



CAMEAU CADOSTIN

**PREDIÇÃO DA TEXTURA DO SOLO COM SENSORES
PROXIMAIS E ATRIBUTOS DE TERRENO COM
DIFERENTES RESOLUÇÕES ESPACIAIS**

LAVRAS-MG

2025

CAMEAU CADOSTIN

**PREDIÇÃO DA TEXTURA DO SOLO COM SENSORES PROXIMAIS E
ATRIBUTOS DE TERRENO COM DIFERENTES RESOLUÇÕES ESPACIAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência do Solo, área de concentração em Fertilidade do Solo e Nutrição de Plantas, para a obtenção do título de Mestre.

Prof. Dr. Sérgio Henrique Godinho Silva
Orientador

LAVRAS-MG

2025

Ficha de identificação da obra elaborada pelo(a) autor(a) através do Sistema de Geração Automática de Ficha Catalográfica da Biblioteca Universitária da UFLA.

Cadostin, Cameau

Predição da textura do solo com sensores proximais e atributos de terreno com diferentes resoluções espaciais / Cameau Cadostin. 2025.

80 p.: il.

Orientador: Sérgio Henrique Godinho Silva

Dissertação (Mestrado Acadêmico) - Universidade Federal de Lavras, 2025.
Bibliografia.

1. textura do solo. 2. modelo digital de terreno. 3. sensoriamento proximal. I. Silva, Sérgio Henrique Godinho. II. Universidade Federal de Lavras. III. Título.

CAMEAU CADOSTIN

**PREDIÇÃO DA TEXTURA DO SOLO COM SENSORES PROXIMAIS E
ATRIBUTOS DE TERRENO COM DIFERENTES RESOLUÇÕES ESPACIAIS**

**PREDICTION OF SOIL TEXTURE WITH PROXIMAL SENSORS AND TERRAIN
ATTRIBUTES AT DIFFERENT SPATIAL RESOLUTIONS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência do Solo, área de concentração em Fertilidade do Solo e Nutrição de Plantas, para a obtenção do título de Mestre.

APROVADA em 17 de fevereiro 2025.

Dr. Bruno Montoani Silva UFLA

Dr. Milson Evaldo Serafim IFMT

Dr. Junior Cesar Avanzi UFLA

Prof. Dr. Sérgio Henrique Godinho Silva

Orientador

LAVRAS-MG

2025

AGRADECIMENTOS

Gostaria de expressar minha gratidão a todos que contribuíram para a elaboração deste trabalho. Em especial, quero agradecer:

Meus pais, que sempre estiveram presentes ao longo de toda a minha trajetória acadêmica;

Ao professor orientador Dr. Sérgio Henrique Godinho Silva, por todo o apoio e orientação. Suas competências, disponibilidade e observações pertinentes foram fundamentais para o sucesso e a realização deste trabalho;

À Coordenação de Aperfeiçoamento de Pessoal do Nível Superior (CAPES), pelo apoio financeiro;

A todos os professores da UFLA;

Agradeço especialmente a Eduane de Pádua e Fernanda Bocoli, por sua ajuda, conselhos e disponibilidade. Sem esquecer o restante da equipe do grupo de pedologia do Departamento de Ciência do Solo;

À Universidade Federal de Lavras, principalmente, ao Departamento de Ciência do Solo, por contribuírem para minha formação acadêmica e profissional;

Por fim, expresso minha gratidão a todos que, de alguma forma, contribuíram para a realização desta dissertação.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO GERAL

A textura do solo é um fator determinante que influencia diversos aspectos do ambiente terrestre, incluindo a fertilidade, a retenção de água e a biodiversidade. Compreender sua distribuição é, portanto, essencial para uma gestão sustentável das terras agrícolas. Com o advento das tecnologias de sensoriamento proximal e remoto, tornou-se possível obter informações detalhadas sobre a textura do solo com maior eficiência. Essas tecnologias permitem analisar as características do solo de forma mais rápida e econômica otimizando os processos de análise. Nesse sentido, inicialmente avaliou-se a contribuição dos dados de sensoriamento proximal e remoto na predição da textura do solo. Para isso, foram coletadas 114 amostras dos horizontes superficial e subsuperficial da Fazenda Muquém da UFLA. Essas amostras foram analisadas pelo método da pipeta para granulometria, complementadas por medições de espectrometria de fluorescência de raios-X portátil e de susceptibilidade magnética. Foram gerados quinze (15) atributos do terreno derivados de Modelos Digitais de Terreno com resolução de 12,5 m, utilizando os softwares QGIS. Os modelos de predição foram construídos utilizando o algoritmo Random Forest, demonstrando que a integração de dados de sensores proximais com informações topográficas melhora significativamente a precisão dos mapas de propriedades do solo. Em segundo lugar, analisou-se o impacto dos atributos do terreno e do material de origem em diferentes resoluções espaciais na predição da textura do solo no campus da UFLA. Modelos Digitais de Terreno derivados de curvas de nível de 1 m a 30 m, assim como dados dos projetos Alos Palsar e SRTM, foram utilizados para gerar 15 atributos do terreno. Os modelos foram treinados com os algoritmos Random Forest e SVM, com base em 232 amostras de solo. A análise revelou que o material de origem foi um fator determinante para a predição da areia, silte e argila, seguido de atributos como o *Analytical Hillshading*, *LS-Factor*, *Channel Network Base Level*, *Multiresolution Index of Ridge Top Flatness* e *Multiresolution Index of Valley Bottom Flatness*. Além disso, os MDT com resolução de 10 m a 20 m produziram os modelos mais precisos, confirmando que resoluções mais altas (1 m, 5 m) não garantem, necessariamente, um melhor desempenho preditivo. Este estudo demonstrou que a combinação de dados de sensoriamento proximal, de MDT e de algoritmos de machine learning constitui uma abordagem eficaz para o mapeamento digital do solo, promovendo uma gestão sustentável dos recursos pedológicos.

Palavras-chave: textura do solo; modelo digital de terreno; sensoriamento proximal; sensoriamento remoto; machine learning; atributos do terreno; material de origem.

ABSTRACT

Soil texture is a key factor influencing various aspects of the terrestrial environment, including fertility, water retention, and biodiversity. Understanding its distribution is therefore essential for sustainable agricultural land management. With the advent of proximal and remote sensing technologies, it has become possible to obtain detailed information about soil texture with greater efficiency. These technologies enable faster and more cost-effective soil analysis, optimizing analytical processes. In this context, the study initially evaluated the contribution of proximal and remote sensing data in predicting soil texture. To achieve this, 114 samples were collected from the surface and subsurface horizons of the Muquéem Farm at UFLA. These samples were analyzed using the pipette method for granulometry, complemented by measurements from portable X-ray fluorescence spectrometry and magnetic susceptibility. Fifteen (15) terrain attributes were derived from Digital Terrain Models with a resolution of 12.5 m, using QGIS software. Prediction models were built using the Random Forest algorithm, demonstrating that integrating proximal sensor data with topographic information significantly improves the accuracy of soil property maps. Secondly, the study analyzed the impact of terrain attributes and parent material at different spatial resolutions on soil texture prediction at the UFLA campus. DTMs derived from contour lines at resolutions ranging from 1 m to 30 m, as well as data from the Alos Palsar and SRTM projects, were used to generate 15 terrain attributes. The models were trained using the Random Forest and SVM algorithms based on 232 soil samples. The analysis revealed that parent material was a determining factor in predicting sand, silt, and clay, followed by attributes such as Analytical Hillshading, LS-Factor, Channel Network Base Level, Multiresolution Index of Ridge Top Flatness, and Multiresolution Index of Valley Bottom Flatness. Additionally, DTMs with resolutions between 10 m and 20 m produced the most accurate models, confirming that higher resolutions (1m, 5m) do not necessarily guarantee better predictive performance. This study demonstrated that the combination of proximal sensing data, DTMs, and machine learning algorithms constitutes an effective approach for digital soil mapping, promoting sustainable management of soil resources.

Keywords: soil texture; digital terrain model; proximal sensing; remote sensing; machine learning; terrain attributes; parent material.

INDICADORES DE IMPACTO

Esta pesquisa apresenta impactos relevantes nos âmbitos social, tecnológico, econômico no contexto da agricultura de precisão e do manejo sustentável do solo. A partir do uso de sensores como a fluorescência de raios X portátil e a suscetibilidade magnética, aliados a atributos derivados de Modelos Digitais de Terreno, foram desenvolvidos modelos preditivos capazes de estimar com alta precisão os teores de areia, silte e argila no solo. Os impactos se expressam na validação de uma metodologia inovadora, de baixo custo e não destrutiva, que permite um diagnóstico rápido na variabilidade espacial da fração textural do solo. E também possibilitam a redução significativa de gastos com análises laboratoriais tradicionais. O trabalho apresenta caráter extensionista ao promover intercâmbio com agricultores e técnicos rurais, impactando áreas da UFLA e propriedades do sul de Minas, com potencial de replicação em outras regiões tropicais. Este estudo está alinhado com as áreas temáticas de Meio Ambiente (5) e Tecnologia e produção (7) conforme a Política Nacional de Extensão Universitária. A pesquisa também contribui diretamente para os Objetivos de Desenvolvimento Sustentável (ODS) da ONU, especialmente o ODS 2 (Fome Zero e Agricultura Sustentável) e o ODS 9 (Indústria, Inovação e Infraestrutura). Esta pesquisa contribui para o avanço das metodologias rápidas de caracterização dos solos ao propor uma abordagem acessível e reprodutível, aplicável em diversos contextos pedológicos. Os resultados tiveram implicações significativas para a cartografia digital de solos e a otimização das práticas agrícolas.

IMPACT INDICATORS

This research presents significant impacts in the social, technological, and economic spheres within the context of agriculture precision and sustainable soil management. Through the use of sensors such as portable X-ray fluorescence and magnetic susceptibility, combined with attributes derived from Digital Terrain Models, predictive models were developed that can accurately estimate the sand, silt, and clay content in soils. The impacts are reflected in the validation of an innovative, low-cost, and non-destructive methodology that enables rapid diagnosis of the spatial variability of soil texture fractions. It also allows for a significant reduction in expenses associated with traditional laboratory analyses. The study has an extensionist character by promoting exchanges with farmers and rural technicians, impacting areas of UFLA and properties in southern Minas Gerais, with the potential for replication in other tropical regions. This study aligns with the thematic areas of Environment (5) and Technology and Production (7) according to the National University Extension Policy. The research also directly contributes to the United Nations Sustainable Development Goals (SDGs), particularly SDG 2 (Zero Hunger and Sustainable Agriculture) and SDG 9 (Industry, Innovation, and Infrastructure). This study contributes to the advancement of rapid soil characterization methodologies by proposing an accessible and reproducible approach, applicable across various pedological contexts. The results have significant implications for digital soil mapping and the optimization of agricultural practices.

SUMÁRIO

	PRIMEIRA PARTE	11
1	INTRODUÇÃO GERAL	12
2	REFERENCIAL TEÓRICO	14
2.1	Análise granulométrica do solo	14
2.1.1	As frações do solo.....	15
2.1.2	Métodos Granulométricos.....	16
2.2	Mapeamento Digital de Solos	17
2.3	Espectrometria portátil de fluorescência de raios-X.....	18
2.4	Atributos do terreno originados do MDT	18
2.5	Modelos numéricos para predição de atributos de solos	23
2.5.1	Random Forest (RF).....	23
2.5.2	Support Vector Machine (SVM)	24
	REFERÊNCIAS.....	25
	SEGUNDA PARTE - ARTIGOS	32
	ARTIGO 1 – Dados de sensoriamento proximal e remoto para a predição de	
	textura do solo	33
1	INTRODUÇÃO.....	34
2	MATERIAIS E MÉTODOS	35
2.1	Área do estudo.....	35
2.2	Descrição mineralógica da fazenda Muquem	36
2.3	Amostragem de Solo e Análises laboratoriais	37
2.4	Dados de sensor remoto.....	38
2.5	Modelagem e validação da predição da textura.....	38
2.6	Importância das Variáveis e mapeamento do solo	39
2.7	Ajuste dos modelos de equações da textura do Solo.....	39
3	RESULTADOS E DISCUSSÃO.....	40
3.1	Textura do solo.....	40
3.2	Variações texturais na área de estudo	41
3.3	Teores químicos totais por fluorescência de raios-X portátil	42
3.4	Susceptibilidade magnética.....	43
3.5	Predição da textura do solo.....	44
3.6	Importância das variáveis preditoras para os melhores modelos	46

3.7	Mapas de textura do solo	48
3.8	Aplicabilidade do modelo gerado por Silva <i>et al.</i> (2020)	49
4	CONCLUSÃO	51
	REFERÊNCIAS	53
	ARTIGO 2 – Análise de atributos do terreno e material de origem em diferentes resoluções espaciais para predição da textura do solo	57
1	INTRODUÇÃO	58
2	MATÉRIAS E MÉTODO	59
2.1	Localização e caracterização da área de estudo	59
2.2	Amostragem de solo e análises laboratoriais	60
2.3	Criação de MDT	61
2.4	Geração de atributos do terreno (AT)	61
2.5	Modelagem e predição da textura do solo	62
2.5.1	Random Forest	62
2.5.2	Support Vector Machine	63
2.6	Validação de predições	63
3	RESULTADOS ET DISCUSSÃO	64
3.1	Estatística descritiva da fração textural	64
3.2	Análise de desempenho conforme das resoluções (Random Forest)	65
3.3	Análise de desempenho conforme das resoluções (SVM)	66
3.4	Resolução optimal global (10-20 m)	68
3.5	Importância de variáveis das predições	69
3.6	Influência dos atributos do terreno na fração textural do solo	72
4	CONCLUSÃO	74
	REFERÊNCIAS	76

PRIMEIRA PARTE

1 INTRODUÇÃO GERAL

A textura do solo é um dos atributos mais fundamentais na caracterização dos solos, influenciando diretamente as propriedades físicas, químicas e biológicas que afetam o desenvolvimento das plantas no perfil do solo. A distribuição das frações texturais (areia, silte e argila) está diretamente relacionada aos processos de formação do solo, à mineralogia da fração fina e às condições ambientais predominantes (Schaetzl; Anderson, 2005). Tradicionalmente, a determinação da textura do solo baseia-se em métodos analíticos laboratoriais caros, destrutivos e demorados (Huuskonen, 2018; Hossain *et al.*, 2018; Tan, 2005). Essas limitações restringem a obtenção de dados detalhados sobre a textura do solo que ainda representa um desafio, especialmente em grande escala, devido à complexidade das análises laboratoriais e ao alto custo associado à amostragem intensiva no campo.

Diante dessas limitações, técnicas alternativas emergiram, buscando utilizar uma variedade de abordagens de sensoriamento proximal e remoto nas análises (Triantafilis *et al.*, 2009; Guo *et al.*, 2015). Uma dessas técnicas de sensoriamento proximal, é a espectrometria de fluorescência de raios-X portátil (pXRF) que ganha uma popularidade enorme na análise de solos (Weindorf *et al.*, 2014). Este equipamento permite uma análise rápida, não destrutiva e *in situ* da composição elementar dos solos, oferecendo um grande potencial para a estimativa direta de propriedades físicas do solo.

Vários estudos demonstraram relações entre as propriedades do solo e dados de sensoriamento remoto. Entre esses, dados elementares obtidos pelo pXRF foram usados para a determinação do teor de carbono orgânico (Gomez *et al.*, 2008; Stevens *et al.*, 2010), pH (Sharma *et al.*, 2014), salinidade (Swanhart *et al.*, 2014), capacidade de troca catiônica (Sharma *et al.*, 2015), horizonte do solo (Weindorf *et al.*, 2012a), material de origem (Weindorf *et al.*, 2015), teor de CaCO_3 (Chakraborty *et al.*, 2017) e a textura do solo (Zhu *et al.*, 2011; Demattê *et al.*, 2007; Breunig *et al.*, 2008; Liao *et al.*, 2013). Além disso, os Modelos Digitais de Terreno (MDT), derivados de diferentes resoluções espaciais, também fornecem atributos topográficos que refletem processos de erosão, deposição e intemperismo, essenciais para compreender a distribuição espacial das frações texturais no solo (McBratney *et al.*, 2003).

Entretanto, embora correlações entre sensores proximais e textura do solo tenham sido estabelecidas em estudos anteriores, a variabilidade geoquímica dos solos e as interações complexas entre as variáveis podem afetar a robustez dos modelos preditivos. Para melhorar a precisão das estimativas, uma abordagem integrada que combine dados de pXRF e susceptibilidade magnética com atributos do terreno complementares (como inclinação, curvatura, índice topográfico, sombra e outros) constitui uma estratégia promissora. Esses

parâmetros, que podem ser facilmente medidos em campo e fornecer informações adicionais que refinam as predições.

Além disso, o avanço das técnicas de aprendizado de máquina (machine learning) oferece novas oportunidades para explorar esses conjuntos de dados multidimensionais. Diversos métodos foram utilizados para a predição de propriedades do solo utilizando dados de sensoriamento remoto, como a *multiple linear regression* (Ben-Dor *et al.*, 2002; Nanni; Demattê, 2006), *partial least squares regression* (Stevens *et al.*, 2008; Gomez *et al.*, 2008), métodos geoestatísticos e híbridos (Lark; Bishop, 2007; Lark *et al.*, 2012; Rivero *et al.*, 2007; Eldeiry & Garcia, 2010) e *boosting regression tree model* (Ciampalini *et al.*, 2014). Entre esses, o *Random Forest* se destaca como o mais aplicado em mapeamento digital de solos (Chen *et al.*, 2022). Sendo capaz de lidar com grandes e complexos conjuntos de dados, e tem sido amplamente utilizado na modelagem da textura do solo (Hengl *et al.*, 2018; Nussbaum *et al.*, 2018; Poppiel *et al.*, 2019). Ele é frequentemente empregado em abordagens de mapeamento digital de solos com conjuntos abrangentes de variáveis ao contrário dos modelos de regressão clássicos (Duchesne; Ouimet, 2021; Gebauer *et al.*, 2022). Ele pode também capturar relações não lineares e interações complexas entre múltiplas variáveis, melhorando assim o desempenho preditivo.

Assim, diante desse contexto, a presente pesquisa busca avaliar o potencial de uma abordagem combinando sensores proximais e atributos de terreno com diferentes resoluções espaciais na predição da textura do solo. Para isso, duas áreas com características distintas foram estudadas. A primeira objetiva de avaliar a contribuição dos dados de sensoriamento proximal e remoto para a predição e o mapeamento da textura do solo, utilizando espectrometria de fluorescência de raios-X portátil, susceptibilidade magnética e atributos do terreno. A segunda área de estudo analisou o impacto da resolução espacial na avaliação dos atributos do terreno e explorou sua integração com os dados do material de origem para a predição da textura do solo.

2 REFERENCIAL TEÓRICO

2.1 Análise granulométrica do solo

A distribuição granulométrica é uma característica intrínseca de cada solo, relacionada com sua capacidade de retenção de água e nutrientes, e independe do manejo (Carvalho et al., 1986). Em língua portuguesa, a princípio adotava-se o termo análise mecânica do solo, posteriormente substituído por “análise granulométrica do solo”, que é mais específico e exprime melhor sua finalidade (Medina; Grohmann, 1962). De forma análoga, em língua inglesa, o termo “mechanical analysis”, utilizado em trabalhos antigos (Wiley, 1894; Briggs et al., 1904; Kilmer; Alexander, 1949), foi substituído por “particle size analysis” em tradução literal, “análise do tamanho de partículas”. Antes do desenvolvimento da pedologia como ciência, antigos agricultores já utilizavam termos como solo leve, pesado, médio e barrento para classificar seus solos (Medina; Grohmann, 1962).

Algumas das primeiras metodologias científicas para análise granulométrica surgiram ainda na segunda metade do século XIX, de forma independente em diversos países como Estados Unidos, Alemanha, Itália, França, Bélgica e Rússia e foram descritas por Wiley (1894). O autor descreve as dificuldades enfrentadas por cientistas pioneiros, principalmente com relação à dispersão do solo e quantificação das suas frações, à morosidade nas análises e à falta de padronização. Com relação à quantificação das frações do solo após a dispersão, tentativas de tornar as análises mais rápidas e precisas foram feitas, a exemplo do método da centrífuga, proposto por Briggs *et al.* (1904). Posteriormente, surgiu o método da pipeta, desenvolvido simultaneamente no País de Gales por Robinson (1922) e nos Estados Unidos, por Jennings *et al.* (1922), conforme citado por Tyner (1940). Esse método, que se utiliza de pipetagem de alíquotas de uma suspensão contendo solo previamente disperso para posterior secagem e pesagem, sofreu adaptações ao longo da história, mas seu princípio se mantém igual, sendo atualmente considerado como padrão (Kilmer; Alexander, 1949; Carvalho *et al.*, 1986; Donagemma *et al.*, 2017). Com o objetivo de tornar a análise granulométrica mais prática e rápida, Bouyoucos (1927) desenvolveu, nos Estados Unidos, a metodologia do densímetro, posteriormente modificada pelo mesmo autor. Operacionalmente mais simples e com boa relação com o método padrão, vem sendo utilizada em análises de rotina (Bouyoucos, 1930; Medina; Grohmann, 1962; Day, 1965; Claessen, 1997; Camargo *et al.*, 2009; Donagemma *et al.*, 2017). A diferença entre os métodos da pipeta e do densímetro consiste na forma de quantificação da argila, sendo, no primeiro, por gravimetria de alíquotas e, no segundo, por estimativa com base na densidade da suspensão. Ambos requerem uma boa dispersão do solo. Recentemente, outros métodos vêm sendo propostos, como os que utilizam granulômetros,


equipamentos previamente calibrados que quantificam a distribuição de partículas de solo dispersas em uma suspensão utilizando feixes de laser, podendo fornecer curvas contínuas de distribuição do tamanho de partículas (Blott *et al.*, 2004; Eshel *et al.*, 2004; Silva *et al.*, 2013; Oliveira *et al.*, 2016).

Outro método, considerado não destrutivo, permite a estimativa diretamente em uma amostra de “terra fina”, que é a análise granulométrica por espectroscopia de infravermelho próximo (NIRS) e espectrometria de fluorescência de raios-X portátil (pXRF). Entretanto, essa técnica, não destrutiva e com resultados rápidos, possibilita a quantificação exata das frações do solo, mas sim uma estimativa, com base em curvas de calibração, as quais devem ser obtidas com base em metodologias referência (Chang *et al.*, 2001; Ferraresi *et al.*, 2012; Franceschini *et al.*, 2013; Silva *et al.*, 2017).

2.1.1 As frações do solo

Normalmente a divisão da classificação dos sólidos se dá baseada nas suas dimensões de suas partículas. Existem diversas classificações a serem utilizadas, como mostra a (Figura 1), mas nacionalmente a representação mais utilizada é a Associação Brasileira de Normas Técnicas-ABNT.

Figura 1 – Classificação do solo.



Fonte: ABNT-NBR 6502 (2015).

Dessa forma, no Brasil a Associação Brasileira de Normas Técnicas (ABNT) define da seguinte forma rochas e solo:

- Argila: Solo de granulação fina composto por fragmentos com dimensões inferiores que 0,002 mm, sendo assim apresentam, podendo ser moldado em diferentes formas.

- **Silte:** Por possuir baixa ou nenhuma plasticidade, os solos apresentam uma resistência quando seco o ar baixa. Seus atributos essenciais são correspondentes à parte composta pela fração silte. É constituído por fragmentos com diâmetros entre 0,002 mm e 0,05 mm.

- **Areia:** Não plástico e não coesivo os sólidos são compostos por pequenos fragmentos de rochas e por minerais possuindo o diâmetro entre 0,05 mm e 2,0 mm. Sendo subdividido em areias grossas, finas e médias.

- **Pedregulhos:** São constituídos por solos minerais ou partículas de rocha, com diâmetro assimilado cerca de 2,0 e 60,0 mm. Podem ainda ser fragmentados em pedregulhos finos, médios ou grossos.

2.1.2 Métodos Granulométricos

Método das peneiras: O método das peneiras granulométricas, também conhecido como análise granulométrica por peneiramento, é outro método amplamente empregado para determinar a granulometria do solo. Nesse método, a amostra do solo é passada por um conjunto de peneiras de malhas diferentes, que são empilhadas em ordem crescente de abertura. As partículas maiores ficam retidas nas peneiras com aberturas menores, enquanto as partículas menores passam pelas aberturas. A quantidade de solo retida em cada peneira é pesada e, com base nesses dados, é possível calcular a distribuição granulométrica da amostra. Esse método é mais rápido que o da sedimentação e permite uma análise mais direta das frações granulométricas.

Método da Sedimentação: O método da sedimentação ou decantação é um processo físico que constitui uma operação unitária. Esse tipo de operação tem a finalidade de separar as partículas sólidas ou gotículas de líquidos por meio de um fluido, sendo um líquido ou gás, ou ainda de líquidos imiscíveis com densidades distintas. O mecanismo adotado nessa operação de separação é a transferência de movimento, por meio da gravidade. A técnica de sedimentação se baseia principalmente na Lei de Stokes. Essa lei relaciona a velocidade das partículas, peso específico delas, viscosidade do fluido, diâmetro e a gravidade, sendo representado pela (Equação 1).

$$v_s = \frac{g * (\rho_p - \rho_w) * d^2}{18 * \mu} \quad (1)$$

Fonte: Lei de Stokes (Victor, 1978)

Sendo:

- v_s = velocidade de sedimentação da partícula, m/s;

- g = aceleração da gravidade, 9.81 m/s^2 ;
- ρ_p = densidade da partícula, kg/m^3 ;
- ρ_w = densidade do fluido, kg/m^3 ;
- d = diâmetro da partícula, m ;
- μ = viscosidade dinâmica, $\text{kg/m}\cdot\text{s}$.

Outros métodos também podem ser utilizados, como a análise por difração a laser e a análise por difração a laser com dispersão de pressão. Esses métodos mais modernos permitem uma análise precisa e rápida, mas podem ser mais complexos e requerer equipamentos especializados.

2.2 Mapeamento Digital de Solos

A predição e o Mapeamento Digital de Solos (MDS) tiveram suas bases estabelecidas por Mcbratney et al. (2003) e definidas por Lagacherie e Mcbratney (2006) como “desenvolvimento de sistemas de informação espacial de solos com modelos numéricos para estimar variações espaço-temporais de classes e propriedades do solo, integrando observações, conhecimento e covariáveis ambientais”. O MDS foi desenvolvido na busca de soluções para as incertezas comuns no método tradicional. Neste contexto, novas abordagens de modelagem quantitativa dos solos têm sido propostas, a fim de descrever, classificar e estudar os padrões de variação espacial dos solos na paisagem, objetivando melhorar o conhecimento da variabilidade espacial dos solos, da precisão e da qualidade da informação, através de diversas técnicas quantitativas, chamadas no conjunto, de Pedometria (Webster, 1984). O MDS é realizado através do uso de funções de predição espacial de solos (FPES). Tais funções constituem um método de ajuste das relações quantitativas existentes entre o solo e o ambiente em que o mesmo ocorre. A estrutura das FPES é simplificada por $S = f(s, c, o, r, p, a, n)$ que constitui o modelo scorpan, onde S = classe ou propriedade do solo a ser predita em função de s = informação do solo previamente disponível, c = clima, o = organismos, r = relevo, p = material de origem, a = tempo, e n = posição espacial (McBratney et al., 2003). Esse modelo constitui uma generalização do bastante conhecido modelo clorpt (Jenny, 1941): $S = f(cl, o, r, p, t)$, onde S = solo, é função de cl = clima, o = organismos, r = relevo, p = material de origem e t = tempo).

A abordagem scorpan permite prever as propriedades do solo levando em consideração a variabilidade espacial. Além disso, os produtos gerados por MDS incluem os conceitos de incerteza e acurácia associados às FPES (Samuel-Rosa et al., 2012; Mcbratney et al., 2000).

2.3 Espectrometria portátil de fluorescência de raios-X

Capaz de quantificar uma gama de elementos em segundos (Ribeiro *et al.*, 2017), o princípio operacional dos espectrômetros de fluorescência de raios-X portáteis (pXRF) é similar aos grandes aparatos usados em laboratórios (Weindorf; Bakr; Zhu, 2014). Fótons de raios-X de alta energia incidem sobre o material analisado a fim de excitar os elétrons das camadas internas dos átomos, fazendo-os sair de orbitais mais internos para orbitais mais externos. Estes, por sua vez, ao retornarem aos seus orbitais originais, emitem o excedente energético na forma de fluorescência. Esta é específica de cada elemento, o que permite a identificação e quantificação de diferentes elementos (Weindorf *et al.*, 2012b).

Excelentes resultados utilizando dados do pXRF já foram reportados na ciência do solo, em predições de pH (Sharma *et al.*, 2014; Silva *et al.*, 2017), capacidade de troca de cátions (Sharma *et al.*, 2015), textura (Pierangeli *et al.*, 2022; Zhu; Weindorf; Zhang, 2011), contaminação do solo (Chakraborty *et al.*, 2017), estudos de gênese e caracterização de perfil do solo (Swanhart *et al.*, 2014; Silva *et al.*, 2018; Stockmann *et al.*, 2016; Weindorf *et al.*, 2012a), além de variáveis para o mapeamento de classes de solo (Silva *et al.*, 2016) e outros.

2.4 Atributos do terreno originados do MDT

A identificação de formas de terreno é tradicionalmente realizada por julgamentos em termos qualitativos, baseando-se nas descrições obtidas na fase de interpretação da paisagem. Métodos paramétricos são também possíveis e de grande interesse, pois fornecem uma base mais objetiva e uniforme para a identificação de sistemas terrestres. Algumas das vantagens da utilização da análise digital do terreno sobre o método tradicional de análise, consistem na rapidez e economia para quantificação e classificação de dados do relevo (Mcbratney; Minasny, 2003).

Vários são os trabalhos que relacionam o comportamento dessas variáveis morfométricas com um determinado padrão de ocorrência de atributos dos solos ou de classes de solos na paisagem (Zhu, 2001; Chagas; Carvalho; BHERING, 2011; Souza; Demattê, 2008; Debella-Gilo; Etzelmüller, 2009). O mapeamento do solo realizado de forma automatizada, resultando no que é denominado de Mapeamento Digital de Solos, faz uso de variáveis ambientais derivadas de um MDT e várias outras, como climáticas, ligadas à vegetação, etc. para a predição espacial de classes de solos (SANCHEZ *et al.*, 2009).

De acordo com o exposto, fica evidente o emprego de atributos do terreno, derivados de um MDT, como variáveis ambientais em estratégias de MDS. O uso dessas informações do terreno pode ser acompanhado de outras variáveis que expressem alguma relação com os fatores de formação dos solos.

Slope (Slp)

Slope refere-se à medida da inclinação de uma superfície. Ela indica o ângulo ou o gradiente do terreno, mostrando quanto a elevação muda em uma certa distância. Nos contextos geográficos e geoespaciais, a inclinação é frequentemente expressa em graus ou em porcentagem (Zevenbergen, 1978):

- Graus: Uma inclinação de 0° é completamente plana, enquanto uma inclinação de 90° é uma queda vertical ou um penhasco;
- Porcentagem: Isso é calculado como a diferença de elevação dividida pela distância horizontal, multiplicada por 100. Por exemplo, uma inclinação de 10% significa que para cada 100 unidades de distância horizontal, a elevação muda em 10 unidades. A inclinação é crucial em vários campos, como a engenharia civil, as ciências ambientais e o planejamento do uso da terra. Ela ajuda a determinar a adequação das terras para construção, agricultura e outros usos. Por exemplo, inclinações mais acentuadas podem estar sujeitas à erosão e deslizamentos de terra, enquanto áreas mais planas são mais adequadas para a construção de estruturas.

Nos modelos digitais de terreno (MDT), a inclinação é calculada para cada pixel comparando sua elevação com a dos pixels vizinhos, frequentemente usando o método de Zevenbergen e Thorne (1987), que considerou os pixels circundantes em uma janela de 3x3 para determinar o gradiente.

Valley Depth (VD)

O *Valley Depth* significa a distância vertical entre a elevação no topo da escarpa e a elevação na base da escarpa. A profundidade do vale é calculada como a diferença entre a elevação e um nível de crista interpolado. A interpolação do nível de crista utiliza o algoritmo implementado na ferramenta *Vertical Distance to Channel Network*. Ele realiza as seguintes etapas: definição das células de crista (usando a ordem de Strahler no MNT invertido); a interpolação do nível da crista e a subtração das elevações originais do nível da crista (Conrad *et al.*, 2015).

Curvature

A *Curvature* é a segunda derivada da elevação, o que destaca a convexidade ou a concavidade do terreno. Se uma superfície é convexa (como o cume de uma montanha), ela terá uma curvatura positiva. Se uma superfície é côncava (como uma depressão ou o fundo de um vale), ela terá uma curvatura negativa. A curvatura é baseada no método de Zevenbergen e Thorne (1987).

Profile Curvature (PrC)

O *Profile Curvature* é a curvatura da superfície na direção da inclinação mais acentuada (no plano vertical de uma linha de fluxo). A Curvatura de Perfil afeta a velocidade de fluxo da água que drena a superfície e influencia a erosão e a deposição. Em locais com Curvatura de Perfil convexa (negativa), a erosão prevalecerá, e em locais com curvatura côncava (positiva), ocorrerá a deposição. A curvatura do perfil é a curvatura paralela à direção da inclinação, reportada em 100 m. É baseada no método de Zevenbergen e Thorne (1987).

Plan Curvature (PIC)

O *Plan Curvature* é a curvatura em um plano horizontal. Ela também pode ser descrita como a curvatura da linha de contorno hipotética que passa por uma célula específica. A curvatura do plano é positiva para células com contornos côncavos e negativa para células com contornos convexos (Zevenbergen, 1978). A curvatura do plano pode ser usada para diferenciar entre cristas e vales. A curvatura planiforme é a curvatura perpendicular à direção da inclinação, relatada em 100 m. É baseada no método de Zevenbergen e Thorne (1987).

Multiresolution Index of Valley Bottom Flatness (MRVBF)

O índice *MRVBF* avalia a planitude e a baixa altitude do terreno em várias escalas e resoluções de DEM para identificar fundos de vales, que representam áreas que são planas em múltiplas escalas e permanecem baixas em relação ao relevo circundante em escalas mais grosseiras (Gallant; Dowling, 2003). A planitude é medida pelo inverso da inclinação, e a baixa altitude é medida por uma classificação da elevação em relação a uma área circular ao redor. As duas medidas, ambas escaladas para o intervalo de 0 a 1, são combinadas por multiplicação e podem ser interpretadas como funções de pertinência de conjuntos fuzzy. A identificação de fundos de vales é realizada em uma variedade de escalas para identificar diferentes escalas de fundos de vales. As medidas de planitude (a partir da inclinação) e planitude do fundo do vale (planitude e baixa altitude) são levadas separadamente ao longo da série de escalas. O algoritmo de planitude do fundo do vale multirresolução (*MRVBF*) identifica fundos de vales usando as seguintes suposições: (1) Fundos de vales são baixos e planos em relação ao seu entorno; (2) Fundos de vales ocorrem em uma variedade de escalas; (3) Fundos de vales maiores são mais planos do que menores.

Multiresolution Index of the Ridge Top Flatness (MRRTF)

O *MRRTF* é um índice topográfico projetado para identificar áreas altas e planas em uma variedade de escalas. Ele complementa o índice *MRVBF*, que é projetado para identificar áreas de material depositado em fundos de vales planos. Ao contrário do *MRVBF*, o índice *MRRTF* não tem uma ligação clara com processos de formação de relevo, mas tem se mostrado um complemento útil ao *MRVBF* na classificação de formas de relevo. Valores zero indicam

áreas que são íngremes ou baixas, com valores 1 e maiores indicando progressivamente áreas maiores de terras altas e planas (Gallant, *et al.*, 2013).

LS-Factor (LSF)

O modelo USLE (Equação Universal de Perda de Solo) é o modelo mais frequentemente usado para a estimativa do risco de erosão do solo. Entre as seis camadas de entrada, a combinação do comprimento da encosta e do ângulo da encosta (fator LS) tem a maior influência na perda de solo (Panagos *et al.*, 2015). O fator S mede o efeito da inclinação da encosta e o fator L define o impacto do comprimento da encosta. O fator LS combinado descreve o efeito da topografia na erosão do solo. O Centro Europeu de Dados de Solo (ESDAC) desenvolveu uma nova avaliação pan-europeia de alta resolução da erosão do solo para obter uma melhor compreensão dos padrões espaciais e temporais da erosão do solo na Europa. O cálculo do LS foi realizado usando a equação original proposta por Desmet e Govers (1996) e implementada usando o Sistema para Análises Geocientíficas Automatizadas (SAGA), que incorpora um algoritmo de fluxo múltiplo e contribui para uma estimativa precisa da acumulação de fluxo. O conjunto de dados do fator LS foi calculado usando um Modelo Digital do terreno (MDT) de alta resolução (25 m) para toda a União Europeia, resultando em uma melhor delimitação das áreas em risco de erosão do solo em comparação com conjuntos de dados de resolução mais baixa. Esta abordagem combinada de uso de ferramentas de software GIS com MDT de alta resolução foi aplicada com sucesso em avaliações regionais no passado e agora está sendo aplicada pela primeira vez em escala europeia.

Aspect (Asp)

O *Aspect* é a direção da bússola que a inclinação do terreno enfrenta. Um aspecto de 0 significa que a inclinação está voltada para o norte, 90 para o leste, 180 para o sul e 270 para o oeste. O aspecto descreve a orientação da inclinação mais forte. Geralmente é reportado em graus, onde uma inclinação diretamente para o norte corresponde a um aspecto de 0°, um aspecto oriental é 90°, o sul é 180° e o oeste é 270°. Por padrão, uma inclinação plana recebe um aspecto arbitrário de 180°. Como o aspecto é diretamente baseado na inclinação, ele varia entre o método de Horn (1981) (padrão) e o de Zevenbergen e Thorne (1987).

Analytical Hillshading (AH)

O *Analytical Hillshading* é um mapa de declives sombreado pelo aspecto do declive. O mapa de declives é uma boa ferramenta para visualizar terrenos, mas não distingue entre montanhas e vales. Pode, portanto, ser ligeiramente difícil de interpretar em terrenos montanhosos. As sombras de relevo são, portanto, muitas vezes preferíveis para visualizar MDT. Com um azimute ocidental (um sol simulado vindo do Oeste), todos os declives orientais

são ligeiramente mais escuros. Este modo de sombrear os declives frequentemente gera um mapa muito mais facilmente interpretado do que o mapa de declives (Zevenbergen, 1978).

Channel Network Base Level (CNBL)

O *Channel Network Base Level* é um índice geomorfológico que representa a posição relativa de um ponto da paisagem em relação ao nível de base da rede de drenagem. Ele permite avaliar a influência dos processos de erosão, transporte e deposição de materiais sedimentares na formação e distribuição dos solos (McBratney *et al.*, 2003). O CNBL é particularmente útil na pedologia para explicar a distribuição espacial das frações granulométricas do solo (argila, silte, areia) e a evolução das propriedades pedogenéticas. O nível base determina a elevação mais baixa que a rede de canais pode atingir através dos processos de erosão e ao qual um rio pode erodir seu leito (Leopold *et al.*, 1964).

Channel Network Distance (CND)

Este módulo calcula a distância vertical até o nível de base de uma rede de canais (Conrad *et al.*, 2015). O algoritmo consiste em duas etapas principais: interpolação da elevação do nível de base da rede de canais e subtração desse nível de base das elevações originais.

Total Catchment Area (TCA)

O *Total Catchment Area* refere-se a toda a área terrestre que contribui com o escoamento para um ponto ou local específico. Ela abrange todas as áreas a montante que drenam para um ponto particular, como um medidor de riacho ou uma saída de bacia hidrográfica. Essencialmente, a TCA representa a área de superfície cumulativa que alimenta água em um determinado local (Gruber, 2008). É a soma de todas as áreas individuais de bacias (ou bacias de drenagem) que fluem para um ponto específico. Inclui tanto o canal principal quanto todos os seus afluentes. A TCA é crucial para entender os processos hidrológicos, a previsão de inundações e a gestão dos recursos hídricos.

Topographic Wetness Index (TWI)

O *Topographic Wetness Index* (TWI), também conhecido como *compound topographic index* (CTI), é um índice de umidade em estado estacionário. Ele é comumente usado para quantificar o controle topográfico sobre os processos hidrológicos. O índice é altamente correlacionado com vários atributos do solo, como profundidade do horizonte, porcentagem de silte, teor de matéria orgânica e fósforo (Sorensen, 2006).

O índice topográfico de umidade é definido como: $TWI = \ln(a/\tan b)$, onde a é a área local a montante drenando através de um certo ponto por unidade de comprimento de contorno e $\tan b$ é a inclinação local em radianos. O TWI tem sido usado para estudar os efeitos da escala espacial nos processos hidrológicos.

Relative Slope Position (RSP)

A *Relative Slope Position* é um conceito usado na geomorfometria e hidrologia para descrever a posição de um ponto dentro de uma paisagem em relação aos seus arredores. Refere-se à posição vertical de um local específico (geralmente representado por uma célula de grade ou ponto) dentro de um terreno ou paisagem. Quantifica quão alto ou baixo o ponto está em relação às áreas vizinhas, considerando a topografia local e a inclinação (Boehner, 2006).

2.5 Modelos numéricos para predição de atributos de solos


2.5.1 Random Forest (RF)

Random Forest ou random decision forest é um método de aprendizado em conjunto para tarefas de classificação, regressão e outras, que opera construindo uma multidão de árvores de decisão no momento do treinamento. Para tarefas de classificação, a saída da floresta aleatória é a classe selecionada pela maioria das árvores (Figura 3). Para tarefas de regressão, é retornada a média ou a predição média das árvores individuais (Horn, 1998). As florestas de decisão aleatórias corrigem o hábito das árvores de decisão de se ajustarem excessivamente ao seu conjunto de treinamento (Hastie *et al.*, 2008). O primeiro algoritmo para florestas de decisão aleatórias foi criado em 1995 por Tin Kam Horn (Horn, 1998). Utilizando o método de subespaço aleatório, que, na formulação de Horn, é uma maneira de implementar a abordagem de "discriminação estocástica" para classificação (Kleinberg, 2000). O desenvolvimento inicial da noção de Breiman de florestas aleatórias introduziu a ideia de buscar um subconjunto aleatório das decisões disponíveis ao dividir um nó, no contexto de crescimento de uma única árvore (Breiman, 2001).

O modelo de Random Forest (RF), proposto por Breiman (2001), é uma das técnicas de aprendizado de máquina mais populares para problemas de regressão e classificação. Nos últimos anos, houve muitos avanços metodológicos e teóricos na abordagem do Random Forest. Alguns desenvolvimentos e extensões metodológicas incluem Random Forests específicas para casos, Random Forest multivariadas e aumento de preditores em Random Forest (Ruo *et al.*, 2014), entre outros. Quanto aos desenvolvimentos teóricos, as propriedades estatísticas e assintóticas do Random Forest têm sido intensivamente investigadas. Avanços foram feitos em áreas como consistência, seleção de variáveis (Robin G., 2010) e construção de intervalos de confiança. Assim, a metodologia de RF tenha se mostrado uma abordagem preditiva confiável em muitas áreas de aplicação. A força desse algoritmo reside na sua capacidade de lidar com conjuntos de dados complexos e mitigar o sobreajuste, tornando-o uma ferramenta valiosa para várias tarefas preditivas em aprendizado de máquina. O operador Random Forest produz um grupo de árvores aleatórias, com a categoria criada pelo método de classificação sendo

escolhida a partir das categorias mais frequentes (moda) geradas por essa árvore aleatória (Biau, 2012). No processo de classificação, o indivíduo depende do voto da maioria dos votos na população do cluster de árvores (Kullarni, 2013).

Figura 2 – Árvores de decisão do Random Forest.



Fonte: Random Forest Explain.png (2023).

2.5.2 Support Vector Machine (SVM)

O *Support Vector Machine (SVM)* é um modelo universal de aprendizado de máquina com um conjunto de funções indicadoras lineares utilizado para estimar a função do problema (Vapnik, 2013). Utilizando os dados de treinamento, a SVM mapeia os dados originais em um espaço de características de alta dimensão, onde um hiperplano é construído (Kavzoglu *et al.*, 2014). O hiperplano linear ótimo é utilizado para separar o espaço de entrada original, e a função kernel é empregada para transformar dados em duas classes, consistindo nos parâmetros de não susceptibilidade e susceptibilidade $\{0, 1\}$. A capacidade da SVM depende de funções de kernel adequadas, que incluem kernel polinomial (PL), kernel sigmoide (SIG), função de base radial (RBF) e kernel linear (LN). Segundo Tien Bui *et al.* (2012), o kernel RBF supera outros em previsões relacionadas ao solo.

REFERÊNCIAS

- BEN-DOR, E.; PATKIN, K.; BANIN, A.; KARNIELI, A. **Mapping of several soil properties using DAIS-7915 hyperspectral scanner data — a case study over clayey soil in Israel.** *Int. J. Remote Sens.* 23, 1043–1062, 2002.
- BIAU G. **Analysis of a random forests model.** *J. Mach. Learn. Res.*, vol. 13, no. 1, pp. 1063–1095, 2012.
- BLOTT, S. J.; CROFT, D. J.; PYE, K.; SAYE, S. E.; WILSON, H. E. W. **Particle size analysis by laser diffraction.** *Geological Society*, v. 232, n. 1, p. 63-73, 2004.
- BOEHNER, J. AND SELIGE, T. **Spatial prediction of soil attributes using terrain analysis and climate regionalisation.** In: Boehner, J., McCloy, K.R., Strobl, J. [Ed.]: *SAGA - Analysis and Modelling Applications*, Goettinger Geographische Abhandlungen, Goettingen: 13-28, 2006.
- BOUYOUCOS, G. J. **A comparison of the hydrometer method and the pipette method for making mechanical analysis of soils, with new directions.** *Agronomy journal*, v. 22, n. 8, p. 747-751, 1930.
- BOUYOUCOS, G. J. **The hydrometer as a new method for the mechanical analysis of soils.** *Soil Science*, v. 23, n. 5, p. 343 354, 1927.
- BREIMAN, L. **Random Forests.** *Machine Learning*. 45 (1): 5–32, 2001. doi:10.1023/A:1010933404324.
- BREUNIG, F.M.; GALVÃO, L.S.; FORMAGGIO, A.R. **Detection of sandy soil surfaces using ASTER-derived reflectance, emissivity and elevation data: potential for the identification of land degradation.** *Int. J. Remote Sens.* 29, 1833–1840, 2008.
- BRIGGS, L. J.; MARTIN, F. O., PEARCE, J. R. **The centrifugal method of mechanical soil analysis.** Washington, D.C.: USDA Bureau of soils, 1904.
- CAMARGO, O. A.; MONIZ, A. C.; JORGE, J. A.; VALADARES, J. M. A. S. **Métodos de análise química, mineralógica e física de solos do Instituto Agronômico de Campinas.** Campinas: Instituto Agrônômico, 77 p. (Boletim Técnico, 106), 2009.
- CARVALHO, M. A.; FREIRE, J. C.; CURTI, N.; BAHIA, V. G. **Eficiência de dispersantes na análise textural de materiais de solos com horizonte B latossólico.** *Ciência e Prática*, v. 10, n. 1, p. 78-92, jan/abr. 1986.
- CHAGAS, C.S.; CARVALHO JÚNIOR, W. de. BHERING, S.B. **Integração de dados dos quickbird e atribut: os do terreno no mapeamento digital de solos por redes neurais artificiais.** *Revista Brasileira de Ciência do Solo*, Viçosa, v.35, p. 693-704, 2011.
- CHAKRABORTY, S. *et al.* **Rapid assessment of smelter/mining soil contamination via portable X-ray fluorescence spectrometry and indicator kriging.** *Geoderma*. v. 306, p. 108–119, 2017.
- CHAKRABORTY, S.; WEINDORF, D.C.; WEINDORF, C.A.; DAS, B.S.; LI, B.; DUDA, B.; PENNINGTON, S.; ORTIZ, R. **Semi-quantitative evaluation of secondary carbonates via portable X-ray fluorescence spectrometry.** *Soil Sci. Soc. Am. J.*, 2017. <https://doi.org/10.2136/sssaj2017.01.0019>.

CHANG, C. W.; LAIRD, D. A.; MAUSBACH, M. J.; HURBURGH, C. R. J. **Near-infrared reflectance spectroscopy-principal components regression analyses of soil properties**. Soil Science Society America Journal, v. 65, p. 480-490, 2001.

CHEN, S.; ARROUAYS, D.; LEATITIA MULDER, V.; POGGIO, L.; MINASNY, B.; ROUDIER, P.; LIBOHOVA, Z.; LAGACHERIE, P.; SHI, Z.; HANNAM, J.; MEERSMANS, J.; RICHER-DE-FORGES, A. C.; WALTER, C. **Digital mapping of Global Soil Map soil properties at a broad scale: a review**. Geoderma 409-115567, 2022. <https://doi.org/10.1016/j.geoderma.2021.115567>.

CIAMPALINI, R.; MARTIN, M.P.; SABY, N.P.; DE FORGES, A.C.R.; ARROUAYS, D.; NEHLIG, P.; MARTELET, G. **Soil texture Global Soil Map products for the French region “Centre”**. In: Arrouays, D., McKenzie, N., Hempel, J., de Forges, A.C.R., McBratney, A. (Eds.), GlobalSoilMap: Basis of the Global Spatial Soil Information System. CRC Press, pp. 121–126, 2014.

CLAESSEN, M. E. C. (org.). **Manual de métodos de análise de solo**. 2. ed. rev. e atual. Rio de Janeiro: EMBRAPA-CNPS, 212 p, 1997.

CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; WICHMANN, V. **System for Automated Geoscientific Analyses (SAGA) v. 2.1.4**. Geoscientific Model Development, 8(7), 1991-2007, 2015. <https://doi.org/10.5194/gmd-8-1991-2015>.

CROFT, D. J.; PYE, K.; SAYE, S. E.; WILSON, H. E. W. **Particle size analysis by laser diffraction**. Geological Society, v. 232, n. 1, p. 63-73, 2004.

DEBELLA-GILO, M.; ETZELMÜLLER, B. **Predição espacial de classes de solo usando análise digital de terreno e modelagem de regressão logística multinomial integrada ao GIS**. Examples from Vestfold County, Norway. CATENA, Amsterdã, v. 77, p. 8-18, 2009.

DEMATTÊ, J.A.M.; GALDOS, M.V.; GUIMARÃES, R.V.; GENÚ, A.M.; NANNI, M.R.; ZULLO JR., J. **Quantification of tropical soil attributes from ETM+/LANDSAT-7 data**. Int. J. Remote Sens. 28, 3813–3829, 2007.

DONAGEMMA, G. K.; VIANA, J. H. M.; ALMEIDA, B. G. de; RUIZ, H. A.; KLEIN, V. A.; DECHEN, S. C. F.; FERNANDES, R. B. A. **Análise Granulométrica**. In: TEIXEIRA, P. C.; DONAGEMMA, G. K.; FONTANA, A.; TEIXEIRA, W. G. (ed.). Manual de métodos de análise de solo. 3. ed. rev. e ampl. Brasília, DF: Embrapa, 2017. pt. 1, cap. 10, p. 95-116, 2017.

DUCHESNE, L., OUIMET, R. **Digital mapping of soil texture in ecoforest polygons in Quebec**. Canada PeerJ 9, e11685, 2021. <https://doi.org/10.7717/peerj.11685>.

ELDEIRY, A.A.; GARCIA, L.A. **Comparison of ordinary kriging, regression kriging, and cokriging techniques to estimate soil salinity using LANDSAT images**. J. Irrig. Drain. Eng. 136, 355–364, 2010.

ESHEL, G.; LEVY, G. J.; MINGELGRIN, U.; SINGER, M. J. **Critical evaluation of the use of laser diffraction for particle-size distribution analysis**. Soil Science Society of America Journal, v. 68, n. 3, p. 736-743, 2004.

FERRARESI, T. M.; SILVA, W. T. L.; MARTIN-NETO, L.; SILVEIRA, P. M.; MADARI, B. E. **Espectroscopia de infravermelho na determinação da textura do solo**. Revista Brasileira de Ciência do Solo, v. 36, n. 6, p. 1769-1777, 2012.

FRANCESCHINI, M. H. D.; DEMATTÊ, J. A. M.; SATO, M. V.; VICENTE, L. E. V.; GREGO, C. R. **Abordagens semiquantitativa e quantitativa na avaliação da textura do solo por espectroscopia de refletância bidirecional no VIS-NIR-SWIR**. Pesquisa Agropecuária Brasileira, v. 48, n. 12, p. 1569-1582, 2013.

- GALLANT, J.C., DOWLING, T.I. **A multiresolution index of valley bottom flatness for mapping depositional areas.** *Water Resources Research*, 39/12:1347-1359, 2003.
- GALLANT, JOHN; DOWLING, TREVOR; AUSTIN, JENET. **Multi-resolution Ridge Top Flatness (MrRTF).** v2. CSIRO. Data Collection, 2013. <https://doi.org/10.4225/08/56EA312A5E63B>
- GEBAUER, A., SAKHAEI, A., DON, A., POGGIO, M., LIEß, M. **Topsoil texture regionalization for agricultural soils in Germany: an iterative approach to advance model interpretation.** *Front. Soil Sci.* 1, 2022. <https://doi.org/10.3389/fsoil.2021.770326>.
- GOMEZ, C., VISCARRA ROSSEL, R.A., MCBRATNEY, A.B. **Soil organic prediction by hyperspectral remote sensing and field VIS–NIR spectroscopy: an Australian case study.** *Geoderma* 146, 403–411, 2008.
- GRUBER, S., PECKHAM, S. **Land-Surface Parameters and Objects in Hydrology.** In: Hengl, T. and Reuter, H.I. (Eds.): *Geomorphometry: Concepts, Software, Applications. Developments in Soil Science*, Elsevier, 33:293-308, 2008.
- GUO, Y., HUANG, J., SHI, Z., LI, H. **Mapping Spatial Variability of Soil Salinity in a Coastal Paddy Field Based on Electromagnetic Sensors.** *PLoS ONE* 10 (5), 2015. <https://doi.org/10.1371/journal.pone.0127996>.
- HENGL, T., NUSSBAUM, M., WRIGHT, M.N., HEUVELINK, G.B.M., GRUBER, S. **Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables.** *PeerJ*, 2018. <https://doi.org/10.7717/peerj.5518>.
- HORN, TK. **The Random Subspace Method for Constructing Decision Forests.** *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 20 (8): 832–844, 1998. doi:10.1109/34.709601S2CID206420153.
- HOSSAIN, M.S.; RAHMAN, G.K.M.M.; ALAM, M.S.; RAHMAN, M.M.; SOLAIMAN, A.R.M.; MIA, M.A.B. **Modelling of soil texture and its verification with related soil properties.** *Soil Res.* 56, 421, 2018. <https://doi.org/10.1071/SR17252>.
- HUUSKONEN, J.; OKSANEN, T. **Soil Sampling with Drones and Augmented Reality in Precision Agriculture.** *Comput. Electron. Agric.* 154, 25–35, 2018.
- JENNINGS, D. S.; THOMAS, M. D.; GARDNER, M. **A new method of mechanical analysis of soils.** *Soil Science*, v. 14, p. 485-499, 1922.
- JENNY, H. **Factors of soil formation, a system of quantitative pedology.** McGraw-Hill: New York. 281 p. 1941.
- KAVZOGLU, T.; SAHIN, E.K.; COLKESEN, I. **Landslide susceptibility mapping using GIS based multi-criteria decision analysis, support vector machines, and logistic regression.** *Landslides* 11 (3), 425–439, 2014.
- KILMER, V. J.; ALEXANDER, L. T. **Methods of making mechanical analysis of soils.** *Soil Science*, v. 68, n. 1, p. 15-24, 1949.
- KLEINBERG, E. **On the Algorithmic Implementation of Stochastic Discrimination.** *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 22 (5): 473–490. CiteSeerX 10.1.1.33.4131, 2000. doi:10.1109/34.857004. S2CID 3563126.

KULLARNI, V. Y.; SINHA, P. K. **Random Forest Classifier: A Survey and Future Research Directions**. Int. J. Adv. Comput., vol. 36, no. 1, pp. 1144 – 1156, 2013.

LAGACHERIE, P.; MCBRATNEY, A.B. **Spatial soil information systems and spatial soil inference systems: perspectives for digital soil mapping**, 2006.

LARK, R.M.; BISHOP, T.F.A. **Cokriging particle size fractions of the soil**. Eur. J. Soil Sci. 58, 763–774, 2007.

LARK, R.M.; DOVE, D.; GREEN, S.L.; RICHARDSON, A.E.; STEWART, H.; STEVENSON, A. **Spatial prediction of seabed sediment texture classes by cokriging from a legacy database of point observations**. Sediment. Geol. 281, 35–49, 2012.

LEOPOLD, L. B.; WOLMAN, M. G.; MILLER, J. P. **Fluvial processes in geomorphology**. W. H. Freeman, 1964.

LIAO, K.; XU, S.; WU, J.; ZHU, Q. **Spatial estimation of surface soil texture using remote sensing data**. Soil Sci. Plant Nutr. 59, 488–500, 2013.

LIAW A.; WIENER M. **Classification and regression by randomForest**. R News. 2:18–22, 2002.
MCBRATNEY, A.B.; MENDONÇA SANTOS, M.L.; MINASNY, B. **On digital soil mapping**. Geoderma 117, 3–52, 2003. [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4).

MCBRATNEY, A.B.; ODEH, I.O.; BISHOP, T.F.; DUNBAR, M.S.; SHATAR, T.M. **An overview of pedometric techniques for use in soil survey**. Geoderma, v.97, p.293-327, 2000.

MEDINA, H. P.; GROHMANN, F. **Contribuição ao estudo da análise granulométrica do solo**. In: Congresso brasileiro de ciência do solo, 6., 1957, Salvador. Anais... Rio de Janeiro: Sociedade Brasileira de Ciência do Solo, p. 29-38, 1962.

NANNI, M.R.; DEMATTÊ, J.A.M. **Spectral reflectance methodology in comparison to traditional soil analysis**. Soil Sci. Soc. Am. J. 70, 393–407, 2006.

NUSSBAUM, M., SPIESS, K., BALTENSWEILER, A., GROB, U., KELLER, A., GREINER, L., SCHAEPMAN, M.E., PAPRITZ, A. **Evaluation of digital soil mapping approaches with large sets of environmental covariates**. SOIL 4, 1–22. <https://doi.org/10.5194/soil-4-1>, 2018.

OLIVEIRA, T. G.; MENDES, G. da. C.; PEREIRA, E. L.; FERREIRA, L. D. **Análise Comparativa entre o Granulômetro a Laser e o Método Convencional de Granulometria por Sedimentação**. In: congresso brasileiro de mecânica dos solos e engenharia geotécnica, 18, 2016.

PANAGOS, P.; BORRELLI, P.; MEUSBURGER, K.; ALEWELL, C.; LUGATO, E.; MONTANARELLA, L. **Estimating the soil erosion cover-management factor at the European scale**. Land Use Policy, 48, 38–50, 2015. <https://doi.org/10.1016/j.landusepol.2015.05.021>

PIERANGELI, L. M. P.; SILVA, S. H. G.; TEIXEIRA, A. F. DOS S.; MANCINI, M.; ANDRADE, R.; MENEZES, M. De.; MARQUES, J. J.; WEINDORF, D. C.; CURI, N. **Combining Proximal and Remote Sensors in Spatial Prediction of Five Micronutrients and Soil Texture in a Case Study at Farmland Scale in Southeastern Brazil**. Agronomy, 12(11), 2022. <https://doi.org/10.3390/agronomy12112699>

POPPIEL, R.R., LACERDA, M.P.C., SAFANELLI, J.L., RIZZO, R., OLIVEIRA, M.P., NOVAIS, J.J., DEMATTE, J.A.M. **Mapping at 30 m resolution of soil attributes at multiple depths in Midwest Brazil**. Remote Sens. 11, 2905, 2019. <https://doi.org/10.3390/rs11242905>.

RIBEIRO, B.T. *et al.* **Portable X-ray fluorescence (pXRF) applications in tropical Soil Science.** Ciência e Agrotecnologia, v. 41, p. 245–254, 2017.

RIVERO, R.G.; GRUNWALD, S.; BRULAND, G.L. **Incorporation of spectral data into multi variate geostatistical models to map soil phosphorus variability in a Florida wetland.** Geoderma 140, 428–443, 2007.

ROBIN, G.; JEAN-MICHEL, P.; CHRISTINE, T.M. **Variable selection using random forests.** Pattern Recognition Letters, 31(14):2225–2236, 2010.

ROBINSON, G. W. A. **New method for the mechanical analysis of soils and other dispersions.** Journal of Agricultural Science, v. 12, n. 3, p. 306-321, 1922.

RUO, X.; DAN, N.; DANIEL, J. N. **Predictor augmentation in random forests.** Statistics and Its Interface, 7:177–186, 2014.

SAMUEL-ROSA, A. S. **Funções de predição espacial de propriedades do solo.** Dissertação (Mestrado em Ciência do Solo). Universidade Federal de Santa Maria. 201p, 2012.

SANCHEZ, R.B.; MARQUES JUNIOR, J.; SOUZA, ZM. de; PEREIRA, G.T.; MARTINS FILHO, M.V. **Variabilidade espacial de atributos do solo e de fatores de erosão em diferentes pedoformas.** Bragantia, Campinas, v.68, n.4, p.1095-1103, 2009.

SCHAETZL, R. J.; ANDERSON, S. **Soils: Genesis and Geomorphology.** Cambridge University Press. ISBN: 0521812011, 2005.

SHARMA, A.; WEINDORF, D.C.; MAN, T.; ALDABAA, A.; CHAKRABORTY, S. **Characterizing soils via portable X-ray fluorescence spectrometer: 3. Soil reaction (pH).** Geoderma 232-234, 141–147, 2014.

SHARMA, A.; WEINDORF, D.C.; WANG, D.D.; CHAKRABORTY, S. **Characterizing soils via portable X-ray fluorescence spectrometer: Cation exchange capacity (CEC).** Geoderma 239–240, 130–134, 2015.

SILVA, E. E. da.; SILVA, L. M. da.; WADT, P. G. S.; MARCHAO, R. L. **Espectroscopia de infravermelho próximo na predição de propriedades químicas e físicas de solos de Roraima.** Biota Amazônia, v. 7, n. 2, p. 31-35, 2017.

SILVA, E. F. da.; NUNES, F. C.; VILAS BOAS, G. da. S.; CALDERANO, S. B. **Análise de solos coesos do litoral Norte da Bahia utilizando a granulometria a laser.** In: congresso brasileiro de ciências do solo, 34. Florianópolis. Anais... Viçosa, MG: Sociedade Brasileira de ciência do solo, 2013.

SILVA, S. H. G.; TEIXEIRA, A. F. D. S.; MENEZES, M. de.; GUILHERME, L. R. G.; MOREIRA, F. M. D. S.; CURI, N. **Multiple linear regression and random forest to predict and map soil properties using data from portable X-ray fluorescence spectrometer (pXRF).** Ciênc Agrotec. 41: 648–664, 2017.

SILVA, S.H.G. *et al.* **Soil weathering analysis using a portable X-ray fluorescence (PXRF) spectrometer in an Inceptisol from the Brazilian Cerrado.** Appl. Clay Sci, v. 162, p. 27–37, 2018.

SILVA, S.H.G.; POGGERE, G.C.; MENEZES, M.De.; CARVALHO, G.S.; GUILHERME, L.R.G.; CURI, N. **Proximal sensing and digital terrain models applied to digital soil mapping and modeling of Brazilian Latosols (Oxisols).** Remote Sens. 8, 614–635, 2016. <https://doi.org/10.3390/rs8080614>.

SORENSEN, R.; ZINKO, U.; SEIBERT, J. **On the calculation of the topographic wetness index: evaluation of different methods based on field observations.** Hydrology and Earth System Sciences. 10 (1): 101–112, 2006. [Bibcode:2006HESS...10..101S](#). [doi:10.5194/hess-10-101-2006](#).

SOUZA JUNIOR, J.G.A.; DEMATTE, J.A.M. **Modelo digital de terreno (MDT) na caracterização de solos desenvolvidos de basalto e material arenítico.** Revista Brasileira de Ciência do Solo, Viçosa, v.32, p. 449-456, 2008.

STEVENS, A.; UDELHOVEN, T.; DENIS, A.; TYCHON, B.; LIOY, R.; HOFFMANN, L.; VAN WESEMAEL, B. **Measuring soil organic carbon in croplands at regional scale using airborne imaging spectroscopy.** Geoderma 158, 32–45, 2010.

STEVENS, A.; VAN WESEMAEL, B.; BARTHOLOMEUS, H.; ROSSILLON, D.; TYCHON, B.; BEN-DOR, E. **Laboratory, field and airborne spectroscopy for monitoring organic carbon content in agricultural soils.** Geoderma 144, 395–404, 2008.

STOCKMANN, U. *et al.* **Utilizing portable X-ray fluorescence spectrometry for in- field investigation of pedogenesis.** Catena, v. 139, p. 220–231, 2016.

SWANHART, S.; WEINDORF, D.C.; CHAKRABORTY, S.; BAKR, N.; ZHU, Y.; NELSON, C.; SHOOK, K.; ACREE, A. **Soil salinity measurement via portable X-ray fluorescence spectrometry.** Soil Sci. 179 (9), 417–423, 2014.

TAN, K.H. **Soil Sampling, Preparation, and Analysis.** CRC Press, Boca Raton, FL, pp. 672, 2005.

TIEN Bui, D.; PRADHAN, B.; LOFMAN, O.; REVHAUG, I. **Landslide susceptibility assessment in Vietnam using support vector machines, decision tree, and Naive Bayes models.** Math. Probl. Eng. 2012, 1–27, 2012.

TRIAANTAFILIS, J.; KERRIDGE, B.; BUCHANAN, S.M. **Digital soil-class mapping from proximal and remotely sensed data at the field level.** Agron. J. 101 (4), 841–853, 2009. UN-FAO, 2015. World Reference Base for Soil Resources 2014. Word Soil Resources Report 106. UN-FAO, Rome.

TYNER, E. H. **The Use of Sodium Metaphosphate for Dispersion of Soils for Mechanical Analysis.** Soil Science Society of America Proceedings, v. 4, n. C, p. 106-113, 1940.

VAPNIK, V. **The Nature of Statistical Learning Theory.** Springer Science and Business Media, 2013.

WEBSTER, R. **Quantitative spatial analysis of soil in the field.** Advances in Soil Science, New York, v. 3, p. 1-70, 1984.

WEINDORF, D.C. *et al.* **Characterizing soils via portable X-ray fluorescence spectrometer. 2. Spodic and Albic horizons.** Geoderma, v. 189–190, p. 268–277, 2012b.

WEINDORF, D.C., BAKR, N., ZHU, Y. **Advances in portable X-ray fluorescence (PXRF) for environmental, pedological, and agronomic applications.** Adv. Agron. 128, 1–45, 2014.

WEINDORF, D.C.; CHAKRABORTY, S.; ALDABAA, A.; PAULETTE, L.; CORTI, G.; COCCO, S.; MICHÉLI, E.; WANG, D.; LI, B.; MAN, T.; SHARMA, A.; PERSON, T. **Lithologic discontinuity identification via proximal sensors.** Soil Sci. Soc. Am. J. 79 (6), 1704–1716, 2015.

WEINDORF, D.C.; ZHU, Y.; HAGGARD, B.; LOFTON, J.; CHAKRABORTY, S.; BAKR, N.; ZHANG, W.; WEINDORF, W.C.; LEGORIA, M. **Enhanced pedon horizonation using portable X ray fluorescence spectroscopy**. Soil Sci. Soc. Am. J. 76 (2), 522–531, 2012a.

WILEY, H. W. **Principles and practice of agricultural analysis**. soils. Easton: P.A. Chemical Publishing, 607 p, 1894.

ZEVENBERGEN, L.W.; THORNE, C.R. **Quantitative analysis of land surface topography**. Earth Surface Processes and Landforms, 1987.

ZHU, A.X.; HUDSON, B.; BURT, J.; LUBICH, K.; SIMONSON, D. **Soil Mapping Using GIS, Expert Knowledge, and Fuzzy Logic**. Soil Science Society American Journal, Londres, v.65, p.1463-1472, 2001.

ZHU, Y.; WEINDORF, D.C.; ZHANG, W. **Characterizing soils using a portable X-ray fluorescence spectrometer**. 1. Soil texture. Geoderma, v. 167–168, p. 167–177, 2011.

SEGUNDA PARTE - ARTIGOS

ARTIGO 1 – Dados de sensoriamento proximal e remoto para a predição de textura do solo

Cameau Cadostin¹, Eduane José de Pádua¹, Fernanda Almeida Bócoli¹, Ana Lúcia Cerino Rodrigues¹, Marco Aurélio Carbone Carneiro¹, Nilton Curi¹, Sérgio Henrique Godinho Silva¹

¹Universidade Federal de Lavras, Trevo Rotatório Professor Edmir Sá Santos - MG, 37203-202, Brasil

RESUMO

Apesar da crescente adoção de sensores proximais em todo o mundo, raros são os trabalhos que combinaram dados proximais com dados de sensoriamento remoto para predizer espacialmente as propriedades do solo. Ao utilizar tais parâmetros, muitas vezes são obtidas melhores predições através da entrada de variáveis adicionais fornecidas pelo uso desses sensores combinados ou não. Este trabalho teve como objetivo avaliar a contribuição de dados de sensoriamento proximal e remoto para predizer e mapear a textura do solo, usando espectrometria de fluorescência de raios-X portátil, susceptibilidade magnética e atributos do terreno. No total, foram coletadas 114 amostras de solo nos horizontes superficial e subsuperficial em toda a área da Fazenda Muquém da UFLA. Essas amostras de solo foram submetidas a análises granulométrica pelo método da pipeta e foram complementadas com análises de sensores próximos para determinar o conteúdo químico elementar total. Quinze (15) atributos do terreno derivados de modelo digital de terreno com resolução de 12,5 m foram gerados via software QGIS. De posse desses dados, modelos de predição foram gerados utilizando os algoritmos Random Forest. Por outro lado, ajustamos as equações do modelo linear generalizado (GLM) apresentadas no artigo publicado por Silva *et al.* (2020) para a nossa área de estudo. Os resultados dos modelos mostraram que as combinações pXRF + SM foram mais eficazes para predizer a areia, enquanto pXRF + SM + AT foram mais adequadas para predizer a argila. Além disso, a equação de Silva mostrou-se eficaz para a areia, mas inadequada para a argila e o silte, destacando a necessidade de modelos específicos. Esses resultados confirmam a eficácia dos sensores proximais e remotos para aprimorar a cartografia digital dos solos e melhorar a gestão agrícola. Os mapas de atributos do solo que foram criados a partir destas previsões auxiliarão a adoção de práticas sustentáveis de gestão do solo.

Palavras-chave: atributos do terreno; susceptibilidade magnética; espectrometria fluorescência de raios-X portátil, textura do solo.

1 INTRODUÇÃO

Os avanços tecnológicos levaram ao desenvolvimento de vários novos métodos na avaliação das propriedades do solo (Ribeiro *et al.*, 2017; Weindorf *et al.*, 2014). Tradicionalmente, a avaliação da textura do solo vem sendo realizada por meio de análises trabalhosas em laboratório, que exigem tempo, recursos e amostragens, muitas vezes não fornecendo uma representação espacial adequada da variabilidade do solo (McBratney *et al.*, 2003). Atualmente, métodos alternativos que permitam a caracterização rápida, econômica e sem a geração de efluentes químicos do solo ganham cada vez mais espaço e importância na avaliação das propriedades do solo.

O desenvolvimento e a eficácia da agricultura de precisão só foram possíveis devido à introdução de novas tecnologias, como o Sistema de Posicionamento Global (GPS), sensores proximais, Sistemas de Informação Geográfica (SIG) e a utilização de softwares avançados e equipamentos precisos (Hedley, 2015). Esses métodos digitais apresentam o potencial de melhorar o mapeamento do solo e seus atributos e estão se tornando ferramentas poderosas capazes de fornecer dados detalhados em áreas extensas semelhantes, o que é essencial para a avaliação e resolução de problemas agrônômicos. Nesse sentido, a integração de dados das novas tecnologias para a predição e o mapeamento da textura do solo em solos tropicais é muito importante e tem grande potencial de contribuir para um maior detalhamento dos mapas de solos e auxiliar em técnicas como a agricultura de precisão.

Nesse contexto, os sensores proximais estão sendo cada vez mais utilizados para a criação de modelos de predição de atributos do solo de forma mais eficaz e rápida (Mancini *et al.*, 2019), além de poderem ser usados em ambientes de campo e de laboratório para fornecer informações rápidas sobre uma diversidade de atributos do solo (Hartemink; Minasny, 2014; Horta *et al.*, 2015; Duda *et al.*, 2017). O equipamento portátil de fluorescência de raios-X (pXRF) é um exemplo, sendo capaz de detectar e quantificar vários elementos em segundos, *ex situ* ou *in situ*, a um baixo custo e sem a geração de resíduos químicos (Weindorf *et al.*, 2014; Horta *et al.*, 2015; Ribeiro *et al.*, 2017). Pode-se citar também a susceptibilidade magnética (SM) obtida por outro sensor proximal, o susceptibilímetro, é um atributo do solo relacionado à concentração de óxidos de ferro magnéticos. Refletindo aspectos como mineralogia, textura, usos, hidrologia, além de diferentes formas e dinâmicas destes óxidos de ferro, podendo ser relacionados a processos de formação e evolução dos solos na paisagem (Curi *et al.*, 2017; Silva *et al.*, 2016). Os principais minerais magnéticos do solo são a magnetita e a maghemita. Esses minerais magnéticos estão frequentemente ligados aos materiais de origem do solo e influenciam a textura do solo, pois como geralmente se encontram em materiais de origem

máficos são mais suscetíveis ao intemperismo, estando relacionados principalmente às frações mais finas do solo como a argila (Machado; Mielniczuk, 2009).

Além disso, atributos do terreno (AT), como a declividade, o índice topográfico de umidade, etc., também podem ser utilizados nestas modelagens e podem ser facilmente obtidos a partir de dados de sensores remotos, como o Modelo digital de terreno (MDT) (Silva *et al.*, 2016). Os dados obtidos por sensores próximos e remotos têm sido frequentemente aplicados em modelos preditivos espaciais para o mapeamento digital dos solos, pois têm relação com a pedogênese, como ao material de origem, hidrologia em topossequências, a erosão do solo e (McBratney *et al.*, 2003; Moore *et al.*, 1993; Adhikari *et al.*, 2014; Fernandes *et al.*, 2019; Grunwald, 2009).

Dentre os vários métodos utilizados para prever classes e atributos do solo, o algoritmo Random Forest (Rad *et al.*, 2014; Silva *et al.*, 2017), é um dos mais promissores e tem fornecido as modelagens mais robustas e acuradas, permitindo usar variáveis numéricas ou categóricas, podendo avaliar a importância de cada variável na geração do modelo final e modelar relações não lineares (Breiman, 2001; Liaw; Wiener, 2002). Além disso, muito se discute se um modelo predito para uma determinada região pode ser aplicado para outra região sem prejuízo na acurácia final, assim é necessário a realização de testes e comparação das acurácias para se chegar a uma conclusão pertinente (Liaw; Wiener, 2002).

Deste modo, os objetivos deste estudo foram: i) Caracterizar os horizontes superficiais e subsuperficiais dos solos da fazenda Muquém; ii) Gerar modelos para prever a distribuição da textura do solo a partir dos dados obtidos destes sensores; iii) Criar e validar um mapa detalhado de predição da textura dos solos para os horizontes superficial e subsuperficial; iv) Avaliar se o modelo predito a partir dos dados de espectrometria de fluorescência de raios-X portátil (pXRF), susceptibilidade magnética (SM) e atributos do terreno (AT) para a área de estudo são mais acuradas que quando se utiliza a equação predita por Silva *et al.* (2020). A hipótese é que os dados dos sensores próximos e remotos podem ser utilizados com sucesso para predição de modelos e geração de mapas robustos da textura do solo em toda a área de estudo.

2 MATERIAIS E MÉTODOS

2.1 Área do estudo


O estudo foi realizado na fazenda Muquém, um dos campos experimentais da Universidade Federal de Lavras, localizada no sul do estado de Minas Gerais, Brasil, com coordenadas geográficas variando aproximadamente entre 21°11'35"S e 21°12'21"S de latitude e 44°59'39"W e 44°58'34"W de longitude, zona 23K (Figura 1). Essa área, de aproximadamente

160 hectares, é classificada como Cwa, de acordo com o sistema de classificação de Köppen, caracterizado por verões quentes e chuvosos e invernos frios e secos, com temperatura média anual de 19 °C e precipitação média anual de 1.530 mm (Dantas, 2007). Os materiais de origem registrados na área compreendem principalmente granito (rocha metamórfica composta principalmente de quartzo, feldspatos e micas), gabro (rocha ígnea composta por minerais plagioclásio e piroxênio ricos em Ca) e pequenas áreas de sedimentos aluviais (Curi *et al.*, 2017). As classes de solos da área são: Latossolos (36%), Cambissolo (26%), Argissolo (21%), Nitossolo (9%), Neossolo Litólico e Cambissolo Háplico Léptico (4%), e solos não discriminados de várzea (5%), de acordo com o levantamento pedológico realizado por Silva *et al.* (2014).

2.2 Descrição mineralógica da fazenda Muquem

A fazenda Muquém está inserida na unidade geomorfológica do Planalto Atlântico, especificamente na superfície do Alto Rio Grande (Silva; Marques; Santos, 2014). Geologicamente, a região é representada, predominantemente, por rochas onde predominam materiais de origem provenientes da alteração de associações de gabros, granitos e gnaisses. Especificamente, a área é composta de gabros epimetamórficos, graníticas, gnaisses leucocráticos e cataclásticos, material coluvionar, granulitos e migmatitos, micaxistos e quartzitos, de acordo com o mapa das unidades litológicas do município de Lavras, escala 1:100.000 (Bueno *et al.*, 1990).

Figura 1 – Mapa da localização da área do estudo e dos locais georreferenciados de amostragem de solo na Fazenda Muquém, estado de Minas Gerais, Brasil.



Fonte: Do autor (2025).

2.3 Amostragem de Solo e Análises laboratoriais

No total, foram coletadas amostras de solo em 57 locais georreferenciados na área de estudo (Figura 1). As amostras foram coletadas nos horizontes superficiais e subsuperficiais, totalizando 114 amostras.

As amostras de solo foram secas ao ar e peneiradas a 2 mm, obtendo-se terra fina seca ao ar (TFSA), que foi utilizada para as mensurações da textura do solo, análise dos teores elementares totais e análise do magnetismo do solo. A textura do solo foi determinada segundo o método da pipeta quantificando-se as frações areia, silte e argila. A susceptibilidade magnética por unidade de massa (MS_{χ}) foi determinada em cerca de 10 g de TFSA usando um magnetômetro modelo Bartington MS2B (Bartington Instruments Ltd., Inglaterra) com leituras em baixa e alta frequência. Os valores de susceptibilidade magnética (MS) foram obtidos através da (Equação 1).

$$MS(\chi) = \chi_{LF} \text{ or } \chi_{HF} \div m \quad (1)$$

Onde: $MS(\chi)$ = susceptibilidade magnética ($\times 10^{-7} \text{ m}^3 \text{ kg}^{-1}$); χ_{LF} = leitura obtida em baixa frequência; e χ_{HF} = leitura obtida em alta frequência respectivamente; m = massa da amostra (g).

Os teores elementares totais foram medidos na TFSA com um espectrômetro pXRF Bruker modelo Tracer 5g (Billerica, EUA), operando a 50 keV com um tubo de raios-X de 100 μA , com varreduras de 60 s de duração, no modo “Soil” em triplicata, de acordo com o método descrito por Chakraborty, *et al.* (2017).

2.4 Dados de sensor remoto

Um MDT ALOS PALSAR Global Radar Imagery, com resolução espacial de 12,5 m, disponível em <https://search.asf.alaska.edu>, foi utilizado para gerar os principais atributos do terreno (AT) utilizados em predições de atributos de solos (Silva *et al.*, 2016; Pierangeli *et al.*, 2022; Thompson *et al.*, 2001) por meio do software SAGA GIS 6.4.0 (Conrad *et al.*, 2015). Os seguintes AT gerados: Slope, Valley Depth, Total Catchment Area, Topographic Wetness Index, Relative Slope position, Profile Curvature, Plan Curvature, Multiresolution Index of Valley Bottom Flatness (MRVBF), Multiresolution Index of the Ridge Top Flatness (MRRTF), LS-Factor, Channel Network Distance, Channel Network Base Level, Aspect, Analytical Hillshading e Altitude.

2.5 Modelagem e validação da predição da textura

Para a predição da textura dos solos, diferentes combinações dos dados de teores elementares totais (pXRF), SM dos horizontes superficiais e subsuperficiais e os atributos do terreno (AT) foram testadas com auxílio do algoritmo de aprendizado de máquina *Random Forest* (RF) (Breiman, 2001), contido no pacote “RandomForest” para o software RStudio (Liaw; Wiener, 2015).

Os parâmetros número de variáveis no subconjunto aleatório em cada nó e número de árvores na floresta foram configurados como *mtry* (quantidade de variáveis a foram consideradas em cada nó) e *ntree* (número de árvores na floresta), respectivamente, para otimizar o desempenho do modelo e garantir resultados consistentes.

- *mtry*: Por padrão, o *randomForest* usa o valor $\sqrt{p}$ para variáveis preditoras numéricas em um problema de regressão, onde p é o número total de variáveis preditoras.
- *ntree*: Foi configurado explicitamente como 1000, o número de árvores na floresta.

Os dados foram organizados em dois conjuntos, um para o treinamento dos modelos, com 70% dos dados, e outro para a etapa de validação dos mapas gerados, com 30% dos dados.

O desempenho dos modelos foi avaliado através do cálculo do coeficiente de determinação (R^2) (Equação 2) e da raiz do erro médio quadrático (RMSE) (Equação 3), almejando-se aquele de maior R^2 e menor RMSE.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{i_{obs}} - y_{i_{pred}})^2}{\sum_{i=1}^n (y_{i_{obs}} - y_{i_{mob}})^2} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{i_{pred}} - y_{i_{obs}})^2}{n}} \quad (3)$$

Onde: $y_{i_{obs}}$: representa os valores observados na análise laboratorial; $y_{i_{pred}}$: representa os valores estimados; $y_{i_{mob}}$: representa a média dos dados observados; n : número de pontos de observação.

2.6 Importância das Variáveis e mapeamento do solo

A importância das variáveis químicas, magnéticas e topográficas para a predição das frações texturais foi avaliada através da métrica Aumento Percentual no Erro Quadrático Médio (%IncMSE), computada pelo algoritmo Random Forest (Breiman, 2001). Esta métrica estima o aumento do Erro Quadrático Médio (MSE) observado quando os valores de uma determinada variável são removidos ou permutados de forma aleatória. Um aumento significativo do MSE após a permutação indica que a variável removida desempenha um papel importante na predição do modelo.

Para mapear os percentuais de areia, silte e argila do solo para toda a área de estudo, foi realizada a espacialização dos dados de solos obtidos pelos sensores para cada horizonte por meio da função Multilevel B-Spline do software SAGA GIS, (Conrad *et al.*, 2015), utilizando tamanho de pixel de 12,5 metros (resolução espacial). Através deste processo, dados pontuais de solo para cada atributo levantado foram interpolados espacialmente para gerar mapas de distribuições contínuas em toda a área. Os valores das variáveis preditoras para toda a área da fazenda foram extraídos e aplicados aos modelos obtidos através do RF, gerando a predição espacial das frações texturais do solo em toda a área de estudo.

2.7 Ajuste dos modelos de equações da textura do Solo

Ajustamos as equações do modelo linear generalizado (GLM) apresentadas no artigo publicado por Silva *et al.* (2020) para a nossa área de estudo. Este estudo foi realizado em oito estados brasileiros (Minas Gerais, São Paulo, Espírito Santo, Rio de Janeiro, Bahia, Pernambuco, Paraná e Santa Catarina) e teve como objetivo predizer a textura dos solos dessas regiões a partir de dados de pXRF. Assim, testamos o desempenho e a aplicabilidade dos modelos de predição das frações texturais desenvolvidos por Silva *et al.* (2020) da nossa área de estudo. <https://doi.org/10.1016/j.geoderma.2019.114136>

3 RESULTADOS E DISCUSSÃO

3.1 Textura do solo

As amostras analisadas mostraram uma ampla gama de classes texturais do solo (Figura 2). Os percentuais de areia, silte e argila das amostras (Tabela 1) confirmaram a variabilidade dos solos avaliados neste estudo. Os teores de argila, silte e areia variaram respectivamente entre 11–66%, 6–41% e 16–62%, considerando tanto os horizontes superficiais quanto os subsuperficiais (Tabela 1). Nenhum dos solos analisados foi classificado como siltoso, devido ao grau de intemperismo avançado. Devido ao clima quente e úmido, a paisagem está submetida a processos de intemperismo e lixiviação intensos, o que favorece à formação de solos proporcionalmente mais argilosos (Brinatti *et al.*, 2010; Kämpf *et al.*, 2012; Schaefer *et al.*, 2008). Observa-se no horizonte superficial ligeiro aumento do teor de argila e a diminuição do teor de areia comparativamente o horizonte subsuperficial. O coeficiente de variação (CV) variou entre 25–45% (altos a muito altos) nos dois horizontes.


Tabela 1 – Análise descritiva da textura do solo da fazenda Muquém, estado de Minas Gerais, Brasil.

		Média	Min.	Max.	SD	CV
	Fração textural	%.....				
Horizonte Superficial	Areia	47	24	69	11,5	25
	Silte	19	9	30	5,3	28
	Argila	35	11	58	12,6	36
Horizonte Subsuperficial	Areia	38	16	62	10,7	28
	Silte	19	6	41	8,8	45
	Argila	43	11	66	14,5	34

*SD – Desvio padrão; CV - Coeficiente de Variação

Fonte: Do autor (2025).

Figura 2 - Classificação textural (USDA, 2017) das amostras de solo coletadas na Fazenda Muquém, Minas Gerais, Brasil.



Fonte: Do autor (2025).

3.2 Variações texturais na área de estudo

Os dados da Tabela 2 mostram predomínio da fração argila em todos os solos, exceto no Cambissolo Háplico (CX). Em ordem decrescente de teor de argila, independente de profundidade: Latossolo Vermelho (LV) > Nitossolo Bruno (NB) > Argissolo Vermelho-Amarelo (PVA) > Cambissolo Háplico (CX). No CX predomina fração areia grossa nas duas profundidades. Há incremento de argila e redução de areia em profundidade em todos os solos.

Para a classe dos Cambissolos (CX) o horizonte superficial apresentou teor de argila entre 10,7 a 34,3 %, com uma média de 22,6 %. O teor de silte apresentou uma média de 20,3 %, enquanto a areia grossa domina com uma média de 37,2 %. No horizonte subsuperficial, a argila teve média de 29,5 %, enquanto a areia grossa diminui para 29,6 %.

Os Argissolos apresentaram um teor médio de argila de 32 %, acompanhado por uma quantidade relativamente alta de silte (22,8%) e de areia grossa (29,3%). Em profundidade, o teor de argila aumenta com uma média de 40,9 %, enquanto a areia grossa diminui para 21,4%. Os Argissolos, frequentemente localizados em áreas onduladas, são caracterizados por presença de gradiente textural. A transição para um teor mais elevado de argila no horizonte subsuperficial corresponde aos processos de iluviação de argila (acumulação de argila translocada) (Santos *et al.*, 2018).

Os Nitossolos (NB) apresentam um teor médio de argila de 39,7%, e de areia grossa de 28,5%. O coeficiente de variação foi elevado para o silte e argila (43,5% e 27,4%), mostrando

uma maior heterogeneidade na textura do horizonte superficial. Já no horizonte subsuperficial, a argila aumentou para 48,5%, enquanto a areia grossa diminuiu para 22,9%. Os maiores teores de argila estão presentes nos Latossolos, com média de 46,7% e variabilidade relativamente baixa (SD = 6 % e CV de 12,9%). Os teores de silte permanecem moderadamente baixos, com média de 15,2 %, e o teor de areia foi menor do que nos Cambissolos. Em profundidade, a argila aumenta consideravelmente com uma média de 54,4%, enquanto a areia grossa diminuiu para 19,8 %. Os maiores teores de argila nos Latossolos (LV) em relação aos demais solos menos intemperizados é coerente com o grau avançado de alteração química nesses solos, o que também explica o baixo teor de areia (Schaefer *et al.*, 2008).

Tabela 2 – Variações texturais (g kg^{-1}) dentro das classes de solo da Fazenda Muquém, Minas Gerais, Brasil.

CLASSE DO SOLO	Fração textural	Horizonte superficial		Horizonte subsuperficial	
		Média	SD	Média	SD
				g kg^{-1}	
CX	Argila	22,59	7,9	29,46	11,13
	Silte	20,32	5,05	24,51	8,45
	Areia grossa	37,19	8,89	29,61	9,48
	Areia fina	19,91	6,48	16,42	4,55
PVA	Argila	32,01	8,96	40,9	11,86
	Silte	22,77	4,54	23,78	8,3
	Areia grossa	29,35	11,25	21,38	6,93
	Areia fina	15,88	2,56	13,95	4,79
NB	Argila	39,68	10,88	48,49	14,26
	Silte	16,48	7,17	14,14	5,43
	Areia grossa	28,52	10,48	22,96	11,71
	Areia fina	15,32	3,68	14,41	2,32
LV	Argila	46,59	6	54,42	8,44
	Silte	15,25	3,35	13,42	6,44
	Areia grossa	23,45	5,52	19,83	6,38
	Areia fina	14,7	2,88	12,33	2,39

* Cambissolos Háplico (CX), Latossolos Vermelho (LV), Argissolo Vermelho-Amarelo (PVA) e Nitossolos Bruno (NB).

Fonte: Do autor (2025).

3.3 Teores químicos totais por fluorescência de raios-X portátil

Os elementos predominantes nos solos estudados foram $\text{Si} > \text{Al} > \text{Fe}$ (Tabela 3). As medições do pXRF, de maneira geral, apresentaram alta dispersão, com CV variando de 12% (Si e Ca) a 146% (K) (Tabela 3). Os elementos Si, Ca e Mg apresentaram concentrações

ligeiramente maiores no horizonte superficial, enquanto que Al e Fe encontravam-se ligeiramente mais concentrados no horizonte subsuperficial. O Si tende a se acumular nos solos principalmente na estrutura cristalina do quartzo e da muscovita, nas frações de areia e silte, e na caulinita, na fração argila, enquanto Fe e Al tendem a se concentrar na fração argila na forma de óxidos, (Al também presente na caulinita) (Mancini *et al.*, 2019). O Ca também apresentou alta variabilidade, com teores mais elevados observados no horizonte superficial. Comumente, em solos agrícolas brasileiros, tem-se a aplicação de calcário para a correção do pH, que além desta função ainda eleva o teor de Ca no solo por conter este elemento em sua composição. O Ca possui baixa mobilidade no solo e quando não é incorporado a maiores profundidades se concentra nos primeiros centímetros dos solos (Alvarez V. *et al.*, 1999).

Tabela 3 - Estatística descritiva dos dados obtidos pelo espectrômetro portátil de fluorescência de raios-X (%) da fazenda Muquém, estado de Minas Gerais, Brasil.

	<i>Mg</i>	<i>Al</i>	<i>Si</i>	<i>P</i>	<i>K</i>	<i>Ca</i>	<i>Ti</i>	<i>V</i>	<i>Cr</i>	<i>Mn</i>	<i>Fe</i>	<i>Cu</i>	<i>Zn</i>	<i>Sr</i>	<i>Zr</i>
Horizontes superficial															
Max	2,11	9,88	24,38	0,043	2,724	1,615	1,833	0,095	0,039	0,128	14,567	0,014	0,016	0,009	0,034
Min	0,000	4,325	15,250	0,006	0,000	0,438	0,065	0,003	0,001	0,005	1,102	0,000	0,004	0,000	0,008
Média	0,750	7,050	19,514	0,021	0,480	1,107	0,701	0,035	0,017	0,046	5,540	0,004	0,008	0,002	0,022
SD	0,315	1,101	2,452	0,008	0,672	0,192	0,385	0,020	0,009	0,028	3,431	0,003	0,003	0,002	0,006
CV (%)	41,9	15,6	12,6	38,1	140,1	17,4	55	58,1	54,6	60,2	61,9	63,8	34,8	72,1	27,6
Horizontes subsuperficial															
Max	1,245	10,772	24,450	0,048	3,225	1,357	1,955	0,103	0,136	0,114	24,211	0,029	0,014	0,008	0,036
Min	0,000	6,103	10,945	0,009	0,000	0,760	0,103	0,005	0,005	0,007	1,152	0,000	0,005	0,000	0,010
Média	0,671	8,285	18,277	0,017	0,472	0,988	0,688	0,037	0,024	0,032	6,939	0,005	0,008	0,002	0,023
SD	0,279	1,132	2,195	0,007	0,694	0,116	0,399	0,021	0,020	0,026	4,315	0,004	0,002	0,002	0,008
CV (%)	41,5	13,7	12	42	146,9	11,7	58	56,8	83	80,7	62,2	83,4	29,2	88,3	32,7

Fonte: Do autor (2025).

3.4 Susceptibilidade magnética

Os resultados da Tabela 4 mostraram a susceptibilidade magnética em baixa frequência (SM_BF) e em alta frequência (SM_AF) e destacam vários aspectos relacionados à distribuição dos minerais magnéticos nos dois horizontes de solo estudados. Os valores máximos elevados de susceptibilidade magnética no horizonte superficial (122,6 e 146,4 para SM_BF) sugerem um teor significativo de minerais contendo ferro, como magnetita (Fe_3O_4) e hematita (Fe_2O_3). Esses minerais foram os principais responsáveis pela resposta magnética.

De acordo com Sadiki *et al.* (2009), Santos *et al.* (2011) e Souza Júnior *et al.* (2010), a susceptibilidade magnética é um atributo do solo que reflete a composição de minerais

ferrimagnéticos nas diferentes frações do solo, indicando o grau de evolução dos processos pedogenéticos. Segundo Souza Júnior *et al.* (2010), os óxidos de ferro são o segundo grupo de minerais mais presentes na fração argila. Os máximos mais elevados em profundidade (146,4 para SM_BF e 128,6 para SM_AF) provavelmente refletem uma proximidade com o material de origem menos alterado e mais rico em ferro. As condições redutoras em profundidade podem preservar os minerais magnéticos, limitando sua transformação em fases secundárias não magnéticas, como hematita ou goethita.

Os resultados mostraram que a susceptibilidade magnética foi diretamente influenciada pelo teor de ferro e pela presença de minerais magnéticos como a magnetita, provavelmente herdados do material de origem. A constância das médias e a baixa variabilidade (CV) indicaram uma homogeneidade química, embora os máximos elevados em profundidade sugiram uma maior contribuição dos minerais primários.

Tabela 4 – Estatística descritiva dos dados obtidos pela susceptibilidade magnética da fazenda Muquém, estado de Minas Gerais, Brasil.

	SM_BF (10^{-7} M ³ KG ⁻¹)	SM_AF (10^{-7} M ³ KG ⁻¹)
	Horizontes superficial	
MAX	122,6	110,4
MIN	0,6	0,6
MEDIA	14,8	13,9
SD	21,3	19,6
CV (%)	1,4	1,4
	Horizontes subsuperficial	
MAX	146,4	128,6
MIN	0,3	0,3
MEDIA	14,8	13,8
SD	25,9	23,7
CV (%)	1,7	1,7

*SM_BF: Susceptibilidade Magnética Baixa Frequência; SM_AF: Susceptibilidade Magnética Alta Frequência.

Fonte: Do autor (2025).

3.5 Predição da textura do solo

O melhor modelo gerado pelo algoritmo RF foi para a predição do teor de areia do horizonte superficial ($R^2 = 0,76$; RMSE = 57,00) utilizando os dados de pXRF + SM+AT dos horizontes superficial e subsuperficial. De forma geral, os modelos que incluíram dados de pXRF + SM ou pXRF + SM + AT mostraram-se melhores, sobretudo para predição de frações do horizonte superficial, exceto para silte (Tabela 5).

O desempenho dos modelos foi melhorado ao considerar os dados dos dois horizontes (superficial e subsuperficial) comparativamente aos modelos que consideraram dados de apenas um deles. Essa afirmação não se confirmou para a predição do silte. Para silte, o melhor modelo

obtido utilizou dados de pXRF+SM apenas do horizonte subsuperficial ($R^2 = 0.67$; RMSE=55.51). No entanto, este e os demais modelos testados para a predição do silte apresentaram resultados considerados insatisfatórios.

Para as predições do teor de areia e de argila, os menores valores de RMSE foram obtidos através de modelos treinados com os conjuntos de dados pXRF + MS + AT do horizonte superficial (Tabela 5). Esses modelos apresentaram valores de RMSE iguais a 5.3 % para a areia e 5.5% para a argila. Por outro lado, os modelos gerados com o conjunto de dados utilizando apenas AT mostraram os piores resultados, com valores de RMSE de 12,3 %, mostrando um alto erro acumulado. Pode-se observar que as predições da areia e da argila para o horizonte superficial forneceram melhores resultados em comparação ao subsuperficial.

Embora os AT venham sendo amplamente utilizados como variáveis preditivas para atributos do solo, eles nem sempre melhoram o desempenho do modelo (Duda *et al.*, 2017). Os AT tendem a ser mais importantes para o mapeamento de atributos de solos em áreas mais homogêneas em termos de classes de solo e materiais de origem (Curi *et al.*, 2017). A Tabela 5 mostra que, pelo menos um modelo preditivo adequado foi obtido para a maioria das frações texturais do solo. Assim, os melhores modelos por atributo do solo foram utilizados para gerar mapas de predição espacial.

Como muitos estudos mostraram na cartografia de solos, precisões com um $R^2 > 70\%$ são consideradas bons resultados, mas são muito difíceis de alcançar (Pierangeli *et al.*, 2022). No entanto, é mais comum encontrar precisões com um $R^2 < 50\%$, como demonstrado por Stumpf *et al.* (2017) ($R^2 = 50\%$). Outros estudos indicaram que, para valores em torno de 20–27% e 8–29%, os resultados não foram tão bons quanto os gerados pelo modelo de predição (Malone *et al.*, 2009). Assim, os melhores modelos para cada atributo do solo foram utilizados para gerar mapas de predição espacial.

Tabela 5 – Coeficiente de determinação (R^2) e Root Mean Square Error (RMSE) para os modelos de predição das frações de argila, silte e areia via algoritmo Random Forest para horizonte superficial e Subsuperficial da Fazenda Muquém, estado de Minas Gerais, Brasil.

Variável	Estatística	Prof. (cm)	AT			PXRF+SM			PXRF+SM+AT		
			Sup	Sub	Sup + Sub	Sup	Sub	Sup + Sub	Sup	Sub	Sup + Sub
Areia	R^2	Sup	0,34	-	0,24	0,66	-	0,73	0,7	-	0,76
		Sub	-	0,32	0,26	-	0,22	0,43	-	0,26	0,47
	RMSE	Sup	80,4	-	100,39	57,43	-	58,16	53,58	-	57
		Sub	-	84,22	83,82	-	89,33	70,75	-	86,12	68,6
Argila	R^2	Sup	0,41	-	0,16	0,62	-	0,71	0,7	-	0,73
		Sub	-	0,27	0,24	-	0,47	0,54	-	0,41	0,52
	RMSE	Sup	75,84	-	103,5	62,16	-	55,06	55	-	54,99
		Sub	-	129,13	123,53	-	118,78	99,35	-	122,61	101,08
Silte	R^2	Sup	0,24	-	0,14	0,27	-	0,16	0,29	-	0,2
		Sub	-	0,31	0,38	-	0,67	0,59	-	0,54	0,53
	RMSE	Sup	36,62	-	39,73	40,54	-	48,52	38,43	-	42,72
		Sub	-	75,11	73,15	-	55,51	58,85	-	63,09	63,58

* AT – atributos do terreno; pXRF - Espectrometria de fluorescência de raios X portátil; MS – susceptibilidade magnética; Sup: horizontes superficiais; Sub: horizontes subsuperficiais.

Fonte: Do autor (2025).


3.6 Importância das variáveis preditoras para os melhores modelos

O percentual de incremento do erro quadrático médio (%IncMSE), que indica a importância de cada variável preditora nos modelos para a predição dos teores de argila, silte e areia está apresentado, em ordem de importância, na Figura 3. Analisando modelos criados com o conjunto de dados pXRF + SM + TA via RF, foi possível identificar as variáveis que mais contribuíram para as previsões dos teores de areia, silte e argila (Figura 3). Para a argila, o silte e a areia, os elementos mais estáveis do perfil do solo, como Al, Si e Fe, apresentaram maior importância nos modelos utilizando dados do horizonte subsuperficial e superficial + subsuperficial. Esses elementos químicos foram semelhantes dos estudos realizados por Pinheiro *et al.* (2018) e Silva *et al.* (2016) em solos tropicais. Para a areia, entre as variáveis mais essenciais estavam Si, Fe, K, Al, Cr e V usando os modelos pXRF + SM do horizonte subsuperficial. Para o silte, as variáveis mais importantes foram K, Ti, Mn, Zn e Al. E finalmente, para a argila, as variáveis mais importantes foram K, Si, Fe, V, Al e Cr. Por outro lado, elementos químicos como Ca e Mg, assim como a susceptibilidade magnética, de maneira geral, apresentaram pouca ou nenhuma importância na predição das frações texturais do solo.

Elementos químicos como K, Si, Fe e Al estiveram entre os mais proeminentes na predição das proporções de argila, silte e areia. Isso mostrou que esses elementos têm um impacto significativo na composição textural do solo e podem ser utilizados para análises e intervenções direcionadas ao manejo dos solos.

O K foi o elemento mais importante para a predição de argila. O K nos solos tropicais provém principalmente da alteração de minerais primários ricos em potássio, como os feldspatos potássicos. Sob o efeito da intensa alteração química, esses minerais liberam potássio gradualmente. Uma parte desse potássio é lixiviada, mas outra parte é retida pelas argilas. No solo argiloso, essa intensidade de lixiviação tende a ser mais constante, ou seja, apesar das maiores quantidades de K percolado, esse tipo de solo inicialmente teve a capacidade de reter maiores quantidades de K (Werle *et al.*, 2008). O silte apresenta uma diversidade de elementos, com o potássio mantendo-se como o principal, mas com a inclusão de titânio (Ti) e manganês (Mn) entre os mais importantes. A presença do Ti pode estar relacionada à mineralogia dos solos, já que a relação entre Ti e a formação de solos é discutida em trabalhos como o de Fernandes *et al.* (2018). Destacou que o Ti é um elemento relativamente imóvel, ou seja, ele não é facilmente lixiviado ou removido do solo. Isso significa que, ao longo do tempo, ele pode se concentrar na fração residual do solo, permitindo inferências sobre a intensidade do intemperismo e o grau de evolução do solo. Na fração areia, elementos como silício (Si) e ferro (Fe) foram mais importantes. A predominância na fração areia está diretamente relacionada ao material de origem e aos processos de intemperismo. A resistência ao intemperismo químico faz com que o quartzo (SiO_2) seja o principal componente da fração areia, enquanto o Fe pode estar presente em óxidos de ferro formados a partir da decomposição de minerais ferromagnesianos como magnetita (Fe_3O_4) e hematita (Fe_2O_3).

Figura 3 – Importância de variáveis dos melhores modelos de predição de conteúdos de areia, silte e argila de solos da Fazenda Muquém/UFLA, município de Ijaci, estado de Minas Gerais, Brasil, pelo algoritmo RF.




*IncMSE - Increase in Mean Squared Error

Fonte: Do autor (2025).

3.7 Mapas de textura do solo

Os mapas de predição espacial das propriedades do solo com base nos melhores modelos de predição estão ilustrados na Figura 4. Cada um dos mapas mostra as concentrações relativas em g kg^{-1} desses componentes na fazenda Muquém. Eles foram gerados a partir dos melhores modelos de predição, com maior R^2 e menor RMSE. Para a areia e a argila, utilizou-se a combinação do conjunto de dados que considera ambos os horizontes (superficial e subsuperficial) com os modelos pXRF+SM+AT e pXRF+SM, respectivamente. Dado que a maioria dos solos brasileiros apresentou baixo teor de silte e maior teor de argila ou areia, os locais com maior teor de argila apresentaram simultaneamente menor teor de areia. Os mapas de teor de areia e argila apresentaram uma tendência oposta, conforme esperado, demonstrando certa coerência entre os dois modelos. Isso ocorre pela a iluviação da argila é um dos principais processos responsáveis pela distribuição inversa entre os teores de areia e argila no solo. Esse processo ocorre quando partículas finas de argila foram transportadas por infiltração e se acumulam em horizontes mais profundos do perfil do solo. Isso leva a uma diminuição do teor de argila na superfície e aumento em horizontes subsuperficiais, resultando na relação inversa observada nos mapas de areia e argila e na tabela 1.

Figura 4 – Mapas preditos das frações texturais argila e areia da Fazenda Muquém, estado de Minas Gerais, Brasil.



Fonte: Do autor (2025).

3.8 Aplicabilidade do modelo gerado por Silva *et al.* (2020)

Segundo os resultados obtidos a partir do ajuste das equações de Silva *et al.* (2020) para as três frações texturais (areia, argila e silte) em dois horizontes (Superficial e Subsuperficial).

Eles mostraram que a fração areia tem um bom ajuste para o horizonte superficial, com um $R^2 = 0,71$ (Tabela 6), o que significa que 71% da variância dos dados foi explicada pelo modelo. No entanto, o horizonte subsuperficial apresentou um ajuste fraco ($R^2 = 0,20$), e a combinação dos dois horizontes também foi moderada ($R^2 = 0,40$). O RMSE foi elevado para a soma dos dois horizontes (106,90) (Tabela 6), indicando um alto erro de predição. O RMSE foi mais baixo para o horizonte subsuperficial (16,94) do que para o horizonte superficial (85,57), o que significa que o modelo foi mais preciso para o horizonte subsuperficial. As equações mostram uma relação linear negativa de areia no horizonte superficial, assim como para a soma dos dois horizontes. Por outro lado, o horizonte subsuperficial apresentou uma relação positiva.

Para a argila, o modelo explicou 58% da variância para o horizonte superficial, mas o ajuste foi ruim para o horizonte subsuperficial ($R^2 = 0$). A combinação dos horizontes resultou em um R^2 de 0,11, indicando um ajuste global fraco. O horizonte subsuperficial apresentou um grande erro de predição (RMSE = 27,76) (Tabela 6), enquanto o horizonte superficial foi mais preciso (RMSE = 8,12). A combinação dos dois horizontes apresentou um erro moderado (RMSE = 19,40). Todas as equações para a argila mostram uma relação positiva com inclinações semelhantes, mas constantes diferentes.

Os modelos ajustados para o silte foram globalmente fracos. O horizonte superficial apresentou um R^2 muito baixo (0,15), o horizonte subsuperficial teve um ajuste ligeiramente melhor ($R^2 = 0,27$) (Tabela 6), e a soma dos dois horizontes permaneceu baixa ($R^2 = 0,25$). O RMSE foi extremamente elevado, particularmente para o horizonte subsuperficial (1520,64), o que indica predições pouco confiáveis. As equações indicaram relações muito fracas de silte, com coeficientes baixos, especialmente para o horizonte superficial e a soma dos dois horizontes conforme os estudos realizados por Arfe *et al.* (2017) e Groat *et al.* (2003).

A fração areia apresentou o melhor ajuste, especialmente para o horizonte superficial. No entanto, a precisão do modelo diminuiu no horizonte subsuperficial e na soma dos dois horizontes. Isso está de acordo com estudos que indicam que a maioria dos solos com maior teor de areia se desenvolveu a partir de arenito (Cunha *et al.*, 2005) ou de sedimentos arenosos do Quaternário, sendo estes últimos comuns na região das Planícies Costeiras do Brasil (Silva *et al.*, 2012). As outras frações apresentaram um ajuste ruim, com R^2 baixos e RMSE muito elevados, o que pode indicar que os modelos lineares das equações testadas não foram adequados para nossa região. Isso pode ser devido ao fato de que o silte representa a fração de máxima instabilidade e a maioria dos solos brasileiros passou por longos períodos de intemperismo e lixiviação (Resende *et al.*, 2014).

Tabela 6 – Resultados de aplicação das equações do artigo *Silva et al. (2020)* em nossa área de estudo.

FRAÇÃO TEXTURAL		HORIZONTE		
		Superficial	Subsuperficial	Superficial e Subsuperficial
Areia	R ²	0,71	0,2	0,4
	RMSE (%)	85,57	16,94	106,90
	Equação de ajuste	Y= -0,8563X+81,703	Y= 4,8575X - 46,46	Y= -0,8309X+70,37
Argila	R ²	0,58	0	0,11
	RMSE (%)	8,12	27,76	19,40
	Equação de ajuste	Y= 4,5512X-252,07	Y= 3,6494X-210,73	Y= 3,971X-215,82
Silte	R ²	0,15	0,27	0,25
	RMSE (%)	797,50	1520,64	1208,54
	Equação de ajuste	Y= -0,0689X+138,67	Y= 0,0758X+51,629	Y= 0,0316X+9,8253

*Y: Fração textural predita; X: Fração textural observada

Fonte: Do autor (2025).

4 CONCLUSÃO

A predição e mapeamento da textura dos solos usando atributos de terreno, dados de pXRF e susceptibilidade magnética auxiliaram de forma eficiente na caracterização dos solos e seus atributos da Fazenda Muquém. A partir do algoritmo Random Forest, modelos de predição foram gerados e as melhores combinações de sensores foram o pXRF + SM para a argila e pXRF + SM + AT para areia. Assim, métodos convencionais e técnicas de sensores proximais dos solos permitiram uma análise detalhada e precisa da distribuição das frações texturais areia e argila na área de estudo. Contudo, as predições de silte não foram satisfatórias. Deste modo, mapas mostrando a variabilidade espacial de argila e da areia do solo foram produzidos. Por outro lado, o ajuste da equação de Silva demonstrou-se altamente eficaz para a predição da fração areia, mas mostrou-se inadequado para a argila e o silte. Isso confirma a importância do desenvolvimento de modelos específicos para a área de estudo, integrando dados de sensores proximais e remotos para aprimorar a precisão das predições. Assim, os resultados obtidos validam a hipótese de que os dados de sensores de sensoriamento proximal e de sensoriamento remoto permitem uma predição confiável da textura dos solos. Esses achados representam um avanço significativo na cartografia digital dos solos, proporcionando ferramentas precisas para o manejo e o planejamento agrícola sustentável.

AGRADECIMENTOS

Os autores agradecem Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Coordenação de Aperfeiçoamento Pessoal de Nível Superior (CAPES), Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), para apoio financeiro e bolsas de estudo.

REFERÊNCIAS

- ADHIKARI, K.; MINASNY, B.; GREVE, M.B.; GREVE, M.H. **Constructing a Soil Class Map of Denmark Based on the FAO Legend Using Digital Techniques**. *Geoderma* 2014, 214–215, 101–113, 2014.
- ALVAREZ V., V.H.; NOVAIS, R.F.; BARROS, N.F.; CANTARUTTI, R.B.; LOPES, A.S. **Interpretação dos resultados das análises de solos**. In: Ribeiro, A.C.; Guimarães, P.T.G.; Alvarez V., V.H. *Recomendações para o uso de corretivos e fertilizantes em Minas Gerais - 5ª aproximação*, Viçosa, cap. 5, pp. 30-35, 1999.
- ARFE, G.; MONDILLO, N.; BALASSONE, G.; BONI, M.; CAPPELLETTI, P.; DI PALMA, T. **Identification of Zn-bearing micas and clays from the cristal and mina grande zinc deposits (Bongará Province, Amazonas Region, Northern Peru)**. *Minerals* 7, 214–230, 2017.
- BREIMAN, L. **Random Forests**. *Machine Learning*. 45 (1): 5–32, 2001. doi:10.1023/A:1010933404324.
- BRINATTI, A.M.; MASCARENHAS, Y.P.; PEREIRA, V.P.; PARTITI, C.S.D.; MACEDO, A. **Mineralogical characterization of a highly-weathered soil by the Rietveld Method**. *Sci. Agric.* 67, 454–464, 2010.
- BUENO, C. R. P. et al. **Unidades litológicas do município de Lavras (MG)**. *Ciência e Prática*. Lavras, v. 14, p. 352-365, 1990.
- CHAKRABORTY, S. *et al.* **Rapid assessment of smelter/mining soil contamination via portable X-ray fluorescence spectrometry and indicator kriging**. *Geoderma*. v. 306, p. 108–119, 2017.
- CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; WICHMANN, V. **System for Automated Geoscientific Analyses (SAGA) v. 2.1.4**. *Geoscientific Model Development*, 8(7), 1991-2007, 2015. <https://doi.org/10.5194/gmd-8-1991-2015>
- CUNHA, P.; MARQUES, J.; CURI, N.; PEREIRA, G.T.; LEPSCH, I.F. **Superfícies geomórficas e atributos de latossolos em uma seqüência arenítico-Basáltica da região de Jaboticabal (SP)**. *Rev. Bras. Cienc. do Solo* 29, 81–90, 2005.
- CURI, N.; SILVA, S.H.G.; POGGERE, G.C.; MENEZES, M.D. **Mapeamento de solos e magnetismo no campus da UFLA como traçadores ambientais**. 1st ed.; Editora UFLA: Lavras, Brazil; Volume 1, 2017.
- DANTAS, A.A.A.; CARVALHO, L.G. De.; FERREIRA, E. **Climatic classification and tendencies in Lavras region, MG**. *Ciência e Agrotecnologia* 31, 1862–1866, 2007.
- DUDA B. M.; WEINDORF D. C.; CHAKRABORTY S.; Man T.; PAULETTE L. **Soil characterization across catenas via advanced proximal sensors**. *Geoderma*. 298: 78–91, 2017.
- FERNANDES, D.; MACHADO, T.; DE MENEZES, M.D.; HENRIQUE, S.; SILVA, G. **Transferability, Accuracy, and Uncertainty Assessment of Different Knowledge-Based Approaches for Soil Types Mapping**. *Catena* 2019, 182, 104134, 2019.
- FERNANDES, L. *et al.* **The role of titanium in soil mineralogy**. *Soil Science Society of America Journal*, 2018.
- GROAT, L.A.; MULJA, T.; MAUTHNER, MA.H.F.; ERCIT, T.S.; RAUDSEPP, M.; GAULT, R.A.; ROLLO, H.A. **Geology and mineralogy of the Little Nahanni rare-element granitic pegmatites, northwest territories**. *Can. Mineral.* 41, 139–160, 2003.

GRUNWALD, S. **Multi-Criteria Characterization of Recent Digital Soil Mapping and Modeling Approaches**. *Geoderma*, 152, 195–207, 2009.

HARTEMINK, A. E.; MINASNY, B. **Towards digital soil morphometrics**. *Geoderma*, 230-231: 305–317, 2014.

HEDLEY, C. **The role of precision agriculture for improved nutrient management on farms**. *J Sci Food Agric* 95(1): 12-19, 2015. URL <https://onlinelibrary.wiley.com/doi/abs/10.1002/jsfa.6734>.

HORTA, A.; MALONE, B.; STOCKMANN, U.; MINASNY, B.; BISHOP, T. F. A.; MCBRATNEY, A. B.; PALLASSER, R.; POZZA, L. **Potential of integrated field spectroscopy and spatial analysis for enhanced assessment of soil contamination: A prospective review**. *Geoderma*, 241-242: 180–209, 2015.

KÄMPF, N.; MARQUES, J.J.; CURI, N. **Mineralogia de Solos Brasileiros**. In: *Pedologia Fundamentos*. SBCS, Viçosa, MG, p. 343, 2012.

LIAW, A.; WIENER, M. **Classification and regression by random Forest**. *R News*, 2:18–22, 2002.

LIAW, A.; WIENER, M. **Package R random Forest**. *R Dev*, Core Team, 2015. <https://doi.org/10.5244/C.22.54>.

MACHADO VEZZANI, F.; MIELNICZUK, J. **Uma visão sobre qualidade do solo 743 uma visão sobre qualidade do solo**. (1) (Vol. 33), 2009.

MALONE, B.P.; MCBRATNEY, A.B.; MINASNY, B.; LASLETT, G.M. **Mapping Continuous Depth Functions of Soil Carbon Storage and Available Water Capacity**. *Geoderma*, 154, 138–152, 2009.

MANCINI, M.; WEINDORF, D. C.; CHAKRABORTY, S.; SILVA, S. H. G.; TEIXEIRA, A. F. D. S.; GUILHERME, L. R. G.; CURI, N. **Tracing tropical soil parent material analysis via portable X-ray fluorescence (pXRF) spectrometry in Brazilian Cerrado**. *Geoderma*, 337: 718–728, 2019.

MCBRATNEY, A. B.; MENDONÇA-SANTOS, M. L.; MINASNY, B. **On digital soil mapping**. *Geoderma* 117: 3-52, 2003.

MOORE, I.D.; GESSLER, P.E.; NIELSEN, G.A.; PETERSON, G.A. **Soil Attribute Prediction Using Terrain Analysis**. *Soil Sci. Soc. Am. J.*, 57, 443–452, 1993.

PIERANGELI, L. M. P.; SILVA, S. H. G.; TEIXEIRA, A. F. DOS S.; MANCINI, M.; ANDRADE, R.; MENEZES, M. De.; MARQUES, J. J.; WEINDORF, D. C.; CURI, N. **Combining Proximal and Remote Sensors in Spatial Prediction of Five Micronutrients and Soil Texture in a Case Study at Farmland Scale in Southeastern Brazil**. *Agronomy*, 12(11), 2022. <https://doi.org/10.3390/agronomy12112699>

PINHEIRO, H.S.K.; JUNIOR, CARVALHO, DE, W.; CHAGAS, C. DA. S.; DOS ANJOS, L.H.C.; OWENS, P.R. **Prediction of topsoil texture through regression trees and multiple linear regressions**. *Rev. Bras. Ciênc Solo* 42, 2018. <https://doi.org/10.1590/18069657rbc20170167>.

RAD, M. R. P.; TOOMANIAN N.; KHORMALI F.; BRUNGARD C. W.; KOMAKI C. B.; BOGAERT, P. **Updating soil survey maps using random forest and conditioned Latin hypercube sampling in the loess derived soils of northern Iran**. *Geoderma*, 232-234: 97–106, 2014.

RESENDE, M.; CURI, N.; REZENDE, S. B.; CORRÊA, G. F.; KER, J.C. **Pedologia: Base Para Distinção de Ambientes**, 6th ed.; Editora UFLA: Lavras, Brazil, 2014.

RIBEIRO, B.T. *et al.* **Portable X-ray fluorescence (pXRF) applications in tropical Soil Science**. *Ciência e Agrotecnologia*, v. 41, p. 245–254, 2017.

SADIKI, A. *et al.* **Using magnetic susceptibility to assess soil degradation in the Eastern Rif, Morocco**. *Earth Surface Processes and Landforms*, Malden, v. 34, n. 15, p. 2057–2069, 2009.

SANTOS, H. L. *et al.* **Susceptibilidade magnética na identificação de compartimentos da paisagem em uma vertente**. *Revista Brasileira de Ciências Agrárias*, Recife, v. 6, n. 4, p. 710–716, 2011.

SANTOS, H.G.; JACOMINE, P.K.T.; ANJOS, L.H.C.; OLIVEIRA, V.A.; LUMBRERAS, J.F.; COELHO, M.R.; ALMEIDA, J.A.; ARAUJO FILHO, J.C.; OLIVEIRA, J.B.; CUNHA, T.J.F. **Sistema Brasileiro de Classificação de Solos**. 5ª ed. Brasília, DF: Embrapa, 2018.

SCHAEFER, C.E.G.R.; FABRIS, J.D.; KER, J.C. **Minerals in the clay fraction of Brazilian Latosols (Oxisols): a review**. *Clay Miner.* 43, 137–154, 2008.

SILVA, B. M.; MARQUES, J. J.; SANTOS, W. **Levantamento Detalhado dos Solos da Fazenda Muquém**. UFLA, Lavras-MG, 2014. <https://www.researchgate.net/publication/270750713>

SILVA, E. E. da.; SILVA, L. M. da.; WADT, P. G. S.; MARCHAO, R. L. **Espectroscopia de infravermelho próximo na predição de propriedades químicas e físicas de solos de Roraima**. *Biota Amazônia*, v. 7, n. 2, p. 31–35, 2017.

SILVA, E.A.; GOMES, J.B.V.; FILHO, J.C.D.A.; VIDAL-TORRADO, P.; COOPER, M.; CURI, N. **Morfologia, mineralogia e micromorfologia de solos de depressões de topo de Tabuleiros Costeiros do Nordeste Brasileiro**. *Ciência e Agrotecnologia* 36, 507–517, 2012.

SILVA, S. H. G.; TEIXEIRA, A. F. D. S.; DE MENEZES, M. D.; GUILHERME, L. R. G.; MOREIRA, F. M. D. S.; CURI, N. **Multiple linear regression and random forest to predict and map soil properties using data from portable X-ray fluorescence spectrometer (pXRF)**. *Ciênc Agrotec.* 41: 648–664, 2017.

SILVA, S. H. G.; WEINDORF, D. C.; PINTO, L. C.; FARIA, W. M.; ACERBI JUNIOR, F. W.; GOMIDE, L. R.; ... CURI, N. **Soil texture prediction in tropical soils: A portable X-ray fluorescence spectrometry approach**. *Geoderma*, 362, 114136, 2020. doi:10.1016/j.geoderma.2019.114136.

SILVA, S.H.G.; POGGERE, G.C.; DE MENEZES, M.D.; CARVALHO, G.S.; GUILHERME, L.R.G.; CURI, N. **Proximal sensing and digital terrain models applied to digital soil mapping and modeling of Brazilian Latosols (Oxisols)**. *Remote Sens.* 8, 614–635, 2016. <https://doi.org/10.3390/rs8080614>.

SOUZA JÚNIOR, I. G. *et al.* **Mineralogia e susceptibilidade magnética dos óxidos de ferro do horizonte B de solos do Estado do Paraná**. *Ciência Rural*, Santa Maria, v. 40, n. 3, p. 513–519, 2010.

STUMPF, F.; SCHMIDT, K.; GOEBES, P.; BEHRENS, T.; SCHÖNBRODT-STITT, S.; WADOUX, A.; XIANG, W.; SCHOLTEN, T. **Uncertainty-Guided Sampling to Improve Digital Soil Maps**. *Catena*, 153, 30–38, 2017.

THOMPSON, J. A.; BELL, J. C.; BUTLER, C. A. **Digital elevation model resolution: effects on terrain attribute calculation and quantitative soil-landscape modeling.** In *Geoderma* (Vol. 100), 2001. www.elsevier.nl/locate/geoderma

USDA, **Soil survey manual Soil Survey Division Staff.** Soil Conservation Service Volume Handbook 18, U.S. Department of Agriculture (chapter 3), 2017.
<https://www.nrcs.usda.gov/sites/default/files/2022-09/SSM-ch3.pdf>

WEINDORF, D. C.; BAKR, N.; ZHU, Y. D. **Advances in portable X-ray fluorescence (PXRF) for environmental, pedological, and agronomic applications.** *Adv Agron.* 128: 1-45, 2014.

WERLE, R.; GARCIA, R. A.; ROSOLEM, C. A. **Lixiviação de potássio em função da textura e da disponibilidade do nutriente no solo.** *Revista Brasileira de Ciência Do Solo*, 32(6), 2297–2305, 2008. doi:10.1590/s0100-06832008000600009

ARTIGO 2 – Análise de atributos do terreno e material de origem em diferentes resoluções espaciais para predição da textura do solo

Cameau Cadostin¹, Fernanda Almeida Bócoli¹, Eduane José de Pádua¹, Renan Previl¹, Marco Aurélio Carbone Carneiro¹, Nilton Curi¹, Sérgio Henrique Godinho Silva¹

¹Universidade Federal de Lavras, Trevo Rotatório Professor Edmir Sá Santos - MG, 37203-202, Brasil

RESUMO

Os Modelos Digitais de Terreno (MDT) são fontes fundamentais para estabelecer correlações entre a ocorrência e a distribuição da fração textural dos solos. A influência dos tipos e das resoluções dos MDT na capacidade preditiva dos modelos de classificação de solos ainda é pouco estudada. Este estudo avaliou os efeitos de diferentes MDT na predição da textura dos solos no campus da UFLA. Quinze atributos do terreno (AT) derivados de diferentes MDT foram gerados. Os MDT utilizados foram obtidos a partir de curvas de nível de 1 m, com resoluções variando de 1 m a 30 m, assim como dos projetos Alos Palsar e SRTM. Os modelos preditivos foram treinados utilizando os algoritmos Random Forest e SVM com base em uma amostra de 232 pontos aleatórios coletados para a determinação da distribuição de areia, silte e argila pela técnica de pipetagem na área de estudo. A validação dos modelos foi realizada com a totalidade dos dados da área estudada. As variáveis que melhor explicaram a ocorrência das frações texturais na UFLA foram, primeiramente, o material de origem, que mostrou uma importância significativa na predição de todas as frações texturais (areia, silte e argila). Em seguida, os atributos do terreno, foram identificados *Analytical Hillshading (AH)* e *Channel Network Base Level (CNBL)* para areia, *LS-Factor (LSF)*, *Multiresolution Index of the Ridge Top Flatness (MRRTF)* e *Multiresolution Index of Valley Bottom Flatness (MRVBF)* para silte e *Channel Network Base Level (CNBL)* e *Multiresolution Index of the Ridge Top Flatness (MRRTF)* para argila. Os MDT com tamanho de pixel de 1 m e 5 m produziram correlações menos precisas. Em contrapartida, os modelos preditivos mais eficientes foram gerados a partir de MDT com resolução espacial de 10 m a 20 m, indicando que esses MDT foram os mais adequados para o relevo da área de estudo. Este estudo também demonstrou que nem sempre a resolução mais alta gera a maior precisão e acurácia. Identificar as combinações ideais de resolução de MDT e tamanho de vizinhança para produzir os mapas digitais de solos mais precisos em uma paisagem específica será extremamente útil para usuários e cientistas da ciência do solo.

Palavras-chave: atributos do terreno; modelo digital do terreno; material de origem; machine learning; textura do Solo.

1 INTRODUÇÃO

A textura do solo constitui um dos atributos físicos mais fundamentais que influenciam diretamente os processos pedológicos e o comportamento dos solos em ecossistemas naturais e agrícolas. Compreender sua distribuição espacial é essencial para a otimização das práticas agrícolas. Nos últimos vinte anos, avanços significativos em tecnologias da informação, ferramentas de Sistemas de Informação Geográfica (SIG), sensores remotos e de proximidade, assim como Modelos Digitais de Terreno (MDT), introduziram novas abordagens na ciência do solo (McBratney *et al.*, 2003). Cientistas do século XXI podem agora estudar e descrever os solos como entidades dinâmicas em um contexto paisagístico interconectado, desenvolvendo técnicas quantitativas para prever as frações texturais dos solos a partir de atributos da paisagem (Minasny *et al.*, 2008).

Nesse contexto, os Modelos Digitais de Terreno (MDT) são amplamente utilizados nas ciências do solo para compreender melhor a dinâmica da nutrição das plantas e a fertilidade dos solos (Kozak; Graham; Wiens, 2008). Assim, os MDT permitem extrair atributos de terreno, que podem ser divididos em primários e secundários, e representam medidas quantitativas da superfície topográfica (Mattivi *et al.*, 2019). Os atributos primários são derivados diretamente do MDT, como altitude, orientação, curvatura, declividade e aspecto das vertentes, entre outros (Elith; Leathwick, 2009; Manel *et al.*, 2010). Em muitos estudos, esses atributos primários têm sido utilizados como indicadores para fatores como radiação solar (Fu; Rich, 2002), evapotranspiração (Guisan; Zimmermann, 2000), fluxos superficiais e subterrâneos (Broxton; Troch; Lyon, 2009), teor de água no solo (Moore; Grayson; Ladson, 1991), vento, taxa de erosão/deposição, características dos solos (Wilson; Gallant, 2000), assim como variáveis climáticas como acúmulo e derretimento de neve (Lyon *et al.*, 2008). Os atributos secundários, por outro lado, são provenientes de análises geomorfológicas mais complexas, como os índices topográficos de umidade, energia de fluxo ou posição topográfica (Wilson; Gallant, 2000; Tagil; Jenness, 2008). Esses atributos secundários são frequentemente uma combinação de atributos primários. Por exemplo, a radiação solar combina declividade, orientação, duração de insolação e o relevo adjacente (Wilson; Gallant, 2000). Os atributos topográficos secundários, como índices de umidade (Beven; Kirkby, 1979), potência dos cursos d'água (Moore; Grayson; Ladson, 1991) ou rugosidade do terreno (Riley; Degloria; Elliot, 1999), possuem alto poder explicativo para avaliar modelos pedológicos relacionados a processos específicos na escala da paisagem.

Diversos estudos têm demonstrado o efeito da resolução dos MDT na distribuição espacial dos atributos de terreno (Chang; Tsai, 1991; Chaplot *et al.*, 2000; Schoorl *et al.*, 2000;

Wilson *et al.*, 2000; Thompson *et al.*, 2001). Por exemplo, Wilson, J. P. (2012) utilizou MDT de diferentes resoluções para explorar esse efeito em um modelo algorítmico. Da mesma forma, Chaplot *et al.* (2000) estudaram a influência da resolução em modelos de predição de hidromorfia dos solos, enquanto Schoorl *et al.* (2000) utilizaram com resoluções variadas (1 m, 3 m, 9 m, 27 m e 81 m) em um modelo chamado LAPSUS para avaliar a erosão e o depósito sedimentar. Além disso, os dados sobre o material de origem, que descrevem a composição geológica e mineralógica dos solos, interagem com os atributos de terreno em diferentes escalas espaciais, influenciando as predições de propriedades pedológicas, como os percentuais de areia, silte e argila.


Assim, este trabalho visa analisar o impacto da resolução espacial na avaliação dos atributos do terreno e explorar sua integração com os dados do material de origem para a predição da textura do solo. Comparando resoluções que variam de 1 metro a 30 metros, provenientes de diferentes fontes de MDT, incluindo ALOS e SRTM, esta pesquisa apresenta uma abordagem que combina esses dados com ferramentas estatísticas e técnicas de aprendizado de máquina para a predição da textura dos solos.

2 MATÉRIAS E MÉTODO

2.1 Localização e caracterização da área de estudo


Este estudo foi realizado no campus da Universidade Federal de Lavras (UFLA), localizado entre as latitudes 21°13'53"S e 20°37'43"S e as longitudes 44°59'41"W e 44°55'48"W, zona 23K, com uma área de 315 ha (Figura 1). A área é composta principalmente por gnaisses e gabros, com pequenas áreas próximas aos corpos d'água contendo sedimentos aluviais (Curi *et al.*, 2017). O clima é classificado como Cwa, de acordo com o sistema de classificação de Köppen, caracterizado por verões quentes e chuvosos e invernos frios e secos, com temperatura média anual de 19 °C e precipitação média anual de 1.530 mm (Alvares *et al.*, 2013; Dantas *et al.*, 2007). As pequenas áreas de terras baixas foram excluídas devido à alta variabilidade dos sedimentos que as compõem. Os solos da região pertenceram predominantemente às classes Entisols, Inceptisols, Ultisols e Oxisols, conforme os critérios das *Keys to Soil Taxonomy* (Soil Survey Staff, 2014). Os usos da terra incluem vegetação nativa, bem como áreas exploradas para o cultivo de eucalipto, pinus, café, pastagens, milho e parcelas experimentais destinadas a culturas diversificadas. A distribuição litológica da área é composta principalmente por materiais de origem, como gnaisses e gabro (Figura 2), contendo também pequenas áreas próximas a corpos d'água com sedimentos aluviais-coluviais (< 5%) (Curi *et al.*, 2017).

Figura 1 – Mapa da localização da área do estudo e dos locais georreferenciados de amostragem de solo na UFLA, estado de Minas Gerais, Brasil.



Fonte: Do autor (2025).

Figura 2 – Distribuição da matéria de origem da área de estudo.



Fonte: Do autor (2025).

2.2 Amostragem de solo e análises laboratoriais

Um total de 232 amostras de solo foram coletadas na área de estudo, sendo 116 amostras para o horizonte superficial e 116 para o horizonte subsuperficial no mesmo local (Figura 1). Destas, 180 amostras (90 amostras para cada horizonte) foram coletadas em uma grade regular de 200 m para o treinamento dos modelos, enquanto as 52 amostras restantes (26 amostras para

cada horizonte) foram coletadas aleatoriamente na área para a validação (Figura 1). As amostras foram secas ao ar, desagregadas, peneiradas a 2 mm e, em seguida, analisadas para determinar a distribuição granulométrica, seguindo o método de Gee e Bauder (1986). A fração de areia (0,05 a 2 mm) foi medida por peneiramento úmido, enquanto a fração de argila foi determinada pelo método da pipeta (Figura 1).

2.3 Criação de MDT

Neste estudo, foram criados os MDT em resoluções espaciais de 1 m, 5 m, 10 m, 20 m e 30 m a partir de uma curva de nível inicial com equidistância de 1 metro. Essas curvas foram obtidas a partir de levantamentos topográficos precisos realizados com drones de alta precisão. Elas fornecem uma representação detalhada da morfologia do terreno, essencial para a geração de MDT em diferentes resoluções. A interpolação por inverso da distância ponderada (IDW) foi utilizada para criar um MDT base com resolução de 1 m. Esse modelo inicial foi então agregado para produzir MDT em resoluções mais baixas (5 m, 10 m, 20 m e 30 m). Essa agregação foi realizada calculando a média dos valores das células em uma janela deslizante correspondente à resolução-alvo, garantindo uma representação fiel das grandes tendências do relevo, ao mesmo tempo que reduz os detalhes.

2.4 Geração de atributos do terreno (AT)

Os Modelos Digitais de Terreno (MDT) criados com resoluções de 1 m, 5 m, 10 m, 20 m e 30 m foram utilizados para gerar 15 diferentes atributos de terreno, essenciais para a predição da textura do solo (Tabela 1). A geração dos atributos de terreno foi realizada com algoritmos integrados em ferramentas especializadas do SAGA GIS. Modelos digitais do Terreno (MDT) com resolução espacial de 30 m foram utilizados para complementar as análises topográficas e gerar esses mesmos atributos de terreno. Esses MDT foram obtidos a partir de duas fontes amplamente reconhecidas por sua cobertura global e precisão: o Shuttle Radar Topography Mission (SRTM) e o ALOS PALSAR (Advanced Land Observing Satellite). Esses produtos derivados permitiram comparar o impacto de diferentes fontes de dados nos resultados finais, especialmente no contexto da modelagem da textura dos solos.

Os atributos de terreno calculados variam em função da resolução dos MDT utilizados. Os MDT de alta resolução (1 m e 5 m) oferecem detalhes precisos, capturando variações topográficas locais, como micro relevos. No entanto, podem amplificar erros nos dados e demandar grande capacidade de processamento. Por outro lado, os MDT de resolução mais baixa (20 m e 30 m) suavizam os detalhes do terreno, destacando as grandes tendências topográficas, mas podem deixar de captar estruturas mais finas.

Tabela 1 – Descrição de atributos do terreno derivados de modelos digitais de terreno.

No	Atributos do terreno (AT)	Abreviação	Breve descrição
1	<i>Altitude</i>	Alt	Designa a altura geométrica vertical entre um ponto e um referente, na maioria das vezes o nível do mar
2	<i>Analytical Hillshading</i>	AH	um mapa de declives sombreado pelo aspecto do declive
3	<i>Aspect</i>	Asp	Slope orientation
4	<i>Channel Network Base Level</i>	CNBL	ponto mais baixo ao qual um rio ou riacho pode erodir seu canal
5	<i>Channel Network Distance</i>	CND	distância vertical até o nível de base de uma rede de canais
6	<i>LS-Factor</i>	LSF	frequentemente usado para a estimativa do risco de erosão do solo
7	<i>Multiresolution Index of the Ridge Top Flatness</i>	MRRTF	Indica posições planas em áreas de grande altitude
8	<i>Multiresolution Index of Valley Bottom Flatness</i>	MRVBF	Indica superfícies planas no fundo do vale
9	<i>Plan Curvature</i>	PIC	Curvatura em um plano horizontal
10	<i>Profile Curvature</i>	PrC	Curvatura da superfície na direção da inclinação mais acentuada
11	<i>Relative Slope position</i>	RSP	Posição de um ponto dentro de uma paisagem em relação aos seus arredores
12	<i>Slope</i>	Slp	Representa inclinação angular local
13	<i>Topographic Wetness Index</i>	TWI	Descreve a tendência de cada célula de acumular água em função do relevo
14	<i>Total Catchment Area</i>	TCA	Representa a área de superfície cumulativa que alimenta água em um determinado local
15	<i>Valley Depth</i>	VD	Cálculo da distância vertical no nível da base de drenagem

Fonte: Do autor (2025).

2.5 Modelagem e predição da textura do solo

As amostras de solo foram divididas em conjuntos de dados para modelagem e validação, consistindo em 70% (n = 180 da grade regular) e 30% (n = 52 coletadas aleatoriamente) do total de dados, respectivamente. As previsões foram avaliadas usando os dados combinados de ambos os horizontes (232 amostras).

2.5.1 Random Forest

O algoritmo Random Forest (RF) foi utilizado para elaborar os modelos preditivos utilizando o software R (versão 4.3.3) (R Development Core Team, 2009), disponível no pacote R "randomForest" (Liaw; Wiener, 2015). A análise RF foi realizada com os seguintes parâmetros: um número de árvores (ntrees) fixado em 5000, um tamanho mínimo dos nós (nodesize) definido como padrão e um valor de mtry equivalente a um terço do número de variáveis preditoras, conforme as recomendações de Liaw e Wiener (2002). Além disso, o RF permite avaliar a importância das variáveis para o modelo, medindo o impacto na precisão das previsões quando uma delas é excluída, enquanto as outras variáveis é mantidas. Assim, se a

exclusão de uma variável causar um aumento no erro de predição, isso indica que essa variável desempenha um papel essencial no modelo (Breiman, 2001; Liaw; Wiener, 2002).

2.5.2 Support Vector Machine

A SVM compreende um conjunto de técnicas de aprendizado supervisionado, propostas por Cortes e Vapnik (1995), baseadas no uso de hiperplanos para a separação ideal entre as classes de um conjunto de dados (Hastie; Tibshirani; Friedman, 2009), maximizando a margem entre os pontos das duas classes mais próximas, chamados de “vetores de suporte”, levando a uma melhor probabilidade de generalização (Lief; Schmidt; Glaser, 2016). O desempenho da generalização da SVM depende de uma boa configuração dos hiperparâmetros (Cherkassky; Ma, 2004). Os parâmetros utilizados para ajustar o modelo no pacote Caret (Kuhn *et al.*, 2020) incluem a penalidade (custo), que controla o equilíbrio entre erros de margem e erros de treinamento, e a largura do kernel (sigma), que controla o grau de não linearidade do modelo (Naghbi; Ahmadi; Daneshi, 2017).

2.6 Validação de predições

Após a realização das predições, elas foram validadas com um conjunto independente de amostras (26 amostras para os horizontes A e B separadamente e 52 amostras de solo para os horizontes A e B combinados). A precisão e a acurácia das predições dos teores de areia, silte e argila pelo algoritmo RF foram avaliadas respectivamente comparando os valores preditos e observados por meio do coeficiente de determinação (R^2) (Equação 1) e do erro quadrático médio (RMSE) (Equação 2). Os modelos com maiores valores de R^2 e menor valores de RMSE foram considerados os melhores para predizer as análises laboratoriais utilizando dados de sensores proximais.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{i_{obs}} - y_{i_{pred}})^2}{\sum_{i=1}^n (y_{i_{obs}} - y_{i_{mob}})^2} \quad (1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{i_{pred}} - y_{i_{obs}})^2}{n}} \quad (2)$$

Onde: $y_{i_{obs}}$: representa os valores observados na análise laboratorial; $y_{i_{pred}}$: representa os valores estimados; $y_{i_{mob}}$: representa a média dos dados observados; n : número de pontos de observação.

3 RESULTADOS ET DISCUSSÃO

3.1 Estatística descritiva da fração textural

Os resultados mostram uma variação significativa das frações texturais entre os horizontes A e B, refletindo os processos pedogenéticos e as dinâmicas de redistribuição de partículas (Tabela 2). Para o horizonte superficial, o teor médio de argila foi de 43,7%, com uma variabilidade moderada ($CV = 23,1\%$). A ampla faixa de variação (19,0–73,0%) indicando uma influência marcante das condições locais. O silte com uma média de 23,0%, apresentou uma variabilidade elevada ($CV = 37,5\%$), destacando diferenças importantes nos processos de transporte e acumulação. A proporção média da areia foi de 33,3%, com uma forte variabilidade ($CV = 37,9\%$), sugerindo impactos significativos dos processos erosivos e dos depósitos. Por outro lado, no horizonte subsuperficial, o teor da argila foi nitidamente mais elevado (55,3 %), o que é típico dos processos de iluviação. A variabilidade mais baixa ($CV = 20,6\%$) reflete uma acumulação mais homogênea. A proporção média do silte foi mais baixa (14,6%), com uma variabilidade muito elevada ($CV = 52,6\%$), indicando uma distribuição irregular ou um transporte para fora deste horizonte. A areia apresenta uma média de 30,1%, a variabilidade continua elevada ($CV = 37,1\%$), embora ligeiramente mais homogênea do que no horizonte superficial. O horizonte subsuperficial foi caracterizado por uma acumulação importante e homogênea de argila, ligada aos processos de iluviação. Em contraste, o horizonte superficial apresenta uma maior riqueza em silte e uma variabilidade textural mais acentuada, sob a influência dos processos de superfície (erosão e depósitos).

Tabela 2 – Análise descritiva de textura do solo do campus da UFLA.


HORIZONTE	FRAÇÃO	MÉDIA	MIN	MAX	SD	CV
Superficial	Argila	43,7	19,0	73,0	10,1	23,1
Superficial	Silte	23,0	5,0	46,0	8,6	37,5
Superficial	Areia	33,3	7,0	60,0	12,6	37,9
Subsuperficial	Argila	55,3	29,0	76,0	11,4	20,6
Subsuperficial	Silte	14,6	0,0	38,0	7,7	52,6
Subsuperficial	Areia	30,1	11,0	63,0	11,2	37,1

Fonte: Do autor (2025).

A análise textural dos solos revela uma distribuição característica dos tamanhos de partículas nas amostras estudadas (Figura 3). O diagrama triangular textural revelou uma concentração marcante das amostras nas zonas dominadas pela argila, com a maioria dos pontos agrupados na parte superior central do diagrama. Essa distribuição indica que os solos da área de estudo foram caracterizados por um teor de argila relativamente elevado, geralmente entre 40% e 70%. As principais classes texturais representadas nas amostras são: Argila (Cl), Argila

siltosa (SiCl), Silte argiloso (ClLo) e Silte argilo-siltoso (SiClLo). É notável a quase ausência de amostras nas regiões dominadas pela areia (Sa) e pelo silte (Si) do triângulo textural, sugerindo uma variabilidade espacial limitada em termos de solos de textura grossa na área de estudo.

Figura 3 – Classificação textural (USDA, 2017) das amostras de solo coletadas da UFLA.



Fonte: Do autor (2025).

3.2 **Análise de desempenho conforme das resoluções (Random Forest)**

O desempenho do modelo Random Forest foi avaliado em diferentes resoluções (de 1m a 30m, incluindo MDT derivados como 30m_ALOS e 30m_SRTM) em termos de RMSE (Root Mean Squared Error) e R² para as seguintes frações texturais (Tabela 3):

Para a areia, o RMSE diminui de 10,22 (1m) para 9,39 (20m), indicando uma melhor predição com resoluções intermediárias. Observa-se um aumento para resoluções mais grosseiras, especialmente com o 30m_ALOS (10,13). O R² passa de 0,28 (1m) para um máximo de 0,42 (20m), sugerindo uma melhor capacidade explicativa do modelo a 20m. O R² diminui em seguida com resoluções mais grosseiras, confirmando uma perda de precisão do modelo. Silte, o RMSE foi mais baixo em 7,09 (20m), confirmando uma melhor predição nessa resolução. Os valores aumentam novamente para os MDT derivados (por exemplo, 7,96 para 30m_ALOS). O R² foi nulo (0) a 1m, o que indica a ausência de relação explicada pelo modelo nessa resolução. O R² atinge um máximo de 0,29 (20m), confirmando uma melhor explicabilidade nessa resolução intermediária. Argila, o RMSE diminui de 11,94 (1m) para 9,75 (20m), atingindo seu mínimo nessa resolução. Ele aumenta ligeiramente para 10,28

(30m_ALOS) e 10,54 (30m_SRTM), mostrando uma degradação da precisão. O R^2 foi mais baixo a 1m (0,09), mas aumenta regularmente até atingir um máximo de 0,44 (30m_ALOS). Isso indica que, embora o RMSE seja mais elevado para o 30m_ALOS, o modelo capta melhor a variabilidade dos dados nessa resolução. Como vários estudos relataram que os atributos do terreno são sensíveis à resolução do DEM (Walker; Willgoose, 1999; Kumar; Verdin; Greenlee, 2000; Thompson; Bell; Butler, 2001; Wu; Li; Huang, 2007; Schunemann, 2016).

As resoluções intermediárias, especialmente 20 m, ofereceram um compromisso ideal entre precisão (RMSE baixo) e explicabilidade (R^2 elevado) para todas as frações texturais (Figura 4). Nessa resolução, o modelo Random Forest capturou bem as relações entre os atributos do terreno, o material de origem e as frações texturais. Resoluções muito finas, como 1 m e 5 m, apresentam RMSE mais altos e R^2 mais baixos para a maioria das frações. Isso pode ser explicado pelo excesso de ruído nos dados nessas resoluções, o que reduz a capacidade do modelo de generalizar. Também parecem menos eficazes, provavelmente devido ao ruído ou à superespecificação de detalhes do terreno que não refletem diretamente as variações da textura do solo. Como muitos autores confirmam, a melhor resolução disponível do MDT nem sempre apresentará melhores resultados (Thompson; Bell; Butler, 2001; Leempoel *et al.*, 2015). Sorensen e Seibert (2007) e Samuel-Rosa *et al.* (2015) relataram que, em alguns casos, um MDT de baixa resolução foi mais útil para a análise e modelagem dos solos.

Tabela 3 – Coeficiente de determinação (R^2) e Root Mean Square Error (RMSE) para os modelos de predição das frações de argila, silte e areia da UFLA via Random Forest.

<i>Random Forest</i>	Areia		Silte		Argila	
Resolução	RMSE	R2	RMSE	R2	RMSE	R2
1m	10,22	0,28	8,8	0	11,94	0,09
5m	9,77	0,36	7,97	0,11	10,84	0,23
10m	9,48	0,41	7,27	0,26	10,19	0,35
20m	9,39	0,42	7,09	0,29	9,75	0,42
30m	9,87	0,35	7,11	0,27	10,13	0,34
30m_alos	10,13	0,31	7,96	0,05	10,28	0,44
30m_SRTM	9,92	0,38	7,86	0,08	10,54	0,31

Fonte: Do autor (2025).

3.3 Análise de desempenho conforme das resoluções (SVM)

O desempenho do modelo SVM (Support Vector Machine) foi avaliado em diferentes resoluções espaciais (Tabela. 4). Os resultados da areia mostraram uma diminuição do RMSE ligeiramente de 10,5 (1m) para 9,76 (10m), antes de aumentar para 10,86 (30m) e atingir um máximo de 11,17 (30m_SRTM). Isso indicou que resoluções mais finas ou muito grosseiras não capturaram de forma eficaz as relações entre areia e os atributos do terreno. Behrens, Zhu,

Schmidt e Scholten (2010) apontaram que escolher diferentes resoluções para diferentes variáveis entre os atributos do solo forneceram resultados distintos e produzir modelos com melhor desempenho. O R^2 foi baixo no geral, atingindo um máximo de 0,37 (10m). O desempenho foi moderado, com um R^2 máximo de 0,37 (10m). Isso indicou relações complexas entre areia e os atributos topográficos, exigindo mais variáveis explicativas. Para o silte, o RMSE foi o mais baixo em 6,98 (10m), confirmando um melhor desempenho nessa resolução intermediária. Os RMSE aumentaram para os MDT derivados, especialmente com 7,87 (30m_ALOS). O R^2 foi muito baixo para resoluções finas, com um mínimo de 0,02 (1m) e um máximo de 0,27 (10m). Isso mostrou que o modelo teve dificuldade em explicar a variabilidade da fração silte, especialmente para resoluções finas. Para a argila, o RMSE diminuiu de 11,04 (1 m) para 9,8 (20m), atingindo um valor mínimo nessa resolução. Observou-se um ligeiro aumento para resoluções mais grosseiras, mas os MDT derivados continuaram competitivos. O R^2 foi mais baixo em 1 m (0,22), mas atinge um máximo de 0,37 (20 m). Isso sugeriu que a fração de argila foi melhor modelada em resoluções intermediárias. A argila apresentou o melhor desempenho global, com um R^2 atingindo 0,37 (20 m), indicando que essa fração está mais fortemente correlacionada com as variáveis.

As resoluções finas (1m e 5m) foram ruins para todas as frações texturais (baixo R^2 e RMSE elevados). Isso confirmou, de forma geral, alguns dos comportamentos de escala hipotetizados por Pain (2005) e Thompson *et al.* (2001), com escalas mais finas sendo necessárias apenas em áreas morfologicamente mais complexas. As resoluções intermediárias (10m e 20m) ofereceram desempenho ótimo para todas as frações, com RMSE mínimo e R^2 máximo para areia e silte a 10m e RMSE mínimo e R^2 máximo para argila a 20m. Para as resoluções grossas (30m, MDT derivados), o desempenho piora a 30m para areia e silte, com R^2 mais baixos e RMSE mais altos. Os dados MDT derivados (30m_ALOS e 30m_SRTM) apresentaram desempenho ligeiramente inferior às resoluções intermediárias, mas permaneceram competitivos para Argila ($R^2 = 0.31$ para 30m_SRTM). A fração argila foi melhor correlacionada com as variáveis explicativas, o que explicou seu melhor desempenho global. A areia e silte necessitaram variáveis adicionais (dados pedológicos, climáticos) para melhorar a modelagem. O modelo SVM mostrou um potencial interessante para modelar as frações texturais, mas seu desempenho foi limitado para algumas frações e resoluções, destacando a importância de uma seleção cuidadosa dos dados e das resoluções espaciais (Figura 4).


Tabela 4 – Coeficiente de determinação (R^2) e Root Mean Square Error (RMSE) para os modelos de predição das frações de argila, silte e areia da UFLA via Support Vector Machine.

<i>SVM</i>	Areia		Silte		Argila	
Resolução	RMSE	R2	RMSE	R2	RMSE	R2
1m	10,5	0,26	8,49	0,02	11,04	0,22
5m	10,64	0,23	8,48	0,02	11,65	0,12
10m	9,76	0,37	6,98	0,27	10,66	0,25
20m	9,91	0,33	7,21	0,26	9,8	0,37
30m	10,86	0,25	7,18	0,26	9,87	0,36
30m_alos	10,78	0,22	7,87	0,07	10,74	0,24
30m_SRTM	11,17	0,21	7,41	0,17	10,27	0,31

*Support Vector Machine

Fonte: Do autor (2025).

Figura 4 – Gráficos de tendências das diferentes resoluções dos MDT do campus da UFLA.



*MDT- Modelo Digital de Terreno

Fonte: Do autor (2025).

3.4 Resolução optimal global (10-20 m)

Os resultados mostram que resoluções intermediárias, como 10 m e 20 m, foram ideais para modelar as relações entre as frações texturais e os atributos do terreno. Essas resoluções oferecem uma melhor combinação de detalhes topográficos e capacidade de generalização do modelo. Argila e areia apresentam RMSE mais altos e R^2 mais baixos em comparação com o silte, sugerindo relações mais complexas ou uma distribuição mais variável para essas frações. A fração silte mostra RMSE globalmente mais baixos, o que pode indicar uma relação mais direta com os atributos topográficos. A predição da argila e da areia foi mais confiável do que a do silte. Isso pode indicar que essas frações texturais foram mais influenciadas pelos atributos

do terreno e pelos materiais de origem, enquanto o silte pode estar menos correlacionado com essas variáveis.

Esses resultados estão em conformidade com os estudos de Thompson *et al.* (2001), Smith *et al.* (2006) e Wu *et al.* (2008), nos quais, à medida que a resolução espacial do MDT é reduzida (aumenta o tamanho do pixel), ocorre a perda de detalhamento nos atributos do terreno. Os MDT com menor tamanho de pixel não são necessariamente considerados as melhores fontes de informações para gerar variáveis preditoras de solos (Cavazzi *et al.*, 2013). Outros autores, como Kienzle (2004), observaram que as variáveis do terreno podem variar significativamente com a mudança no tamanho da célula do MDT. Deng e Wilson (2006) também relataram que as variáveis respondem de maneiras distintas à alteração da resolução, especialmente quando a resolução é aumentada. Sorensen e Seibert (2007) mapearam diversos índices topográficos calculados para diferentes MDT.

3.5 Importância de variáveis das predições

A figura 5 apresenta a importância relativa das variáveis geomorfológicas e do material de origem na predição das frações texturais do solo. Os valores indicam o peso ou a contribuição relativa de cada variável no modelo.

A predição da argila, da areia e do silte foi fortemente influenciada pelo material de origem (Mat_orig), pois a composição do material de origem determina o tamanho das partículas e sua resistência à erosão (Mancini *et al.*, 2019). Isso é válido para todos os MDT (1m, 5m, 10m, 20m, 30m, 30m_Alos, 30m_SRTM). A forte influência do material de origem (Mat_orig) na predição da areia foi explicada pela relação direta entre a composição do material de origem e os processos pedogenéticos (Stockmann *et al.*, 2016). O material de origem controlou a textura do solo determinando a proporção de areia, silte e argila. Rochas ricas em minerais resistentes (como o quartzo) Gnaisse produzem mais partículas arenosas, enquanto minerais mais alteráveis contribuem para a formação de argila ou silte, como o Gabro. Isso permanece válido para todos os (MDT), independentemente de sua resolução, pois o material de origem atua como um fator fundamental e invariável. A contribuição do material de origem foi predominante, sugerindo que a composição geológica (gabro, rico em ferro e magnésio, e gnaisse, rico em quartzo) determina em grande parte a proporção das frações texturais. Muitos estudos mostraram que a variabilidade do solo é melhor explicada pelo material original do solo (Curi *et al.*, 1990).

As variáveis como CNBL (*Channel Network Base Level*) teve uma importância notável na predição da areia e da argila. O CNBL é uma medida que reflete a posição na rede de drenagem, indicando se uma área está próxima de um rio ou em um ponto baixo do relevo. Os

solos próximos ao CNBL são mais propensos a conter argila e outras partículas finas, enquanto as áreas mais distantes do CNBL, onde os processos erosivos predominam, tendem a acumular mais areia (Campos *et al.*, 2020; Giasson *et al.*, 2013; Ten Caten *et al.*, 2012; Bock; Köthe, 2008). Isso se deve à baixa energia dos cursos da água dessas áreas, o que favoreceu a decantação das partículas mais finas, como a argila.

AH (*Analytical Hillshading*) teve uma forte influência na predição da areia, pois reflete a exposição do relevo à luz e influencia indiretamente os processos de alteração e erosão. As áreas expostas recebem mais calor e radiação, o que acelera a alteração mecânica e química do material de origem, favorecendo a produção de areia. Além disso, as variações na iluminação estão associadas a gradientes de declive e drenagem, que influenciam a distribuição das partículas arenosas (Gobat; Duckert; Gallandat, 1989; Burga *et al.*, 2010).

MRRTF (*Multiresolution Index of the Ridge Top Flatness*) influenciou a predição de argila e silte ao capturar os processos relacionados às zonas de cristas planas e estáveis. Essas zonas, menos propensas à erosão, favoreceram uma alteração química prolongada dos minerais do material de origem (ex. Gabro, Basalto), o que gera argila (Gallant *et al.*, 2013). Além disso, as cristas também permitem a acumulação de partículas silte provenientes de uma alteração parcial antes de sua transformação completa em argila ou seu transporte. Assim, o MRRTF reflete ambientes de estabilidade geomorfológica essenciais para a formação e conservação das partículas finas, tornando-o determinante para a predição de argila e silte.

As variáveis como LSF (*LS-Factor*) e MRVBF (*Multiresolution Index of Valley Bottom Flatness*) foram predominantes na predição do silte. Explica-se pelos processos geomorfológicos e hidrológicos que capturam, os quais estão diretamente relacionados à distribuição espacial das partículas silte no solo. O LSF representa o fator comprimento-declive, que descreve o potencial de erosão em uma área. Durante a erosão, as partículas de silte estão facilmente transportadas pela água, mas depositaram-se assim que a velocidade do fluxo diminuiu, especialmente em zonas intermediárias. O LSF permitiu identificar as áreas onde o transporte de partículas é ativo, mas onde depósitos intermediários de silte ocorreu devido a mudanças na topografia (Panagos *et al.*, 2015). O MRVBF identifica as zonas planas nos fundos de vales, que são ambientes de depósito de partículas finas transportadas das encostas (Gallant; Dowling, 2013). Essas zonas formam bacias de acumulação para o silte, que se deposita quando a energia dos fluxos diminuiu.

Figura 5 – Importância de variáveis dos melhores modelos de predição de conteúdos de areia, silte e argila de solos da UFLA.

(Continua)





Figura 5 – Importância de variáveis dos melhores modelos de predição de conteúdos de areia, silte e argila de solos da UFLA.

(Conclusão)



Fonte: Do autor (2025).

3.6 Influência dos atributos do terreno na fração textural do solo

Os atributos do terreno desempenham um papel essencial na distribuição das frações texturais do solo, especialmente a areia, o silte e a argila. Na literatura, vários estudos demonstraram que essas variáveis topográficas influenciam diretamente os processos de erosão, transporte e deposição das partículas do solo.


A inclinação influencia significativamente a dinâmica das frações texturais do solo. Uma forte inclinação favorece a erosão das partículas finas, aumentando assim a proporção de areia nas zonas de maior altitude, enquanto o silte e a argila são mais transportados para as áreas baixas, onde se acumulam (Thompson *et al.*, 2001; Wilson; Gallant, 2000). O índice de umidade

topográfica (TWI) reflete a capacidade de uma área de acumular água e sedimentos finos: nas zonas com alta umidade, observa-se um aumento nos teores de silte e argila, enquanto a areia geralmente diminui (Böhner; Selige, 2006; Gessler *et al.*, 1995; Moore *et al.*, 1993). A influência da rede de drenagem, representada por índices como o *Catchment Network of Basin Location* (CNBL) e a profundidade do vale (VD), também é determinante. As zonas próximas aos cursos d'água favorecem a deposição de sedimentos ricos em areia e argila, dependendo da dinâmica de transporte sedimentar (Grimaldi *et al.*, 2007; Conrad, 2012). Além disso, índices como o *MRRTF* e *MRVBF* desempenham um papel crucial na alteração prolongada dos minerais e na formação de argila, favorecendo assim seu acúmulo em áreas de relevos planos e estáveis (Pinheiro *et al.*, 2018).

Outras variáveis, como a orientação da inclinação (aspecto) e o sombreamento de colina (Hillshade), influenciam indiretamente a distribuição das frações texturais, modulando a exposição ao sol e a umidade do solo. As áreas sombreadas e úmidas tendem a acumular mais silte e argila, enquanto as áreas expostas ao sol sofrem uma evaporação mais rápida, favorecendo a presença de areia (Wilson; Gallant, 2000). Os parâmetros como a curvatura do terreno (PIC, PrC) e a altitude também modulam a distribuição das partículas texturais. As formas convexas favorecem a erosão e a perda de partículas finas, enquanto as formas côncavas e as baixas altitudes favorecem o acúmulo de silte e argila (Hall; Olson, 1991; Gessler *et al.*, 1995; Figueiredo, 2006).

No entanto, no contexto deste estudo, a figura 6 mostrou os atributos que influenciaram muito a previsão da fração textural dos solos na área de estudo. Como explicado na seção anterior (seção 3.5), temos: *Analytical Hillshading* (AH), *LS-Factor* (LSF), *Channel Network Base Level* (CNBL), *Multiresolution Index of Ridge Top Flatness* (MRRTF) e *Multiresolution Index of Valley Bottom Flatness* (MRVBF). Assim, compreender as relações entre os atributos do terreno e a textura do solo é essencial para aprimorar os modelos de previsão espacial e melhorar a cartografia digital dos solos.

Figura 6 – Influência dos atributos de terreno na areia, silte e argila de acordo com o número de MDT no campus da UFLA.



*Número de MDT: 1m, 5m, 10m, 20m, 30m, 30m_Alos e 30m_SRTM.

Fonte: Do autor (2025).

4 CONCLUSÃO

Este estudo destacou a importância dos atributos do terreno e do material de origem na predição da textura do solo na UFLA, considerando diferentes resoluções espaciais de Modelos Digitais de terreno (MDT). Os resultados demonstraram que o material de origem foi um fator determinante na distribuição das frações texturais (areia, silte e argila), evidenciando sua influência direta nos processos de formação do solo. Além disso, atributos do terreno, como o *Analytical Hillshading* (AH), *LS-Factor* (LSF), *Channel Network Base Level* (CNBL), o *Multiresolution Index of Ridge Top Flatness* (MRRTF) e o *Multiresolution Index of Valley*

Bottom Flatness (MRVBF), mostraram-se relevantes para a predição das diferentes frações texturais. Em relação às resoluções espaciais, observou-se que MDT com resolução de 10 a 20 m proporcionaram modelos preditivos mais precisos, enquanto resoluções mais finas (1 m e 5 m) nem sempre resultaram em melhor desempenho. Esses achados reforçam que a escolha da resolução ideal depende das características da paisagem e dos processos pedogenéticos envolvidos. Conclui-se que a integração de dados de sensoriamento proximal, atributos do terreno derivados de MDT e algoritmos de aprendizado de máquina constitui uma abordagem eficaz para a análise digital do solo. Esta pesquisa destaca a importância de uma abordagem multidimensional para a predição da textura do solo. Os resultados obtidos abrem caminho para estudos futuros, permitindo aprimorar os modelos preditivos e contribuir para práticas de gestão sustentável do solo na região de Lavras.

AGRADECIMENTOS

Os autores agradecem Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Coordenação de Aperfeiçoamento Pessoal de Nível Superior (CAPES), Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), para apoio financeiro e bolsas de estudo.

REFERÊNCIAS

- ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; DE MORAES GONÇALVES, J.L.; SPAROVEK. **Köppen's climate classification map for Brazil**. Meteorol. Z. 22, 711–728, 2013. <https://doi.org/10.1127/0941-2948/2013/0507>.
- BEHRENS, T.; ZHU, A.X.; SCHMIDT, K.; SCHOLTEN, T. **Multi-scale digital terrain analysis and feature selection in digital soil mapping**. Geoderma, 155:175-185, 2010.
- BEVEN, K.J.; KIRKBY, M.J. **A physically based, variable contributing area model of basin hydrology**. Hydrological Sciences Bulletin, 24, 43–69, 1979.
- BOCK, K. R. **Predicting the depth of hydromorphic soil characteristics influenced by ground water**. In: SAGA-secoads Out. Hamburg: Universität Hamburg, Institut für Geographie, v. 2. p. 13-22, 2008.
- BÖHNER, J.; KÖTHE, R.; CONRAD, O.; GROSS, J.; RINGELER, A.; SELIGE, T. **Soil regionalisation by means of terrain analysis and process parameterisation**. In: Micheli E, Nachtergaele FO, Jones RJA, Montanarella L, editors. Soil Classification 2001. Luxembourg: European Communities; p. 213-22, 2002. (European Soil Bureau Research Report No. 7).
- BREIMAN, L. **Random forests**. Mach. Learn. 45, 5–32, 2001.
- BROXTON, P.D.; TROCH, P.A.; LYON, S.W. **On the role of aspect to quantify water transit times in small mountainous catchments**. Water Resources Research, 45, W08427, 2009.
- BURGA, C.A.; KRUSI, B.; EGLI, M.; WERNLI, M.; ELSENER, S.; ZIEFLE, M.; FISCHER, T.; MAVRIS, C. **Plant succession and soil development on the foreland of the Morteratsch glacier (Pontresina, Switzerland): straight forward or chaotic**. Flora-Morphology, Distribution, Functional Ecology of Plants, 205, 561–576, 2010.
- CAMPOS, A. R., *et al.* **Selection of Environmental Covariates for Classifier Training Applied in Digital Soil Mapping**, 2020.
- CAVAZZI, S.; CORSTANJE, R.; MAYR, T.; HANNAM, J.; FEALY, R. **Are fine resolution digital elevation models always the best choice in digital soil mapping?** Geoderma, 195/196:111-121, 2013.
- CHANG, K.; TSAI, B. **The effect of DEM resolution on slope and aspect mapping**. Cartography and Geographic Information Systems 18, 69–77, 1991.
- CHAPLOT, V.; WALTER, C.; CURMI, P. **Improving soil hydromorphy prediction according to DEM resolution and available pedological data**. Geoderma 97, 405–422, 2000.
- CHERKASSKY, V.; MA, Y. **Practical selection of SVM parameters and noise estimation for SVM regression**. Neural Netw. 17, 113–126, 2004. [https://doi.org/10.1016/S0893-6080\(03\)00169-2](https://doi.org/10.1016/S0893-6080(03)00169-2).
- CORTES, C.; VAPNIK, V. **Support-vector networks**. Mach. Learn. 20, 273–297, 1995.
- CURI, N.; FRANZMEIER, D. P. **Toposequence of Oxisols from the Central Plateau of Brazil: II. Mineralogy**. Soil Science Society of America Journal, 54(2), 449–455, 1990.
- CURI, N.; SILVA, S.H.G.; POGGERE, G.C.; MENEZES, M.D. **Mapeamento de solos e magnetismo no campus da UFLA**. Editora UFLA, Lavras, 2017.
- DANTAS, A.A.A.; CARVALHO, L.G. De.; FERREIRA, E. **Climatic classification and tendencies in Lavras region, MG**. Ciência e Agrotecnologia 31, 1862–1866, 2007.

DENG, Y.; WILSON, J.P. **The role of attribute selection in GIS representations of the biophysical environment.** *Annals of Association of American Geographers*, 96, pp. 47–63, 2006.

ELITH, J.; LEATHWICK, J.R. **Species distribution models: ecological explanation and prediction across space and time.** *Annual Review of Ecology, Evolution, and Systematics*, 40, 677–697, 2009.

FIGUEIREDO, S.R. **Mapeamento supervisionado de solos através do uso de regressões logísticas múltiplas e sistema de informações geográficas** [dissertação]. Porto Alegre: Universidade Federal do Rio Grande do Sul; 2006.

FU, P.; RICH, P.M. **A geometric solar radiation model with applications in agriculture and forestry.** *Computers and Electronics in Agriculture*, 37, 25–35, 2002.

GALLANT, J.; DOWLING, T.; AUSTIN, J. **Multi-resolution Ridge Top Flatness (MrRTF).** v2. CSIRO. Data Collection, 2013. <https://doi.org/10.4225/08/56EA312A5E63B>

GEE, G.W.; BAUDER, J.W. **Particle-size analysis. Methods of Soil Analysis.** Part 1 – Physical and Mineralogical Methods. Soil Science Society of America, American Society of Agronomy, pp. 383–411, 1986. <https://doi.org/10.2136/sssabookser5.1.2ed.c15>.

GESSLER, P.E.; MOORE, I.D.; MCKENZIE, N.J.; RYAN, P.J. **Soil-landscape modelling and spatial prediction of soil attributes.** *IntJ Geogr Inf Syst.* 9:421–32, 1995. <https://doi.org/10.1080/02693799508902047>

GIASSON, E.; HARTEMINK, A.E.; TORNQUIST, C.G.; TESKE, R.; BAGATINI, T. **Avaliação de cinco algoritmos de árvores de decisão e três tipos de modelos digitais de elevação para mapeamento digital de solos a nível semidetalhado na Bacia do Lageado Grande, RS, Brasil.** *Ci. Rural*, 43:61–67, 2013.

GOBAT, J.M.; DUCKERT, O.; GALLANDAT, J.D. **Quelques relations ‘microtopographie-sols-vegetation dans les pelouses pseudo-alpines du Jura suisse: exemples d’un systeme naturel et d’un systeme anthropise.** Societe neuchateloise des sciences naturelles, 1989.

GUISAN, A.; ZIMMERMANN, N.E. **Predictive habitat distribution models in ecology.** *Ecological Modelling*, 135, 147–186, 2000.

HALL, G.F.; OLSON, C.G. **Predicting variability of soils from landscape models.** In: **Mausbach MJ, Wilding LP, editors. Spatial variabilities of soils and landforms.** Madison: Soil Science Society of America; 1991. p. 9–24. <https://doi.org/10.2136/sssaspecpub28.c2>

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction.** Springer, New York (745p), 2009.

KIENZLE, S. **The effect of DEM raster resolution on first order, second order and compound terrain derivatives.** *Transactions in GIS*, 8, pp. 83–112, 2004.

KOZAK, K.H.; GRAHAM, C.H.; WIENS, J.J. **Integrating GIS-based environmental data into evolutionary biology.** *Trends in Ecology & Evolution*, 23, 141–148, 2008.

KUHN, M.; WING, J.; WESTON, S.; WILLIAMS, A.; KEEFER, C.; ENGELHARDT, A.; COOPER, T.; MAYER, Z.; KENKEL, B.; BENESTY, M.; LESCARBEAU, R.; ZIEM, A.; SCRUTTA, L.; TANG, Y.; CANDAN, C.; HUNT, T. **Caret: classification and regression training.** R package version 6, 0–85, 2020.

KUMAR, P.; VERDIN, K.L.; GREENLEE, S.K. **Basin level statistical properties of topographic index for North America.** *Adv. Water Resour.* 23, 571–578, 2000. [https://doi.org/10.1016/S0309-1708\(99\)00049-4](https://doi.org/10.1016/S0309-1708(99)00049-4).

LEEMPOEL, K.; PARISOD, C.; GEISER, C.; DAPRÀ, L.; VITTOZ, P.; JOOST, S. **Very high-resolution digital elevation models: are multi-scale derived variables ecologically relevant?** *Methods Ecol. Evol.* 6, 1373–1383, 2015. <https://doi.org/10.1111/2041-210X.12427>.

LIAW, A.; WIENER, M. **Classification and regression by random forest.** *R News* 2, 18–22, 2002.

LIAW, A.; WIENER, M. **Package R randomForest.** R Dev. Core Team, 2015. <https://doi.org/10.5244/C.22.54>.

LIEß, M.; SCHMIDT, J.; GLASER, B. **Improving the spatial prediction of soil organic carbon stocks in a complex Tropical Mountain landscape by methodological specifications in machine learning approaches.** *PLoS One* 11, 1–22, 2016. <https://doi.org/10.1371/journal.pone.0153673>.

LYON, S.W.; TROCH, P.A.; BROXTON, P.D.; MOLOTCH, N.P.; BROOKS, P.D. **Monitoring the timing of snowmelt and the initiation of streamflow using a distributed network of temperature/light sensors.** *Ecohydrology*, 1, 215–2, 2008.

MANCINI, F.; D'ELIA, A.; GALLI, A.; BITELLI, G. **Soil texture prediction using remote sensing and digital elevation models: A case study.** *International Journal of Applied Earth Observation and Geoinformation*, 78, 150–160, 2019.

MANEL, S.; JOOST, S.; EPPERSON, B.K.; HOLDEREGGER, R.; STORFER, A.; ROSENBERG, M.S.; SCRIBNER, K.T.; BONIN, A.; FORTIN, M.-J. **Perspectives on the use of landscape genetics to detect genetic adaptive variation in the field.** *Molecular Ecology*, 19, 3760–3772, 2010a.

MATTIVI, P.; FRANCI, F.; LAMBERTINI, A.; BITELLI, G. **TWI computation: a comparison of different open source GISs.** *Open Geospatial Data, Software and Standards* 4-6, 2019. <https://doi.org/10.1186/s40965-019-0066-y>.

MCBRATNEY, A.B.; MENDONCA SANTOS, M.L.; MINASNY, B. **On digital soil mapping.** *Geoderma* 117, 3–52, 2003.

MINASNY, B.; MCBRATNEY, A.B.; SALVADOR-BLANES, S. **Quantitative models for pedogenesis a review.** *Geoderma* 144, 140–157, 2008.

MOORE, I.D.; GRAYSON, R.B.; LADSON, A.R. **Digital terrain modelling: a review of hydrological, geomorphological, and biological applications.** *Hydrological Processes*, 5, 3–30, 1991.

NAGHIBI, S.A.; AHMADI, K.; DANESHI, A. **Application of support vector machine, random forest, and genetic algorithm optimized random forest models in groundwater potential mapping.** *Water Resour. Manag.* 31, 2761–2775, 2017. <https://doi.org/10.1007/s11269-017-1660-3>

PAIN, C.F. **Size does matter: relationships between image pixel size and landscape process scales.** *MODSIM 2005 International Congress on Modeling and Simulation*, pp. 1430–1436, 2005.

PANAGOS, P.; BORRELLI, P.; MEUSBURGER, K.; ALEWELL, C.; LUGATO, E.; MONTANARELLA, L. **Estimating the soil erosion cover-management factor at the European scale.** *Land Use Policy*, 48, 38–50, 2015. <https://doi.org/10.1016/j.landusepol.2015.05.021>

PINHEIRO, H. S. K.; CARVALHO JUNIOR, W. De; CHAGAS, C. DA S.; ANJOS, L. H. C. DOS; OWENS, P. R. **Prediction of Topsoil Texture Through Regression Trees and Multiple Linear Regressions**. Revista Brasileira de Ciência Do Solo, 42(0), 2018. doi:10.1590/18069657rbc20170167

R Development Core Team. **R: A Language and Environmental for Statistical Computing**. R Found. Stat. Comput, 2009.

RILEY, S.J.; DEGLORIA, S.D.; ELLIOT, R. **A terrain ruggedness index that quantifies topographic heterogeneity**. Intermountain Journal of Sciences, 5, 23– 27, 1999.

SAMUEL-ROSA, A.; DALMOLIN, R.S.D.; MIGUEL, P. **Building predictive models of soil particle-size distribution**. Rev Bras Ciênc Solo 37, 422–430, 2013. <https://doi.org/10.1590/S0100-06832013000200013>

SCHOORL, J.M.; SONNEVELD, M.P.W.; VELDKAMP, A. **Three-dimensional landscape process modeling: the effect of DEM resolution**. Earth Surface Processes and Landforms 25, 1025–1034, 2000.

SCHUNEMANN, A.L. **Geotecnologias para mapeamento digital na Antártica marítima**. Doctoral thesis - Universidade Federal de Viçosa, Viçosa, p. 2016.

SMITH, M.P.; ZHU, A.-X.; BURT, J.E.; STILES, C. **The effects of DEM resolution and neighborhood size on digital soil survey**. Geoderma, 137:58-69, 2006.

Soil Survey Staff. **Keys to Soil Taxonomy**. 12th ed. USDA-NRCS, 2014. Available online at: https://www.nrcs.usda.gov/wps/portal/nrcs/detail/soils/survey/class/taxonomy/?cid=nrcs142p2_053580

SORENSEN, R.; SEIBERT, J. **Effects of DEM resolution on the calculation of topographical indices: TWI and its componentes**. J. Hydrol. 347, 79–89, 2007. <https://doi.org/10.1016/J.JHYDROL.2007.09.001>.

STOCKMANN, U.; MINASNY, B.; MCBRATNEY, A. B. **How fast does soil change?: Developing and testing a framework for soil condition monitoring**. Geoderma, 268, 1–12, 2016.

TAGIL, S.; JENNESS, J. **GIS-based automated landform classification and topographic, landcover and geologic attributes of landforms around the Yazoren Polje, Turkey**. J. Appl. Sci., 8:910-921, 2008.

TEN CATEN, A.; DALMOLIN, R.S.D.; PEDRON, F.A.; MENDONCA-SANTOS, M.L. **Spatial resolution of a digital elevation model defined by the wavelet function**. Pesq. Agropec. Bras., 47:449-457, 2012.

THOMPSON, J.A.; BELL JC BUTLER, C.A. **Digital elevation model resolution: effects on terrain attribute calculation and quantitative soil-landscape modeling**. Geoderma, 100:67-89, 2001. [https://doi.org/10.1016/S0016-7061\(00\)00081-1](https://doi.org/10.1016/S0016-7061(00)00081-1)

THOMPSON, J.A.; BELL, J.C.; BUTLER, C.A. **Digital elevation model resolution: effects on terrain attribute calculation and quantitative soil-landscape modeling**. Geoderma, 100: 67-89, 2001.

USDA. **Soil survey manual Soil Survey Division Staff**. Soil Conservation Service Volume Handbook 18, U.S. Department of Agriculture (chapter 3), 2017. <https://www.nrcs.usda.gov/sites/default/files/2022-09/SSM-ch3>.

WALKER, J.P.; WILLGOOSE, G.R. **On the effect of digital elevation model accuracy on hydrology and geomorphology.** Water Resour. Res. 7, 2259–2268. Warnes, G.R., Bolker, B., Bonebakker, L., Gentleman, R., Liaw, W.H.A., Lumley, T., 1999.

WILSON, J. P. **Digital terrain modeling.** Geomorphology, 137(1), 107–121, 2012.
doi:10.1016/j.geomorph.2011.03.012

WILSON, J.P.; GALLANT, J.C. **Terrain Analysis. Principles and applications.** Wiley, New York, NY, 2000.

WILSON, J.P.; REPETTO, P.L.; SNYDER, R.D. **Effect of data source, grid resolution, and flow routing method on computed topographic attributes.** In: Wilson, J.P., Gallant, J.C. (Eds.), Terrain Analysis: Principles and Applications. John Wiley & Sons, New York, pp. 133–161, 2000.

WU, S.; LI, J.; HUANG, G.H. **Modeling the effects of elevation data resolution on the performance of topography-based watershed runoff simulation.** Environ. Model. Softw. 22, 1250–1260, 2007. <https://doi.org/10.1016/j.envsoft.2006.08.001>.

WU, W.; FAN, Y.; WANG, Z.; LIU, H. **Assessing effects of digital elevation model resolutions on soil-landscape correlations in a hilly area.** Agric. Ecosyst. Environ., 126:209–216, 2008.