

**UNIVERSIDADE FEDERAL DE PELOTAS**  
**Faculdade de Agronomia Eliseu Maciel**  
**Programa de Pós-Graduação em Manejo e Conservação do Solo e da Água**



**Dissertação**

**Predição espacial de carbono orgânico do solo em escala de propriedade agrícola na região Sul do Brasil**

**Jéferson Diego Leidemer**

**Pelotas, 2022**

**Jéferson Diego Leidemer**

**Predição espacial de carbono orgânico do solo em escala de propriedade agrícola na região Sul do Brasil**

Dissertação apresentada ao Programa de Pós-Graduação em Manejo e Conservação do Solo e da Água da Faculdade de Agronomia Eliseu Maciel da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Ciências.

<b>Orientador</b>	<b>Dr. Pablo Miguel</b>
<b>Coorientadores</b>	<b>Dr<sup>a</sup>. Lizete Stumpf</b>
	<b>Dr. Jean Michel Moura-Bueno</b>

**Pelotas, 2022**

Universidade Federal de Pelotas / Sistema de Bibliotecas  
Catalogação na Publicação

L527p Leidemer, Jéferson Diego

Predição espacial de carbono orgânico do solo em escala de propriedade agrícola na região Sul do Brasil / Jéferson Diego Leidemer ; Pablo Miguel, orientador ; Lizete Stumpf, Jean Michel Moura-Bueno, coorientadores. — Pelotas, 2022.

80 f. : il.

Dissertação (Mestrado) — Manejo e Conservação do Solo e da Água, Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas, 2022.

1. Mapeamento digital de solos. 2. Modelo digital de elevação. 3. Carbono orgânico do solo. 4. Random forest. 5. Aeronave remotamente pilotada. I. Miguel, Pablo, orient. II. Stumpf, Lizete, coorient. III. Moura-Bueno, Jean Michel, coorient. IV. Título.

CDD : 631.4

**Jeferson Diego Leidemer**

**Predição espacial de carbono orgânico do solo em escala de propriedade agrícola na região Sul do Brasil**

**Dissertação aprovada como requisito parcial para obtenção do grau de Mestre em Ciências, Pós-Graduação em Manejo e Conservação do Solo e da Água, Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas.**

**Data da Defesa: 30/11/2022**

**Banca examinadora:**

**Prof. Dr. Pablo Miguel (Orientador)  
Doutor em Ciência do Solo pela Universidade Federal de Santa Maria**

**Prof. Dr. Ricardo Bergamo Schenato  
Doutor em Ciência do Solo pela Universidade Federal de Santa Maria**

**Prof. Dr. Rodrigo Rizzi  
Doutor em Sensoriamento Remoto pelo Instituto Nacional de Pesquisas Espaciais**

**Prof. Dr. Alexandre Felipe Bruch  
Doutor em Geografia pela Universidade Federal do Rio Grande do Sul**

## **Agradecimentos**

À minha família, especialmente aos meus pais, Francisca Terezinha Martins Leidemer e Silmar Leidemer, pelo suporte incondicional as minhas decisões, por todos os conselhos, apoio, incentivos e lições que me tornaram quem eu sou hoje.

À minha namorada Nielle Versteg, que esteve sempre ao meu lado fornecendo todo o apoio, carinho e incentivo durante as etapas dessa jornada. Pela compreensão e atenção fornecidas nos momentos difíceis.

Ao meu orientador Prof. Dr. Pablo Miguel, por toda ajuda oferecida, tempo dedicado e conhecimentos passados para a conclusão desse estudo. Por ser receptivo a novas ideias, sempre buscando inovar em seu campo de atuação.

Aos coorientadores Dr<sup>a</sup>. Lizete Stumpf e Dr. Jean Michel Moura-Bueno, pelos conselhos, críticas e ajuda oferecidas e pelo tempo disponibilizado para esclarecer dúvidas e oferecer novos ensinamentos. Ao Dr. Alexandre Felipe Bruch, pelo apoio oferecido e tempo dedicado, sem o qual a execução deste estudo teria sido muito mais difícil.

A todos do grupo de Pedologia da Faculdade de Agronomia Eliseu Maciel, os quais foram imprescindíveis em todas as etapas deste estudo. Aos amigos Victoria e Ariel, pela amizade, convivência e descontração que tornaram essa jornada mais amena e divertida.

Ao PPG MACSA e Universidade Federal de Pelotas por disponibilizar toda a estrutura viabilizando esta formação e pela oportunidade de realização deste estudo. Gostaria também de agradecer a Condição de Aperfeiçoamento de Pessoal de Educação Superior (CAPES) pela concessão da bolsa de estudo.

Meu muito obrigado!

“Aos meus pais, Francisca Terezinha Martins  
Leidemer e Silmar Leidemer e a minha namorada Nielle  
Versteg.”

**Dedico**

## Resumo

LEIDEMER, J. D. **Mapeamento digital do carbono orgânico do solo em escala de bacia hidrográfica no Sul do Rio Grande do Sul**. 2022. 80f. Dissertação (Mestrado em Manejo e Conservação do Solo e da Água) – Programa de Pós-Graduação em Manejo e Conservação do Solo e da Água, Universidade Federal de Pelotas, 2022.

A preocupação com a qualidade do solo vem crescendo a cada ano, pois exerce uma influência sobre a qualidade da água, segurança alimentar e produção de energia. Estudos envolvendo a determinação de atributos do solo a nível de propriedade agrícola, com alta resolução espacial ainda são escassos. Entre esses atributos se destaca o carbono orgânico do solo (COS), pois este pode servir como indicador da fertilidade, qualidade do solo, bem como indicador de qualidade para o meio ambiente. Um ponto chave no mapeamento em escala de propriedade é a sua resolução espacial. Menores áreas mapeadas necessitam de uma maior resolução espacial, capaz de representar de forma mais detalhada suas características, que acabam perdidas conforme a resolução diminui. O Mapeamento Digital de Solos (MDS) tem se mostrado bastante efetivo para o mapeamento de propriedades do solo em áreas com estas características. Este estudo realizou o MDS do COS, utilizando Random Forest (RF), em 4 Áreas de Estudo (AE) de aproximadamente 30 ha denominadas de AE-A, AE-B, AE-C e AE-D, com características de localização e relevo distintas, na Bacia Hidrográfica do Arroio Epaminondas (BHAÉ) no sul do Rio Grande do Sul - Brasil. Foram estimadas a acurácia do modelo e a incerteza dos mapas preditos em 3 diferentes resoluções espaciais (1 m, 5 m e 10 m). A acurácia dos modelos treinados com covariáveis com resolução espacial de 1 m se mostrou superior em relação as demais resoluções, apresentando um  $R^2$  de 0,67 para AE-A,  $R^2$  de 0,83 para a AE-B,  $R^2$  de 0,88 para a AE-D e  $R^2$  de 0,68 para AE-D. Os mapas que apresentaram as menores incertezas foram, no geral, os mapas com resolução espacial de 1 m, com destaque para as AE-C e AE-D, variando entre 0,08 e 0,46 e 0,14 e 0,74 respectivamente. A AE-C também apresentou os menores coeficientes de variação (CV), 17,02% para a resolução espacial de 1 m, 20,19% para resolução de 5 m e 22,83% para a resolução de 10 m.

**Palavras-chave:** Mapeamento digital de solos. Modelo digital de elevação. Carbono orgânico do solo *Random forest*. Aeronave remotamente pilotada.

## Abstract

LEIDEMER, J. D. **Spatial prediction of soil organic carbon at farm scale in the southern region of Rio Grande do Sul.** 2022. 80f. Dissertation (Master degree in Manejo e Conservação do Solo e da Água) – Programa de Pós-Graduação em Manejo e Conservação do Solo e da Água, Universidade Federal de Pelotas, Pelotas, 2022.

Concerns about soil quality has been growing every year, as it has an influence on water quality, food security and energy production. Soil attributes at farm scale with high spatial resolution are still scarce. Among them, soil organic carbon (SOC) stands out, as it can serve as an indicator of fertility, soil quality, as well as a quality indicator for the environment. A key point in farm scale mapping is its spatial resolution. Smaller mapped areas need a higher spatial resolution, capable of representing their characteristics in a more detailed way, which are lost as the resolution decreases. Digital Soil Mapping (DSM) has been shown to be very effective for mapping soil properties in areas with these characteristics. This study carried out the DSM of the SOC, using Random Forest (RF), in 4 Study Areas (SA) of approximately 30 ha called SA-A, SA-B, SA-C and SA-D, with distinct characteristics of location and reliefs, in the Epaminondas Stream Hydrographic Basin (ESHB) in the south of Rio Grande do Sul - Brazil. The model accuracy and the uncertainty of the predicted maps were estimated at 3 different spatial resolutions (1 m, 5 m and 10 m). The accuracy of the models trained with covariates with a spatial resolution of 1 m was higher than the other resolutions, with an  $R^2$  of 0.67 for SA-A,  $R^2$  of 0.83 for SA-B,  $R^2$  of 0.88 for SA-D and  $R^2$  of 0.68 for SA-C. The maps that presented the smallest uncertainties were, in general, maps with a spatial resolution of 1 m, with emphasis on the SA-C and SA-D, ranging between 0.08 and 0.46 and 0.14 and 0.74 respectively. The SA-C also showed the lowest coefficients of variation (CV), 17.02% for the 1 m spatial resolution, 20.19% for the 5 m resolution and 22.83% for the 10 m resolution.

**Keywords:** Digital soil mapping. Digital elevation model. Soil organic carbon. Random forest. Remotely piloted aircraft.

## Lista de Figuras

Figura 1 - Mapa de localização das áreas de estudo. ....	28
Figura 2 - Mapa de altitude com destaque das AE.....	29
Figura 3 - Mapa de declividade com destaque às áreas de estudo. ....	30
Figura 4 - Mapa de classes de solo com destaque às áreas de estudo.....	31
Figura 5 - Ortomosaico das áreas de estudo. ....	32
Figura 6 - Localização das amostragens de solo para análise de carbono orgânico do solo e área de interesse das áreas de estudo.....	36
Figura 7 - Boxplots do COS.....	38
Figura 8 – Distribuição de novos pontos com auxílio de buffer .....	39
Figura 9 - MDEs das AE-A, AE-B, AE-C e AE-D.....	44
Figura 10 - Mapa de COS predito e incerteza estimada para a AE-A.....	46
Figura 11 - Mapa de COS predito e incerteza estimada para a AE-B.....	47
Figura 12 - Mapa de COS predito e incerteza estimada para a AE-C.....	48
Figura 13 - Mapa de COS predito e incerteza estimada para a AE-D.....	49
Figura 14 - As 10 covariáveis mais importantes para a predição do COS na AE-A com resolução espacial de 1 m, 5 m e 10 m. ....	50
Figura 15 - As 10 covariáveis mais importantes para a predição do COS na AE-B com resolução espacial de 1 m, 5 m e 10 m. ....	51
Figura 16 - As 10 covariáveis mais importantes para a predição do COS na AE-C com resolução espacial de 1 m, 5 m e 10 m. ....	51
Figura 17 - As 10 covariáveis mais importantes para a predição do COS na AE-D com resolução espacial de 1 m, 5 m e 10 m. ....	52

## Lista de Tabelas

Tabela 1 - Covariáveis do terreno derivadas do MDE e sensor orbital .....	34
Tabela 2 - Resultados da análise de carbono orgânico do solo. ....	37
Tabela 3 - Conjunto de dados final para cada uma das diferentes áreas de estudo e diferentes resoluções espaciais.....	39
Tabela 4 - Estatística descritiva do conjunto de dados de COS.....	42
Tabela 5 - Acurácia do modelo preditivo para as áreas de estudo A, B, C e D e resolução espacial de 1m, 5m e 10m.. ..	43

### **Lista de abreviaturas e siglas**

AE	Área de Estudo
ARP	Aeronaves Remotamente Pilotadas
BHAE	Bacia Hidrográfica do Arroio Epaminondas
cLHS	conditioned Latin Hypercube Sampling
CO	Carbono Orgânico
COP	Conferências de Partes
COS	Carbono Orgânico do Solo
CV	Coeficiente de Variação
DECEA	Departamento de Controle do Espaço Aéreo
EVI	Índice de Vegetação Aprimorado
GNSS	Global Navigation Satellite System
GPP	Gross Primary Productivity
GPS	Global Soil Partnership
LAI	Éndice de Área Foliar
MAE	Erro Médio Absoluto
MDS	Mapeamento Digital de Solos
MDS	Modelo Digital de Superfície
MOS	Matéria Orgânica do Solo
MRE	Erro Médio Relativo
NDVI	Índice de Vegetação por Diferença Normalizada
PPP	Posicionamento por Ponto Preciso
QRF	Quantile Regression Forest
R <sup>2</sup>	Coeficiente de Determinação
RF	Random Forest
RFE	Recursive Feature Elimination
RMSE	Rraiz do Erro Quadrático Médio
RTK	Posicionamento Cinemático em Tempo Real
SD	Desvio Padrão
SRTM	Shuttle Radar Topography Mission

## Sumário

1.	Introdução .....	14
2.	Revisão de literatura.....	16
2.1	Mapeamento Digital de Solos.....	16
2.2	Predição de atributos de solo – Carbono Orgânico do Solo.....	19
2.3	Aeronave remotamente pilotada para geração de modelos digitais de elevação .....	22
3.	Hipóteses .....	24
4.	Objetivo Geral.....	24
4.1	Objetivos específicos.....	24
Capítulo 1 – Efeito da resolução espacial na modelagem de carbono orgânico do solo a partir de modelo digital de elevação de alta resolução .....		
25		
1.	Introdução .....	25
2.	Materiais e métodos .....	28
2.1	Área de estudo .....	28
2.2	Levantamento aéreo de alta resolução .....	32
2.2.1	Levantamento com ARP.....	32
2.2.2	Pontos de controle com GNSS.....	33
2.2.3	Geração do MDE detalhado .....	33
2.3	Covariáveis.....	34
2.4	Amostragem e análises de solos.....	36
2.5	Modelagem e mapeamento do carbono orgânico do solo.....	40
2.5.1	Random forest.....	40
2.5.2	Acurácia e incerteza .....	40
3.	Resultados .....	42
3.1	Estatística descritiva do carbono orgânico do solo.....	42
3.2	Validação do modelo .....	42
3.3	Mapeamento de alta resolução .....	43

3.3.1	Modelo digital de elevação de alta resolução .....	43
3.3.2	Modelagem de predição do COS .....	44
3.3.3	Incerteza associada ao modelo de predição .....	45
3.4	Importância das covariáveis .....	50
4.	Discussão .....	53
5.	Conclusão .....	57
6.	Referências .....	58

## 1. Introdução

O solo desde sempre foi, mesmo que indiretamente, o principal meio de sustento dos seres humanos, onde, regiões mais férteis dispunham de diversas plantas para coletar e animais para caçar. A criação das primeiras ferramentas agrícolas data de aproximadamente 12.000 anos atrás, período também associado a criação da agricultura. Foi devido a essa descoberta, utilizar o solo a seu favor para cultivar alimento, que o ser humano deixou de ser nômade e passou a viver em assentamentos. Ao longo do tempo o ser humano também aprendeu sobre a importância da fertilidade do solo, as civilizações mais antigas que se tem notícia se formaram ao longo de áreas de solo fértil.

A importância do solo nos acompanha até os dias atuais. Mesmo com toda a tecnologia que é empregada na agricultura e nas formas de cultivo, o solo ainda é o principal meio de cultura para a humanidade. A Organização das Nações Unidas para a Alimentação e a Agricultura (do inglês FAO-UN) divulgou em seu último relatório em 2015 que para os próximos 30 anos serão necessários aumentos na produção de alimento no mundo todo, devido ao aumento populacional que ocorrerá principalmente em países em desenvolvimento. Portanto, explorar o solo de forma sustentável e tratar esse recurso natural com a mesma importância que se trata a alimentação deve constar na agenda de cada governante, pois ele é e será o principal meio para produção de alimento e um dos principais meios para produção de energia.

Ao mesmo tempo em que há a necessidade de se aumentar a produção, há a necessidade de conservar o solo e o meio ambiente, pois a degradação do solo e do meio ambiente se apresenta de forma negativa na produção e na qualidade de vida de quem habita a região. Em tempos em que a preocupação com mudanças climáticas tem estado tão em evidência, encontrar formas de entender e aprimorar a relação entre o carbono orgânico (CO) e o uso e manejo do solo tem sido o objeto de muitas pesquisas. O carbono orgânico do solo (COS) é considerado um indicador da qualidade do solo, portanto entender melhor essa relação, do uso e manejo do solo com o COS, servirá não só para manter ou até mesmo aumentar a qualidade do solo como também para amenizar os problemas relacionados as mudanças climáticas.

É possível afirmar que para que haja um aumento na produção de alimentos e aumento na eficiência da utilização do recurso solo necessitamos cada vez mais de um maior número de informações detalhadas de todos os atributos do solo e com o COS não seria diferente. Atualmente os desafios estão ligados ao mapeamento desse

COS em escala de propriedade, bacia hidrográfica ou município. Porém essa é uma tarefa bastante complexa e dispendiosa para ser feita nessas escalas, utilizando os métodos convencionais. Portanto, é importante que se entenda cada vez mais a distribuição espacial das classes de solo bem como suas propriedades. A pedometria aliada ao mapeamento digital de solos (MDS) tem se mostrado uma poderosa ferramenta para providenciar esse tipo de informação. Na atual realidade, em que o volume de informação necessário, bem como velocidade em que essa informação deve ser disponibilizada, o MDS tem se mostrado muito efetivo em suprir essa demanda. Recursos como mineração de dados e aprendizado de máquina têm cada vez ganhado mais força nessa área, possibilitando a realização de tarefas que antes seriam muito onerosas ou demandariam de uma escala de tempo inviável. Assim sendo, o MDS é uma ferramenta com a qual é possível realizar estudos e pesquisas detalhadas, que de outra forma, seriam inviáveis em escala de tempo e mesmo financeiramente para muitos países.

## 2. Revisão de literatura

### 2.1 Mapeamento Digital de Solos

O solo desempenha um papel fundamental para a manutenção da vida na Terra. É um meio de extrema importância para produção de alimentos, combustíveis, estabilidade climática e para a biodiversidade (GREINER et al., 2017; MCBRATNEY; FIELD; KOCH, 2014). Ainda segundo McBratney *et al.* (2014), devido sua extrema importância, o solo deveria receber a mesma atenção que é dada para a conservação da água, segurança alimentar e produção de energia. Para Koch *et al.* (2013), um solo totalmente funcional deveria ser o cerne da resolução de grandes problemas, como a segurança alimentar, biodiversidade, mudanças climáticas e regulação da água doce do planeta. Já Amundson *et al.* (2015) colocam que os impactos que nós, seres humanos, estamos causando no solo durante esse século trarão graves consequências para a vida na Terra nos séculos seguintes. Devido a toda essa importância e preocupação, diversos estudos relacionados a segurança do solo tem surgido nos últimos anos (BENNETT et al., 2019; BOUMA, 2019; DAZZI et al., 2019; KIDD et al., 2018). Segundo Koch *et al.* (2013), para que um determinado tipo de solo continue sendo funcional, ou seja, continue a fornecer alimentos, por exemplo, deve-se trabalhar para a melhoria deste através de pesquisas relacionadas a segurança do solo, propondo assim, a sua sustentabilidade e biodiversidade.

Para que se possa administrar de forma eficiente e precisa esse recurso natural, é necessário ter informações confiáveis sobre suas propriedades e funções. Porém os mapas de solo convencionais atualmente disponíveis, geralmente estão em escala inadequada e carecem de maiores detalhes. Além disso, ainda há uma demanda grande relacionada as propriedades do solo, que não são atendidas em sua totalidade pelos mapas existentes (ARROUAYS et al., 2014; ROSSITER, 2016). Segundo Arrouays *et al.* (2017), menos de 1/3 do planeta possui mapeamento em escala 1:1.000.000 ou maior, grande parte destes mapas convencionais não trazem respostas aos atuais problemas relacionados ao meio ambiente como por exemplo, erosão e compactação do solo, ou estão desatualizados.

Para tentar solucionar alguns desses problemas, as informações coletadas a campo e obtidas em laboratório passaram a ser processadas utilizando modelos computacionais. Apesar da utilização desses modelos computacionais para a elaboração de mapas não ser algo novo, passaram a ganhar maior destaque a partir do início da década de 1990, já que cada vez mais pesquisadores vem se aventurando

nesta área (MCKENZIE; AUSTIN, 1993; MOORE et al., 1993; SKIDMORE et al., 1991). Esses modelos computacionais se baseiam na teoria dos fatores de formação do solo, proposta em 1883 por Dokuchaev (1967), e que mais tarde foi estudada de forma mais profunda e se popularizou a partir de 1941 através dos estudos de Jenny (1994). Dokuchaev, em 1883, publicou um estudo sobre os solos chamados de Chernozem, onde ele aponta o clima, atividades biológicas, topografia, material de origem e o tempo como sendo os principais fatores de formação do solo. Já Hans Jenny propôs um modelo baseado nesses fatores de formação do solo propostos por Dokuchaev:

$$S = f(cl, o, r, p, t, \dots)$$

Nesse modelo, S representa o solo em função do fator climático (cl ou c), dos fatores biológicos ou dos organismos (o) e dos fatores topográficos ou relevo (r), que se relacionam com o material de origem ou parental (p) através do tempo (t). O modelo ainda deixa espaço para fatores desconhecidos (...) que possam ser incluídos.

Uma série de pesquisadores passaram então a realizar interações entre as variáveis do modelo de Hans Jenny de forma espacializada, através métodos geoestatísticos (TROEH, 1964; DAVIES e GAMM, 1970; LASLETT *et al.*, 1987; MCBRATNEY e WEBSTER, 1983). McBratney *et al.* (2003) sintetizaram esse conhecimento que foi sendo lapidado ao longo dos anos em um *framework* genérico para a predição espacial de classes ou atributos do solo, chamado de modelo *scorpan*:

$$S_c \text{ ou } S_a = f(s, c, o, r, p, a, n)$$

Onde, ( $S_c$ ) é a classe de solo ou o atributo do solo ( $S_a$ ) em função da propriedade do solo em um determinado ponto (s), do fator climático (c), dos organismos (o), do relevo (r), do material parental (p), do fator tempo (a) e da posição espacial (n). A partir desses estudos relacionados ao modelo *scorpan* o termo Mapeamento Digital de Solos (MDS) se popularizou. O MDS pode ser definido como sendo, a criação e a população de um sistema de informação espacial de solo pelo uso de métodos de observação em campo e em laboratório, associados a um sistema de inferência espacial (LAGACHERIE; MCBRATNEY, 2006).

A partir dos anos 2000 houve um grande crescimento no número de artigos publicados em periódicos e no número de citações relacionadas ao MDS (MINASNY; MCBRATNEY, 2016). Porém mesmo com esse aumento, há um consenso entre os pesquisadores de que ainda há muito por fazer nessa área. Desta forma, pesquisadores vem reunindo esforços ao redor do mundo para mudar essa realidade.

A exemplo dos esforços temos a Suécia (SÖDERSTRÖM et al., 2016), Índia (DHARUMARAJAN et al., 2019, 2020), França (LANDRÉ et al., 2020; MULDER et al., 2016), Chile (PADARIAN; MINASNY; MCBRATNEY, 2017; PFEIFFER et al., 2020) e trabalhos realizados na América Latina como um todo (GUEVARA et al., 2018).

O Brasil não tem ficado atrás das pesquisas mundiais, em 2006, Mendonça-Santos e Dos Santos (2006) chamaram a atenção para a importância e necessidade da pesquisa e mapeamento de solo em grandes escalas no país. Esse tipo de informação é de extrema importância, pois serve de base para o planejamento e gerenciamento dos recursos naturais, agricultura e o meio ambiente. Desde então diversas pesquisas relacionadas ao tema surgiram, como (GIASSON *et al.*, 2006; TEN CATEN *et al.*, 2011) com trabalhos relacionados ao mapeamento de classes de solo, (SAMUEL-ROSA, 2012) que trabalhou com funções de predição espacial de propriedades do solo, (MOURA-BUENO, 2014) que trabalhou com a qualidade dos Modelos Digitais de Elevação (MDE) e predição de carbono em escala de propriedade rural e (CANCIAN, 2019) que avaliou a possibilidade e a eficiência de se utilizar dados legados para a produção de MDS.

As grandes vantagens de se utilizar técnicas de MDS estão no fato de que toda a informação gerada e processada já fica armazenada em bases de dados. Essas informações podem ser organizadas de forma a permitir que pesquisadores a utilizem para outros fins além do MDS em si. Além disso, por utilizar modelos matemáticos, é possível avaliar índices de certeza e acurácia presentes nesses mapas buscando assim formas de aperfeiçoá-los. O MDS também pode facilmente prover informações ao longo do tempo, pois ao elaborar um *framework* para a sua pesquisa, o pesquisador pode atualizar o MDS fornecendo novas informações ou gerar facilmente novos mapas, podendo assim acompanhar sua evolução ao longo de um período. Devido a sua alta reprodutibilidade e automatização, associado a facilidade em se trabalhar com dados legados comparado ao mapeamento convencional, o MDS é uma alternativa rápida e barata para se elaborar mapas de classe e atributos do solo (MCBRATNEY. *et al.*, 2003; MINASNY e MCBRATNEY, 2016).

## 2.2 Predição de atributos de solo – Carbono Orgânico do Solo

O aumento do nível de CO<sub>2</sub> na atmosfera tem levado inquietações à comunidade científica (QIAO et al., 2019; SHAIKH et al., 2018). Sendo no solo que se encontra a maior parte do Carbono da Terra (LAL, 2004; SCHARLEMANN et al., 2014) e tendo ele maior capacidade de armazenamento do que os seres vivos ou a atmosfera (BIRD et al., 2001; JI et al., 2020), é natural que seja dada bastante atenção para a relação entre o solo e o COS.

O COS do solo pode apresentar muitas variações ao longo do espaço e do tempo, sendo atualmente as transformações antrópicas, como agricultura, um dos principais fatores de alteração nas concentrações desse COS (CAREY et al., 2020; SILVA et al., 2020a). A FAO prevê que para 2050 a população na Terra passará dos 9 bilhões de habitantes e que o aumento da produção necessária para suprir a demanda de alimento no mundo deverá ser de cerca de 70%, desse valor, em torno de 77% deverá ser nos países em desenvolvimento (ALEXANDRATOS; BRUINSMA, 2012). Esse crescimento de produção, segunda as projeções, se dará através do aumento no rendimento da produção, aumento na área a ser cultivada e na intensidade desse cultivo, ou seja, haverá uma exigência ainda maior do solo. Entretanto, Lal (2010) diz que o aumento na produção agrícola pode ser uma via de duas mãos, pois ao utilizar práticas que aumentem o COS no solo, o produtor não só aumenta a fertilidade e conseqüentemente a produção, como também retira o C da atmosfera sequestrando-o para o solo. Porém, essa é uma área que carece de mais pesquisa científica, pois estudos relacionando a produção com o estoque de COS ainda são escassos (MCBRATNEY et al., 2017).

O COS encontra-se principalmente incorporado a matéria orgânica (MO), segundo Schulten e Leinweber (2000), este pode compreender mais de 50% da matéria orgânica do solo (MOS). Maiores níveis de COS refletem em uma maior fertilidade desse solo. O COS está associado a melhorias na estrutura e agregados, a um maior acúmulo de nutrientes e incrementos na atividade biológica e retenção de água (JOHANNES *et al.*, 2017; ANTHONY *et al.*, 2020; BOSELLI *et al.*, 2020; LI MA *et al.*, 2020).

Arrouays *et al.* (2020) relatam que as informações referentes ao COS a nível global ainda são bastante escassas, estando nas pesquisas e mapeamentos locais uma das soluções para reverter esse problema. Portanto, diversos pesquisadores tem trabalhado em mapear o COS (ELLILI et al., 2019; GOMES et al., 2019; PAUL et al.,

2020; TAJIK; AYOUBI; ZERAATPISHEH, 2020), adotando para isso métodos de interpolação. Porém, apesar de gerarem bons resultados, estes requerem uma maior densidade da malha de amostragem (GÖL; BULUT; BOLAT, 2017; LONG et al., 2018), gerando assim maiores custos relacionados a deslocamento, análises laboratoriais e consumindo mais tempo do pesquisador. Uma alternativa a utilização de modelos baseados na interpolação, é a utilização dos MDS. Os dados utilizados pelo MDS são provenientes de análises químicas e físicas de amostras georreferenciadas de solo, covariáveis oriundas do MDE e do sensoriamento remoto. Posteriormente, estas informações são processadas através de um algoritmo preditor capaz de gerar uma base de dados georreferenciada com as informações das propriedades do solo na paisagem, estimando ainda os erros e incertezas do modelo utilizado (MINASNY et al., 2013). Além disso, são mais eficientes em relação aos custos, podem ser facilmente produzidos e atualizados quando comparados com métodos convencionais (ARROUAYS et al., 2020a). Portanto, o MDS tem sido uma ferramenta muito utilizada por pesquisadores e organizações para o mapeamento de COS ao redor do mundo.

A Organização das Nações Unidas para a Alimentação e a Agricultura (FAO-UN), criou em 2012 a *Global Soil Partnership* (GPS) que tem como principal objetivo posicionar o solo nas agendas globais, por meio de diversas ações coletivas, como promover o uso sustentável, garantir a saúde e produtividade do solo (FAO-UN). A GPS por sua vez estabeleceu uma parceria com a *GlobalSoilMap* (GlobalSoilMap.Net), que teve como objetivo elaborar MDS em escala global e em alta resolução, utilizando tecnologia de ponta para mapear classes e propriedades do solo, como por exemplo, o COS. A GPS deixou a cargo da *GlobalSoilMap* a incumbência de definir as especificações e os procedimentos para a elaboração de MDS (ARROUAYS et al., 2020b).

Poggio e Gimona (2014) conduziram um estudo em que desenvolveram e testaram uma metodologia para modelar a distribuição lateral e vertical dos estoques de COS na Escócia, além de modelar e espacializar a incerteza dos resultados. Para tanto, utilizaram uma abordagem baseada em modelo aditivo generalizado 3D (3DGAM) em conjunto com krigagem 3D. O estudo utilizou covariáveis como MDE, aspecto do relevo, declividade, índice de vegetação aprimorado (EVI), índice de área foliar (LAI), além de informações referentes a mais de 7800 perfis de solo distribuídos por todo o país. As covariáveis que mais influenciaram o modelo foram a posição

geográfica, elevação, declividade e LAI. As covariáveis selecionadas parecem estar relacionadas com a produtividade do ecossistema além dos processos de formação do solo. Foram observados que os estoques de COS diminuíram em altitudes maiores do que 800 m onde há uma maior predominância de afloramentos rochosos e solos pedregosos, foram menores em terreno com declividade acentuada e com melhor drenagem e, por fim, onde houve uma maior densidade de vegetação os estoques de COS também se apresentaram mais elevados. Os autores também destacam a importância das informações espacializadas sobre a variabilidade das propriedades do solo para o manejo e uso da terra, além de servir como base para os estudos sobre as impacto das mudanças climáticas. Também enfatizam a necessidade dessas informações virem acompanhadas das estimativas de incerteza, que são fundamentais para o planejamento e gerenciamento de estudos futuros.

Gomes *et al.* (2019) mapearam a distribuição de carbono lateral e vertical em todo o Brasil, além de comparar o desempenho de alguns métodos de aprendizado de máquina (*machine learnig*) como, *Random Forest* (RF), *Cubist*, *Support Vector Machines* e *Generalized Linear Models*. Como covariáveis, foram utilizados dados legados de solo provenientes do Projeto Radam, dados provenientes do MDE, índice de vegetação por diferença normalizada (NDVI), precipitação, temperatura, além de covariáveis representando os biomas do Brasil, ao todo, a base de dados foi composta por 74 covariáveis. Para otimizar a predição de COS reduzindo o tempo e recursos computacionais necessários para realizar o mapeamento, os autores utilizaram um recurso chamado de *Recursive Feature Elimination* (RFE) para selecionar as covariáveis mais representativas em cada modelo. O algoritmo RF obteve o melhor desempenho no estudo, tendo como covariáveis de maior importância a classe do solo, índices de vegetação, temperatura e índices morfométricos como elevação, declividade e profundidade de vale, sendo as covariáveis preditoras NDVI e gross primary productivity (GPP) as que mais contribuíram para a previsão do COS em camadas superficiais. Em relação aos estoques de carbono, houve uma variação de 0,01 a 205,8 g kg<sup>-1</sup> em todo o território nacional, sendo que os maiores estoques de carbono se encontram na região sul e noroeste do Brasil e os menores estoque se encontram na região nordeste. Os autores também destacam a importância de se utilizar o MDS para modelar os estoques de COS devido a capacidade de se avaliar a incerteza do modelo e consideraram o algoritmo RF uma ferramenta poderosa de predição, atingindo a maior acurácia ao se comparar com os demais modelos.

### **2.3 Aeronave remotamente pilotada para geração de modelos digitais de elevação**

É possível afirmar que as Aeronaves Remotamente Pilotadas (ARP) tem sua origem pouco tempo após os primeiros voos bem-sucedidos com aeronaves pilotadas por seres humanos. O giroscópio, inventado por Elmer Sperry em 1911, tornou possível o voo estabilizado de aeronaves já nessa época e os avanços tecnológicos pelos quais os rádios vinham passando possibilitou o início de pesquisas relacionadas ao controle remoto de aeronaves. Essa tecnologia evoluiu desde bombas rudimentares capazes de se deslocar até o alvo de forma autônoma, até os modernos equipamentos disponíveis hoje, capazes de serem controlados a milhares de quilômetros de distância via satélite de forma precisa graças ao Sistema de Posicionamento Global (GNSS) (KEANE; CARR, 2013).

O emprego de ARPs para o uso civil iniciou um crescimento gradativo a partir do início dos anos 2000 (COLOMINA; MOLINA, 2014) juntamente com a evolução e miniaturização de componentes eletrônicos, como as baterias de lítio (RITCHIE; HOWARD, 2006; SCROSATI, 2000). Já na agricultura, tem se notado um crescimento no emprego de ARPs nos últimos 10 anos (FREEMAN; FREELAND, 2015; GIACOMO; DAVID, 2018; REJEB et al., 2022; VAN DER MERWE et al., 2020), sendo algumas das principais aplicações desses equipamentos a aquisição de dados de solo, relevo e vegetação (COMBA et al., 2018; GAO; LIAN; GE, 2022; HUGENHOLTZ et al., 2013; KRŠÁK et al., 2016; LUO et al., 2019; SANKARAN et al., 2015; SIEBERT; TEIZER, 2014; VAN DER VEEKE et al., 2021; ZHENG et al., 2020; ZHOU et al., 2017).

Essa tecnologia está sendo amplamente adotada devido a inúmeras vantagens, como a possibilidade de operar e registrar imagens mesmo que com o céu encoberto (CHENG; CHAN; LEE, 2020), capacidade de se trabalhar em uma ampla escala temporal (ANGNUURENG et al., 2022), câmeras de alta qualidade, alta resolução e diferentes tipos de sensores multiespectrais (NEX et al., 2022). As ARPs podem ser divididas em asa fixa e asa rotativa, cada uma com suas vantagens. Asa fixa consegue cobrir uma maior área, possui maior autonomia e maior velocidade de deslocamento. Já as ARPs de asas rotativas são operadas com mais facilidade, necessitam de menor área para manobrar, realizam pouso e decolagem vertical e são capazes de realizar voo pairado, quando a ARP se mantém sobrevoando de forma constante determinado ponto (ROCH, 2020). Além dessas vantagens, as ARPs são consideradas como sendo uma tecnologia que colabora com a sustentabilidade na

agricultura (AHMAD et al., 2020), colaboram para o reduzido custo e facilidade de aquisição de imagens para análise, processamento e geração de produtos cartográficos (GREEN et al., 2019) e são capazes de gerar produtos, como o MDE, de alta qualidade e boa acurácia se comparados com soluções como o *Shuttle Radar Topography Mission* (SRTM) (AKTURK; ALTUNEL, 2019; CALOU et al., 2021; GUO; LI, 2020).

### **3. Hipóteses**

- i. A acurácia dos modelos treinados para a predição de COS em escala de propriedade agrícola melhora à medida que a resolução espacial das covariáveis aumenta, reduzindo a incerteza em relação a covariáveis de baixa resolução espacial.

### **4. Objetivo Geral**

Este estudo visa gerar um conjunto de informação dos teores de COS em escala de propriedade através do MDS na Bacia Hidrográfica do Arroio Epaminondas (BHAÉ).

#### **4.1 Objetivos específicos**

- i. Quantificar e gerar mapas de COS em 4 propriedades agrícolas;
- ii. Identificar, entre 3 resoluções espaciais (1 m, 5 m e 10 m), a resolução que tem a capacidade de fornecer o melhor mapa de COS nas condições estabelecidas por este estudo;
- iii. Estabelecer uma referência para a avaliação de COS no futuro.

## Capítulo 1 – Efeito da resolução espacial na modelagem de carbono orgânico do solo a partir de modelo digital de elevação de alta resolução

### 1. Introdução

A FAO-UN divulgou em seu último relatório em 2015 que para os próximos 30 anos serão necessários aumentos na produção de alimento no mundo todo, devido ao crescimento populacional, que ocorrerá principalmente em países em desenvolvimento. Atualmente o principal meio de produção de alimentos advém do recurso solo, e segundo Koch *et al.* (2013), para que um determinado tipo de solo continue sendo funcional, deve-se trabalhar para a melhoria de sua qualidade através de pesquisas relacionadas a segurança do solo, a sua sustentabilidade e manutenção e/ou aumento da sua biodiversidade.

A matéria orgânica do solo (MOS) é um importante componente do solo, ela atua na ciclagem de nutrientes, na estabilidade dos agregados, na capacidade de retenção de água, nas propriedades físicas e químicas, além de estar diretamente ligada a manutenção da biologia do solo (ANGELETTI *et al.*, 2021; WERTS, 2022; YANG *et al.*, 2014). O principal componente da MOS é o C e sua forma orgânica, o carbono orgânico do solo (COS), provém da decomposição de plantas, animais e microrganismos (BRONICK e LAL, 2005). O incremento do COS traz inúmeros benefícios para o solo, como aumento ou preservação da fertilidade, resistência a erosão, manutenção da água, além de benefícios para o meio ambiente por meio do sequestro de C da atmosfera (BOSSIO *et al.*, 2020; LAL, 2015). Já a redução do COS também reflete na redução das funções do solo, ou seja, o solo torna-se mais propício a erosão (ZHU; DENG; SHANGGUAN, 2018) devido a falta de propriedades cimentantes proporcionadas pelo COS (XUE *et al.*, 2019). Além disso, sua capacidade de retenção de água acaba por ser reduzida (LAL, 2020; RAWLS *et al.*, 2003) e a quantidade de nutrientes disponíveis para as plantas diminui, por consequência, sua fertilidade e capacidade de produção de alimentos (FELLER *et al.*, 2012; LORENZ; LAL; EHLERS, 2019).

O aumento na produção de alimentos pode trazer consequências ao meio ambiente se o solo não for bem manejado. Sendo o solo o maior reservatório de C do planeta, a forma como é explorado pode contribuir para o aumento ou redução de suas reservas (BURAKA; ELIAS; LELAGO, 2022; GUTWEIN *et al.*, 2022). Em tempos em que a preocupação com mudanças climáticas tem estado tão em evidência,

diversas nações tem se reunido ao longo do anos em conferências, como as três conferências do Rio de Janeiro e Conferências de Partes (COP, do inglês), para buscar meios e estipular metas para lidar com problemas como os do C (WIESE-ROZANOV, 2022). Em virtude disso, encontrar formas de entender e aprimorar a relação entre o carbono orgânico (CO) e o uso e manejo do solo tem sido o objeto de muitas pesquisas (BABU et al., 2020; BREG VALJAVEC et al., 2022; NIU et al., 2021; RAMESH et al., 2019), principalmente em escala de propriedade agrícola (FAO, 2020).

O COS pode apresentar muitas variações ao longo do espaço e do tempo, sendo atualmente as transformações antrópicas, como agricultura, um dos principais fatores de alteração nas concentrações desse COS (CAREY et al., 2020; SILVA et al., 2020a). As diversas modificações no uso e cobertura da terra, alterações no sistema climático, demanda e capacidade de simular diferentes cenários com os atributos do solo tem incidido sobre o aumento nas pesquisas com a espacialização deste atributo (YANG et al., 2022; ZERAATPISHEH et al., 2019). O COS é considerado um indicador da qualidade do solo, portanto, entender melhor essa relação do solo com o CO serve não só para manter ou até mesmo aumentar a qualidade do solo como também para amenizar os problemas relacionados as mudanças climáticas (ATOLOYE et al., 2022; BAVEYE et al., 2020). O COS é um atributo com extensas relações com o clima e a capacidade produtiva dos solos, logo, é amplamente estimado através do mapeamento digital de solos (MDS) cuja finalidade é gerar informações espacializadas deste atributo (DORJI et al., 2014; DU et al., 2021; MORA-VALLEJO et al., 2008; OWUSU et al., 2019).

O MDS pode ser definido como sendo, a criação e a população de um sistema de informação espacial de solo pelo uso de métodos de observação em campo e em laboratório, associados a um sistema de inferência espacial através de um *framework* genérico para a predição espacial de classes ou atributos do solo, chamado de modelo SCORPAN. (LAGACHERIE; MCBRATNEY, 2006). O conceito modelo SCORPAN remete aos fatores de formação do solo, onde a classe de solo ou o atributo do solo se dá em função da propriedade do solo em um determinado ponto (s), do fator climático (c), dos organismos (o), do relevo (r), do material parental (p), do fator tempo (a) e da posição espacial (n). O uso de atributos do relevo como dados de entrada para o MDS é algo previsto desde o início no modelo SCORPAN (MCBRATNEY; MENDONÇA SANTOS; MINASNY, 2003b), conseqüentemente, as covariáveis

derivadas dos MDE desempenham papéis fundamentais na eficácia das estimativas realizadas. Portanto, um fator intrínseco aos MDE são suas resoluções espaciais, que irão determinar a área representativa de uma porção do espaço a qual será associada a uma estimativa de carbono. O MDS em diversas escalas tem sido objeto de estudo ao longo dos últimos anos (LEMERCIER et al., 2022). Contudo, muitos estudos têm focado em mapas de COS em escalas nacional (GOMES et al., 2019; ODEBIRI; MUTANGA; ODINDI, 2022) e regional (SILVA et al., 2020b; ZHOU et al., 2020) devido à facilidade de se obter informações geoespaciais. Neste sentido, as informações disponíveis para suprir esta demanda, em geral, provém do *Shuttle Radar Topography Mission* (SRTM) (RABUS et al., 2003) ou ALOS PALSAR (ROSENQVIST et al., 2007). O SRTM conta com resolução espacial aproximada de 30 m, já o ALOS PALSAR conta resolução espacial de 12,5 m, proveniente da remostragem do SRTM para o Brasil. Porém, nos últimos anos, mapas digitais de carbono em escala de propriedade com auxílio de Aeronaves Remotamente Pilotadas (ARPs) (GUO et al., 2020) têm surgido. O principal emprego das ARPs têm sido na geração de Modelos Digitais de Elevação (MDE) (FLORINSKY, 2016) de alta resolução (LEAL-ALVES et al., 2020; SANTANA et al., 2022), além da obtenção de imagens multiespectrais relacionadas ao uso, cobertura e propriedades do solo (BELMONTE et al., 2022; FAWCETT et al., 2020; WHITESIDE; BARTOLO, 2018).

O propósito deste estudo foi o de produzir mapas de COS com diferentes resoluções espaciais em diferentes áreas de estudo (AE), utilizando Random Forest (RF). Baseado nos conhecimentos em relação a escala e resolução espacial, é possível que a acurácia dos modelos treinados para a predição de COS em escala de propriedade agrícola melhore à medida que a resolução espacial das covariáveis aumenta e que modelos treinados com covariáveis com altas resoluções espaciais produzam mapas de COS com menor incerteza em relação a covariáveis de baixa resolução espacial. Com o objetivo de testar essa hipótese o estudo buscou: (i) quantificar e gerar mapas de COS em 4 propriedades agrícolas; (ii) identificar, entre 3 resoluções espaciais (1 m, 5 m e 10 m), a resolução que tem a capacidade de fornecer o melhor mapa de COS nas condições estabelecidas por este estudo; (iii) estabelecer uma referência para a avaliação de COS no futuro.

## 2. Materiais e métodos

### 2.1 Área de estudo

O estudo foi realizado na área de captação da bacia hidrográfica do arroio Epaminondas (BHAE), em quatro propriedades rurais, denominadas área de estudos A (AE-A), B (AE-B), C (AE-C) e D (AE-D) (Figura 1). Nesta área de bacia estão inseridas propriedades rurais que exercem atividades de pecuária com pastagem nativa e cultivada, além de cultivos anuais de milho e soja. Na região, ainda se encontram empreendimentos como agroindústrias e extração de argila e granito. A BHAE conta com área de aproximadamente 33,3 km<sup>2</sup> e corresponde a aproximadamente 70% da bacia hidrográfica do arroio Santa Bárbara, que abastece o município de Pelotas através da Barragem do Santa Bárbara. Segundo a classificação climática de Köppen, o clima da região está classificado com Cfa (clima temperado úmido com verão quente). Os valores de precipitação média anual são de 1386,6 mm (TEIXEIRA et al., 2013).

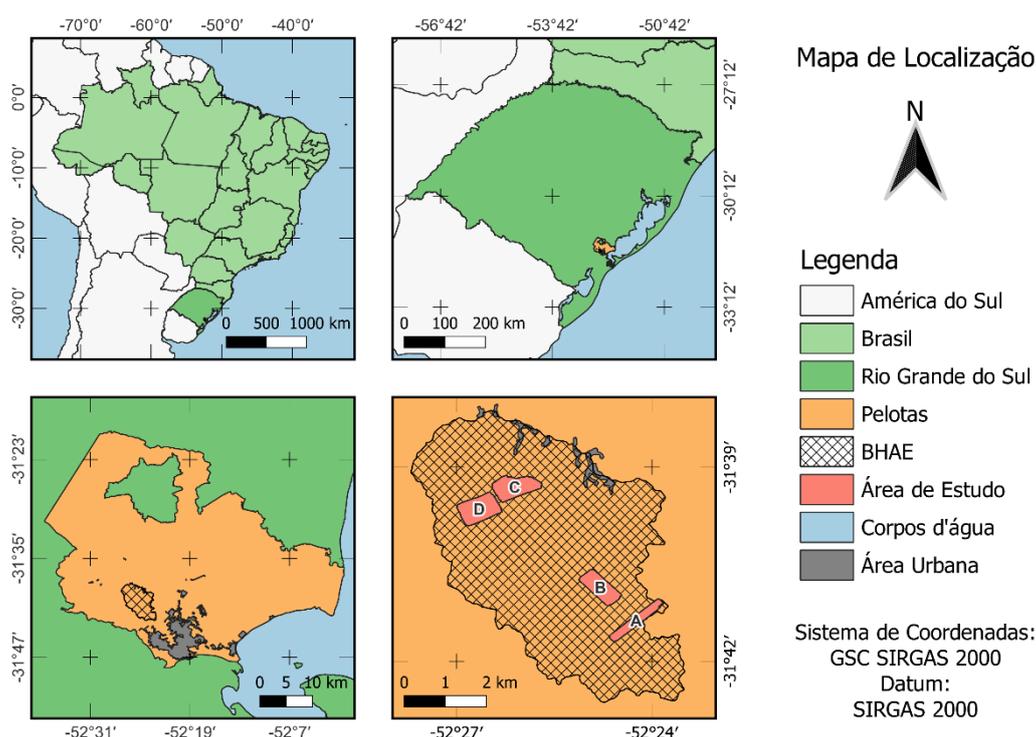


Figura 1 - Mapa de localização das áreas de estudo.

A BHAE encontra-se entre as latitudes de  $-52^{\circ}27'$  e  $-52^{\circ}23'$  e entre as longitudes de  $-31^{\circ}38'$  e  $-31^{\circ}42'$ . Esta área foi escolhida devido a sua importância para o abastecimento de água da cidade de Pelotas, bem como pela grande variabilidade na distribuição de solos, os quais abrangem desde solos de várzea (imperfeitamente a mal drenados) até solos rasos.

As 4 áreas de estudo (AE) foram selecionadas baseadas em sua posição relativa ao terreno (Figura 2) e devido a semelhança no manejo realizado na área. Tanto a AE-A quanto a AE-B estão localizadas em uma região mais baixa da bacia, com uma altitude média de aproximadamente 31 m e 27 m, respectivamente. Já as AE-C e AE-D encontram-se em uma área mais elevada da bacia, contando com uma altitude média de aproximadamente 67 m e 61 m, respectivamente.

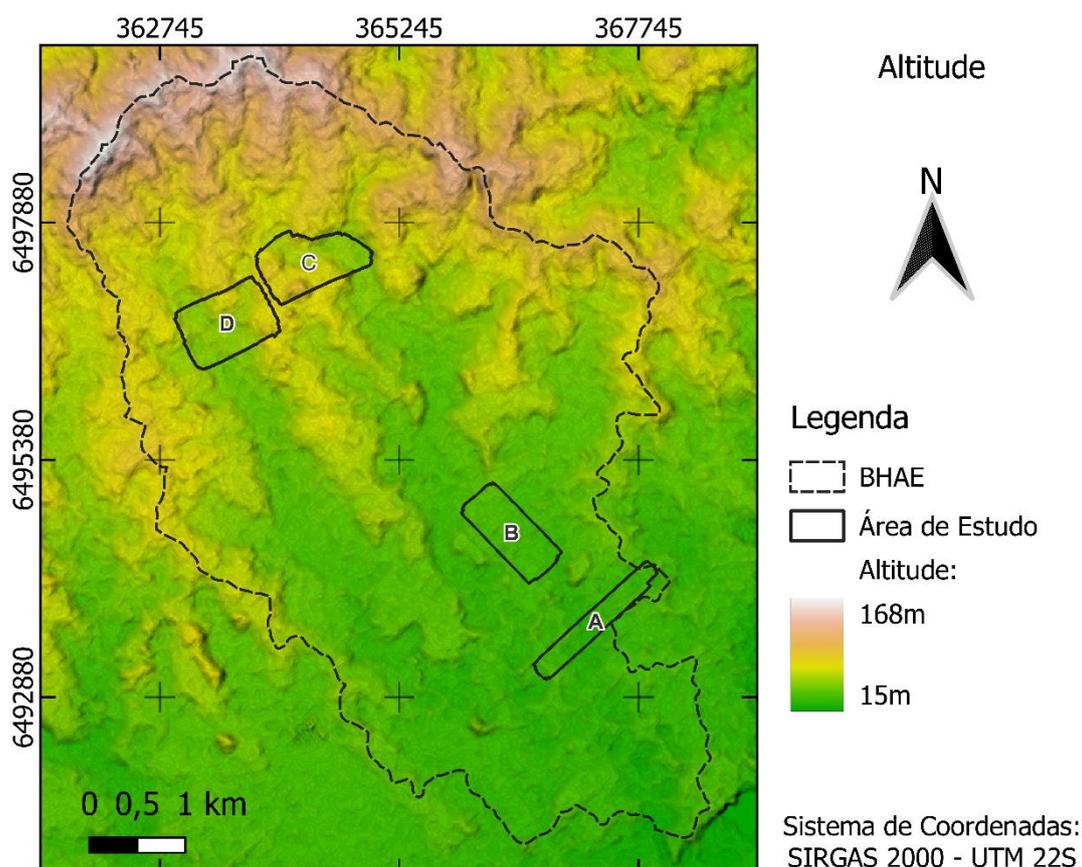


Figura 2 - Mapa de altitude com destaque das AE.

Outra característica levada em consideração foi a declividade (Figura 3). A AE-A e a AE-B se encontram em áreas menos declivosas, tendo a AE-A uma declividade média de aproximadamente 5,7% (suave ondulado) e a AE-B uma declividade média de 3,4% (suave ondulado). As AE-C e AE-D, entretanto, estão localizadas em uma porção mais declivosa da bacia, possuindo uma declividade média de 8,8% (ondulado) e 7,7% (suave ondulado), respectivamente.

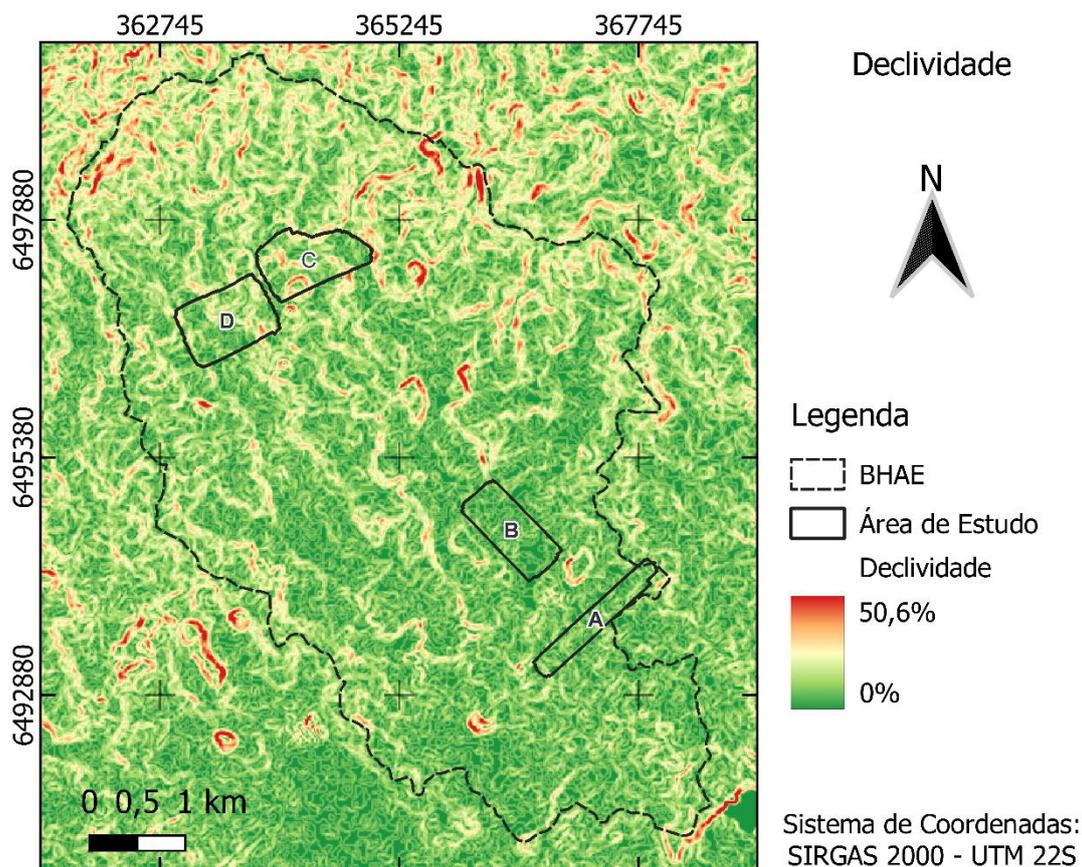


Figura 3 - Mapa de declividade com destaque às áreas de estudo.

A Figura 4 mostra o mapa de classe de solos da BHAE, onde predominam Planossolos no terço inferior e Argissolos no terço médio e superior. No terço inferior da bacia, são encontrados, PLANOSSOLOS HÁPLICOS Eutróficos gleissólicos horizonte A fraco (SXe), GLEISSOLOS HÁPLICOS Ta Eutróficos típicos horizonte A proeminente (GXve) e ARGISSOLOS AMARELOS Alumínicos abruptos horizonte A moderado (PAa), além de associações de GXve com SXe. No terço médio são encontrados ARGISSOLOS VERMELHO-AMARELOS Eutróficos típico horizonte A moderado (PVAe) e ARGISSOLOS VERMELHO-AMARELOS Alumínicos abrupto horizonte A moderado (PVAa). Já no terço superior além dos PVAe encontram-se NEOSSOLOS LITÓLICOS Eutróficos fragmentários A moderado (RLe) e CAMBISSOLOS HÁPLICOS Sódicos leptofragmentários A moderado (CXn) e associações de PVAe com CXn, RLe com CXn e PVAe com CXn e RLe. As AE-A e AE-B estão localizadas nas áreas com predominância de SXe, já parte da AE-C encontra-se em PVAe e parte em PVAa. Por fim, na AE-D encontra-se predominantemente o PVAe.

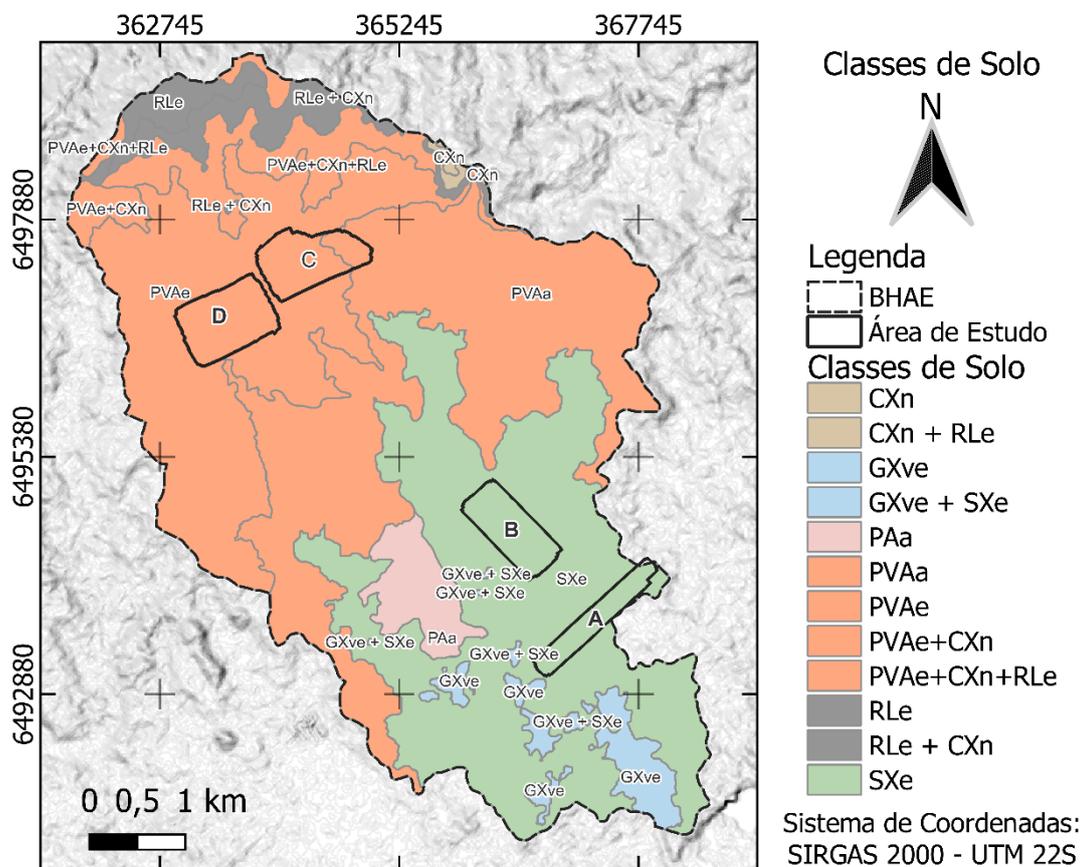


Figura 4 - Mapa de classes de solo com destaque às áreas de estudo.

Tanto a AE-A quanto a AE-B possuem área de cerca de 20 ha, já as AE-C e AE-D, área de aproximadamente 22 ha. A AE-A produz soja durante a safra de verão e na entressafra a área é coberta com pastagem e utilizada para a produção de gado de corte. As AE-B, AE-C e AE-D também produzem soja durante a safra de verão, porém, na entressafra, a área fica em pousio com plantas de cobertura como azevém (*Lolium multiflorum Lam.*) e nabo (*Raphanus sativus L.*). Em todas as áreas de estudo, o cultivo é com preparo convencional do solo não sendo utilizado o sistema de plantio direto. Além disso, tanto a AE-A quanto a AE-B também possuem área com eucalipto (*Eucalyptus spp.*) para silvicultura e todas as áreas de estudo possuem área com floresta preservada (Figura 5).

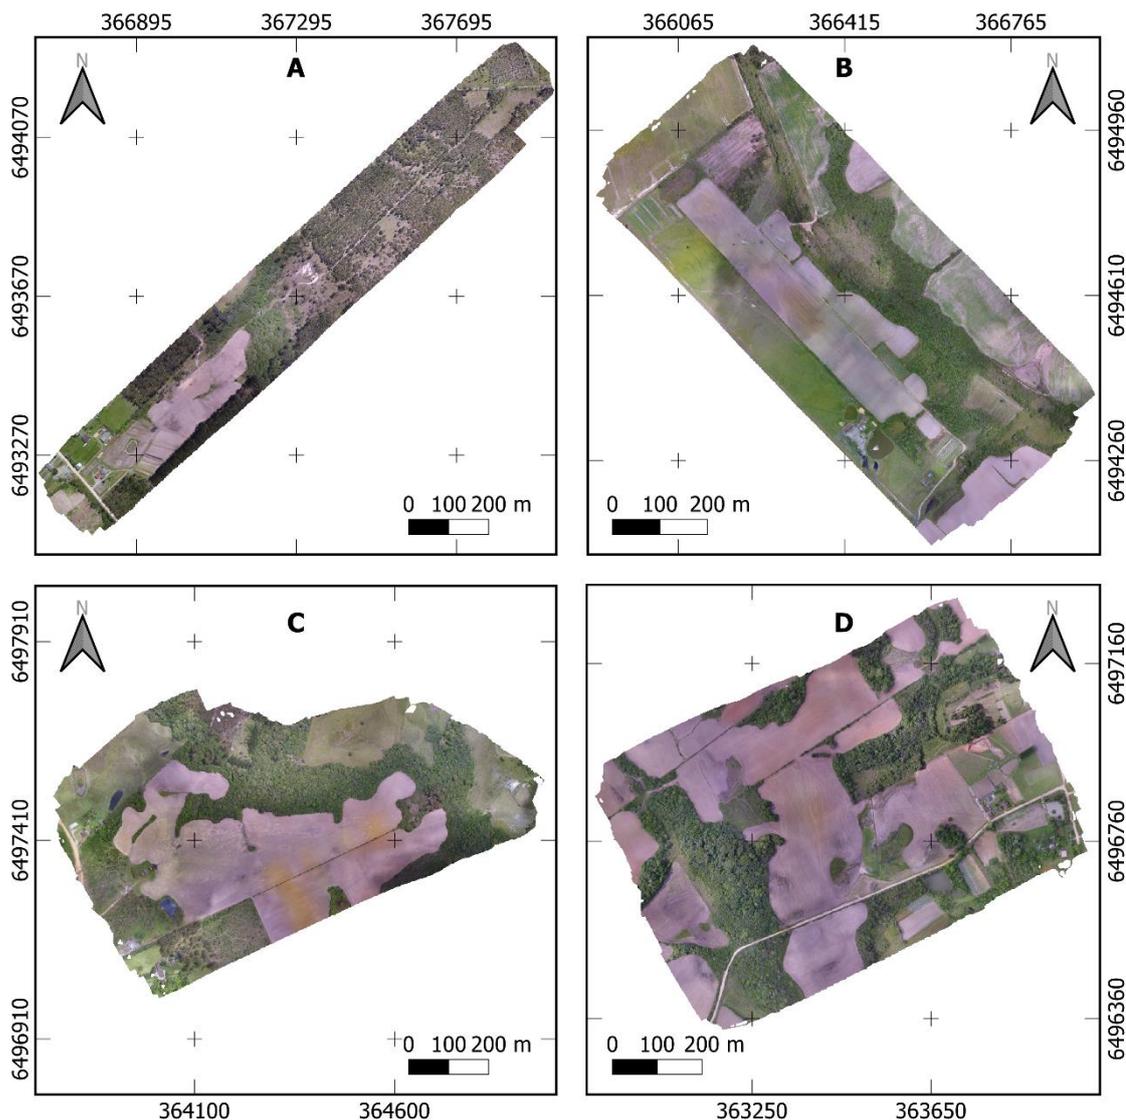


Figura 5 - Ortomosaico das áreas de estudo. A: AE-A; B: AE-B; C: AE-C; D: AE-D.

## 2.2 Levantamento aéreo de alta resolução

### 2.2.1 Levantamento com ARP

O levantamento aéreo foi realizado utilizando uma ARP modelo *DJI Phantom 3 Pro*, equipado com a câmera RGB DJI FC300X. A câmera conta com sensor de 1/2,3" CMOS, resolução de 12MP (4000×3000) e distância focal de 2,8 mm. O planejamento e gerenciamento dos voos foram realizados utilizando um *smartphone*, através do aplicativo *DroneDeploy: Drone Mapping Software*. Já para o processamento das imagens foi utilizado o *software Metashape* da *Agisoft*. Os mapas temáticos e pós processamento dos MDE foram realizados através do *software Quantum GIS* (QGIS.ORG, 2021).

### 2.2.2 Pontos de controle com GNSS

Para realizar a correção em 3 dimensões dos produtos gerados a partir das imagens da ARP foram utilizados pontos de controle no solo. Os alvos para os pontos de controle foram confeccionados utilizando piso vinílico com padrão xadrez preto e branco com uma área de aproximadamente 50 cm x 50 cm. O par de receptores (base e rover) do *Global Navigation Satellite System* (GNSS) utilizados são da marca Emlid, modelo *Reach RS+*. Estes são receptores multi-constelação, GPS, GLONASS, BeiDou e Galileu, que operam nas bandas L1 e L2. O levantamento de pontos com o GNSS utilizou o posicionamento cinemático em tempo real (RTK), os dados brutos da base foram pós processados no *site* do Instituto Brasileiro de Geografia e Estatística (IBGE) utilizando o método de Posicionamento por Ponto Preciso (PPP).

### 2.2.3 Geração do MDE detalhado

Os trabalhos a campo consistiram no levantamento dos pontos de controle e levantamento aéreo com ARP. Os levantamentos foram realizados obedecendo as normas estabelecidas pelo Departamento de Controle do Espaço Aéreo (DECEA). O plano de voo de cada uma das 4 áreas de estudo foi elaborado no aplicativo *Drone Deploy*, com uma sobreposição longitudinal de 75% e sobreposição lateral de 70%, foram realizados entre 2 e 4 voos por AE com uma variação na resolução espacial das imagens entre 2,1 e 3,0 cm / px. Antes da realização dos voos, 24 alvos foram distribuídos de forma aleatória no solo, porém de forma que se encontrassem centralizado com a linha de voo da ARP. Posteriormente, utilizando o *rover*, foi realizado o georreferenciamento do centro de cada um dos alvos.

Os trabalhos de escritório consistiram nos pós processamento dos dados brutos da base no PPP do IBGE para a correção de erros e no processamento das imagens da ARP no *software Metashape*. No *Metashape*, o fluxo de trabalho foi o seguinte: alinhamento das imagens, inserção e processamento dos pontos de controle para aumentar a precisão horizontal e vertical do produto final, nuvem densa de pontos, construção do modelo 3d, aplicação de textura, construção do modelo digital de superfície (MDS), construção do ortomosaico. Ainda foi realizado uma classificação da nuvem densa de pontos para que no final fosse gerado o produto de interesse para esse trabalho, o modelo digital de elevação. Esse processo se dá pela subtração dos pontos que não foram classificados como solo da nuvem densa de pontos, de posse dessa nova nuvem densa de pontos o *software* tenta construir da melhor forma

possível o MDE. Por fim, cada um dos MDE foi reamostrado para uma resolução espacial de 1 m, 5 m e 10 m utilizando o método de reamostragem *nearest neighbor*.

### 2.3 Covariáveis

Os atributos do terreno foram derivados a partir do MDE utilizando o *software* SAGA GIS 7.71 (CONRAD et al., 2015). Ao todo foram geradas 34 covariáveis utilizando como base cada um dos 12 MDE criados de acordo com o item **Erro! Fonte de referência não encontrada.** Além disso, foram adicionadas mais 9 covariáveis derivadas a partir de imagens multiespectrais de satélite (R, G, B, NIR) com resolução espacial de 3 m (PLANET EXPLORER, 2022) do mês de dezembro de 2021 e 10 m L2A do sensor *Multispectral Instrument* (MSI) ("Sentinel-2 - Missions", 2022) do mês de fevereiro de 2022. As imagens multiespectrais com resolução espacial de 3 m foram reamostradas para 1 m e 5 m utilizando o método de reamostragem *nearest neighbor*. A Tabela 1 a seguir mostra todas as covariáveis utilizadas neste estudo.

Tabela 1 - Covariáveis do terreno derivadas do MDE e sensor orbital

Atributos	Abreviação	Descrição sucinta	Referência
Aspect	ASP	Orientação do declive	(OLAYA, 2009)
blue	BLUE	Banda azul do sensor do satélite	Planet Explorer, (2022); Sentinel-2 - Missions, (2022)
green	GREEN	Banda verde do sensor do satélite	Planet Explorer, (2022); Sentinel-2 - Missions, (2022)
red	RED	Banda vermelha do sensor do satélite	Planet Explorer, (2022); Sentinel-2 - Missions, (2022)
nir	NIR	Banda infravermelho próximo do sensor do satélite	Planet Explorer, (2022); Sentinel-2 - Missions, (2022)
Convergence index	CI	Índice de convergência / divergência em relação ao escoamento	Olaya e Conrad (2009)
Cross-sectional curvature	CSC	Mede a curvatura perpendicular à direção do declive	Olaya (2009)
Diurnal anisotropic heating	DAH	Medição contínua da energia dependente da exposição	Böhner e Antonić (2009)
Easternness	E	Seno de aspecto	Olaya (2009)
Digital elevation model	ELEV	Modelo Digital de Elevação	Florinsky (2016)
Flow line curvature	FLC	Representa a projeção de uma linha de gradiente em um plano horizontal	Olaya (2009)
Flow Accumulation (Top-Down)	FLOW	Fluxo acumulado para cada célula.	Gruber e Peckham (2009)
General curvature	GC	A combinação das curvaturas do plano e do perfil	Olaya (2009)

Longitudinal curvature	LC	Mede a curvatura na direção do declive	Olaya (2009)
LS Factor	LS	Fator Topográfico	Desmet e Govers (1996)
Maximal curvature	MAXC	Curvatura máxima na seção normal local	Olaya (2009)
Mass balance index	MBI	Índice de equilíbrio entre erosão e deposição	Möller <i>et al.</i> (2008)
Minimal curvature	MINC	Curvatura mínima para seção normal local	Olaya (2009)
Multiresolution index of ridge top flatness	MRRTF	Indica posições planas em áreas de alta altitude	Gallant e Dowling (2003)
Multiresolution index of valley bottom flatness	MRVBF	Indica superfícies planas no fundo do vale	Wang <i>et al.</i> (2010)
Mid-slope position	MSP	Representa a distância do topo ao vale, variando de 0 a 1	Böhner e Selige (2006)
Northernness	N	Cosseno de aspecto	Olaya (2009)
Normalized Difference Vegetation Index	NDVI	$\frac{NIR - RED}{NIR + RED}$	Carlson e Ripley (1997)
Normalized Difference Water Index	NDWI	$\frac{GREEN - NIR}{GREEN + NIR}$	Gao (1996)
Normalized height	NH	Distância vertical entre a base e o cume da declividade normalizada	Böhner e Selige (2006)
Normalized Pigment Chlorophyll Ratio Index	NPCRI	$\frac{RED - BLUE}{RED + BLUE}$	Sosa <i>et al.</i> (2021)
Plan curvature	PLANC	Curvatura da linha de contorno hipotética passando por uma célula específica	Olaya (2009)
Profile curvature	PROC	Descreve a curvatura da superfície na direção da inclinação mais íngreme	Olaya (2009)
Real surface area	RSA	Cálculo real da área da célula	Olaya (2004)
Slope	S	Representa declividade angular local	Câmara <i>et al.</i> (1996)
Soil Adjusted Vegetation Index	SAVI	$(1 + L) \times \frac{NIR - RED}{NIR + RED + L}$	Huete (1988)
Soil Brightness Index	SBI	$\sqrt{RED^2 + NIR^2}$	Elvidge e Lyon (1985)
Slope height	SH	Distância vertical entre a base e o cume da encosta	Böhner e Selige (2006)
Surface specific points	SSP	Indica diferenças entre pontos de deslocamento de superfície específicos	Peucker e Douglas (1975)
Standardized height	STANH	Distância vertical entre a base e o índice de inclinação padronizado	Böhner e Selige (2006)
Tangencial curvature	TANC	Medido no plano normal em uma direção perpendicular ao gradiente	Olaya (2009)
Total curvature	TC	Medida geral da curvatura da superfície	Olaya (2009)
Topographic position index	TPI	Diferença entre a elevação de um ponto e a elevação circundante	Gallant e Wilson (2000)
Terrain ruggedness index	TRI	Índice quantitativo de heterogeneidade topográfica	Riley <i>et al.</i> (1999)

Terrain surface convexity	TSC	Razão entre o número de células que têm curvatura positiva e o número total	Iwahashi e Pike (2007)
Topographic wetness index	TWI	Descreve a tendência de cada célula em acumular água em função do relevo	Pei <i>et al.</i> (2010)
Valley depth	VD	Cálculo da distância vertical ao nível da base de drenagem	Böhner e Selige (2006)
Vector ruggedness measure	VRM	Mede a variação da rugosidade do terreno	Hobson (1972)

## 2.4 Amostragem e análises de solos

A malha amostral para a determinação do COS foi gerada utilizando o método conditioned Latin Hypercube Sampling (cLHS) (MINASNY; MCBRATNEY, 2006). O cLHS foi implementado através do pacote cLHS (ROUDIER, 2014) do software R (TEAM R DEVELOPMENT CORE, 2018). Foram realizadas entre 42 e 46 amostragens em cada AE, levando em consideração a acessibilidade do terreno para a realização da coleta (Figura 6).

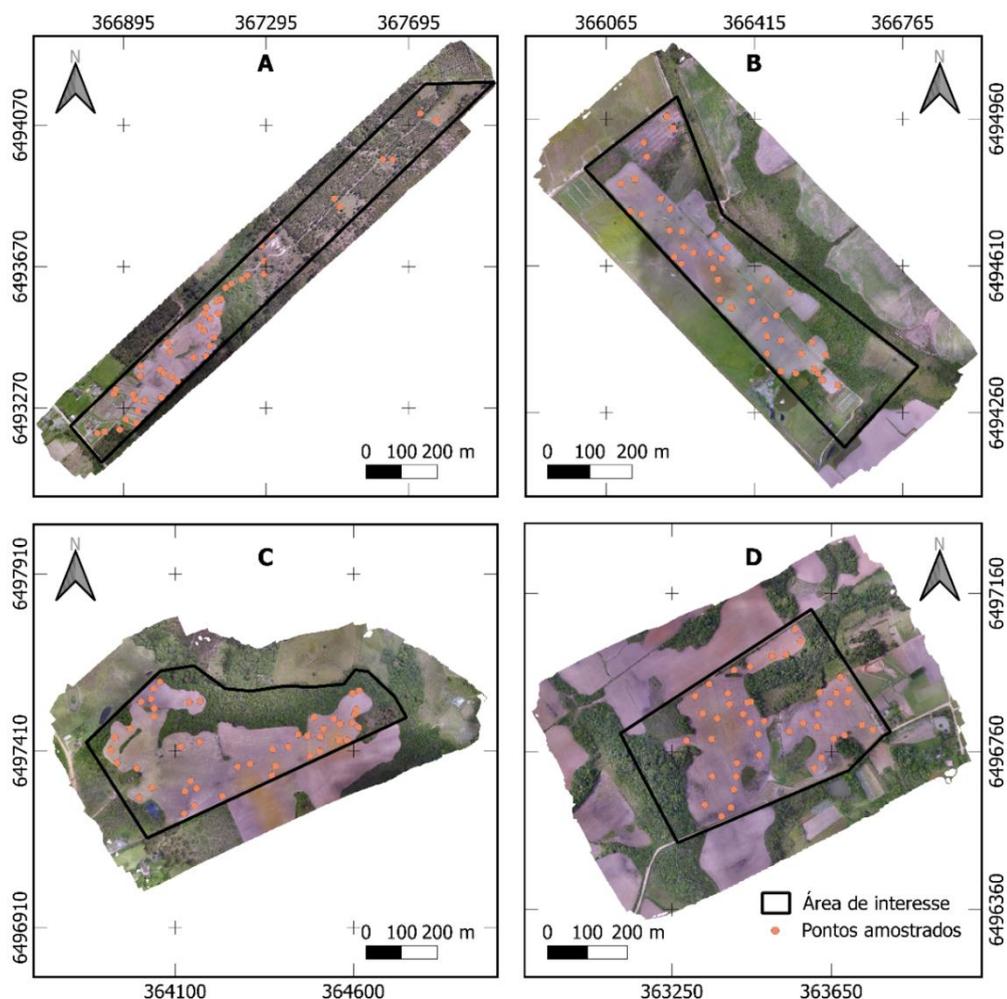


Figura 6 - Localização das amostragens de solo para análise de carbono orgânico do solo e área de interesse das áreas de estudo. A: AE-A; B: AE-B; C: AE-C; D: AE-D.

Para a determinação do COS, cada amostra foi coletada a uma profundidade de 0 – 20 cm utilizando trado holandês. A amostragem foi realizada com o auxílio de um GNSS para a localização dos pontos gerados com o cLHS. No laboratório as amostras foram secas ao ar, destorroadas e passadas por peneira com malha de 2 mm, denominadas terra fina seca ao ar (TFSA). O teor de COS (Tabela 2) foi determinado via oxidação úmida com dicromato de potássio,  $K_2Cr_2O_7$  0,4 mol L<sup>-1</sup> e aquecimento em bloco digestor. A titulação foi por meio de sulfato de ferro II OSO,  $Fe(NH_4)_2(SO_4)_2 \cdot 6H_2O$  sendo a difenilamina,  $(C_6H_5)_2NH$ , o indicador (TEIXEIRA et al., 2017).

Tabela 2 - Resultados da análise de carbono orgânico do solo.

AE-A*		AE-B		AE-C		AE-D	
Amostra	C g/kg						
A - 01	6.99	B - 01	8.09	C - 01	10.89	D - 01	13.05
A - 02	8.31	B - 02	6.25	C - 02	11.18	D - 02	8.99
A - 03	5.94	B - 03	6.12	C - 03	13.91	D - 03	8.88
A - 04	4.63	B - 04	6.38	C - 04	8.98	D - 04	9.47
A - 05	9.86	B - 05	3.75	C - 05	11.31	D - 05	7.78
A - 06	10.00	B - 06	4.83	C - 06	21.63	D - 06	12.06
A - 07	8.75	B - 07	5.62	C - 07	15.70	D - 07	12.66
A - 08	8.44	B - 08	13.78	C - 08	18.64	D - 08	6.43
A - 09	7.16	B - 09	12.59	C - 09	13.55	D - 09	6.67
A - 10	6.45	B - 10	7.86	C - 10	17.55	D - 10	11.33
A - 11	8.44	B - 11	14.14	C - 11	10.32	D - 11	10.64
A - 12	3.88	B - 12	7.37	C - 12	8.10	D - 12	7.68
A - 13	7.09	B - 13	14.10	C - 13	10.11	D - 13	12.45
A - 14	8.07	B - 14	13.42	C - 14	13.91	D - 14	7.78
A - 15	9.63	B - 15	6.28	C - 15	13.94	D - 15	9.91
A - 16	9.36	B - 16	2.86	C - 16	13.22	D - 16	9.94
A - 17	13.20	B - 17	8.41	C - 17	15.01	D - 17	13.18
A - 18	16.20	B - 18	7.33	C - 18	10.37	D - 18	12.95
A - 19	6.23	B - 19	24.53	C - 19	11.78	D - 19	10.57
A - 20	4.47	B - 20	10.19	C - 20	12.05	D - 20	9.94
A - 21	15.20	B - 21	23.22	C - 21	10.63	D - 21	6.23
A - 22	3.71	B - 22	20.36	C - 22	9.87	D - 22	8.88
A - 23	5.60	B - 23	6.68	C - 23	10.56	D - 23	13.22
A - 24	11.30	B - 24	7.99	C - 24	13.58	D - 24	11.36
A - 25	9.14	B - 25	6.94	C - 25	14.20	D - 25	8.16
A - 26	6.86	B - 26	3.27	C - 26	14.11	D - 26	6.41
A - 27	11.40	B - 27	20.19	C - 27	15.32	D - 27	8.33
A - 28	12.40	B - 28	20.95	C - 28	12.18	D - 28	8.06
A - 29	12.70	B - 29	13.42	C - 29	11.09	D - 29	10.74
A - 30	9.77	B - 30	11.72	C - 30	10.92	D - 30	10.31
A - 31	3.38	B - 31	12.38	C - 31	10.88	D - 31	5.29
A - 32	11.20	B - 32	11.85	C - 32	8.39	D - 32	6.25
A - 33	9.54	B - 33	18.38	C - 33	10.33	D - 33	8.29
A - 34	1.59	B - 34	16.53	C - 34	11.65	D - 34	8.62
A - 35	6.19	B - 35	25.15	C - 35	7.79	D - 35	15.33
A - 36	6.29	B - 36	31.33	C - 36	7.55	D - 36	11.34
A - 37	7.09	B - 37	13.29	C - 37	10.65	D - 37	7.75
A - 38	9.19	B - 38	14.85	C - 38	10.40	D - 38	10.04

A - 39	6.93	B - 39	10.59	C - 39	13.81	D - 39	3.89
A - 40	7.82	B - 40	10.59	C - 40	14.71	D - 40	6.96
A - 41	11.30	B - 41	13.39	C - 41	10.76	D - 41	7.58
A - 42	13.70	B - 42	12.02	C - 42	10.50	D - 42	6.54
A - 43	11.70					D - 43	8.91
A - 44	10.40					D - 44	4.50
A - 45	4.08						
A - 46	7.65						

\* <sup>1</sup> (AE-A) área de estudo A; (AE-B) área de estudo B; (AE-C) área de estudo C; (AE-D) área de estudo D.

É muito comum na região a incorporação de casca de arroz carbonizada como aporte de matéria orgânica e minerais para o solo. Essa incorporação nem sempre é feita de forma uniforme, fazendo com que a concentração de COS em certas áreas seja mais elevada. Cientes dessa característica, antes de realizar a modelagem dos dados foram identificados e retirados os *outliers* do conjunto de dados. Para tanto foi considerado como *outlier* todos os valores que se desviassem mais do que 1,5x do intervalo interquartil, tanto superior quanto inferior (Figura 7).

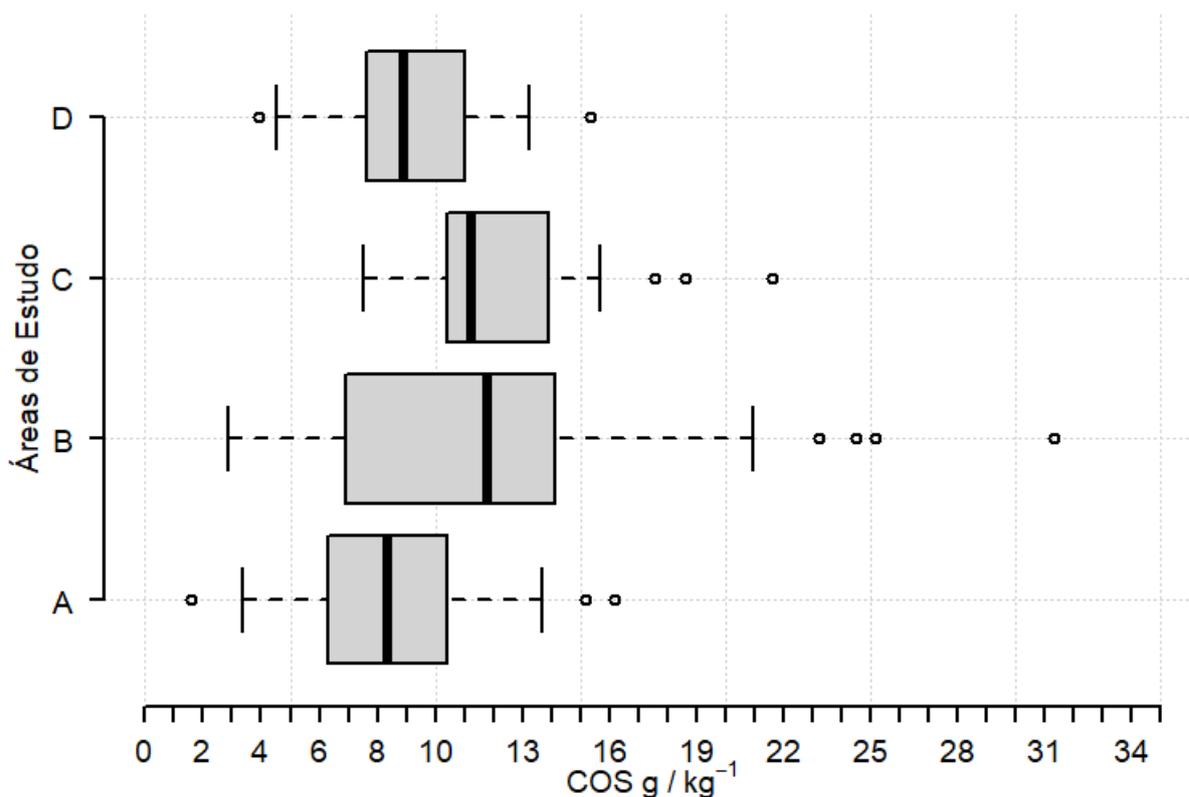


Figura 7 - Boxplots do COS. A, B, C e D são as áreas de estudo. Cada caixa representa o intervalo interquartil, a barra destacada dentro de cada caixa representa a mediana, as barras ao final das linhas tracejadas representam os limites superiores e inferiores.

Devido a maior resolução espacial das imagens geradas utilizando ARP, a densidade amostral das áreas acabou sendo baixa. Convencionou-se então a criação de um buffer ao redor de cada ponto (Figura 8) e dentro destes foram distribuídos mais pontos, com o valor de COS do ponto original, utilizando como referência cada um dos MDE de diferentes resoluções criados. O raio do buffer de cada uma das imagens foi estipulado utilizando a própria resolução espacial da imagem, ou seja, imagens com resolução espacial de 1 m receberam um buffer de 1 m e assim por diante.

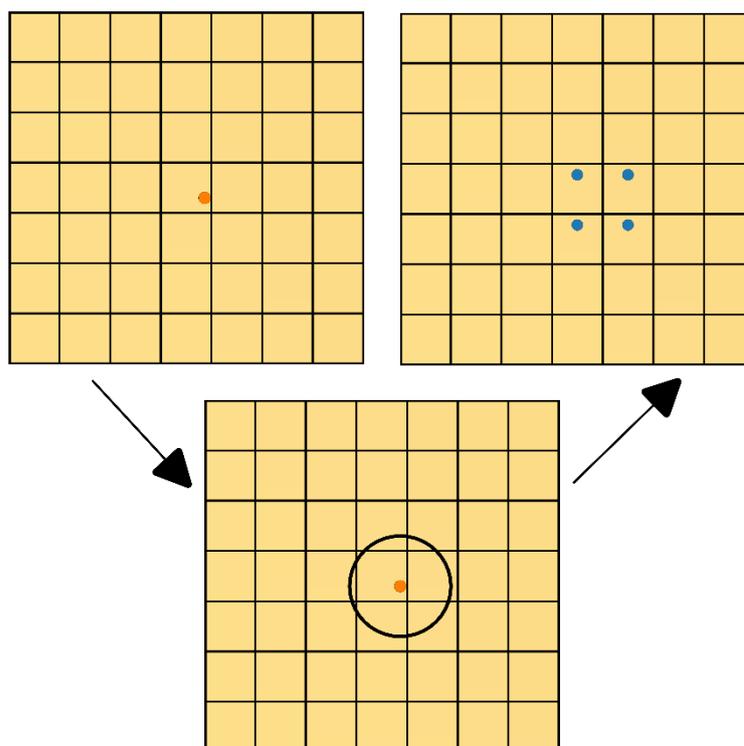


Figura 8 – Distribuição de novos pontos com auxílio de buffer

O conjunto de dados final ( $n$ ) após a remoção dos outliers e a geração de novos pontos dentro do *buffer* pode ser encontrado na Tabela 3.

Tabela 3 - Conjunto de dados final para cada uma das diferentes áreas de estudo e diferentes resoluções espaciais.

Resolução espacial	A*	Amostras totais ( $n$ )		
		B	C	D
1 m	142	126	147	133
5 m	135	125	136	133
10 m	144	129	144	134

\* (A) área de estudo A; (B) área de estudo B; (C) área de estudo C; (D) área de estudo D.

## 2.5 Modelagem e mapeamento do carbono orgânico do solo

### 2.5.1 Random forest

Para a realização desse estudo foi empregado o método de classificação e regressão RF. O RF consiste em diversos conjuntos de árvores de decisão independentes que através de um treinamento supervisionado é capaz de realizar a classificação ou regressão de um conjunto de dados (BREIMAN, 2001). As árvores de decisão são geradas e treinadas utilizando *bootstrapping* que é uma técnica de reamostragem que consiste em retirar uma amostra menor de um conjunto de dados maior. Essa amostra então é “escrita” e retorna para o conjunto de dados, de onde novamente é retirada uma amostra. Esse processo é repetido  $n$  vezes, onde  $n$  é o número de amostras no conjunto. No final do processo é obtido uma amostra *bootstrap*, ao qual repetido  $B$  vezes se obtém um conjunto de  $B$  amostras *bootstrap*. O RF utiliza esses conjuntos de informações para construir as árvores de decisões (KUHN; JOHNSON, 2013).

A modelagem dos dados foi realizada no R versão 4.0.2 (R CORE TEAM, 2021) utilizando o pacote *caret* (KUHN, 2008). Antes de realizar a modelagem, alguns parâmetros foram ajustados. A escolha do parâmetro *mtry* foi feita com base no desempenho do modelo. Utilizando a função “train” do pacote *caret* o melhor valor de tunagem foi encontrado através do procedimento de reamostragem utilizando validação cruzada (VC), o valor para parâmetro *k-fold* da VC escolhido foi 10. Os testes foram realizados utilizando valores *mtry* entre 1 e 20, o valor da tentativa com a menor raiz do erro quadrático médio (RMSE em inglês) foi escolhido como o valor final para o *mtry*. Já para o número de árvores de decisão, o valor escolhido foi 500, visto que o erro se manteve estável próximo a esse valor para qualquer um dos modelos treinados. (KUHN; JOHNSON, 2013).

### 2.5.2 Acurácia e incerteza

Como parâmetros de avaliação da acurácia do modelo treinado foram utilizados a RMSE, coeficiente de determinação ( $R^2$ ), erro médio absoluto (MEA do inglês) e erro médio relativo (MRE do inglês) (KHALEDIAN; MILLER, 2020; KUHN; JOHNSON, 2013; LEMERCIER et al., 2022).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (obs_i - pred_i)^2} \quad (1)$$

$$R^2 = \frac{\sum_{i=1}^n (obs_i pred_i - \overline{obs} \overline{pred})^2}{(\sum_{i=1}^n obs_i^2 - \overline{obs}^2)(\sum_{i=1}^n pred_i^2 - \overline{pred}^2)} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |pred_i - obs_i| \quad (3)$$

$$MRE = \frac{1}{n} \sum_{i=1}^n \frac{|obs_i - pred_i|}{pred_i} \times 100\% \quad (4)$$

Temos que,  $obs_i$  e  $pred_i$  são os valores observado e preditos de COS respectivamente;  $\overline{obs}$  e  $\overline{pred}$  são as médias dos valores observados e preditos.

A incerteza dos mapas preditos foi calculada utilizando *quantile regression forest* (QRF) (MEINSHAUSEN, 2006) utilizando o pacote *quantregForest* no R (MEINSHAUSEN, 2017). QRF é muito usada em RF pois seus intervalos de predição cobrem novas observações com alta probabilidade. Em situações com dados esparsos o QRF se destaca em relação a regressão de krigagem, sendo recomendado para situações com dados esparsos. Através do QRF a incerteza é caracterizada pela distribuição condicional da variável de resposta. O QRF mantém o valor de todas as observações do nó de cada árvore e preserva todos os parâmetros da função de distribuição condicional, ao contrário do RF que mantém somente a média. Dessa forma é capaz de avaliar a distribuição condicional (VAYSSE; LAGACHERIE, 2017). Para a representação da incerteza nos mapas, foi utilizado o coeficiente de variação (CV),

$$CV = \frac{\sigma}{\mu} \quad (5)$$

onde,  $\sigma$  é o desvio padrão calculado para cada pixel e  $\mu$  é a média calculado para cada pixel, ambos utilizando os dados disponibilizado pelo QRF.

### 3. Resultados

#### 3.1 Estatística descritiva do carbono orgânico do solo

A estatística descritiva para os valores de COS determinados em laboratório é apresentada na tabela 4. É possível observar que os valores de COS para a AE-A variaram entre 3,38 g kg<sup>-1</sup> e 16,20 g kg<sup>-1</sup>, para a AE-B entre 2,86 g kg<sup>-1</sup> e 16,53 g kg<sup>-1</sup>, para a AE-C entre 7,55 g kg<sup>-1</sup> e 17,55 g kg<sup>-1</sup> e por fim para a AE-D, entre 3,89 g kg<sup>-1</sup> e 15,33 g kg<sup>-1</sup>. O desvio padrão (SD) dos valores obtidos na AE-C foi de 2,32 e da AE-D de 2,58, já para as AE-A e AE-B, o SD foi de 3,06 e 3,75, respectivamente. O coeficiente de variação (CV) foi 0,20 para a AE-C, de 0,28 para a AE-D, de 0,35 para a AE-A e 0,39 para a AE-B.

Tabela 4 - Estatística descritiva do conjunto de dados de COS.

	A <sup>1</sup>	B	C	D
Min	3,38	2,86	7,55	3,89
Max	16,20	16,53	17,55	15,33
Mediana	8,44	9,30	11,14	8,90
Média	8,61	9,56	11,79	9,21
SD <sup>2</sup>	3,06	3,75	2,32	2,58
CV <sup>3</sup>	0,35	0,39	0,20	0,28

<sup>1</sup> (A) área de estudo A; (B) área de estudo B; (C) área de estudo C; (D) área de estudo D. <sup>2</sup> Desvio Padrão (*standard deviation*). <sup>3</sup> Coeficiente de Variação.

#### 3.2 Validação do modelo

Na Tabela 5 são apresentados os resultados referentes a estatística do modelo preditivo. A AE-C apresentou o maior valor de R<sup>2</sup> (0,88) para a resolução espacial de 1 m entre as 4 AE, seguido pela AE-B (0,83) e tendo a AE-A o menor valor de R<sup>2</sup>, 0,67. Nos modelos preditos com covariáveis com resolução espacial de 5m, a AE-C também apresentou o maior valor de R<sup>2</sup> (0,80), próximo ao valor da AE-B que apresentou um R<sup>2</sup> de 0,79. O menor valor e R<sup>2</sup> foi encontrado na AE-D, 0,53. Com resolução espacial de 10m, o maior R<sup>2</sup> foi calculado para a AE-B (0,82), seguido pela AE-C (0,72), já o menor valor foi calculado para a AE-D (0,40).

Em relação ao RMSE, a AE-C apresentou o menor valor de RMSE para os modelos preditos em todas as 3 resoluções espaciais, 1,10 g kg<sup>-1</sup> (1m), 1,16 g kg<sup>-1</sup> (5 m) e 1,36 g kg<sup>-1</sup> (10 m). O maior valor de RMSE para resolução de 1m, 5m e 10m foi encontrado na AE-A, 1,96 g kg<sup>-1</sup>, 1,95 g kg<sup>-1</sup> e 2,37 g kg<sup>-1</sup>, respectivamente.

Tabela 5 - Acurácia do modelo preditivo para as áreas de estudo A, B, C e D e resolução espacial de 1m, 5m e 10m. Em negrito os maiores valores de R<sup>2</sup> e menores valores de RMSE para cada resolução espacial.

Resolução espacial	A				B			
	R <sup>2</sup>	RMSE (g kg <sup>-1</sup> )	MAE	MRE(%)	R <sup>2</sup>	RMSE (g kg <sup>-1</sup> )	MAE	MRE(%)
1 m	0,67	1,96	1,55	17,68	0,83	1,68	1,33	15,17
5 m	0,63	1,95	1,58	19,20	0,79	1,79	1,32	15,15
10 m	0,43	2,37	1,91	21,96	<b>0,82</b>	1,61	1,24	13,73
	C				D			
	R <sup>2</sup>	RMSE (g kg <sup>-1</sup> )	MAE	MRE(%)	R <sup>2</sup>	RMSE (g kg <sup>-1</sup> )	MAE	MRE(%)
1 m	<b>0,88</b>	<b>1,10</b>	0,85	7,17	0,68	1,55	1,20	13,08
5 m	<b>0,80</b>	<b>1,16</b>	0,89	7,55	0,53	1,90	1,53	16,96
10 m	0,72	<b>1,36</b>	1,06	9,03	0,40	2,05	1,67	18,15

\* R<sup>2</sup>: coeficiente de determinação; RMSE: raiz do erro quadrático médio; MAE: erro médio absoluto; MRE: erro médio relativo.

### 3.3 Mapeamento de alta resolução

#### 3.3.1 Modelo digital de elevação de alta resolução

Na Figura 9 são apresentadas as variações da altitude dentro de cada uma das AE. As AE-A e AE-B encontram-se no terço inferior da BHAE em uma área mais plana, portanto possuem uma menor variação no relevo, as AE-C e AE-D encontram-se no terço médio em uma área mais declivosa da BHAE, possuindo uma maior variabilidade na altitude. A altitude na AE-A variou entre 25,26 m no ponto mais baixo e 33,98 m no ponto mais alto, uma diferença de 8,72 m. A AE-B possui uma amplitude de altitude de 7,73 m, tendo o ponto mais baixo 22,36 m, o mais baixo entre as 4 AE, e o ponto mais alto 30,09 m. A AE-C possui o ponto mais alto entre as 4 AE, 82,82 m, e seu ponto mais baixo possui 53,13 m, uma diferença de 29,69 m. Já a AE-D possui 77,36 m no seu ponto mais alto e 51,61 m em seu ponto mais baixo, uma diferença de 25,75 m.

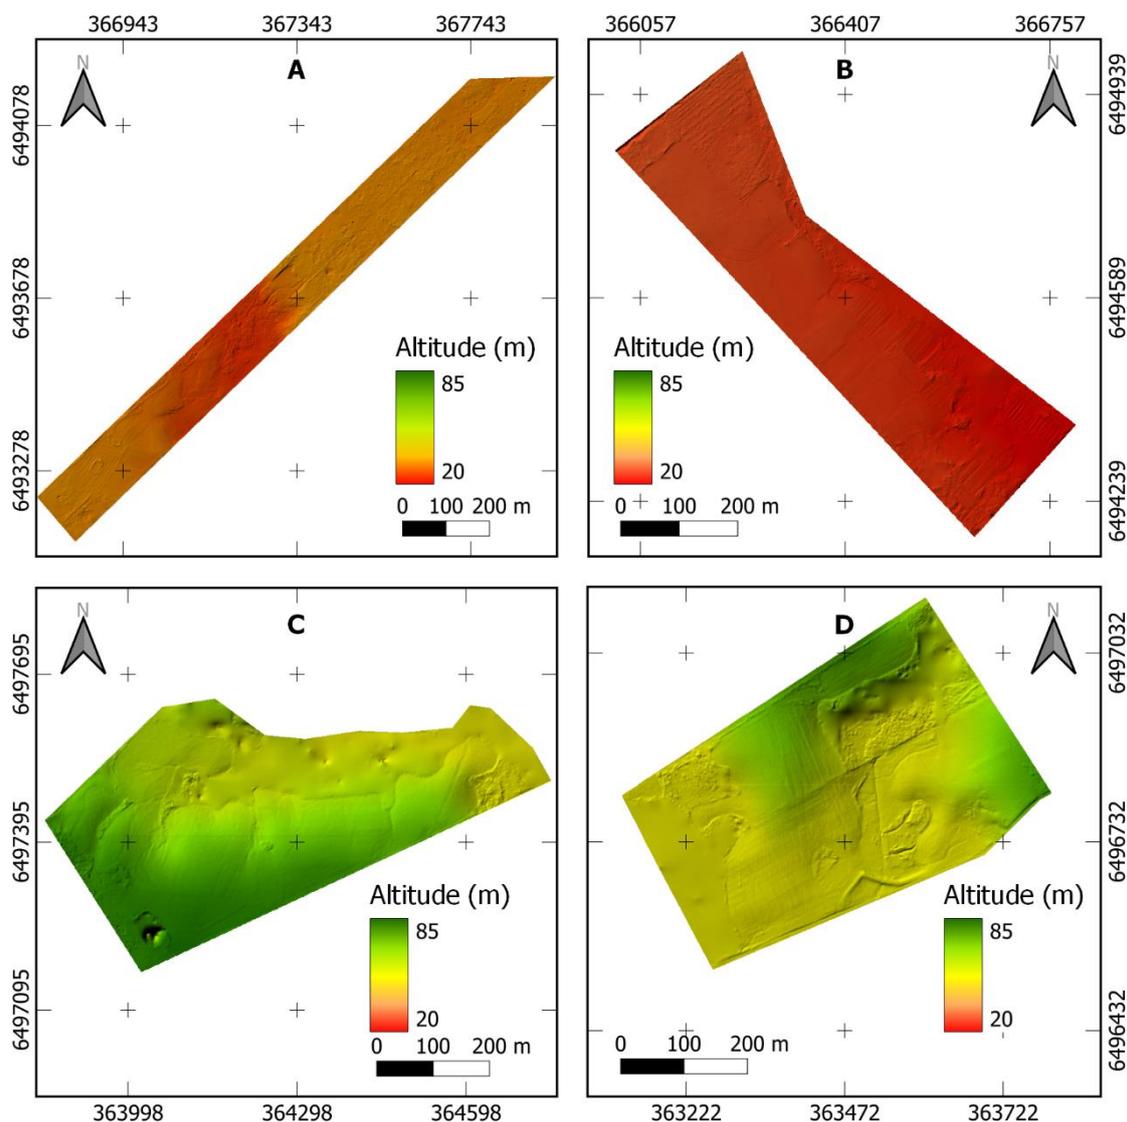


Figura 9 - MDEs das AE-A, AE-B, AE-C e AE-D

### 3.3.2 Modelagem de predição do COS

A partir da interpretação dos mapas preditos de COS, os quais apresentam mapas de incerteza e a estatística descritiva calculada (Figura 10, Figura 11, Figura 12, Figura 13), é possível identificar que nas AE, o COS variou entre  $3,73 \text{ g kg}^{-1}$  e  $17,1 \text{ g kg}^{-1}$ . O menor valor de COS ( $3,73 \text{ g kg}^{-1}$ ) foi predito na AE-B, em resolução espacial de 10m (Figura 11). O maior valor de COS foi predito na AE-C,  $17,1 \text{ g kg}^{-1}$  com resolução espacial de 1m (Figura 12). As médias ficaram bem próximas nas AE-A, AE-B e AE-D em todas as resoluções espaciais, variando entre  $9,23 \text{ g kg}^{-1}$  e  $9,48 \text{ g kg}^{-1}$ . A áreas de estudo com a maior média foi a AE-C, com média variando entre  $12,05 \text{ g kg}^{-1}$  e  $12,17 \text{ g kg}^{-1}$ . Os maiores valores de SD e CV foram encontrados na AE-

B, 2,08 (1m), 2,54 (5m) e 2,90 (10m) para o SD, e CV de 21,91%, 27,38% e 31,38% para as resoluções espaciais de 1m, 5m e 10m respectivamente.

### **3.3.3 Incerteza associada ao modelo de predição**

As AE que apresentaram a menor incerteza foram as AE-C (Figura 12) e AD-D (Figura 13), variando entre 0,08 e 0,46 e 0,14 e 0,74 respectivamente. Além de apresentar os menores valores de incerteza, a AE-C também apresentou os menores CV, 17,02% para a resolução espacial de 1 m, 20,19% para resolução de 5 m e 22,83% para a resolução de 10 m. Já as AE-A (Figura 10) e AE-B (Figura 11) apresentaram os maiores valores de incerteza, variando entre 0,17 e 0,90 e 0,12 e 0,95 respectivamente. Os maiores valores de incerteza foram encontrados para a AE-B, bem como os maiores CV. O CV para a resolução de 1 m foi de 27,85%, para resolução de 5 m, 37,45% e para resolução espacial de 10 m foi de 40,94%.

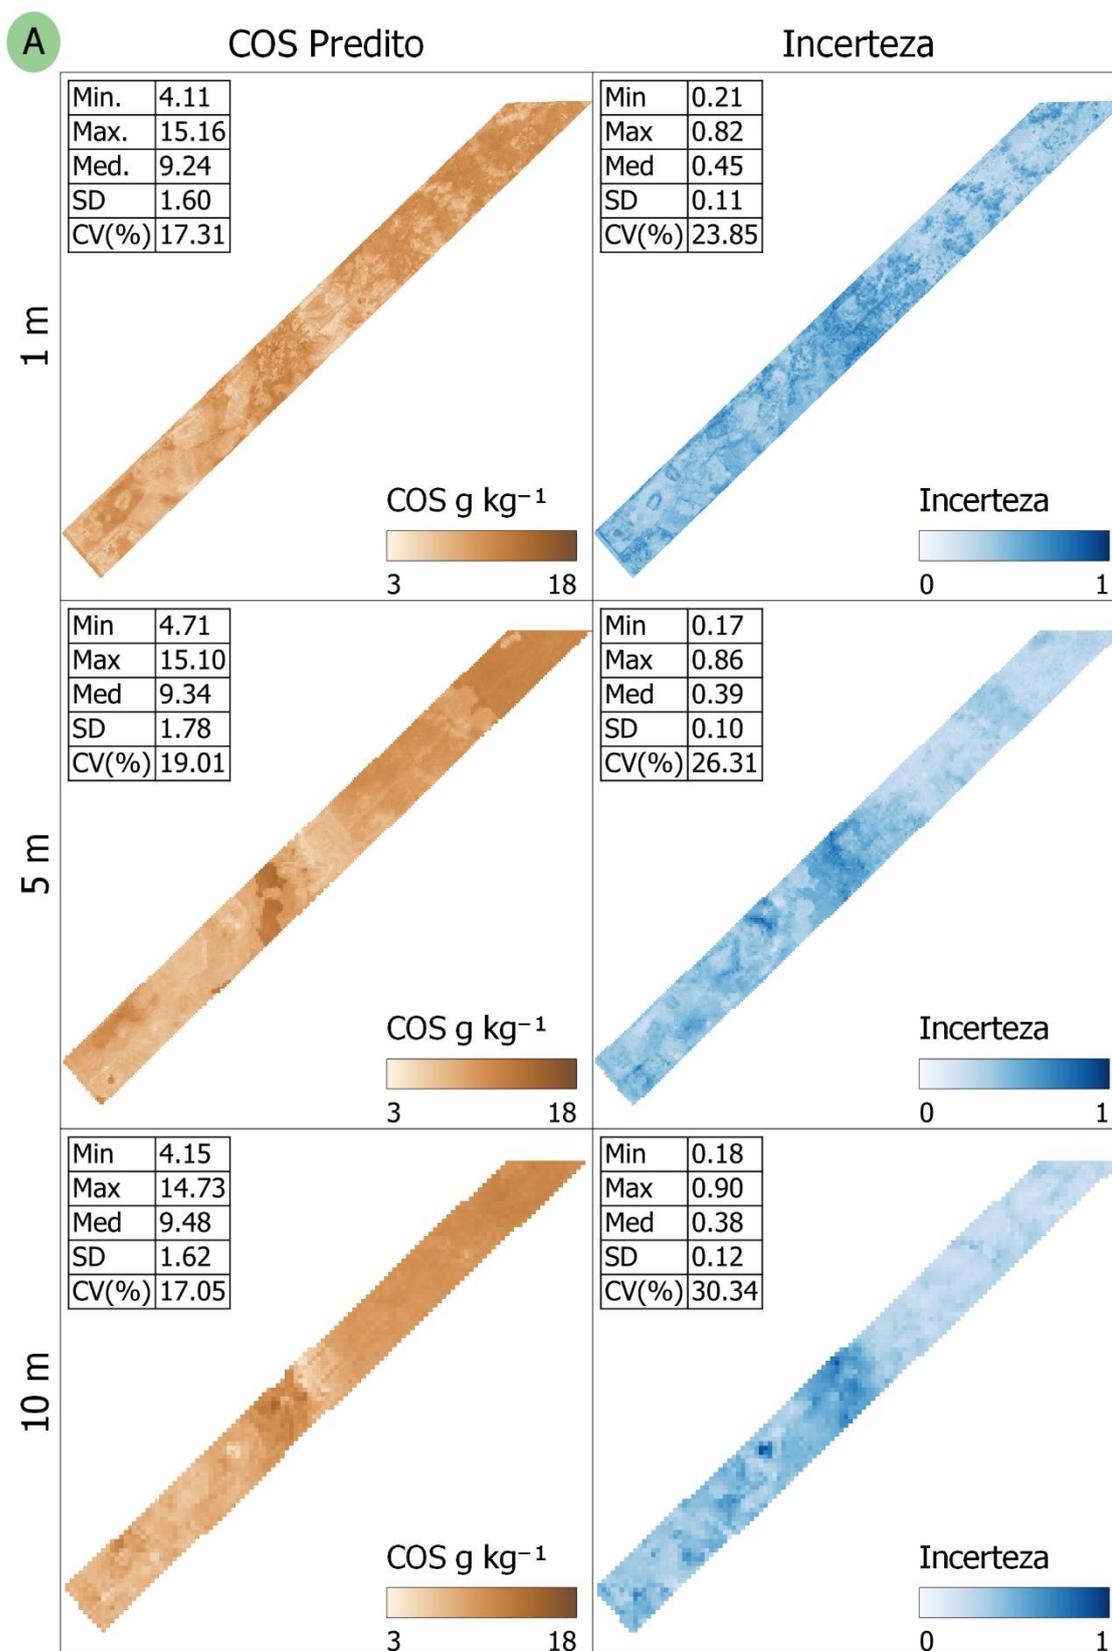


Figura 10 - Mapa de COS predito e incerteza estimada para a AE-A

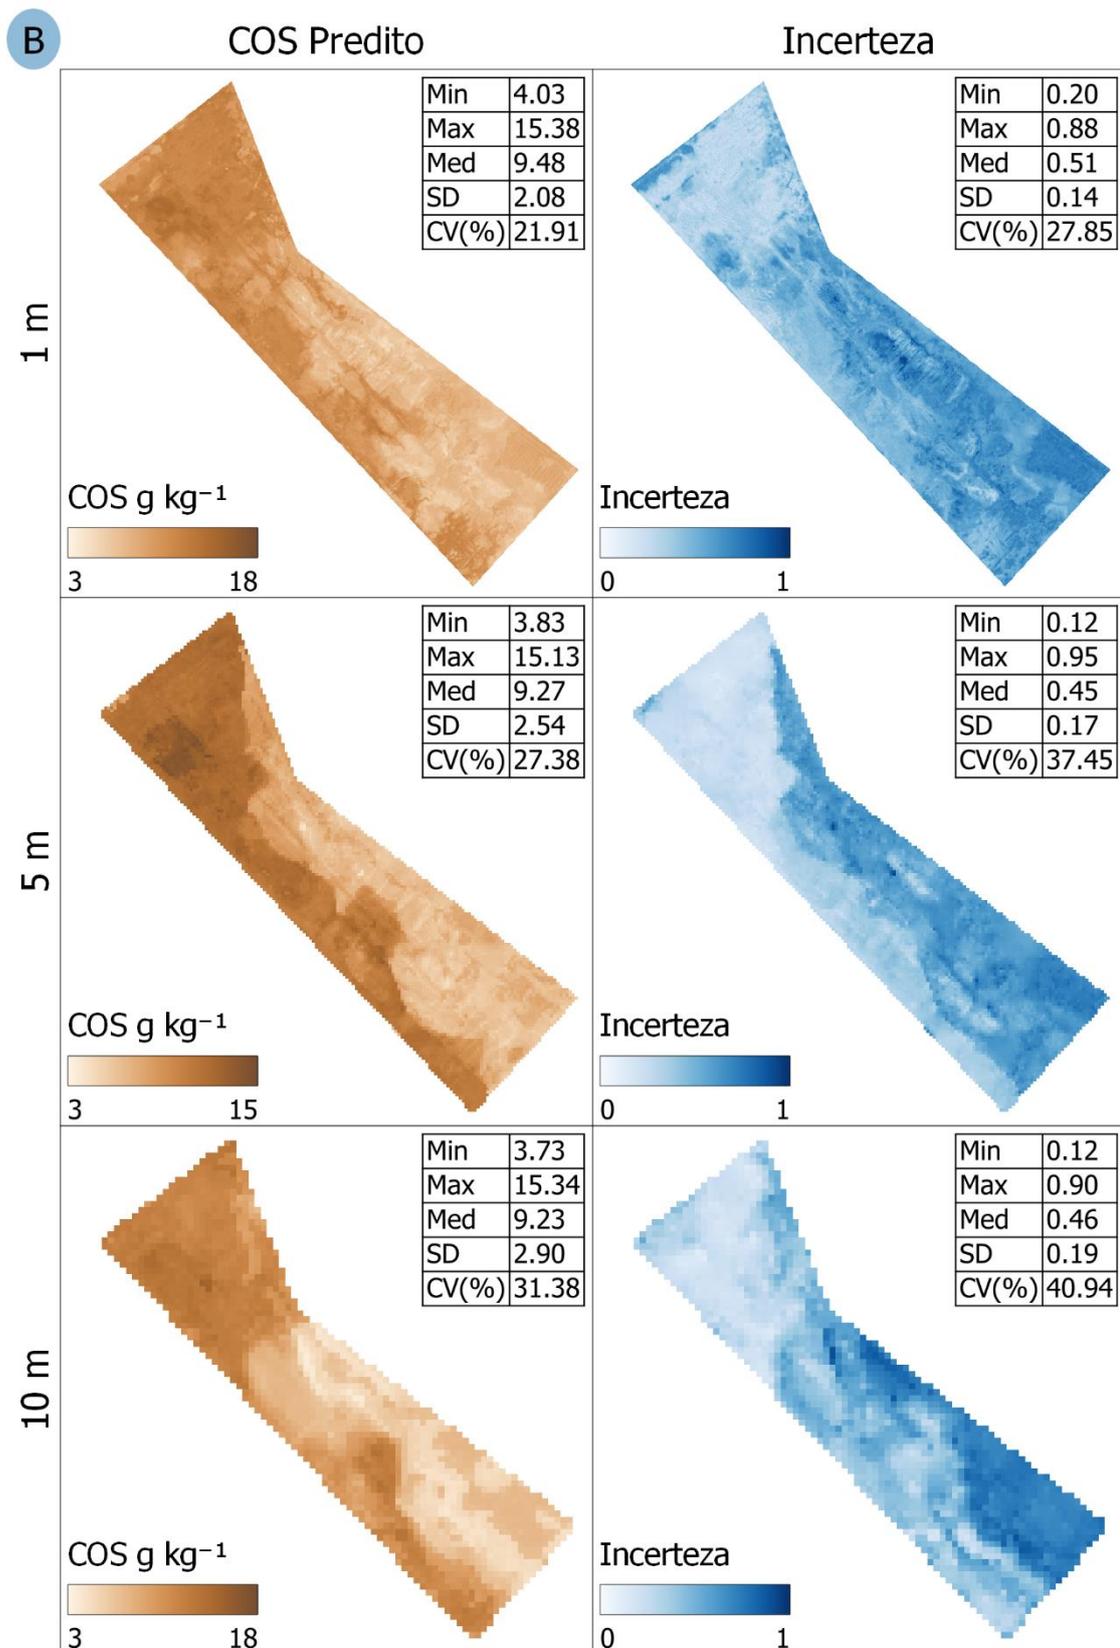


Figura 11 - Mapa de COS predito e incerteza estimada para a AE-B

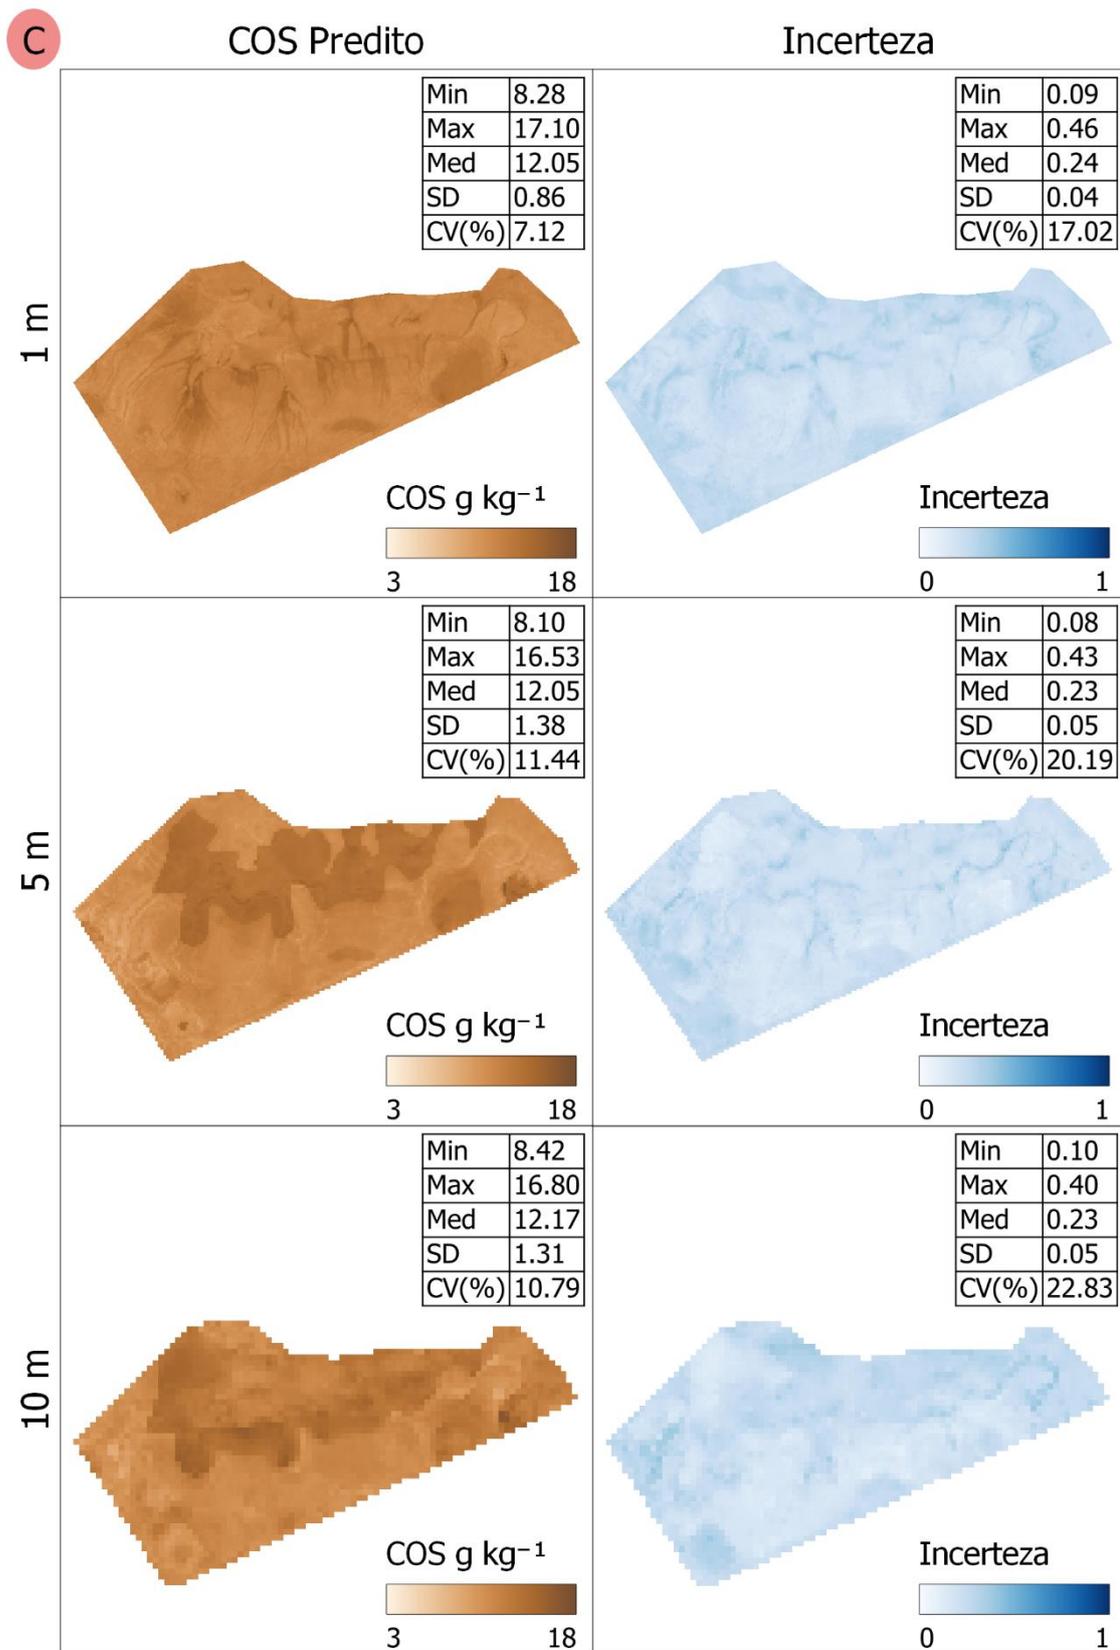


Figura 12 - Mapa de COS predito e incerteza estimada para a AE-C

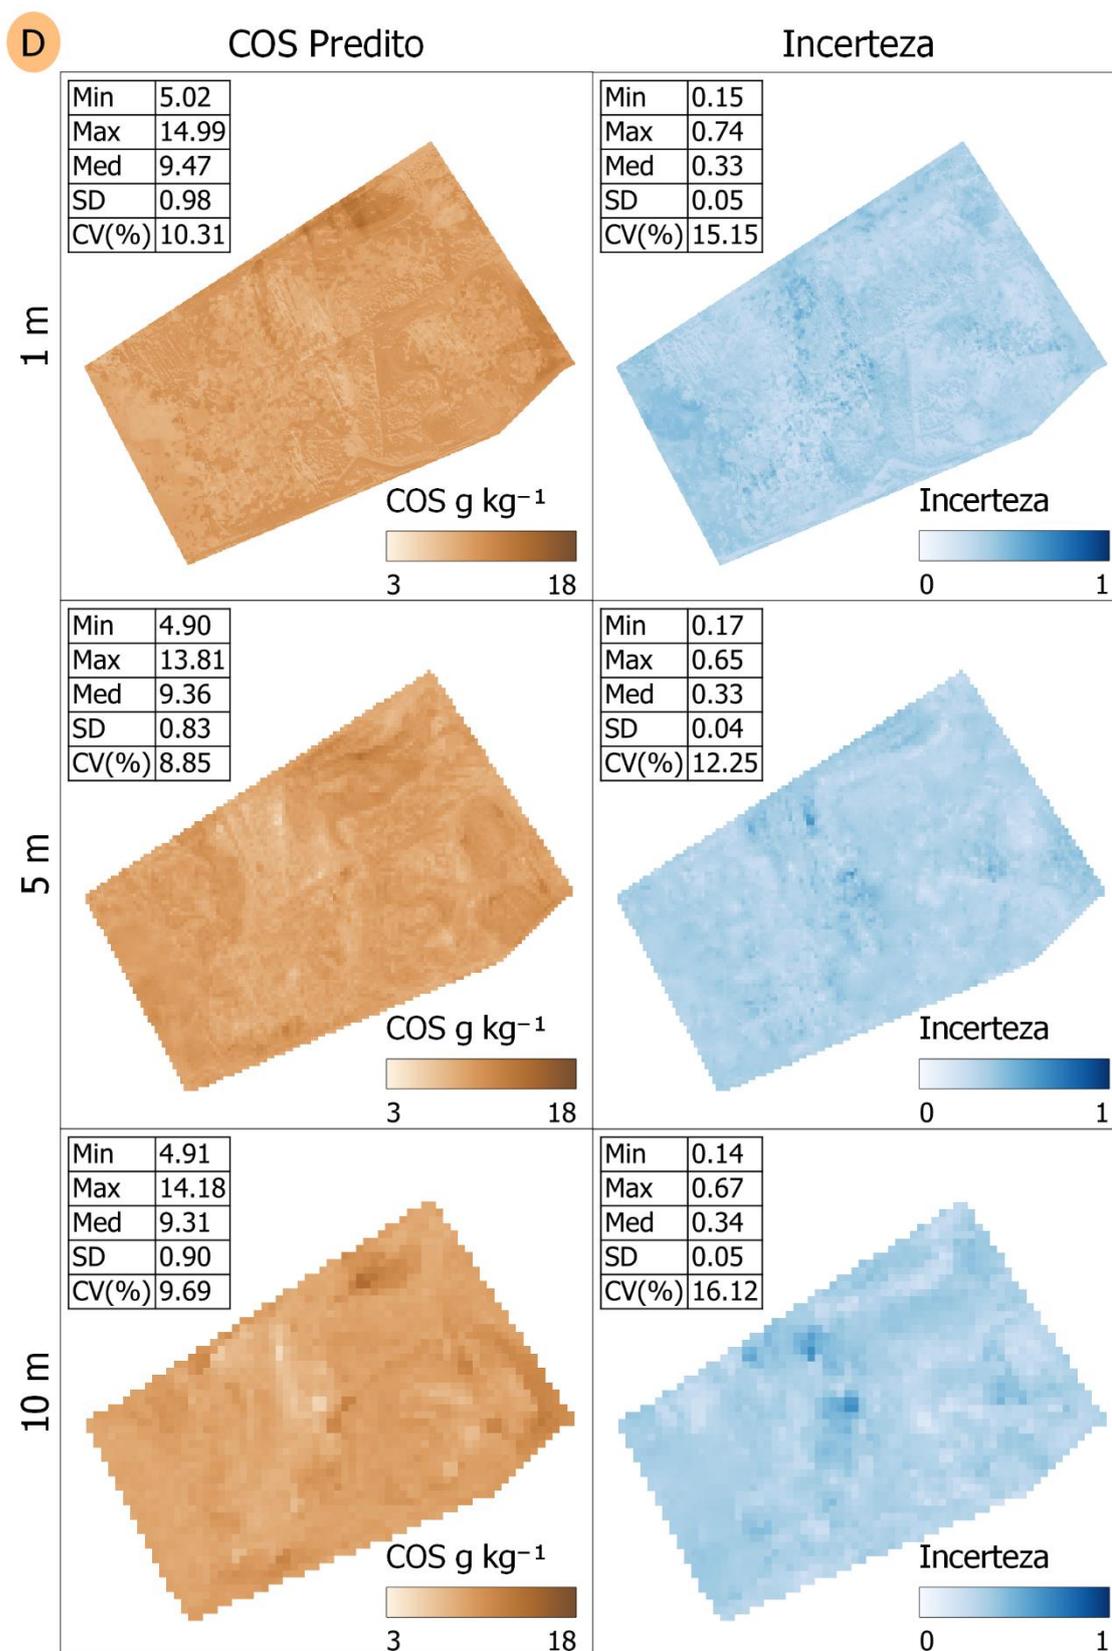


Figura 13 - Mapa de COS predito e incerteza estimada para a AE-D

### 3.4 Importância das covariáveis

As 10 covariáveis mais importantes para a predição do COS do solo utilizando RF na AE em resoluções espaciais de 1 m, 5 m e 10 m são apresentadas nas Figura 14, Figura 15, Figura 16 e Figura 17. Na maioria das AE as covariáveis relacionadas aos fatores terreno foram as mais importantes na predição do COS. Na AE-A (Figura 14), para resolução espacial de 1m, a variável MRVBF teve a maior influência para o treinamento do modelo, para resolução espacial de 5 m as covariáveis SH, STANH e VD apresentaram maior influência e para resolução de 10 m as covariáveis MRRTF, MSP e VD. Em relação as covariáveis derivadas de sensor orbital, para resolução espacial de 1 m, a banda do azul e banda do verde aparecem entre as 10 covariáveis mais importantes. Para resolução espacial de 5 m, o NDVI e a banda do azul aparecem entre as 10 mais importantes. Já para resolução espacial de 10 m, apenas covariáveis relacionadas ao relevo aparecem entre as 10 mais importantes.

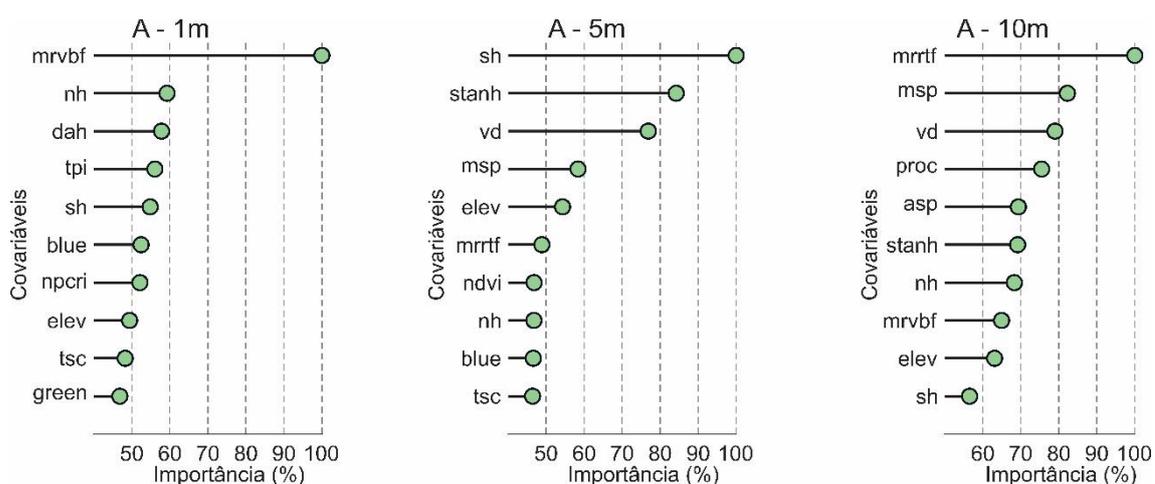


Figura 14 - As 10 covariáveis mais importantes para a predição do COS na AE-A com resolução espacial de 1 m, 5 m e 10 m.

Em relação a AE-B (Figura 15), as covariáveis SH e ELEV contribuíram mais para a predição do COS na resolução de 1 m, enquanto para a resolução espacial de 5 m, a covariável que mais contribuiu foi a MRRTF. As covariáveis NH e MSP tiveram maior influência no modelo com resolução espacial de 10 m. Em relação as covariáveis obtidas através de sensor orbital, na AE-B com resolução espacial de 1 m o NDWI e bandas do verde, vermelho e azul aparecem entre as 10 covariáveis mais importantes e para a resolução de 5 m, o NDWI e a banda do verde. Para resolução de 10 m, a variável NPCRI aparece entre as 10 mais importantes.

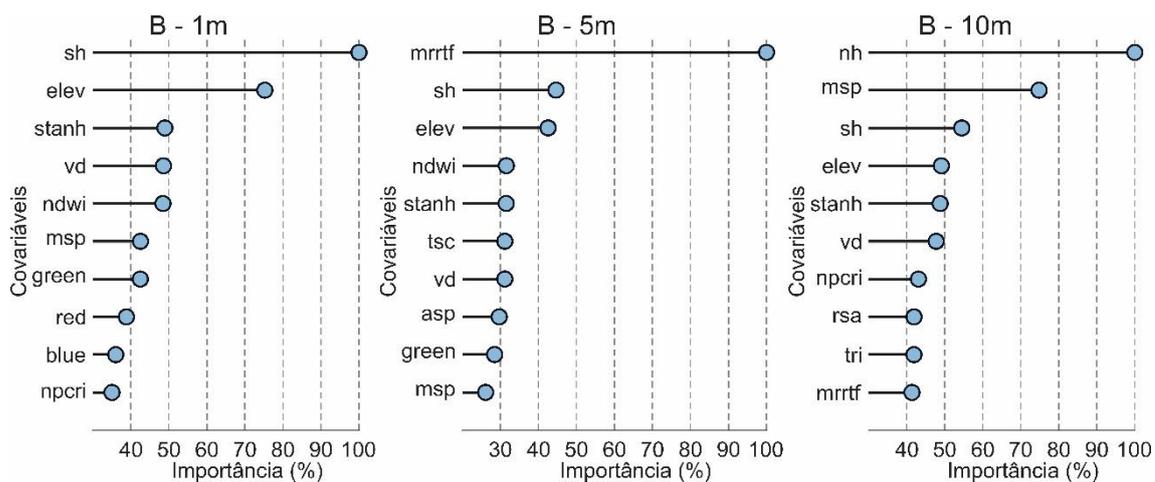


Figura 15 - As 10 covariáveis mais importantes para a predição do COS na AE-B com resolução espacial de 1 m, 5 m e 10 m.

As covariáveis TPI e elev aparecem em primeiro no nível de importância para a predição do COS para resolução espacial de 1m na AE-C (Figura 16). Para resolução de 5 m, as covariáveis VD e TPI foram as de maior importância, enquanto para a resolução de 10 m foi a variável VD. As covariáveis baseadas em sensor orbital NIR, SBI e NPCRI figuram entre as 10 covariáveis mais importantes para resolução de 1 m e para resolução espacial de 5 m, o NIR e SBI.

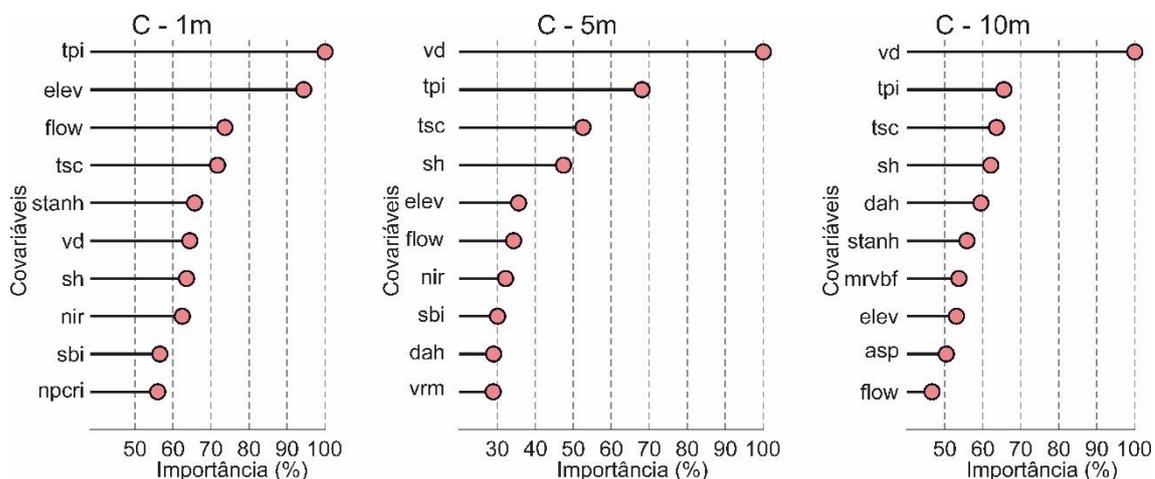


Figura 16 - As 10 covariáveis mais importantes para a predição do COS na AE-C com resolução espacial de 1 m, 5 m e 10 m.

A Figura 17 mostra que para AE-D com resolução espacial de 1 m as covariáveis com maior importância foram DAH, SH e NDWI, para a resolução de 5 m a maior importância ficou com as covariáveis MRRTF e DAH e para resolução espacial de 10 m, NPCRI, SH e DAH. Quanto as covariáveis baseadas em sensor orbital, NDWI, NPCRI e SBI aparecem entre as 10 covariáveis mais importantes para

resolução de 1 m e para a resolução de 5 m, a banda do azul. Já para resolução de 10 m, o NPCRI, sendo essa a variável que mais contribuiu com a predição de COS nessa AE para resolução espacial de 10 m.

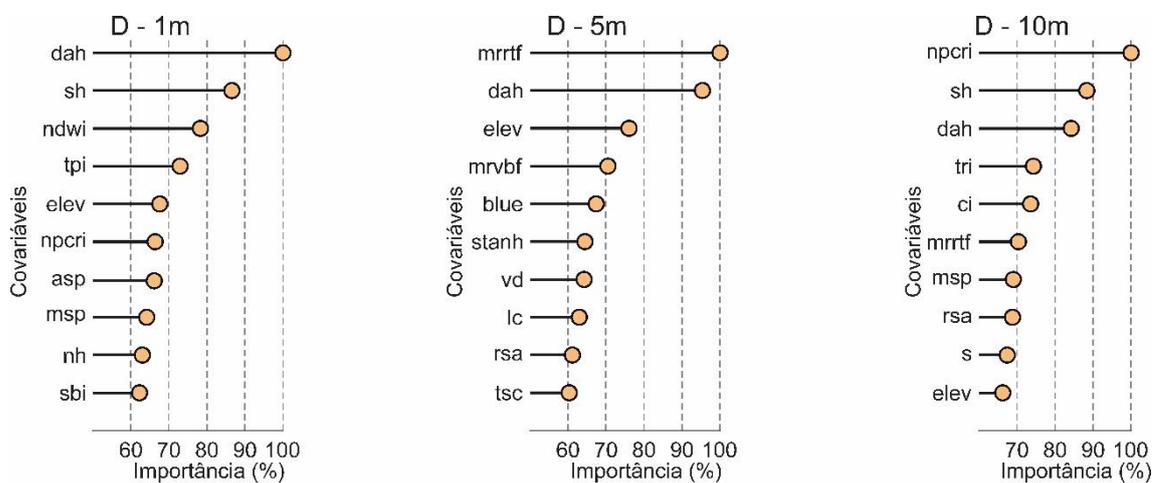


Figura 17 - As 10 covariáveis mais importantes para a predição do COS na AE-D com resolução espacial de 1 m, 5 m e 10 m.

#### 4. Discussão

A performance dos modelos preditores utilizando covariáveis com uma resolução espacial de 1 m foi visivelmente superior do que para as demais resoluções na maioria dos casos (Tabela 5). Em todas as 4 AE o  $R^2$  foi maior para os modelos treinados utilizando covariáveis com 1 m de resolução espacial em relação as resoluções espaciais menores.

Porém o mesmo comportamento não ocorreu em relação ao RMSE, este teve um aumento consistente nas AE-C e AE-D conforme a resolução da AE diminuiu, ou seja, quanto menor a resolução espacial maior o erro do modelo predito. Na AE-A, entretanto, o RMSE para as resoluções de 1 m e 5 m foram praticamente os mesmos, nessa AE o RMSE teve um aumento significativo somente para a resolução de 10 m.

Entre as 4 AE, a AE-B foi a que apresentou menor diferença tanto para  $R^2$  quanto para o RMSE. O  $R^2$  não apresentou diferença expressiva entre as 3 resoluções, contudo, diferente dos outros casos, nesta AE o desempenho do modelo predito foi levemente melhor para a resolução de 10 m. Em relação ao RMSE, este, além de também apresentar pouca variação, o menor erro também foi encontrado para o modelo treinado com covariáveis com resolução espacial de 10 m. Um das possíveis explicações para esse resultado pode estar na posição em que cada uma das AE se encontra no relevo, além do próprio relevo dentro das AE. No que se refere as covariáveis do terreno, o que se espera é que uma maior resolução espacial seja capaz de representar melhor o terreno em áreas pequenas do que menores resoluções espaciais. No entanto as AE-A e AE-B encontram-se no terço inferior da BHAÉ, uma área menos declivosa. Por serem áreas mais uniformes, a menor variação de valores pode estar influenciando o treinamento do modelo, já que essa uniformidade está presente em todas as resoluções, diferente das demais AE. Este comportamento é contrário ao encontrado no estudo realizado por Saurette *et al.* (2022), nele os autores sugerem que a resolução espacial das covariáveis exerceu uma menor influência em relação ao número de amostras. Porém, ao contrário deste estudo, os autores variaram o número de amostras e utilizaram diferentes algoritmos de *machine learning* em uma única área.

A variação do COS dentre as 4 AE ficou dentro do esperado, levando em consideração os dados resultantes das análises de laboratório (Figura 10, Figura 11, Figura 12, Figura 13). No geral os maiores teores de COS se concentraram nas áreas

mais baixas, áreas de drenagem, áreas úmidas e áreas de floresta. Em todas as AE houve uma coerência nos mapas preditos para cada uma das 3 resoluções, onde a distribuição do COS foi parecida. Os menores teores de COS foram encontrados dentro da área de lavoura, mostrando que está havendo um aporte negativo de COS nas AE. As AE são cultivadas por meio do plantio convencional, antes da semeadura a área é arada e gradeada causando a desagregação do solo, após a colheita o solo permanece descoberto até a germinação das plantas de cobertura.

Por consequência, a matéria orgânica é retirada durante a colheita e não há um novo aporte dessa matéria orgânica na área, além disso, antes da semeadura e após a colheita o solo permanece descoberto sendo afetado pela erosão e escoamento superficial. No mapa com resolução de 1m da AE-C é possível observar que as regiões que mais concentram COS dentro da lavoura são as áreas com início de erosão por sulcos, que concentram o escoamento de água ou áreas que possuem um acúmulo excessivo de água. Esse comportamento também pode ser observado nas demais AE, exceto na AE-B, ainda que de forma menos evidente. Estudos como os de Lal (2013) e Salemme et al. (2018) corroboram com este cenário, estabelecendo uma relação de redução do COS em áreas onde ocorrem práticas agrícolas. Além disso, estudos de Fissore et al. (2017), Olson et al. (2016) e Young et al. (2014) mostraram que a topografia em conjunto com processos erosivos e de deposição são responsáveis pelo transporte e o acúmulo de COS ao longo do terreno.

Os mapas de COS preditos para a AE-B mostram uma maior concentração de COS na área mais elevada da AE. Esta área abrange parte da lavoura e área de silvicultura. Nesta AE foi possível observar uma menor homogeneidade na incorporação da casca de arroz carbonizada ao solo, consequentemente uma maior amplitude nos valores de COS, o que pode ser confirmado ao se observar o *boxplot* da Figura 7. A AE-B possui ao mesmo tempo um dos menores valores de COS e o maior valor de COS, além de possuir a maior quantidade de *outliers* e os maiores valores de *outliers*.

Em nenhuma das AE foi possível realizar a amostragem de todos os pontos gerados a partir do cLHS devido à dificuldade de acesso em alguns locais, como áreas com vegetação densa e com espinhos e áreas de banhado. Entretanto, em todas as AE, exceto a AE-B, foi possível realizar amostragens de forma representativa em todo o relevo. Já na AE-B, a porção mais baixa do terreno encontrava-se inacessível durante o período de coleta das amostras. O resultado apresentado pela AE-B

demonstra a importância de se realizar uma amostragem uniforme da área, de forma que as suas principais características sejam representadas. Como solução para o problema se sugere realizar a amostragem da área em períodos mais secos do ano ou procurar empregar metodologias como a proposta por Cambule *et al.* (2013). Estes autores propuseram uma metodologia para a realização de MDS em áreas inacessíveis, construindo um modelo baseado em amostras de uma área acessível combinados com dados espaciais baseados nos fatores de formação do solo para mapear uma área inacessível com características semelhantes.

Os mapas de incerteza apresentaram dois cenários distintos, um para as AE-A e AE-B e outro para as AE-C e AE-D (Figura 10, Figura 11, Figura 12, Figura 13). As duas primeiras áreas, que se encontram no terço inferior da bacia e apresentam um relevo mais plano apresentaram no geral uma maior incerteza e uma maior variabilidade dessa incerteza. As AE-C e AE-D que se encontram no terço superior da bacia e em região mais declivosa apresentaram uma menor incerteza e menor variabilidade nos valores de incerteza. Este comportamento pode estar relacionado com as covariáveis utilizadas neste estudo. A maioria das covariáveis utilizadas foram derivadas do MDE, 34 das 43 covariáveis utilizadas, além disso as covariáveis com maior importância para explicação do modelo também são as covariáveis derivadas do MDE. Dessa forma, entende-se que uma maior variabilidade nas características do terreno atuou de forma benéfica na atenuação da incerteza dos mapas gerados. Do mesmo modo, a baixa variabilidade do terreno nas duas AE mais planas, atuou de forma negativa nos mapas gerados, causando uma maior incerteza nessas áreas.

Em estudo realizado por Guo *et al.* (2021), estes observaram que em áreas de baixo relevo há também uma baixa variabilidade nos atributos do terreno, conseqüentemente diminuindo a capacidade preditiva do modelo. MDE com melhores resoluções espaciais podem ser capazes de representar melhor o relevo da área, atenuando o problema, como pode ser observado comparando os mapas com resolução espacial de 1 m frente aos de 10 m nas AE-A e AE-B. Entre as diferentes resoluções espaciais os valores de SD e CV da incerteza aumentaram de forma gradativa acompanhando o aumento da resolução espacial para as AE-A, AE-B e AE-C, ou seja, as resoluções espaciais de 1 m tiveram o menor valor de SD e CV e resoluções espaciais de 10 m, os maiores valores. Para a AE-D, a resolução espacial de 5 m obteve o menor valor de SD e CV e a resolução de 10 m o maior valor de SD e CV. Essa diferença é mais evidente nas AE-A e AE-B, onde houve uma maior

diferença entre o CV dos mapas de incerteza do que nas demais AE. Não é possível afirmar se o modelo está tendo mais dificuldade em prever o COS nas áreas de menor resolução espacial, porém observou-se que a menor densidade de *pixels* dos mapas com resolução espacial menor tem influenciado na amplitude dos valores. Dessa forma, os mapas com menor densidade de *pixels* possuem uma proporção maior de valores extremos do que mapas com maior densidade de *pixels*.

A predominância das covariáveis do terreno (Figura 14, Figura 15, Figura 16 e Figura 17) entre as covariáveis com maior importância para a predição do COS nas AE pode ter relação com a distribuição dos pontos amostrados dentro de cada área. A maioria das amostras se encontraram dentro do limite da lavoura, assim, os valores extraídos de cada variável associada com a vegetação teve uma menor capacidade de explicar a área como um todo, como consequência uma menor relevância para o modelo. Ainda assim, covariáveis como NDVI, NDWI, NPCRI e a banda do azul obtiveram uma importância considerável para a maioria dos mapas.

Covariáveis como MRVBF e ELEV também mostraram grande importância em um estudo realizado por Lamichhane *et al.* (2022), onde realizaram o mapeamento de carbono em áreas agricultáveis do Nepal. Em relação as covariáveis obtidas por sensor orbital, covariáveis como NDVI e a banda do azul também estiveram dentre as mais importantes. Covariáveis como NDVI, ELEV, MRVBF, TPI também se mostraram importantes em estudos realizados por (DHARUMARAJAN *et al.*, 2020, 2021; ZHANG; ZHANG; XU, 2022). Os resultados encontrados corroboram com os resultados de Gomes *et al.* (2019), para mapeamento digital de carbono em escala nacional no Brasil, onde nos primeiros 15 cm de profundidade, as covariáveis como NDVI, VD, ELEV, SH e STANH tiveram uma maior influência na predição.

## 5. Conclusão

Este estudo mostrou que é possível realizar o mapeamento de COS em alta resolução em escala de propriedade agrícola, utilizando covariáveis derivadas a partir de MDE obtidos através de ARPs. Dentre as 4 AE, as localizadas no terço superior da BHAE, em relevo mais declivoso, apresentaram no geral os melhores resultados. Dentre as 3 resoluções espaciais, os mapas gerados a partir de covariáveis com maiores resoluções espaciais, 1 m, obtiveram os melhores resultados. A incerteza para esses mapas foi menor em relação a mapas produzidos com menores resoluções espaciais, 5 m ou 10 m. A acurácia do modelo também se mostrou melhor para os modelos treinados com covariáveis com maiores resoluções espaciais, sendo a AE-C a área que apresentou o melhor desempenho dentre todas. Em relação a importância das covariáveis, as relacionadas ao relevo no geral obtiveram a maior importância, visto que são maioria e as áreas apresentam pouca variabilidade de vegetação.

O estudo também mostrou que houve limitações relacionadas ao número de amostras. Por se tratar de covariáveis de alta resolução espacial a malha amostral se mostrou insuficiente, sendo necessário a utilização de um *buffer* para a criação aleatória de mais pontos. O acesso a algumas regiões das AE também se mostrou um problema, em virtude disso algumas dessas regiões ficaram sem serem amostras. Esse fator pode ter prejudicado o treinamento e consequentemente o resultado final em algumas das AE. Como proposta para trabalhos futuros, sugere-se a realização do mapeamento com uma maior malha amostral e a realização de amostragens nas regiões que se encontravam inacessíveis. Além disso, uma maior diversidade de covariáveis, que representem melhor os fatores de formação do solo, é sugerido.

## 6. Referências

AHMAD, Ali; ORDOÑEZ, Javier; CARTUJO, Pedro; MARTOS, Vanesa. Remotely Piloted Aircraft (RPA) in Agriculture: A Pursuit of Sustainability. **Agronomy**, v. 11, n. 1, p. 7, 2020. DOI: 10.3390/agronomy11010007. Disponível em: <https://www.mdpi.com/2073-4395/11/1/7>.

AKTURK, Emre; ALTUNEL, Arif Oguz. Accuracy assessment of a low-cost UAV derived digital elevation model (DEM) in a highly broken and vegetated terrain. **Measurement**, v. 136, p. 382–386, 2019. DOI: 10.1016/j.measurement.2018.12.101. Disponível em: <https://doi.org/10.1016/j.measurement.2018.12.101>.

ALEXANDRATOS, N.; BRUINSMA, J. **World agriculture towards 2030/2050: the 2012 revision**. Rome: FAO, 2012.

AMUNDSON, Ronald; BERHE, Asmeret Asefaw; HOPMANS, Jan W.; OLSON, Carolyn; SZTEIN, A. Ester; SPARKS, Donald L. Soil and human security in the 21st century. **Science**, v. 348, n. 6235, 2015. DOI: 10.1126/science.1261071.

ANGELETTI, Carlo; MONACI, Elga; GIANNETTA, Beatrice; POLVERIGIANI, Serena; VISCHETTI, Costantino. Soil organic matter content and chemical composition under two rotation management systems in a Mediterranean climate. **Pedosphere**, v. 31, n. 6, p. 903–911, 2021. DOI: 10.1016/S1002-0160(21)60032-2. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1002016021600322>.

ANGNUURENG, D. B.; BREMPONG, K. E.; JAYSON-QUASHIGAH, P. N.; DADA, O. A.; AKUOKO, S. G. I.; FRIMPOMAA, J.; MATTAH, P. A.; ALMAR, R. Satellite, drone and video camera multi-platform monitoring of coastal erosion at an engineered pocket beach: A showcase for coastal management at Elmina Bay, Ghana (West Africa). **Regional Studies in Marine Science**, v. 53, p. 102437, 2022. DOI: 10.1016/j.rsma.2022.102437. Disponível em: <https://doi.org/10.1016/j.rsma.2022.102437>.

ANTHONY, Mark A.; CROWTHER, Thomas W.; MAYNARD, Daniel S.; VAN DEN HOOGEN, Johan; AVERILL, Colin. Distinct Assembly Processes and Microbial Communities Constrain Soil Organic Carbon Formation. **One Earth**, v. 2, n. 4, p. 349–360, 2020. DOI: 10.1016/j.oneear.2020.03.006. Disponível em: <https://doi.org/10.1016/j.oneear.2020.03.006>.

ARROUAYS, Dominique et al. **GlobalSoilMap. Toward a Fine-Resolution Global Grid of Soil Properties**. [s.l.: s.n.]. v. 125 DOI: 10.1016/B978-0-12-800137-

0.00003-0.

ARROUAYS, Dominique; LAGACHERIE, Philippe; HARTEMINK, Alfred E. Digital soil mapping across the globe. **Geoderma Regional**, v. 9, p. 1–4, 2017. DOI: 10.1016/j.geodrs.2017.03.002. Disponível em: <http://dx.doi.org/10.1016/j.geodrs.2017.03.002>.

ARROUAYS, Dominique; MCBRATNEY, Alex; BOUMA, Johan; LIBOHOVA, Zamir; RICHER-DE-FORGES, Anne C.; MORGAN, Cristine L. S.; ROUDIER, Pierre; POGGIO, Laura; MULDER, Vera Leatitia. Impressions of digital soil maps: The good, the not so good, and making them ever better. **Geoderma Regional**, v. 20, p. e00255, 2020. a. DOI: 10.1016/j.geodrs.2020.e00255. Disponível em: <https://doi.org/10.1016/j.geodrs.2020.e00255>.

ARROUAYS, Dominique; POGGIO, Laura; SALAZAR GUERRERO, Osvaldo A.; MULDER, Vera Laetitia. Digital soil mapping and GlobalSoilMap. Main advances and ways forward. **Geoderma Regional**, v. 21, p. e00265, 2020. b. DOI: 10.1016/j.geodrs.2020.e00265. Disponível em: <https://doi.org/10.1016/j.geodrs.2020.e00265>.

ATOLOYE, Idowu A.; JACOBSON, Astrid R.; CREECH, J. Earl; REEVE, Jennifer R. Soil organic carbon pools and soil quality indicators 3 and 24 years after a one-time compost application in organic dryland wheat systems. **Soil and Tillage Research**, v. 224, n. May, p. 105503, 2022. DOI: 10.1016/j.still.2022.105503. Disponível em: <https://doi.org/10.1016/j.still.2022.105503>.

BABU, Subhash et al. Soil carbon dynamics in diverse organic land use systems in North Eastern Himalayan ecosystem of India. **Catena**, v. 194, n. July, p. 104785, 2020. DOI: 10.1016/j.catena.2020.104785. Disponível em: <https://doi.org/10.1016/j.catena.2020.104785>.

BAVEYE, Philippe C.; SCHNEE, Laura Sophie; BOIVIN, Pascal; LABA, Magdeline; RADULOVICH, Ricardo. Soil Organic Matter Research and Climate Change: Merely Re-storing Carbon Versus Restoring Soil Functions. **Frontiers in Environmental Science**, v. 8, n. September, p. 1–8, 2020. DOI: 10.3389/fenvs.2020.579904. Disponível em: <https://www.frontiersin.org/article/10.3389/fenvs.2020.579904/full>.

BELMONTE, Antonella; RIEFOLO, Carmela; LOVERGINE, Francesco; CASTRIGNANÒ, Annamaria. Geostatistical Modelling of Soil Spatial Variability by Fusing Drone-Based Multispectral Data, Ground-Based Hyperspectral and Sample

Data with Change of Support. **Remote Sensing**, v. 14, n. 21, p. 5442, 2022. DOI: 10.3390/rs14215442. Disponível em: <https://www.mdpi.com/2072-4292/14/21/5442>.

BENNETT, John McLean; MCBRATNEY, Alex; FIELD, Damien; KIDD, Darren; STOCKMANN, Uta; LIDDICOAT, Craig; GROVER, Samantha. Soil Security for Australia. **Sustainability**, v. 11, n. 12, p. 3416, 2019. DOI: 10.3390/su11123416.

BIRD, M.; SANTRÛCKOVÁ, H.; LLOYD, J.; VEENENDAAL, E. Global Soil Organic Carbon Pool. In: Global Biogeochemical Cycles in the Climate System. Eds: Schulze, E.-D., Heimann, M., Harrison, S., Holland, E., Lloyd, J., Prentice, I.C., and Schimel, D. **Academic Press, San Diego**, p. 185–199, 2001.

BÖHNER, J.; ANTONIĆ, O. Chapter 8 Land-Surface Parameters Specific to Topo-Climatology. *In: Developments in Soil Science*. [s.l.: s.n.]. v. 33p. 195–226. DOI: 10.1016/S0166-2481(08)00008-1. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0166248108000081>.

BÖHNER, Jürgen; SELIGE, Thomas. Spatial prediction of soil attributes using terrain analysis and climate regionalisation. *In: BÖHNER, Jürgen; MCCLOY, Keith R.; STROBL, Josef (org.). SAGA - Analyses and Modelling Applications*. [s.l.: s.n.]. v. 115p. 13–28.

BOSELLI, Roberta; FIORINI, Andrea; SANTELLI, Stefano; ARDENTI, Federico; CAPRA, Federico; MARIS, Stefania Codruta; TABAGLIO, Vincenzo. Cover crops during transition to no-till maintain yield and enhance soil fertility in intensive agro-ecosystems. **Field Crops Research**, v. 255, n. June, p. 107871, 2020. DOI: 10.1016/j.fcr.2020.107871. Disponível em: <https://doi.org/10.1016/j.fcr.2020.107871>.

BOSSIO, D. A. et al. The role of soil carbon in natural climate solutions. **Nature Sustainability**, v. 3, n. 5, p. 391–398, 2020. DOI: 10.1038/s41893-020-0491-z. Disponível em: <http://dx.doi.org/10.1038/s41893-020-0491-z>.

BOUMA, Johan. Soil Security in Sustainable Development. **Soil Systems**, v. 3, n. 1, p. 5, 2019. DOI: 10.3390/soilsystems3010005.

BREG VALJAVEC, Mateja; ČARNI, Andraž; ŽLINDRA, Daniel; ZORN, Matija; MARINŠEK, Aleksander. Soil organic carbon stock capacity in karst dolines under different land uses. **CATENA**, v. 218, n. July, p. 106548, 2022. DOI: 10.1016/j.catena.2022.106548. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0341816222005343>.

BREIMAN, Leo. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. DOI: 10.1023/A:1010933404324.

BRONICK, C. J.; LAL, R. Soil structure and management: a review. **Geoderma**, v. 124, n. 1–2, p. 3–22, 2005. DOI: 10.1016/j.geoderma.2004.03.005. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0016706104000898>.

BURAKA, Tadele; ELIAS, Eyasu; LELAGO, Alemu. Soil organic carbon and its' stock potential in different land-use types along slope position in Coka watershed, Southern Ethiopia. **Heliyon**, v. 8, n. 8, p. e10261, 2022. DOI: 10.1016/j.heliyon.2022.e10261. Disponível em: <https://doi.org/10.1016/j.heliyon.2022.e10261>.

CALOU, Vinícius Bitencourt Campos; TEIXEIRA, Adunias Dos Santos; DA SILVA, José Adriano; DE OLIVEIRA, Márcio Regys Rabelo; DO NASCIMENTO, Ícaro Vasconcelos. Statistical process control and mapping accuracy standards applied to aerial surveys. **Revista Ciencia Agronomica**, v. 52, n. 1, p. 1–9, 2021. DOI: 10.5935/1806-6690.20210006.

CÂMARA, Gilberto; SOUZA, Ricardo Cartaxo Modesto; FREITAS, Ubirajara Moura; GARRIDO, Juan. Spring: Integrating remote sensing and gis by object-oriented data modelling. **Computers & Graphics**, v. 20, n. 3, p. 395–403, 1996. DOI: 10.1016/0097-8493(96)00008-8. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/0097849396000088>.

CAMBULE, A. H.; ROSSITER, D. G.; STORVOGEL, J. J. A methodology for digital soil mapping in poorly-accessible areas. **Geoderma**, v. 192, n. 1, p. 341–353, 2013. DOI: 10.1016/j.geoderma.2012.08.020. Disponível em: <http://dx.doi.org/10.1016/j.geoderma.2012.08.020>.

CANCIAN, Luciano Campos. **Estratégias para predição de classes de solo**. 2019. 2019.

CAREY, Chelsea J.; WEVERKA, Jacob; DIGAUDIO, Ryan; GARDALI, Thomas; PORZIG, Elizabeth L. Exploring variability in rangeland soil organic carbon stocks across California (USA) using a voluntary monitoring network. **Geoderma Regional**, v. 22, p. e00304, 2020. DOI: 10.1016/j.geodrs.2020.e00304. Disponível em: <https://doi.org/10.1016/j.geodrs.2020.e00304>.

CARLSON, Toby N.; RIPLEY, David A. On the relation between NDVI, fractional vegetation cover, and leaf area index. **Remote Sensing of Environment**, v. 62, n. 3, p. 241–252, 1997. DOI: 10.1016/S0034-4257(97)00104-1. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425797001041>.

CHENG, K. H.; CHAN, S. N.; LEE, Joseph H. W. Remote sensing of coastal

algal blooms using unmanned aerial vehicles (UAVs). **Marine Pollution Bulletin**, v. 152, n. February, p. 110889, 2020. DOI: 10.1016/j.marpolbul.2020.110889. Disponível em: <https://doi.org/10.1016/j.marpolbul.2020.110889>.

COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79–97, 2014. DOI: 10.1016/j.isprsjprs.2014.02.013. Disponível em: <http://dx.doi.org/10.1016/j.isprsjprs.2014.02.013>.

COMBA, Lorenzo; BIGLIA, Alessandro; RICAUDA AIMONINO, Davide; GAY, Paolo. Unsupervised detection of vineyards by 3D point-cloud UAV photogrammetry for precision agriculture. **Computers and Electronics in Agriculture**, v. 155, n. October, p. 84–95, 2018. DOI: 10.1016/j.compag.2018.10.005. Disponível em: <https://doi.org/10.1016/j.compag.2018.10.005>.

CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; WEHBERG, J.; WICHMANN, V.; BÖHNER, J. System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. **Geoscientific Model Development**, v. 8, n. 7, p. 1991–2007, 2015. DOI: 10.5194/gmd-8-1991-2015. Disponível em: <https://gmd.copernicus.org/articles/8/1991/2015/>.

DAVIES, B. E.; GAMM, S. A. Trend surface analysis applied to soil reaction values from Kent, England. **Geoderma**, Amsterdam, v. 3, 1970. DOI: 10.1017/CBO9781107415324.004.

DAZZI, Carmelo; GALATI, Antonino; CRESCIMANNO, Maria; LO PAPA, Giuseppe. Pedotechnique applications in large-scale farming: Economic value, soil ecosystems services and soil security. **Catena**, v. 181, n. December 2018, p. 104072, 2019. DOI: 10.1016/j.catena.2019.104072. Disponível em: <https://doi.org/10.1016/j.catena.2019.104072>.

DESMET, P. J. J.; GOVERS, G. A GIS procedure for automatically calculating the USLE LS factor on topographically complex landscape units. **Journal of Soil and Water Conservation**, v. 51, n. 5, p. 427–433, 1996.

DHARUMARAJAN, S. et al. Digital soil mapping of soil organic carbon stocks in Western Ghats, South India. **Geoderma Regional**, v. 25, p. e00387, 2021. DOI: 10.1016/j.geodrs.2021.e00387. Disponível em: <https://doi.org/10.1016/j.geodrs.2021.e00387>.

DHARUMARAJAN, S.; HEGDE, Rajendra; JANANI, N.; SINGH, S. K. The need for digital soil mapping in India. **Geoderma Regional**, v. 16, p. e00204, 2019.

DOI: 10.1016/j.geodrs.2019.e00204. Disponível em: <https://doi.org/10.1016/j.geodrs.2019.e00204>.

DHARUMARAJAN, S.; KALAISELVI, B.; SUPUTHRA, Amar; LALITHA, M.; HEGDE, Rajendra; SINGH, S. K.; LAGACHERIE, Philippe. Digital soil mapping of key GlobalSoilMap properties in Northern Karnataka Plateau. **Geoderma Regional**, v. 20, p. e00250, 2020. DOI: 10.1016/j.geodrs.2019.e00250. Disponível em: <https://doi.org/10.1016/j.geodrs.2019.e00250>.

DOKUCHAEV, Vasily Vasili'evich. Russian Chernozem. **Israel Program for Scientific Translations Ltd**, Jerusalem, 1967.

DORJI, Tshering; ODEH, Inakwu O. A.; FIELD, Damien J.; BAILLIE, Ian C. Digital soil mapping of soil organic carbon stocks under different land use and land cover types in montane ecosystems, Eastern Himalayas. **Forest Ecology and Management**, v. 318, n. 2014, p. 91–102, 2014. DOI: 10.1016/j.foreco.2014.01.003. Disponível em: <http://dx.doi.org/10.1016/j.foreco.2014.01.003>.

DU, Ling; MCCARTY, Gregory W.; LI, Xia; RABENHORST, Martin C.; WANG, Qianfeng; LEE, Sangchul; HINSON, Audra L.; ZOU, Zhenhua. Spatial extrapolation of topographic models for mapping soil organic carbon using local samples. **Geoderma**, v. 404, n. February, p. 115290, 2021. DOI: 10.1016/j.geoderma.2021.115290. Disponível em: <https://doi.org/10.1016/j.geoderma.2021.115290>.

ELLILI, Yosra; WALTER, Christian; MICHOT, Didier; PICHELIN, Pascal; LEMERCIER, Blandine. Mapping soil organic carbon stock change by soil monitoring and digital soil mapping at the landscape scale. **Geoderma**, v. 351, n. March, p. 1–8, 2019. DOI: 10.1016/j.geoderma.2019.03.005. Disponível em: <https://doi.org/10.1016/j.geoderma.2019.03.005>.

ELVIDGE, Christopher D.; LYON, Ronald J. P. Influence of rock-soil spectral variation on the assessment of green biomass. **Remote Sensing of Environment**, v. 17, n. 3, p. 265–279, 1985. DOI: 10.1016/0034-4257(85)90099-9. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/0034425785900999>.

FAO. **A protocol for measurement, monitoring, reporting and verification of soil organic carbon in agricultural landscapes**. [s.l.] : FAO, 2020. DOI: 10.4060/cb0509en. Disponível em: <http://www.fao.org/documents/card/en/c/cb0509en>.

FAWCETT, Dominic et al. Multi-Scale Evaluation of Drone-Based Multispectral Surface Reflectance and Vegetation Indices in Operational Conditions. **Remote**

**Sensing**, v. 12, n. 3, p. 514, 2020. DOI: 10.3390/rs12030514. Disponível em: <https://www.mdpi.com/2072-4292/12/3/514>.

FELLER, Christian; BLANCHART, Eric; BERNOUX, Martial; LAL, Rattan; MANLAY, Raphaël. Soil fertility concepts over the past two centuries: the importance attributed to soil organic matter in developed and developing countries. **Archives of Agronomy and Soil Science**, v. 58, n. sup1, p. S3–S21, 2012. DOI: 10.1080/03650340.2012.693598. Disponível em: <http://www.tandfonline.com/doi/abs/10.1080/03650340.2012.693598>.

FISSORE, C.; DALZELL, B. J.; BERHE, A. A.; VOEGTLE, M.; EVANS, M.; WU, A. Influence of topography on soil organic carbon dynamics in a Southern California grassland. **Catena**, v. 149, p. 140–149, 2017. DOI: 10.1016/j.catena.2016.09.016.

FLORINSKY, Igor V. Digital Elevation Models. *In: Digital Terrain Analysis in Soil Science and Geology*. [s.l.] : Elsevier, 2016. p. 77–108. DOI: 10.1016/B978-0-12-804632-6.00003-1. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/B9780128046326000031>.

FREEMAN, Patricia K.; FREELAND, Robert S. Agricultural UAVs in the U.S.: Potential, policy, and hype. **Remote Sensing Applications: Society and Environment**, v. 2, p. 35–43, 2015. DOI: 10.1016/j.rsase.2015.10.002. Disponível em: <http://dx.doi.org/10.1016/j.rsase.2015.10.002>.

GALLANT, J. C.; WILSON, J. P. Primary topographic attributes. **Terrain Analysis: Principles and Applications**, n. January, p. 51–85, 2000.

GALLANT, John C.; DOWLING, Trevor I. A multiresolution index of valley bottom flatness for mapping depositional areas. **Water Resources Research**, v. 39, n. 12, 2003. DOI: 10.1029/2002WR001426. Disponível em: <http://doi.wiley.com/10.1029/2002WR001426>.

GAO, Bo-Cai. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257–266, 1996. DOI: 10.1016/S0034-4257(96)00067-3. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425796000673>.

GAO, Yurong; LIAN, Xugang; GE, Linlin. Inversion model of surface bare soil temperature and water content based on UAV thermal infrared remote sensing. **Infrared Physics & Technology**, v. 125, n. July, p. 104289, 2022. DOI: 10.1016/j.infrared.2022.104289. Disponível em:

<https://doi.org/10.1016/j.infrared.2022.104289>.

GIACOMO, R.; DAVID, G. **E-Agriculture In Action: Drones For Agriculture**. [s.l: s.n.].

GIASSON, Elvio; CLARKE, Robin Thomas; INDA, Alberto Vasconcellos; MERTEN, Gustavo Henrique; TORNQUIST, Carlos Gustavo. Digital soil mapping using multiple logistic regression on terrain parameters in southern Brazil. **Scientia Agricola**, v. 63, n. 3, p. 262–268, 2006. DOI: 10.1590/S0103-90162006000300008.

**Global Soil Partnership | Food and Agriculture Organization of the United Nations**. [s.d.]. Disponível em: <http://www.fao.org/global-soil-partnership/en/>. Acesso em: 4 ago. 2020.

**GlobalSoilMap.Net | ISRIC**. [s.d.]. Disponível em: <https://www.isric.org/projects/globalsoilmapnet>. Acesso em: 4 ago. 2020.

GÖL, Ceyhun; BULUT, Sinan; BOLAT, Ferhat. Comparison of different interpolation methods for spatial distribution of soil organic carbon and some soil properties in the Black Sea backward region of Turkey. **Journal of African Earth Sciences**, v. 134, p. 85–91, 2017. DOI: 10.1016/j.jafrearsci.2017.06.014.

GOMES, Lucas Carvalho; FARIA, Raiza Moniz; DE SOUZA, Eliana; VELOSO, Gustavo Vieira; SCHAEFER, Carlos Ernesto G. R.; FILHO, Elpídio Inácio Fernandes. Modelling and mapping soil organic carbon stocks in Brazil. **Geoderma**, v. 340, n. December 2017, p. 337–350, 2019. DOI: 10.1016/j.geoderma.2019.01.007. Disponível em: <https://doi.org/10.1016/j.geoderma.2019.01.007>.

GREEN, David R.; HAGON, Jason J.; GÓMEZ, Cristina; GREGORY, Billy J. Using Low-Cost UAVs for Environmental Monitoring, Mapping, and Modelling: Examples From the Coastal Zone. *In: Coastal Management*. [s.l.] : Elsevier, 2019. p. 465–501. DOI: 10.1016/B978-0-12-810473-6.00022-4. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/B9780128104736000224>.

GREINER, Lucie; KELLER, Armin; GRÊT-REGAMEY, Adrienne; PAPRITZ, Andreas. Soil function assessment: review of methods for quantifying the contributions of soils to ecosystem services. **Land Use Policy**, v. 69, n. September, p. 224–237, 2017. DOI: 10.1016/j.landusepol.2017.06.025. Disponível em: <https://doi.org/10.1016/j.landusepol.2017.06.025>.

GRUBER, S.; PECKHAM, S. Chapter 7 Land-Surface Parameters and Objects in Hydrology. *In: Developments in Soil Science*. [s.l: s.n.]. v. 33p. 171–194. DOI: 10.1016/S0166-2481(08)00007-X. Disponível em:

<https://linkinghub.elsevier.com/retrieve/pii/S016624810800007X>.

GUEVARA, Mario et al. No silver bullet for digital soil mapping: Country-specific soil organic carbon estimates across Latin America. **Soil**, v. 4, n. 3, p. 173–193, 2018. DOI: 10.5194/soil-4-173-2018.

GUO, Long; FU, Peng; SHI, Tiezhu; CHEN, Yiyun; ZENG, Chen; ZHANG, Haitao; WANG, Shanqin. Exploring influence factors in mapping soil organic carbon on low-relief agricultural lands using time series of remote sensing data. **Soil and Tillage Research**, v. 210, n. March, p. 104982, 2021. DOI: 10.1016/j.still.2021.104982. Disponível em: <https://doi.org/10.1016/j.still.2021.104982>.

GUO, Long; FU, Peng; SHI, Tiezhu; CHEN, Yiyun; ZHANG, Haitao; MENG, Ran; WANG, Shanqin. Mapping field-scale soil organic carbon with unmanned aircraft system-acquired time series multispectral images. **Soil and Tillage Research**, v. 196, n. October 2019, p. 104477, 2020. DOI: 10.1016/j.still.2019.104477. Disponível em: <https://doi.org/10.1016/j.still.2019.104477>.

GUO, Nan; LI, Yongbin. The Accuracy of Low-Altitude Photogrammetry of Drones. **International Journal of Pattern Recognition and Artificial Intelligence**, v. 34, n. 8, 2020. DOI: 10.1142/S0218001420590296.

GUTWEIN, Sebastian; ZALTZBERG-DREZDAHL, Keith; TOENSMEIER, Eric; FERGUSON, Rafter. Estimating Land Cover-Based Soil Organic Carbon Values to Support Soil Health, Decarbonization, and Climate Resilience Planning in Massachusetts. **SSRN Electronic Journal**, v. 9, n. July, p. 100076, 2022. DOI: 10.2139/ssrn.4160601. Disponível em: <https://doi.org/10.1016/j.soisec.2022.100076>.

HOBSON, R. D. Surface roughness in topography: quantitative approach. In: CHORLEY, Richard J. (org.). **Spatial Analysis in Geomorphology**. 1. ed. London: Routledge, 1972. DOI: 10.4324/9780429273346. Disponível em: <https://www.taylorfrancis.com/books/9781000000252>.

HUETE, A. .. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, New York, v. 25, n. 3, p. 295–309, 1988. DOI: 10.1016/0034-4257(88)90106-X. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/003442578890106X>.

HUGENHOLTZ, Chris H.; WHITEHEAD, Ken; BROWN, Owen W.; BARCHYN, Thomas E.; MOORMAN, Brian J.; LECLAIR, Adam; RIDDELL, Kevin; HAMILTON, Tayler. Geomorphological mapping with a small unmanned aircraft system (sUAS): Feature detection and accuracy assessment of a photogrammetrically-derived digital

terrain model. **Geomorphology**, v. 194, p. 16–24, 2013. DOI: 10.1016/j.geomorph.2013.03.023. Disponível em: <http://dx.doi.org/10.1016/j.geomorph.2013.03.023>.

IBGE. **Serviço online para Pós-Processamento de dados GNSS**. [s.d.]. Disponível em: <https://www.ibge.gov.br/geociencias/informacoes-sobre-posicionamento-geodesico/servicos-para-posicionamento-geodesico/16334-servico-online-para-pos-processamento-de-dados-gnss-ibge-ppp.html?=&t=o-que-e>. Acesso em: 22 set. 2022.

IWAHASHI, Junko; PIKE, Richard J. Automated classifications of topography from DEMs by an unsupervised nested-means algorithm and a three-part geometric signature. **Geomorphology**, v. 86, n. 3–4, p. 409–440, 2007. DOI: 10.1016/j.geomorph.2006.09.012. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0169555X06004375>.

JENNY, Hans. **Factors of soil formation, A System of Quantitative Pedology**. New York: Dover Publications Inc., 1994. v. 9780521851 DOI: 10.1017/CBO9780511535802.014.

JI, Huai; HAN, Jiangang; XUE, Jianming; HATTEN, Jeff A.; WANG, Minhuang; GUO, Yanhui; LI, Pingping. Soil organic carbon pool and chemical composition under different types of land use in wetland: Implication for carbon sequestration in wetlands. **Science of the Total Environment**, v. 716, p. 136996, 2020. DOI: 10.1016/j.scitotenv.2020.136996. Disponível em: <https://doi.org/10.1016/j.scitotenv.2020.136996>.

JOHANNES, Alice; MATTER, Adrien; SCHULIN, Rainer; WEISSKOPF, Peter; BAVEYE, Philippe C.; BOIVIN, Pascal. Optimal organic carbon values for soil structure quality of arable soils. Does clay content matter? **Geoderma**, v. 302, n. May, p. 14–21, 2017. DOI: 10.1016/j.geoderma.2017.04.021. Disponível em: <http://dx.doi.org/10.1016/j.geoderma.2017.04.021>.

KEANE, John F.; CARR, Stephen S. A brief history of early unmanned aircraft. **Johns Hopkins APL Technical Digest (Applied Physics Laboratory)**, v. 32, n. 3, p. 558–571, 2013.

KHALEDIAN, Yones; MILLER, Bradley A. Selecting appropriate machine learning methods for digital soil mapping. **Applied Mathematical Modelling**, v. 81, p. 401–418, 2020. DOI: 10.1016/j.apm.2019.12.016.

KIDD, Darren; FIELD, Damien; MCBRATNEY, Alex; WEBB, Mathew. A

preliminary spatial quantification of the soil security dimensions for Tasmania. **Geoderma**, v. 322, n. March, p. 184–200, 2018. DOI: 10.1016/j.geoderma.2018.02.018. Disponível em: <https://doi.org/10.1016/j.geoderma.2018.02.018>.

KOCH, Andrea et al. Soil Security: Solving the Global Soil Crisis. **Global Policy**, v. 4, n. 4, p. 434–441, 2013. DOI: 10.1111/1758-5899.12096.

KRŠÁK, B.; BLIŠŤAN, P.; PAULIKOVÁ, A.; PUŠKÁROVÁ, P.; KOVANIČ, Ľ.; PALKOVÁ, J.; ZELIŽŇAKOVÁ, V. Use of low-cost UAV photogrammetry to analyze the accuracy of a digital elevation model in a case study. **Measurement**, v. 91, p. 276–287, 2016. DOI: 10.1016/j.measurement.2016.05.028. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0263224116301749>.

KUHN, Max. Building Predictive Models in R Using the caret Package. **Journal of Statistical Software**, v. 28, n. 5, 2008. DOI: 10.18637/jss.v028.i05. Disponível em: <http://www.jstatsoft.org/v28/i05/>.

KUHN, Max; JOHNSON, Kjell. **Applied Predictive Modeling**. New York, NY: Springer New York, 2013. DOI: 10.1007/978-1-4614-6849-3. Disponível em: <http://link.springer.com/10.1007/978-1-4614-6849-3>.

LAGACHERIE, P.; MCBRATNEY, A. B. Spatial Soil Information Systems and Spatial Soil Inference Systems: Perspectives for Digital Soil Mapping. **Developments in Soil Science**, v. 31, n. C, p. 3–22, 2006. DOI: 10.1016/S0166-2481(06)31001-X.

LAL, R. Soil carbon sequestration impacts on global climate change and food security. **Science**, v. 304, n. 5677, p. 1623–1627, 2004. DOI: 10.1126/science.1097396.

LAL, Rattan. Beyond Copenhagen: Mitigating climate change and achieving food security through soil carbon sequestration. **Food Security**, v. 2, n. 2, p. 169–177, 2010. DOI: 10.1007/s12571-010-0060-9.

LAL, Rattan. Intensive Agriculture and the Soil Carbon Pool. **Journal of Crop Improvement**, v. 27, n. 6, p. 735–751, 2013. DOI: 10.1080/15427528.2013.845053. Disponível em: <http://www.tandfonline.com/doi/abs/10.1080/15427528.2013.845053>.

LAL, Rattan. Restoring Soil Quality to Mitigate Soil Degradation. **Sustainability**, v. 7, n. 5, p. 5875–5895, 2015. DOI: 10.3390/su7055875. Disponível em: <http://www.mdpi.com/2071-1050/7/5/5875>.

LAL, Rattan. Soil organic matter and water retention. **Agronomy Journal**, v. 112, n. 5, p. 3265–3277, 2020. DOI: 10.1002/agj2.20282. Disponível em:

<https://onlinelibrary.wiley.com/doi/10.1002/agj2.20282>.

LAMICHHANE, Sushil; ADHIKARI, Kabindra; KUMAR, Lalit. National soil organic carbon map of agricultural lands in Nepal. **Geoderma Regional**, v. 30, n. July, p. e00568, 2022. DOI: 10.1016/j.geodrs.2022.e00568. Disponível em: <https://doi.org/10.1016/j.geodrs.2022.e00568>.

LANDRÉ, A.; CORNU, S.; MEUNIER, J. D.; GUERIN, A.; ARROUAYS, D.; CAUBET, M.; RATIÉ, C.; SABY, N. P. A. Do climate and land use affect the pool of total silicon concentration? A digital soil mapping approach of French topsoils. **Geoderma**, v. 364, n. May 2019, p. 114175, 2020. DOI: 10.1016/j.geoderma.2020.114175. Disponível em: <https://doi.org/10.1016/j.geoderma.2020.114175>.

LASLETT, G. M.; MCBRATNEY, A. B.; PAHL, P. J.; HUTCHINSON, M. F. Comparison of several spatial prediction methods for soil pH. **Journal of Soil Science**, v. 38, n. 2, p. 325–341, 1987. DOI: 10.1111/j.1365-2389.1987.tb02148.x.

LEAL-ALVES, Deivid Cristian; WESCHENFELDER, Jair; ALBUQUERQUE, Miguel da Guia; ESPINOZA, Jean Marcel de Almeida; FERREIRA-CRAVO, Marlize; ALMEIDA, Luis Pedro Melo De. **Digital elevation model generation using UAV-SfM photogrammetry techniques to map sea-level rise scenarios at Cassino Beach, Brazil. SN Applied Sciences**, 2020. DOI: 10.1007/s42452-020-03936-z.

LEMERCIER, Blandine; LAGACHERIE, Philippe; AMELIN, Julien; SAUTER, Joëlle; PICHELIN, Pascal; RICHER-DE-FORGES, Anne C.; ARROUAYS, Dominique. Multiscale evaluations of global, national and regional digital soil mapping products in France. **Geoderma**, v. 425, n. 15, p. 116052, 2022. DOI: 10.1016/j.geoderma.2022.116052. Disponível em: <https://doi.org/10.1080/10106049.2021.1886344>.

LI MA; QING WANG; SONGTAO SHEN. Response of soil aggregate stability and distribution of organic carbon to alpine grassland degradation in Northwest Sichuan. **Geoderma Regional**, v. 22, 2020. DOI: 10.1016/j.geodrs.2020.e00309.

LONG, Jun; LIU, Yaling; XING, Shihe; QIU, Longxia; HUANG, Qian; ZHOU, Biqing; SHEN, Jinquan; ZHANG, Liming. Effects of sampling density on interpolation accuracy for farmland soil organic matter concentration in a large region of complex topography. **Ecological Indicators**, v. 93, n. May, p. 562–571, 2018. DOI: 10.1016/j.ecolind.2018.05.044. Disponível em: <https://doi.org/10.1016/j.ecolind.2018.05.044>.

LORENZ, Klaus; LAL, Rattan; EHLERS, Knut. Soil organic carbon stock as an indicator for monitoring land and soil degradation in relation to United Nations' Sustainable Development Goals. **Land Degradation & Development**, v. 30, n. 7, p. 824–838, 2019. DOI: 10.1002/ldr.3270. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1002/ldr.3270>.

LUO, Wei; XU, Xianli; LIU, Wen; LIU, Meixian; LI, Zhenwei; PENG, Tao; XU, Chaohao; ZHANG, Yaohua; ZHANG, Rongfei. UAV based soil moisture remote sensing in a karst mountainous catchment. **CATENA**, v. 174, n. November 2018, p. 478–489, 2019. DOI: 10.1016/j.catena.2018.11.017. Disponível em: <https://doi.org/10.1016/j.catena.2018.11.017>.

MCBRATNEY, A. ...; MENDONÇA SANTOS, M. ...; MINASNY, B. On digital soil mapping. **Geoderma**, v. 117, n. 1–2, p. 3–52, 2003. a. DOI: 10.1016/S0016-7061(03)00223-4. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0016706103002234>.

MCBRATNEY, A. B.; MENDONÇA SANTOS, M. L.; MINASNY, B. On digital soil mapping. **Geoderma**, Amsterdam, v. 117, n. 1–2, p. 3–52, 2003. b. DOI: 10.1016/S0016-7061(03)00223-4.

MCBRATNEY, A. B.; WEBSTER, R. Optimal interpolation and isarithmic mapping of soil properties: V. Co-regionalization and multiple sampling strategy. **Journal of Soil Science**, v. 34, n. 1, p. 137–162, 1983. DOI: 10.1111/j.1365-2389.1983.tb00820.x.

MCBRATNEY, Alex B.; FIELD, Damien J.; MORGAN, Cristine L. S.; JARRETT, Lorna E. Soil Security: A Rationale. *In*: FIELD, Damien J.; MORGAN, Cristine L. S.; MCBRATNEY, Alex B. (org.). **Global Soil Security**. Cham: Springer International Publishing, 2017. p. 3–14. DOI: 10.1007/978-3-319-43394-3\_1. Disponível em: [https://doi.org/10.1007/978-3-319-43394-3\\_1](https://doi.org/10.1007/978-3-319-43394-3_1).

MCBRATNEY, Alex; FIELD, Damien J.; KOCH, Andrea. The dimensions of soil security. **Geoderma**, v. 213, p. 203–213, 2014. DOI: 10.1016/j.geoderma.2013.08.013. Disponível em: <http://dx.doi.org/10.1016/j.geoderma.2013.08.013>.

MCKENZIE, N. J.; AUSTIN, M. P. A quantitative Australian approach to medium and small scale surveys based on soil stratigraphy and environmental correlation. **Geoderma**, v. 57, n. 4, p. 329–355, 1993. DOI: 10.1016/0016-7061(93)90049-Q.

MEINSHAUSEN, Nicolai. Quantile Regression Forests. **Journal of Machine Learning Research**, Zürich, Switzerland, v. 7, 2006. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/j.1541-0420.2010.01521.x>.

MEINSHAUSEN, Nicolai. **Quantregforest: Quantile Regression Forests. R package**. 2017. Disponível em: <https://cran.r-project.org/package=quantregForest>. Acesso em: 12 jan. 2022.

MENDONÇA-SANTOS, M. L.; DOS SANTOS, H. G. Chapter 3 The State of the Art of Brazilian Soil Mapping and Prospects for Digital Soil Mapping. **Developments in Soil Science**, v. 31, n. C, p. 39–55, 2006. DOI: 10.1016/S0166-2481(06)31003-3.

MINASNY, Budiman; MCBRATNEY, Alex B. A conditioned Latin hypercube method for sampling in the presence of ancillary information. **Computers & Geosciences**, v. 32, n. 9, p. 1378–1388, 2006. DOI: 10.1016/j.cageo.2005.12.009. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S009830040500292X>.

MINASNY, Budiman; MCBRATNEY, Alex B. Digital soil mapping: A brief history and some lessons. **Geoderma**, v. 264, p. 301–311, 2016. DOI: 10.1016/j.geoderma.2015.07.017. Disponível em: <http://dx.doi.org/10.1016/j.geoderma.2015.07.017>.

MINASNY, Budiman; MCBRATNEY, Alex B.; MALONE, Brendan P.; WHEELER, Ichsani. **Digital Mapping of Soil Carbon**. [s.l.] : Elsevier, 2013. v. 118 DOI: 10.1016/B978-0-12-405942-9.00001-3. Disponível em: <http://dx.doi.org/10.1016/B978-0-12-405942-9.00001-3>.

MÖLLER, Markus; VOLK, Martin; FRIEDRICH, Klaus; LYMBURNER, Leo. Placing soil-genesis and transport processes into a landscape context: A multiscale terrain-analysis approach. **Journal of Plant Nutrition and Soil Science**, v. 171, n. 3, p. 419–430, 2008. DOI: 10.1002/jpln.200625039. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1002/jpln.200625039>.

MOORE, I. D.; GESSLER, Paul E.; NIELSEN, G. A.; PETERSON, G. A. Soil Attribute Prediction Using Terrain Analysis. **Soil Science Society of America Journal**, v. 57, n. 2, p. NP-NP, 1993. DOI: 10.2136/sssaj1993.572npb.

MORA-VALLEJO, Alejandra; CLAESSENS, Lieven; STOOORVOGEL, Jetse; HEUVELINK, Gerard B. M. Small scale digital soil mapping in Southeastern Kenya. **Catena**, v. 76, n. 1, p. 44–53, 2008. DOI: 10.1016/j.catena.2008.09.008.

MOURA-BUENO, Jean Michel. **Modelos digitais de elevação e predição do**

**carbono orgânico do solo no planalto do estado do Rio Grande do Sul.** 2014. Universidade Federal de Santa Maria, Santa Maria, Dissertação de Mestrado - Centro de Ciências Rurais, 2014.

MULDER, V. L.; LACOSTE, M.; RICHER-DE-FORGES, A. C.; ARROUAYS, D. GlobalSoilMap France: High-resolution spatial modelling the soils of France up to two meter depth. **Science of the Total Environment**, v. 573, p. 1352–1369, 2016. DOI: 10.1016/j.scitotenv.2016.07.066. Disponível em: <http://dx.doi.org/10.1016/j.scitotenv.2016.07.066>.

NEX, F.; ARMENAKIS, C.; CRAMER, M.; CUCCI, D. A.; GERKE, M.; HONKAVAARA, E.; KUKKO, A.; PERSELLO, C.; SKALLOUD, J. UAV in the advent of the twenties: Where we stand and what is next. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 184, n. December 2021, p. 215–242, 2022. DOI: 10.1016/j.isprsjprs.2021.12.006. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2021.12.006>.

NIU, Xiaoqian; LIU, Chenggong; JIA, Xiaoxu; ZHU, Juntao. Changing soil organic carbon with land use and management practices in a thousand-year cultivation region. **Agriculture, Ecosystems & Environment**, v. 322, n. March, p. 107639, 2021. DOI: 10.1016/j.agee.2021.107639. Disponível em: <https://doi.org/10.1016/j.agee.2021.107639>.

ODEBIRI, Omosalewa; MUTANGA, Onisimo; ODINDI, John. Deep learning-based national scale soil organic carbon mapping with Sentinel-3 data. **Geoderma**, v. 411, n. September 2021, p. 115695, 2022. DOI: 10.1016/j.geoderma.2022.115695. Disponível em: <https://doi.org/10.1016/j.geoderma.2022.115695>.

OLAYA, V. Chapter 6 Basic Land-Surface Parameters. *In: Developments in Soil Science*. [s.l: s.n.]. v. 33p. 141–169. DOI: 10.1016/S0166-2481(08)00006-8. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0166248108000068>.

OLAYA, V.; CONRAD, O. Chapter 12 Geomorphometry in SAGA. *In: Developments in Soil Science*. [s.l: s.n.]. v. 33p. 293–308. DOI: 10.1016/S0166-2481(08)00012-3. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0166248108000123>.

OLAYA, Victor. A gentle introduction to SAGA GIS. **The SAGA User Group eV, Gottingen, Germany**, p. 216, 2004. Disponível em: <http://sourceforge.net/projects/saga-gis/files/SAGA - Documentation/>.

OLSON, Kenneth R.; AL-KAISI, Mahdi; LAL, Rattan; CIHACEK, Larry. Impact

of soil erosion on soil organic carbon stocks. **Journal of Soil and Water Conservation**, v. 71, n. 3, p. 61A-67A, 2016. DOI: 10.2489/jswc.71.3.61A.

OWUSU, Stephen; YIGINI, Yusuf; OLMEDO, Guillermo F.; OMUTO, Christian T. Spatial prediction of soil organic carbon stocks in Ghana using legacy data. 2019. DOI: 10.1016/j.geoderma.2019.114008.

PADARIAN, J.; MINASNY, B.; MCBRATNEY, A. B. Chile and the Chilean soil grid: A contribution to GlobalSoilMap. **Geoderma Regional**, v. 9, p. 17–28, 2017. DOI: 10.1016/j.geodrs.2016.12.001. Disponível em: <http://dx.doi.org/10.1016/j.geodrs.2016.12.001>.

PAUL, S. S.; COOPS, N. C.; JOHNSON, M. S.; KRZIC, M.; CHANDNA, A.; SMUKLER, S. M. Mapping soil organic carbon and clay using remote sensing to predict soil workability for enhanced climate change adaptation. **Geoderma**, v. 363, n. August 2019, p. 114177, 2020. DOI: 10.1016/j.geoderma.2020.114177. Disponível em: <https://doi.org/10.1016/j.geoderma.2020.114177>.

PEI, Tao; QIN, Cheng-Zhi; ZHU, A. Xing; YANG, Lin; LUO, Ming; LI, Baolin; ZHOU, Chenghu. Mapping soil organic matter using the topographic wetness index: A comparative study based on different flow-direction algorithms and kriging methods. **Ecological Indicators**, v. 10, n. 3, p. 610–619, 2010. DOI: 10.1016/j.ecolind.2009.10.005. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1470160X09001691>.

PEUCKER, Thomas K.; DOUGLAS, David H. Detection of Surface-Specific Points by Local Parallel Processing of Discrete Terrain Elevation Data. **Computer Graphics and Image Processing**, v. 4, n. 4, p. 375–387, 1975. DOI: 10.1016/0146-664X(75)90005-2. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/0146664X75900052>.

PFEIFFER, Marco et al. CHLSOC: The Chilean Soil Organic Carbon database, a multi-institutional collaborative effort. **Earth System Science Data**, v. 12, n. 1, p. 457–468, 2020. DOI: 10.5194/essd-12-457-2020.

**Planet Explorer**. 2022. Disponível em: <https://www.planet.com/explorer/>. Acesso em: 14 jan. 2022.

POGGIO, Laura; GIMONA, Alessandro. National scale 3D modelling of soil organic carbon stocks with uncertainty propagation - An example from Scotland. **Geoderma**, v. 232–234, p. 284–299, 2014. DOI: 10.1016/j.geoderma.2014.05.004. Disponível em: <http://dx.doi.org/10.1016/j.geoderma.2014.05.004>.

QGIS.ORG. QGIS Association. **QGIS Geographic Information System**, 2021. Disponível em: <http://www.qgis.org>.

QIAO, Hui; ZHENG, Fengtian; JIANG, Hongdian; DONG, Kangyin. The greenhouse effect of the agriculture-economic growth-renewable energy nexus: Evidence from G20 countries. **Science of the Total Environment**, v. 671, p. 722–731, 2019. DOI: 10.1016/j.scitotenv.2019.03.336. Disponível em: <https://doi.org/10.1016/j.scitotenv.2019.03.336>.

R CORE TEAM. R: A Language and Environment for Statistical Computing. **R Foundation for Statistical Computing**, Vienna, Austria, p. <https://www.R-project.org>, 2021. Disponível em: <https://www.r-project.org/>. Acesso em: 20 out. 2021.

RABUS, Bernhard; EINEDER, Michael; ROTH, Achim; BAMLER, Richard. The shuttle radar topography mission—a new class of digital elevation models acquired by spaceborne radar. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 57, n. 4, p. 241–262, 2003. DOI: 10.1016/S0924-2716(02)00124-7. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0924271602001247>.

RAMESH, Thangavel et al. Soil organic carbon dynamics: Impact of land use changes and management practices: A review. *In: Advances in Agronomy*. [s.l.: s.n.]. v. 156p. 1–107. DOI: 10.1016/bs.agron.2019.02.001. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0065211319300343>.

RAWLS, W. J.; PACHEPSKY, Y. A.; RITCHIE, J. C.; SOBECKI, T. M.; BLOODWORTH, H. Effect of soil organic carbon on soil water retention. **Geoderma**, v. 116, n. 1–2, p. 61–76, 2003. DOI: 10.1016/S0016-7061(03)00094-6.

REJEB, Abderahman; ABDOLLAHI, Alireza; REJEB, Karim; TREIBLMAIER, Horst. Drones in agriculture: A review and bibliometric analysis. **Computers and Electronics in Agriculture**, v. 198, n. April, p. 107017, 2022. DOI: 10.1016/j.compag.2022.107017. Disponível em: <https://doi.org/10.1016/j.compag.2022.107017>.

RILEY, Shawn J.; DEGLORIA, Stephen D.; ELLIOT, Robert. A Terrain Ruggedness Index that Quantifies Topographic Heterogeneity. **Intermountain Journal of Sciences**, v. 5, n. 1–4, p. 23–27, 1999.

RITCHIE, Andrew; HOWARD, Wilmont. Recent developments and likely advances in lithium-ion batteries. **Journal of Power Sources**, v. 162, n. 2 SPEC. ISS., p. 809–812, 2006. DOI: 10.1016/j.jpowsour.2005.07.014.

ROCH, Jean Louis. UAV Classification and Associated Mission Planning.

**Multi-rotor Platform Based UAV Systems**, p. 27–44, 2020. DOI: 10.1016/B978-1-78548-251-9.50002-9.

ROSENQVIST, Ake; SHIMADA, Masanobu; ITO, Norimasa; WATANABE, Manabu. ALOS PALSAR: A Pathfinder Mission for Global-Scale Monitoring of the Environment. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 11, p. 3307–3316, 2007. DOI: 10.1109/TGRS.2007.901027. Disponível em: <http://ieeexplore.ieee.org/document/4358862/>.

ROSSITER, David G. Digital Soil Resource Inventories: Status and Prospects in 2015. **Springer**, Singapore, n. February 2016, p. 358, 2016. DOI: 10.1007/978-981-10-0415-5.

ROUDIER, Pierre. cLHS - A R Package for Conditioned Latin Hypercube Sampling. 2014.

SALEMME, Ronald K.; OLSON, Kenneth R.; GENNADIYEV, Alexander N.; KOVACH, Roman G. Effects of Land Use Change, Cultivation, and Landscape Position on Prairie Soil Organic Carbon Stocks. **Open Journal of Soil Science**, v. 08, n. 07, p. 163–173, 2018. DOI: 10.4236/ojss.2018.87013. Disponível em: <http://www.scirp.org/journal/doi.aspx?DOI=10.4236/ojss.2018.87013>.

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

SANKARAN, Sindhuja et al. Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review. **European Journal of Agronomy**, v. 70, p. 112–123, 2015. DOI: 10.1016/j.eja.2015.07.004. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1161030115300095>.

SANTANA, Lucas Santos; FERRAZ, Gabriel Araújo E. Silv.; MARIN, Diego Bedin; FARIA, Rafael de Oliveira; SANTANA, Mozarte Santos; ROSSI, Giuseppe; PALCHETTI, Enrico. Digital Terrain Modelling by Remotely Piloted Aircraft: Optimization and Geometric Uncertainties in Precision Coffee Growing Projects. **Remote Sensing**, v. 14, n. 4, 2022. DOI: 10.3390/rs14040911.

SAURETTE, Daniel D.; BERG, Aaron A.; LAAMRANI, Ahmed; HECK, Richard J.; GILLESPIE, Adam W.; VORONEY, Paul; BISWAS, Asim. Effects of sample size and covariate resolution on field-scale predictive digital mapping of soil carbon. **Geoderma**, v. 425, n. February, p. 116054, 2022. DOI: 10.1016/j.geoderma.2022.116054. Disponível em:

<https://doi.org/10.1016/j.geoderma.2022.116054>.

SCHARLEMANN, Jörn P. W.; TANNER, Edmund V. J.; HIEDERER, Roland; KAPOS, Valerie. Global soil carbon: Understanding and managing the largest terrestrial carbon pool. **Carbon Management**, v. 5, n. 1, p. 81–91, 2014. DOI: 10.4155/cmt.13.77.

SCHULTEN, H. R.; LEINWEBER, P. New insights into organic-mineral particles: Composition, properties and models of molecular structure. **Biology and Fertility of Soils**, v. 30, n. 5–6, p. 399–432, 2000. DOI: 10.1007/s003740050020.

SCROSATI, Bruno. Recent advances in lithium ion battery materials. **Electrochimica Acta**, v. 45, n. 15–16, p. 2461–2466, 2000. DOI: 10.1016/S0013-4686(00)00333-9. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0013468600003339>.

**Sentinel-2 - Missions - Sentinel Online - Sentinel Online**. 2022. Disponível em: <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2>. Acesso em: 21 jan. 2022.

SHAIKH, Muhammad S.; SHAIKH, Pervez H.; QURESHI, Khadija; BHATTI, Inamullah. **Green House Effect and Carbon Foot Print**. [s.l.] : Elsevier Ltd., 2018. DOI: 10.1016/b978-0-12-803581-8.10456-4. Disponível em: <http://dx.doi.org/10.1016/B978-0-12-803581-8.10456-4>.

SIEBERT, Sebastian; TEIZER, Jochen. Mobile 3D mapping for surveying earthwork projects using an Unmanned Aerial Vehicle (UAV) system. **Automation in Construction**, v. 41, p. 1–14, 2014. DOI: 10.1016/j.autcon.2014.01.004. Disponível em: <https://doi.org/10.1016/j.autcon.2014.01.004>.

SILVA, Paulo Alexandre Da; DE LIMA, Bruno Horschut; LA SCALA, Newton; PERUZZI, Nelson José; CHAVARETTE, Fabio Roberto; PANOSSO, Alan Rodrigo. Spatial variation of soil carbon stability in sugarcane crops, central-south of Brazil. **Soil and Tillage Research**, v. 202, n. April, p. 104667, 2020. a. DOI: 10.1016/j.still.2020.104667. Disponível em: <https://doi.org/10.1016/j.still.2020.104667>.

SILVA, Paulo Alexandre Da; DE LIMA, Bruno Horschut; LA SCALA, Newton; PERUZZI, Nelson José; CHAVARETTE, Fabio Roberto; PANOSSO, Alan Rodrigo. Spatial variation of soil carbon stability in sugarcane crops, central-south of Brazil. **Soil and Tillage Research**, v. 202, n. April, p. 104667, 2020. b. DOI: 10.1016/j.still.2020.104667. Disponível em: <https://doi.org/10.1016/j.still.2020.104667>.

SKIDMORE, Andrew K.; RYAN, Philip J.; DAWES, Warwick; SHORT, David;

O'LOUGHLIN, Emmett. Use of an expert system to map forest soils from a geographical information system. **International Journal of Geographical Information Systems**, v. 5, n. 4, p. 431–445, 1991. DOI: 10.1080/02693799108927867.

SÖDERSTRÖM, Mats; SOHLENIUS, Gustav; RODHE, Lars; PIIKKI, Kristin. Adaptation of regional digital soil mapping for precision agriculture. **Precision Agriculture**, v. 17, n. 5, p. 588–607, 2016. DOI: 10.1007/s11119-016-9439-8.

SOSA, Leandro; JUSTEL, Ana; MOLINA, Íñigo. Detection of Crop Hail Damage with a Machine Learning Algorithm Using Time Series of Remote Sensing Data. **Agronomy**, v. 11, n. 10, p. 2078, 2021. DOI: 10.3390/agronomy11102078. Disponível em: <https://www.mdpi.com/2073-4395/11/10/2078>.

TAJIK, Samaneh; AYOUBI, Shamsollah; ZERAATPISHEH, Mojtaba. Digital mapping of soil organic carbon using ensemble learning model in Mollisols of Hyrcanian forests, northern Iran. **Geoderma Regional**, v. 20, p. e00256, 2020. DOI: 10.1016/j.geodrs.2020.e00256. Disponível em: <https://doi.org/10.1016/j.geodrs.2020.e00256>.

TEAM R DEVELOPMENT CORE. A Language and Environment for Statistical Computing. **R Foundation for Statistical Computing**, Vienna, Austria, v. 2, p. <https://www.R-project.org>, 2018. Disponível em: <https://www.r-project.org/>. Acesso em: 10 ago. 2020.

TEIXEIRA, Claudia Fernanda Almeida; DAMÉ, Rita De Cássia Fraga; DISCONZI, Pamela Bilhafan; PINTO, Marília Alves Brito; WINKLER, Antony Severo; SANTOS, Jacira Porto Dos. Estatística de Mallows na seleção de modelos de predição da precipitação média mensal e anual no Rio Grande do Sul. **Revista Agro@Mambiente on-Line**, v. 7, n. 2, p. 145, 2013. DOI: 10.18227/1982-8470ragro.v7i2.973.

TEIXEIRA, Paulo César; DONAGEMMA, Guilherme Kangussu; FONTANA, Ademir; TEIXEIRA, Wenceslau Geraldes. **Manual de Métodos de Análise de Solo**. Brasília: EMBRAPA, 2017. Disponível em: [http://www.cse.edu.uy/sites/www.cse.edu.uy/files/documentos/Liccom\\_Camejo\\_2011-07-28.pdf](http://www.cse.edu.uy/sites/www.cse.edu.uy/files/documentos/Liccom_Camejo_2011-07-28.pdf).

TEN CATEN, Alexandre; DALMOLIN, Ricardo Simão Diniz; PEDRON, Fabrício Araújo; MENDONÇA-SANTOS, Maria de Lourdes. Regressões logísticas múltiplas: Fatores que influenciam sua aplicação na predição de classes de solos.

**Revista Brasileira de Ciencia do Solo**, v. 35, n. 1, p. 53–62, 2011. DOI: 10.1590/s0100-06832011000100005.

TROEH, Frederick R. Landform Parameters Correlated to Soil Drainage. **Soil Science Society of America Journal**, v. 28, n. 6, p. 808–812, 1964. DOI: 10.2136/sssaj1964.03615995002800060035x.

VAN DER MERWE, Deon; BURCHFIELD, David R.; WITT, Trevor D.; PRICE, Kevin P.; SHARDA, Ajay. **Drones in agriculture**. 1. ed. [s.l.] : Elsevier Inc., 2020. v. 162 DOI: 10.1016/bs.agron.2020.03.001. Disponível em: <http://dx.doi.org/10.1016/bs.agron.2020.03.001>.

VAN DER VEEKE, S.; LIMBURG, J.; KOOMANS, R. L.; SÖDERSTRÖM, M.; VAN DER GRAAF, E. R. Optimizing gamma-ray spectrometers for UAV-borne surveys with geophysical applications. **Journal of Environmental Radioactivity**, v. 237, n. July, p. 106717, 2021. DOI: 10.1016/j.jenvrad.2021.106717. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0265931X21001892>.

VAYSSE, Kévin; LAGACHERIE, Philippe. Using quantile regression forest to estimate uncertainty of digital soil mapping products. **Geoderma**, v. 291, p. 55–64, 2017. DOI: 10.1016/j.geoderma.2016.12.017. Disponível em: <http://dx.doi.org/10.1016/j.geoderma.2016.12.017>.

WANG, Daming; LAFFAN, Shawn W.; LIU, Yu; WU, Lun. Morphometric characterisation of landform from DEMs. **International Journal of Geographical Information Science**, v. 24, n. 2, p. 305–326, 2010. DOI: 10.1080/13658810802467969. Disponível em: <http://www.tandfonline.com/doi/abs/10.1080/13658810802467969>.

WERTS, Scott. Factors of soil formation: Soil biota and organic matter as a factor for soil formation and weathering processes. *In: Reference Module in Earth Systems and Environmental Sciences*. [s.l.] : Elsevier, 2022. DOI: 10.1016/B978-0-12-822974-3.00070-7. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/B9780128229743000707>.

WHITESIDE, Timothy G.; BARTOLO, Renée E. A robust object-based woody cover extraction technique for monitoring mine site revegetation at scale in the monsoonal tropics using multispectral RPAS imagery from different sensors. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, n. March, p. 300–312, 2018. DOI: 10.1016/j.jag.2018.07.003. Disponível em: <https://doi.org/10.1016/j.jag.2018.07.003>.

WIESE-ROZANOV, Liesl. Soil organic carbon commitments under three Rio Conventions: Opportunities for integration. **Soil Security**, v. 6, p. 100052, 2022. DOI: 10.1016/j.soisec.2022.100052. Disponível em: <https://doi.org/10.1016/j.soisec.2022.100052>.

XUE, Bin; HUANG, Li; HUANG, Yanan; ZHOU, Fangliang; LI, Feng; KUBAR, Kashif Ali; LI, Xiaokun; LU, Jianwei; ZHU, Jun. Roles of soil organic carbon and iron oxides on aggregate formation and stability in two paddy soils. **Soil and Tillage Research**, v. 187, n. July 2018, p. 161–171, 2019. DOI: 10.1016/j.still.2018.12.010. Disponível em: <https://doi.org/10.1016/j.still.2018.12.010>.

YANG, Fei; ZHANG, Gan-Lin; YANG, Jin-Ling; LI, De-Cheng; ZHAO, Yu-Guo; LIU, Feng; YANG, Ren-Min; YANG, Fan. Organic matter controls of soil water retention in an alpine grassland and its significance for hydrological processes. **Journal of Hydrology**, v. 519, p. 3086–3093, 2014. DOI: 10.1016/j.jhydrol.2014.10.054. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S002216941400849X>.

YANG, Ren-Min; LIU, Li-An; ZHANG, Xin; HE, Ri-Xing; ZHU, Chang-Ming; ZHANG, Zhong-Qi; LI, Jian-Guo. The effectiveness of digital soil mapping with temporal variables in modeling soil organic carbon changes. **Geoderma**, v. 405, n. August 2021, p. 115407, 2022. DOI: 10.1016/j.geoderma.2021.115407. Disponível em: <https://doi.org/10.1016/j.geoderma.2021.115407>.

YOUNG, Claudia J.; LIU, Shuguang; SCHUMACHER, Joseph A.; SCHUMACHER, Thomas E.; KASPAR, Thomas C.; MCCARTY, Gregory W.; NAPTON, Darrell; JAYNES, Dan B. Evaluation of a model framework to estimate soil and soil organic carbon redistribution by water and tillage using <sup>13</sup>Cs in two U.S. Midwest agricultural fields. **Geoderma**, v. 232–234, p. 437–448, 2014. DOI: 10.1016/j.geoderma.2014.05.019. Disponível em: <http://dx.doi.org/10.1016/j.geoderma.2014.05.019>.

ZERAATPISHEH, Mojtaba; AYOUBI, Shamsollah; JAFARI, Azam; TAJIK, Samaneh; FINKE, Peter. Digital mapping of soil properties using multiple machine learning in a semi-arid region, central Iran. **Geoderma**, v. 338, n. August 2018, p. 445–452, 2019. DOI: 10.1016/j.geoderma.2018.09.006.

ZHANG, Zhaotong; ZHANG, Hongqi; XU, Erqi. Enhancing the digital mapping accuracy of farmland soil organic carbon in arid areas using agricultural land use history. **Journal of Cleaner Production**, v. 334, n. December 2021, p. 130232, 2022. DOI: 10.1016/j.jclepro.2021.130232. Disponível em:

<https://doi.org/10.1016/j.jclepro.2021.130232>.

ZHENG, Hengbiao; ZHOU, Xiang; HE, Jiaoyang; YAO, Xia; CHENG, Tao; ZHU, Yan; CAO, Weixing; TIAN, Yongchao. Early season detection of rice plants using RGB, NIR-G-B and multispectral images from unmanned aerial vehicle (UAV). **Computers and Electronics in Agriculture**, v. 169, n. March 2019, p. 105223, 2020. DOI: 10.1016/j.compag.2020.105223. Disponível em: <https://doi.org/10.1016/j.compag.2020.105223>.

ZHOU, Tao; GENG, Yajun; CHEN, Jie; PAN, Jianjun; HAASE, Dagmar; LAUSCH, Angela. High-resolution digital mapping of soil organic carbon and soil total nitrogen using DEM derivatives, Sentinel-1 and Sentinel-2 data based on machine learning algorithms. **Science of the Total Environment**, v. 729, p. 138244, 2020. DOI: 10.1016/j.scitotenv.2020.138244. Disponível em: <https://doi.org/10.1016/j.scitotenv.2020.138244>.

ZHOU, X. et al. Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 246–255, 2017. DOI: 10.1016/j.isprsjprs.2017.05.003. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0924271616302337>.

ZHU, Guangyu; DENG, Lei; SHANGGUAN, Zhouping. Effects of soil aggregate stability on soil N following land use changes under erodible environment. **Agriculture, Ecosystems & Environment**, v. 262, n. April, p. 18–28, 2018. DOI: 10.1016/j.agee.2018.04.012. Disponível em: <https://doi.org/10.1016/j.agee.2018.04.012>.