outro lado, solos mais arenosos, como o tipo 1, são considerados de maior risco e podem não ser elegíveis para financiamento agrícola, especialmente quando o teor de argila é muito baixo, como o solo tipo 0 considerado inapto pela IN 02/2008. Assim, a superestimação do tipo de solo 0 ou a confusão entre os tipos 1 e 2 pode resultar na concessão de seguros para áreas que, na prática, apresentam maior vulnerabilidade agrícola, o que poderia gerar prejuízos tanto para os agricultores quanto para as seguradoras.

Enquadramento na IN 01/2022

O conjunto de validação das amostras de solos com os teores medidos e preditos pelo modelo Cubist, tendo as curvas espectrais como variáveis preditoras, foram classificadas e as legendas apresentadas na escala de teores de AD, segundo a IN 01/2022. A Figura 3 apresenta os gráficos ternários da distribuição da água disponível das 383 amostras do conjunto de validação medidas em laboratório e preditas pelo Cubist (Figuras 3).

Os valores de AD, obtidos com a FTP definida pela IN 01/2022 apresentaram

uma variação de $0,20\text{mm cm}^{-1}$ a $2,30\text{mm cm}^{-1}$, com uma média de $1,197\text{mm cm}^{-1}$ para os teores de argila, silte e areia medidos em laboratório. Para as frações granulométricas preditas pelo Cubist, os valores mínimos e máximos foram de $0,33\text{mm cm}^{-1}$ e $1,81\text{mm cm}^{-1}$, respectivamente, com uma média de $1,20\text{mm cm}^{-1}$. A Agência Nacional de Águas e Saneamento Básico – ANA (Agência Nacional de Águas e Saneamento Básico, 2021) publicou um mapa com os resultados de CAD, calculados pela diferença da água disponível na CC e no PMP, para todo o Brasil com valores calculados para SC de $0,55\text{mm cm}^{-1}$ a $1,57\text{mm cm}^{-1}$. Araújo Filho *et al.* (2022) elaboraram um catálogo de AD de solos do Brasil, sendo que para SC os valores de AD variaram de $0,40\text{mm cm}^{-1}$ a $1,94\text{mm cm}^{-1}$. Os autores observaram que, isoladamente, a textura apresenta maior potencial de explicar as variações da AD nos solos mais arenosos, mas sua importância diminui gradativamente à medida que o teor de argila aumenta e as características taxonômicas nos solos mais argilosos passam a exercer maior influência nos valores de AD do que os grupamentos texturais. Bortolini e Albuquerque (2018) relataram em um estudo com 70 perfis de solos totalizando 296 horizontes pedogenéticos de Santa Catarina que isso pode ser explicado pela relação não linear entre argila e retenção de água

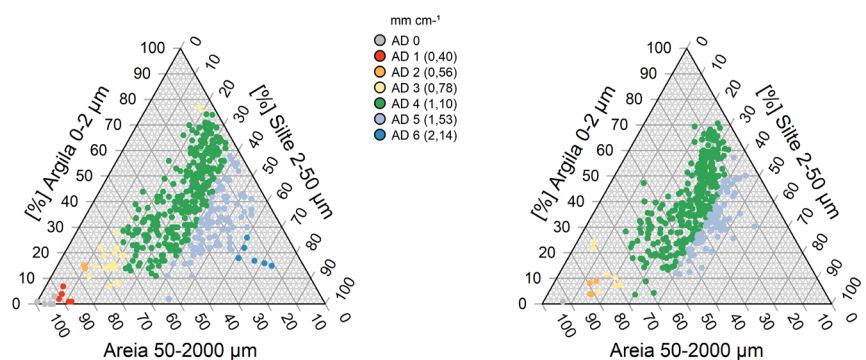


Figura 3. Gráficos ternários da distribuição da água disponível das 383 amostras do conjunto de validação medidas em laboratório (esquerda) e preditas pelo Cubist (direita), conforme IN 01/2022

Figure 3. Ternary plots of the available water distribution of the 383 samples from the validation set measured in the laboratory (left) and predicted by the Cubist model, according to IN 01/2022

e que os solos mais argilosos também apresentam modificações em sua estrutura, o que altera a distribuição do tamanho dos poros e a retenção de água. Os valores de AD obtidos com este estudo se aproximaram dos valores de AD obtidos por Araújo Filho *et al.* (2022). Embora tenha usado conjuntos de dados diferentes, a FPT utilizada foi a mesma.

Na Figura 3, a relação entre AD e a distribuição granulométrica das amostras, definida pela nova metodologia (vigente apenas para a soja), mostra que as classes média-argilosa, argilosa, média-siltosa e siltosa apresentaram os maiores valores de AD. Por outro lado, as classes com menores valores de AD foram média-arenosa, arenosa-média e muito arenosa. Uma clara diferença entre as duas classificações pode ser observada nas Figuras 2 e 3. O tipo de solo 3, conforme definido pela IN 02/2008, apresentou os maiores valores de AD (1,5mm cm⁻³). Isso indica que, à medida que o teor de argila nas amostras de solo aumenta, os valores de AD também se elevam. Os solos com teores de argila acima de 35% apresentaram valores mais elevados de AD; no entanto, ao aplicar a FTP proposta pela IN 01/2022, esse aumento gradual do percentual de argila não resultou em um aumento direto da AD. Solos com valores mais elevados de AD foram observados nas classes média-siltosa e siltosa, como relatado por Teixeira *et al.* (2021) e Araújo Filho *et al.* (2022). Os menores valores de AD foram observados nas classes texturais muito arenosa, arenosa-média e média-arenosa em ambas classificações (Figuras 2 e 3). Na IN 02/2008 o tipo de solo 0 é considerado como inapto (AD < 0,7mm cm⁻³), enquanto que na IN 01/2022, apenas as amostras com valores de AD = 0.34mm cm⁻³ são enquadradas no tipo de solo 0 e consideradas de alto risco/inaptas ao cultivo agrícola. Entretanto, solos arenosos com maiores teores de areia fina e matéria orgânica podem apresentar valores de AD elevados, assim como solos com os mesmos teores de argila, mas com tamanhos de partículas diferentes e mineralogias

distintas, também podem apresentar valores diferentes de AD quando comparados entre si (Costa *et al.*, 2013).

Conclusões

Este estudo comprova a eficácia da análise de solo utilizando espectroscopia de reflectância nas regiões VIS-NIR-SWIR, aliada a modelos de aprendizado de máquina, na predição dos teores de argila e areia total.

A matriz de confusão evidenciou que a maioria das amostras foi corretamente classificada, mas também destacou erros importantes associados às próprias regras da IN 02/2008, o que pode potencialmente impactar o manejo agrícola e a concessão de seguro.

Dada a estreita relação entre a espectroscopia VIS-NIR-SWIR e os métodos laboratoriais tradicionais, esta técnica pode ser recomendada como um método complementar para a quantificação de atributos do solo, especialmente em situações que envolvem um grande volume de amostras.

Referências

AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO—COORDENAÇÃO DE ESTUDOS SETORIAIS (Brasília). **Capacidade de água disponível – CAD ou AWC dos solos do Brasil**. Brasília: ANA, 2021. 1 mapa. Escala 1:250.000. Disponível em: <https://metadados.snirh.gov.br/geonetwork/srv/api/records/28fe4baa-66f3-4f6b-b0d2-890abf5910c4>. Acesso em: 19 agosto 2023.

AHMADI, A.; EMAMI, M.; DACCACHE, A.; HE, L. Soil properties prediction for precision agriculture using visible and near-infrared spectroscopy: A systematic review and meta-analysis. *Agronomy*, v.11, 2021. DOI: <https://doi.org/10.3390/agronomy11030433>.

ARAÚJO FILHO, J.C.; BARROS, A.H.C.; GALVÃO, P.V.M.; TEIXEIRA, W.G.; LIMA, E.P.; VICTORIA, D.C.; ANDRADE JUNIOR, A.S.; XAVIER, J.P.S.; LUMBRERAS, J.F.;

COELHO, M.R.; MANSILLA BACA, J.F.; MONTEIRO, J.E.B.A.; OLIVEIRA, F.C.S.F.; SILVA FILHO, A.D.; BARROS, J.P.F.G. **Avaliação, predição e mapeamento de água disponível em solos do Brasil**. Rio de Janeiro: Embrapa Solos. 2022. (Boletim de pesquisa e desenvolvimento/Embrapa Solos, ISSN 1678-0892; 282). Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1143345/avaliacao-predicao-e-mapeamento-de-agua-disponivel-em-solos-do-brasil>. Acesso em: 19 agosto 2023.

BAUMANN, P.; HELFENSTEIN, A.; GUBLER, A.; KELLER, A.; MEULI, R. G.; WÄCHTER, D.; LEE, J., VISCARRA ROSSEL, R.; SIX, J. Developing the Swiss mid-infrared soil spectral library for local estimation and monitoring. *Soil*, v.7, 2021. DOI: <https://doi.org/10.5194/soil-7-525-2021>.

BENEDETTI, F.; van EGMOND, F. **Global Soil Spectroscopy Assessment. Spectral soil data: needs and capacities**. Rome: FAO, 2021. DOI: <https://doi.org/10.4060/cb6265en>.

BORTOLINI, D.; ALBUQUERQUE, J.A. Estimation of the retention and availability of water in soil of the state of Santa Catarina. *Revista Brasileira de Ciência do Solo*, v.42, e0170250, 2018. DOI: <https://doi.org/10.1590/18069657rbcs20170250>.

BRASIL. **Instrução Normativa nº 2 de 09 de outubro de 2008**. Brasília: Ministério da Agricultura, Pecuária e Abastecimento, [2008]. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/riscos-seguro/programa-nacional-de-zoneamento-agricola-de-risco-climatico/documentos/INn2de09.10.2008.pdf/view>. Acesso em: 10 abril 2016.

BRASIL. **Instrução Normativa nº 1 de 21 de junho de 2022**. Brasília: Ministério da Agricultura, Pecuária e Abastecimento, [2022]. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/riscos-seguro/programa-nacional-de-zoneamento-agricola-de-risco-climatico/>

- documentosrmativan1de21dejunhode-2022site.pdf/view. Acesso em: 10 jul 2022.
- CEZAR, E.; NANNI, M.R.; GUERRERO, C.; SILVA JUNIOR, C.A.; CRUCIOL, L.G.T.; CHICATI, M.L.; SILVA, G.F.C. Organic matter and sand estimates by spectroradiometry: strategies for the development of models with applicability at a local scale. **Geoderma**, v.340, 2019. DOI: <https://doi.org/10.1016/j.geoderma.2019.01.021>.
- COSTA, A.; ALBUQUERQUE, J.A.; COSTA, A.; PÉRTILE, P.; SILVA, F.R. Water retention and availability in soils of the state of Santa Catarina-Brasil: Effect of textural classes, soil classes and lithology. **Revista Brasileira de Ciência do Solo**, v.37, 2013. DOI: <https://doi.org/10.1590/S0100-06832013000600010>.
- DE CARVALHO, A. L.; SANTOS, D. V.; MARENGO, J. A., COUTINHO; S. M. V.; MAIA, S. M. F. Impacts of extreme climate events on Brazilian agricultural production. **Sustentabilidade em Debate**, v.11, 2020. DOI: <https://doi.org/10.18472/SustDeb.v11n3.2020.33814>.
- DEMATTÊ, J. A. M.; FONGARO, C. T.; RIZZO, R.; SAFANELLI, J. L. Geospatial Soil Sensing System (GEOS3): A powerful data mining procedure to retrieve soil spectral reflectance from satellite images. **Remote Sensing of Environment**, v.212, 2018. DOI: <https://doi.org/10.1016/j.rse.2018.04.047>.
- DEMATTÊ, J.A.M.; DOTTO, A.D.; PAIVA, A.F.S., SATO, M.V.; DALMOLIN, R.S.D.; ARAÚJO, M.S.B.; SILVA, E.B.; NANNI, M.R.; TEN CATEN, A.; NORONHA, N.C.; LACERDA, M.P.C.; ARAÚJO FILHO, J.C.; RIZZO, R. BELLINASSO, H.; FRANCELINO, M.R.; SCHAEFEN, C.E.G.R.; VICENTE, L.E.; SANTOS, U.J.; SAMPAIO, E.V.S.B.; MENEZES, R.S.C.; SOUZA, J.J.L.L.; ABRAHÃO, W.A.P.; COELHO, R.M.; GREGO, C.R.; LANI, J.L.; FERNANDES, A.R.; GONÇALVES, D.A.M.; SILVA, S.H.G.; MENEZES, M.D.; CURI, N.; COUTO, E.G.; ANJOS, L.H.C.; CEDDIA, M.B.; PINHEIRO, E.F.M.; GRUNWALD, S.; VASQUES, G.M.; MARQUES JÚNIOR, J.; SILVA, A.J.; BARRETO, M.C.V.; NÓBREGA, G.N.; SILVA, M.Z.; SOUZA, S.F.; VALLADARES, G.S.; VIANA, J.H.M.; TERRA, F.S.; HORÁK-TERRA, I.; FIORIO, P.R.; SILVA, R.C.; FRADE JÚNIOR, E.F.; LIMA, R.H.C.; ALBA, J.M.F.; SOUZA JUNIOR, V.S.; SANTOS BREFIN, M.L.M.; RUIVO, M.L.P.; FERREIRA, T.O.; BRAIT, M.A.; CAETANO, N.R.; BRINGHENTI, I.; MENDES, W.S.; SAFANELLI, J.L.; GUIMARAES, C.C.B.; POPPIEL, R.R.; BARROS E SOUZA, A.; QUESADA, C.A.; COUTO, H.T.Z. The Brazilian Soil Spectral Library (BSSL): A general view, application and challenges. **Geoderma**, v.354, 2019a. DOI: <https://doi.org/10.1016/j.geoderma.2019.05.043>.
- DEMATTÊ, J.A.M.; DOTTO, A.C.; BEDIN, L.G.; SAYÃO, V.M.; BARROS E SOUZA, A. Soil analytical quality control by traditional and spectroscopy techniques: Constructing the future of a hybrid laboratory for low environmental impact. **Geoderma**, v.337, 2019b. DOI: <https://doi.org/10.1016/j.geoderma.2018.09.010>.
- DEMATTÊ, J.A.M.; PAIVA, A.F.S., POPPIEL, R.R.; ROSIN, N.A.; RUIZ, L.F.C.; MELLO, F.A.O.; MINASNY, B.; GRUNWALD, S.; GE, Y.; BEM DOR, E.; GHOLIZADEH, A.; GOMEZ, C.; CHABRILLAT, S.; FRANCO, N.; AYOUBI, S.; FIANTIS, D.; BINEY, J.K.M.; WANG, C.; BELAL, A.; NAIMI, S.; HAFSHEJANI, N.A.; BELLINASSO, H.; MOURA-BUENO, J.M.; SILVERO, N.E.Q. The Brazilian Soil Spectral Service (BraSpecS): A User-Friendly System for Global Soil Spectra Communication. **Remote Sensing**, v.14, 2022. DOI: <https://doi.org/10.3390/rs14030740>.
- DOTTO, A. C.; DALMOLIN, R.S.D.; ten CATEN, A.; MOURA-BUENO, J.M. Potential of spectroradiometry to classify soil clay content. **Revista Brasileira de Ciência do Solo**, v.40, 2016. DOI: <https://doi.org/10.1590/018069657rbcs20151105>.
- FRANCESCHINI, M. H.D.; DEMATTÊ, J.A.M.; SATO, M.V.; VICENTE, L.E.; GREGO, C.R. et al. Abordagens semiquantitativa e quantitativa na avaliação da textura do solo por espectroscopia de reflectância bidirecional no VIS-NIR-SWIR. **Pesquisa Agropecuária Brasileira**, Brasília, v.48, 2013. DOI: <http://dx.doi.org/10.1590/S0100-204X2013001200006>.
- HOLMES, G.; HALL, M.; PRANK, E. Generating rule sets from model trees. In: AUSTRALIAN JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE, 12., 1999, Sydney, **Proceedings**[...] Berlin, 1999.
- HOSSEINI, E.; ZAREI, M.; MOOSAVI, A.A.; GHASEMI-FASAEI, R.; BAGHERNEJAD, M.; MOZAFFARI, H. Feasibility of Vis-NIR spectroscopy approach to predict soil biological attributes in arid land soils. **PLoS ONE**, v.19, e0311122, 2024. DOI: <https://doi.org/10.1371/journal.pone.0311122>.
- JACONI, A.; VOS, C.; DON, A. Soil texture - Near infrared spectroscopy as an easy and precise method to estimate soil texture. **Geoderma**, v.337, 2019. DOI: <https://doi.org/10.1016/j.geoderma.2018.10.038>.
- LACERDA, M.; DEMATTÊ, J.A.M.; SATO, M.V.; FONGARO, C.T.; GALLO, B.C.; SOUZA, A.B. Tropical texture determination by proximal sensing using a regional spectral library and its relationship with soil classification. **Remote Sensing**, v. 8, 2016. DOI: <https://doi.org/10.3390/rs8090701>.
- MELSER, D.; LE, T.; RUTHBAH, U. Climate change and its impact on home insurance uptake in Australia. **Ecological Economics**, v.222, 2024. DOI: <https://doi.org/10.1016/j.ecolecon.2024.108195>.
- MENDES, W.S.; DEMATTÊ, J. A. M.; ROSIN, N. A.; TERRA, F. S.; POPPIEL, R. R.; URBINA-SALAZAR, D. F.; BOECHAT, C. L.; SILVA, E. B.; CURI, N., SILVA, S. H. G.; Uemeson, J.S.; Valladares, G.S. The Brazilian soil Mid-infrared Spectral Library: The Power of the Fundamental Range. **Geoderma**, v.415, 2022. <https://doi.org/10.1016/j.geoderma.2022.115776>.
- MENDES, W.S.; MEDEIROS NETO, L.

- G.; DEMATTÊ, J. A. M.; GALLO, B. C.; RIZZO, R.; SAFANELLI, J. L.; FONGARO, C. T. Is it possible to map subsurface soil attributes by satellite spectral transfer models? **Geoderma**, v.343, 2019. DOI: <https://doi.org/10.1016/j.geoderma.2019.01.025>.
- OECD-FAO. **Agricultural Outlook 2021-2030**. OECD Publishing, Paris, 2021. DOI: <https://doi.org/10.1787/19991142>.
- PAIVA, A. F. S.; POPPIEL, R. R.; ROSIN, N. A.; GRESCHUK, L. T.; ROSAS, J. T. F.; DEMATTÊ, J. A. M. The Brazilian Program of soil analysis via spectroscopy (ProBASE): Combining spectroscopy and wet laboratories to understand new technologies. **Geoderma**, v.421, 2022. DOI: <https://doi.org/10.1016/j.geoderma.2022.115905>.
- PICCINI, C.; METZGER, K.; DEBAENE, G.; STENBERG, B.; GÖTZINGER, S.; BORŮVKA, L.; SANDÉN, T.; BRAGAZZA, L.; LIEBISCH, F. In-field soil spectroscopy in Vis–NIR range for fast and reliable soil analysis: A review. In **European Journal of Soil Science**, v.75, 2024. DOI: <https://doi.org/10.1111/ejss.13481>.
- R CORE TEAM**. R: A language and environment for statistical computing. R version 4.1.1. Viena, Áustria: R Foundation for Statistical Computing, 2021. Disponível em: <<https://www.R-project.org/>>. Acesso em: 10 abril 2023.
- ROMERO, D. J.; BEN-DOR, E.; DEMATTÊ, J.A.M.; BARROS e SOUZA, A.; VICENTE, L.E.; TAVARES, T.R.; MARTELLO, M.; STRABELI, T.F.; BARROS, P.P.S.; FIORIO, P.R.; GALLO, B.C.; SATO, M.V.; EITELWEIN, M.T. Internal soil standard method for the Brazilian soil spectral library: Performance and proximate analysis. **Geoderma**, v.312, 2018. DOI: <https://doi.org/10.1016/j.geoderma.2017.09.014>
- SHEPHERD, K.D.; FERGUSON, R.; HOOVER, D.; VAN EGMOND, F.; SANDERMAN, J.; GE, Y. A global soil spectral calibration library and estimation service. **Soil Security**, v.7, 2022. DOI: <https://doi.org/10.1016/j.soisec.2022.100061>.
- SILVA, E. B.; GIASSON, É.; DOTTO, A. C.; ten CATEN, A.; DEMATTÊ, J. A. M., BACIC, I. L. Z., VEIGA, M. 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**, v.43, 2019. DOI: <https://doi.org/10.1590/18069657rbcs20180174>.
- SORIANO-DISLA, J. M.; JANIK, L. J.; VISCARRA-ROSSEL, R. A.; MACDONALD, L. M.; MCLAUGHLIN, M. J. The performance of visible, near-, and mid-infrared reflectance spectroscopy for prediction of soil physical, chemical, and biological properties. **Applied Spectroscopy Reviews**, v.49, 2014. DOI: <https://doi.org/10.1080/05704928.2013.811081>.
- STEVENS, A.; TÓTH M.N.G.; MONATARELLA, L.; VAN WESEMAEL, B. Prediction of Soil Organic Carbon at the European scale by visible and near infrared reflectance spectroscopy. **PlosOne**, v.19, 2013. DOI: <http://doi.org/10.1371/journal.pone.0066409>.
- SUMMERAUER, L.; BAUMANN, P.; RAMIREZ-LOPEZ, L.; BARTHEL, M.; BAUTERS, M.; BUKOMBE, B.; REICHENBACH, M.; BOECKX, P.; KEARSLEY, E.; VAN OOST, K.; VANLAUWE, B.; CHIRAGAGA, D.; HERI-KAZI, A. B.; MOONEN, P.; SILA, A.; SHEPHERD, K.; BAZIRAKE MUJINYA, B.; VAN RANST, E.; BAERT, G.; SIX, J. The central African soil spectral library: A new soil infrared repository and a geographical prediction analysis. **Soil**, v.7, 2021. DOI: <https://doi.org/10.5194/soil-7-693-2021>
- TEIXEIRA, W.G.; VICTORIA, D.C.; BARROS, A.H.C.; LUMBRERAS, J.F.; ARAÚJO FILHO, J.C.; SILVA, F.A.M.; LIMA, E.P.; BUENO FILHO, J.S.S.; MONTEIRO, J.E.B.A. Predição de água disponível no solo em função da granulometria para uso nas análises de risco no zoneamento agrícola de risco climático. Rio de Janeiro: Embrapa Solos, 2021. (**Boletim de pesquisa e desenvolvimento/Embrapa Solos**, ISSN 1678-0892; 272).
- THOMAS, C. L.; HERNANDEZ-ALLICA, J.; DUNHAM, S. J.; MCGRATH, S. P.; HAEFELE, S. M. A comparison of soil texture measurements using mid-infrared spectroscopy (MIRS) and laser diffraction analysis (LDA) in diverse soils. **Scientific Reports**, v.11, 2021. DOI: <https://doi.org/10.1038/s41598-020-79618-y>
- VASQUES, G.M.; DEMATTÊ, J.A.M.; VISCARRA ROSSEL, R.A.; RAMIREZ-LÓPEZ, L.; TERRA, F.S. Soil classification using visible/near-infrared diffuse reflectance spectra from multiple depths. **Geoderma**, v.223-225, 2014. DOI: <https://doi.org/10.1016/j.geoderma.2014.01.019>.
- VEIGA, M.; SANTOS, O. V.; HAMMES, L. A.; PANDOLFO, C. Distribuição espacial dos teores de argila, silte e areia na camada superficial do solo em Santa Catarina. **Revista Agropecuária Catarinense**, Florianópolis, SC, v.25, n.1, p. 63-68, 2012.
- VISCARRA ROSSEL, R. A.; WEBSTER, R. Predicting soil properties from the Australian soil visible-near infrared spectroscopic database. **European Journal of Soil Science**, v. 63, 2012. DOI: <https://doi.org/10.1111/j.1365-2389.2012.01495.x>.
- ZENG, R.; ROSSITER, D.G.; YANG, F.; LI, D-C.; ZHAO, Y-G.; ZHANG, G-L. How accurately can soil classes be allocated based on spectrally predicted physio-chemical properties. **Geoderma**, v.303, 2017. DOI: <https://doi.org/10.1016/j.geoderma.2017.05.011>.
- ZHANG, M.; SHI, W.; XU, Z. Systematic comparison of machine-learning models in classification and interpolation of soil particle size fractions using diferent transformed data. **Hydrology and Earth System Sciences**, v.24, 2020. DOI: <https://doi.org/10.5194/hess-24-2505-2020>.
- ZHANG, X., XUE, J., XIAO, Y., SHI, Z., CHEN, S. Towards Optimal Variable Selection Methods for Soil Property Prediction Using a Regional Soil Vis-NIR Spectral Library. **Remote Sensing**, v.15, 2023. DOI: <https://doi.org/10.3390/rs15020465>.