

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DO SOLO

Matheus Flesch Soligo

**MÉTODOS DE AMOSTRAGEM PARA A MODELAGEM ESPACIAL DE
FÓSFORO DISPONÍVEL NO SOLO**

Santa Maria, RS, Brasil

2021

Matheus Flesch Soligo

**MÉTODOS DE AMOSTRAGEM PARA A MODELAGEM ESPACIAL DE
FÓSFORO DISPONÍVEL NO SOLO**

Dissertação apresentada ao Curso de mestrado do Programa de Pós-Graduação em Ciência do Solo da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de Mestre em Ciência do solo.

Orientador: Prof. Fabrício de Araújo Pedron

Santa Maria, RS, Brasil

2021

Ficha cartográfica elaborada através do Programa de Geração Automática da Biblioteca Central da UFSM, com os dados fornecidos pelo autor.

Soligo, Matheus Flesch
MÉTODOS DE AMOSTRAGEM PARA A MODELAGEM ESPACIAL DE
FÓSFORO DISPONÍVEL NO SOLO / Matheus Flesch Soligo.- 2021.
64 p.; 30 cm

Orientador: Fabrício de Araújo Pedron
Coorientador: Ricardo Bergamo Schenato
Dissertação (mestrado) - Universidade Federal de Santa
Maria, Centro de Ciências Rurais, Programa de Pós
Graduação em Ciência do Solo, RS, 2021

1. Mapeamento digital de solos 2. geoestatística 3.
design de amostragem 4. pedometria 5. agricultura de
precisão I. Pedron, Fabrício de Araújo II. Schenato,
Ricardo Bergamo III. Título.

Matheus Flesch Soligo

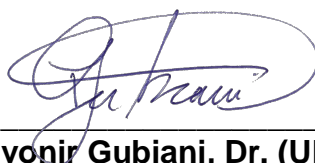
**MÉTODOS DE AMOSTRAGEM PARA A MODELAGEM ESPACIAL DE
FÓSFORO DISPONÍVEL NO SOLO**

Dissertação apresentada ao Curso de mestrado do Programa de Pós-Graduação em Ciência do Solo da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de Mestre em Ciência do solo.

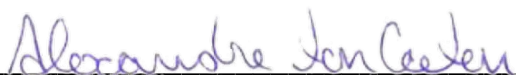
Aprovado em 30 de março de 2021:



Fabrício de Araújo Pedron, Dr. (UFSM)
(Presidente / Orientador)



Paulo Ivonir Gubiani, Dr. (UFSM)



Alexandre ten Caten, Dr. (UFSC)

Santa Maria, RS, Brasil
2021

AGRADECIMENTOS

A Deus, por guiar meu caminho.

A toda a minha família, em especial aos meus pais Gilberto Luiz Soligo e Roselene Ap. Flesch Soligo, pela paciência e apoio, e por acreditarem em mim e me ajudarem em todos os momentos.

A minha namorada Gabriela Christine da Silva, por estar ao meu lado nos momentos mais difíceis, pelos conselhos e por toda a ajuda.

Ao meu orientador, prof. Fabrício de Araújo Pedron por sempre estar disposto a ajudar durante a execução do trabalho.

Aos professores Ricardo Simão Diniz Dalmolin e Ricardo Bergamo Schenato pelo auxílio sempre que precisei.

Ao professor Alexandre ten Caten, pela importante influência que teve em minhas escolhas, desde o período de graduação, e também no mestrado.

A todo o grupo de pedologia da UFSM, em especial ao Pós-Doc Jean Michel Moura Bueno, por acompanhar toda a minha trajetória no mestrado e pelos inúmeros conselhos prestados.

Ao meu colega e principalmente amigo, Renan Storto Nalin, pela parceria durante este período.

Ao prof. Alessandro Samuel-Rosa e a doutoranda Maiara Pusch pela ajuda técnica que foi indispensável para a execução deste trabalho.

Ao Programa de Pós-Graduação em Ciência do Solo da Universidade Federal de Santa Maria, pela oportunidade de crescimento profissional.

A Capes, pela concessão da bolsa de estudos.

A todos(as) meu muito obrigado!

RESUMO

MÉTODOS DE AMOSTRAGEM PARA A MODELAGEM ESPACIAL DE FÓSFORO DISPONÍVEL NO SOLO

A amostragem representa uma etapa crucial para o mapeamento digital de solos, pois interfere diretamente nos custos operacionais do projeto e nas etapas seguintes do processamento dos dados, até a qualidade do mapa gerado. Dada a necessidade de obtenção de informações relacionadas a diferentes métodos de coleta de dados, o objetivo deste estudo foi comparar o desenho amostral e dois métodos de modelagem científica na predição espacial do P disponível no solo. O estudo foi realizado em uma propriedade rural de 160 ha localizada no município de Tupanciretã - RS. Nesta área ocorrem intensas atividades agrícolas, adição de insumos (fertilizantes) e irrigação por sistema de pivô central. Três métodos de amostragem foram testados - grade regular simples (RG) com distância fixa entre pontos, amostragem de cobertura espacial (SCS) contendo pontos em distâncias curtas e amostragem de recozimento simulado considerando a distribuição marginal de covariáveis ambientais (DIST) - como base para a previsão de o conteúdo de fósforo disponível no solo, a uma profundidade de 0 - 10 cm. A densidade amostral foi priorizada nos três métodos de amostragem. Os resultados foram validados com um conjunto externo e independente contendo 50 pontos. Assim, cada conjunto de calibração contém 160 (com exceção da grade regular, que tem 162), que foram usados para aprender dois modelos preditivos: krigagem com deriva externa (KED), considerado um modelo misto por englobar a abordagem geoestatística e determinística ; e krigagem comum (OK). Além disso, para conhecimento prévio das classes de solo que ocorrem na área, 8 perfis representativos tiveram sua morfologia analisada. A qualidade dos mapas de visualização foi avaliada pelo cálculo do erro. O melhor resultado de previsão foi encontrado combinando a amostragem DIST com o modelo KED, que tem um erro absoluto médio inferior (MAE) = 14,62, erro médio (ME) = -3,12 e erro quadrático médio da raiz (RMSE) = 23,44 mg dm⁻³ e uma maior eficiência Nash-Sutcliffe (NSE) = 0,13. Os resultados encontrados no presente estudo confirmaram a hipótese de que golpes amostrais que consideram covariáveis ambientais contribuem para o aumento da qualidade dos mapas de atributos preditos do solo.

Palavras-chave: Mapeamento digital de Solos, geoestatística, design de amostragem, pedometria, agricultura de precisão.

ABSTRACT

SAMPLING METHODS FOR PHOSPHORUS AVAILABLE SPATIAL MODELING IN THE SOIL

Sampling represents a crucial step for digital soil mapping because it directly interferes with the operational costs of the project and in the following steps of data processing, up to the quality of the generated map. Given the need to obtain information related to different data collection methods, the aim of this study was to compare the sampling design and two scientific modeling methods in the spatial prediction of P available on soil. The study was conducted in a 160 ha rural property located in the municipality of Tupanciretã - RS. In this area there are intense agricultural activities, the addition of inputs (fertilizers), and irrigation using a central pivot system. Three sampling methods were tested - simple regular grid (RG) with fixed distance between points, spatial coverage sampling (SCS) containing points over short distances and simulated annealing sampling considering the marginal distribution of environmental covariates (DIST) - as a basis for prediction of the available phosphorus content in the soil, at a depth of 0 - 10 cm. The sampling density was prioritized in the three sampling methods. The results were validated with an external and independent set containing 50 points. Thus, each calibration set contains 160 (with the exception of the regular grid, which has 162), which were used to learn two predictive models: kriging with external drift (KED), considered a mixed model because it encompasses the geostatistical approach and deterministic; and ordinary kriging (OK). In addition, for prior knowledge of the soil classes that occur in the area, 8 representative profiles had their morphology analyzed. The quality of the visualization maps was assessed by calculating the error. The best prediction result was found by combining the DIST sampling with the KED model, which has a lower mean absolute error (MAE) = 14.62, mean error (ME) = -3.12 and root mean squared error (RMSE) = 23.44 mg dm⁻³ and a higher Nash-Sutcliffe efficiency (NSE) = 0.13. The results found in the present study confirmed the hypothesis that sample strokes that consider environmental covariables contribute to the increase in the quality of the predicted soil attribute maps.

Keywords: Digital soil mapping, geostatistic, sampling design, pedometric, precision agriculture.

SUMÁRIO

1. INTRODUÇÃO	9
2. REVISÃO BIBLIOGRÁFICA	12
2.1. IMPORTÂNCIA DO SOLO E OS FATORES RELACIONADOS A SUA FORMAÇÃO	12
2.2. FÓSFORO NO SOLO E SUA IMPORTÂNCIA PARA AS PLANTAS	14
2.3. MAPEAMENTO DIGITAL DE SOLOS	16
2.4. AMOSTRAGEM NO MAPEAMENTO DIGITAL DE SOLOS	19
3. MATERIAL E MÉTODOS	21
3.1. ÁREA DE ESTUDO	21
3.2. OBTENÇÃO DE COVARIÁVEIS DO TERRENO	23
3.3. DESIGN'S DE AMOSTRAGEM	23
3.3.1. Grid regular - RG.....	24
3.3.2. <i>Spatial Coverage Sampling</i> - SCS	25
3.3.3. <i>Spatial simulated annealing</i> - DIST	25
3.3.4. Validação externa	26
3.4. OBTENÇÃO DE DADOS ANALÍTICOS DO SOLO.....	26
3.5. MODELAGEM ESTATÍSTICA ESPACIAL	27
4. RESULTADOS	28
4.1. CARACTERIZAÇÃO DOS DADOS DE P DISPONÍVEL	29
4.2. AJUSTES DE MODELOS	30
4.3 PREDIÇÃO ESPACIAL E ESTATÍSTICAS DE AVALIAÇÃO DE ACURÁCIA.....	32
5. DISCUSSÃO	33
6. CONCLUSÕES	41
REFERÊNCIAS BIBLIOGRÁFICAS	42
APÊNDICES.....	48

1. INTRODUÇÃO

A crescente demanda por alimentos e a necessidade de uso sustentável dos recursos naturais tornam essenciais pesquisas que contribuam para gerar mapas de propriedades do solo, de alta qualidade e resolução espacial (McBratney et al., 2014; Bouma, 2021). O fósforo (P) é um macronutriente essencial para as culturas e está intimamente ligado à produtividade agrícola, sendo responsável por diversos processos de transferência de energia no interior da planta (Ye et al., 2013). Além disso, no sul do Brasil, as práticas agrícolas inadequadas têm promovido a erosão do solo (Deuschle et al., 2019) e a transferência do P para os cursos d'água (Bender et al., 2018; Tiecher et al., 2020), exigindo atenção quanto ao manejo da adubação fosfatada. Os fatores do solo desempenham um papel crítico na eficiência do uso do fertilizante P (Yu et al., 2021), o que justificam a necessidade de mapas de P cada vez mais precisos e acurados. Entretanto, para alcançar esse nível de informação, um planejamento criterioso é necessário, a fim de orientar a tomada de decisão desde a amostragem inicial, até o processo de gerar os mapas de P disponível, para que estes sejam confiáveis e viáveis economicamente.

A predição espacial pode ser realizada por meio de modelos geoestatístico (Webster e Oliver, 2007), determinístico (Hengl et al., 2004) ou híbrido (Knotters et al., 1995; McBratney et al., 2000), ajustados a partir de um banco de dados que contempla um conjunto de amostras localizadas na área a ser mapeada. O design amostral e a densidade da amostragem são fatores que interferem diretamente nos custos do projeto e na acurácia final dos mapas (de Gruijter et al., 2006; Wadoux, et al., 2019). Na literatura, é possível encontrar estudos que propõem diferentes métodos para alocar pontos de amostragem buscando o melhor ajuste dos modelos preditivos. Brus (2019) apresenta uma revisão atualizada de métodos de amostragem apresentados por de Gruijter et al. (2006). Diversos design's amostrais são documentados neste trabalho, avaliando a aplicabilidade em situações variadas com conjuntos de calibração obtidos de estudos anteriores ao redor do mundo (dados legados), por exemplo: cLHS (Minasny e McBratney, 2006); cobertura do espaço por *k-means* (Brus et al., 2007); amostragem *Kennard-Stone* (Kennard e Stone, 1969) e amostragem de superfície de resposta (Lesch, et al., 1995).

Entre os desenhos amostrais disponíveis, três foram abordados no presente estudo. O primeiro trata-se de um grid regular com distância fixa entre os pontos. Este método é comumente utilizado por projetos de agricultura de precisão (Matos-Moreira et al., 2017) por facilitar o processo de amostragem. O segundo desenho amostral, a *Spatial Coverage Sampling* (SCS), refere-se a uma otimização pelo critério *mean of the squared shortest distance* (MSSD), que visa fazer uma cobertura espacial de pontos, dividindo a área a ser mapeada em agrupamentos por *k-means* (Brus et al., 2007). Este método prioriza a geoestatística, porém, diferente do grid regular, há um critério de otimização para a alocação dos pontos. Por fim, o terceiro desenho amostral, o *spatial simulated annealing* (DIST), também se trata de uma otimização, porém, que considera a distribuição marginal das variáveis auxiliares no histograma (por exemplo, covariáveis ambientais) que estejam disponíveis e que representem os fatores de formação do solo da área a ser mapeada (Samuel-Rosa, 2016).

Entretanto, há poucos estudos que comparam diferentes desenhos amostrais em uma mesma área com o objetivo de gerar mapas digitais de propriedades do solo. É provável que isso ocorra devido à alta variabilidade espacial do P, ocasionando um exaustivo trabalho de coleta a campo por normalmente ser necessário uma quantidade elevada de amostras, e conseqüentemente, um alto custo de análises laboratoriais. Porém, conforme descrito por Minasny e McBratney (2010), o mapeamento digital de solos (MDS) deve avançar em pesquisas que busquem entender a relação entre as otimizações dos locais de amostragem e a acurácia das predições espaciais da variável de solo alvo. Um dos fatores condicionantes dessa relação é a variabilidade intrínseca de cada variável de solo. O P disponível, por exemplo, apresenta complexa interação com os fatores de formação do solo, como por exemplo geologia, atributos do terreno (Page et al., 2005) e uso da terra (Liu et al., 2009), e outras propriedades como teor de argila (Camargo et al., 2013), matéria orgânica e mineralogia. Além disso, o manejo antrópico do solo, como adubações, correções e preparo do solo (Alovisi et al., 2020; Bortoluzzi et al., 2015) também contribuem para heterogeneidade do solo na paisagem, mesmo em escala de propriedade rural (Zhang e Zhang, 2014). Nesse cenário, ainda existem demandas científicas sobre quais as formas de amostragens e sua combinação com modelos de predição são mais adequadas para a modelagem

espacial do P disponível no solo, especialmente para regiões agrícolas com solos subtropicais.

Diante disso, nossa hipótese é que modelos calibrados com um design amostral que considere covariáveis ambientais apresentam maior acurácia nas predições. Assim, o objetivo deste trabalho foi comparar três design's de amostragem e dois métodos de modelagem aplicados na predição espacial do P disponível no solo.

2. REVISÃO BIBLIOGRÁFICA

2.1. IMPORTÂNCIA DO SOLO E OS FATORES RELACIONADOS A SUA FORMAÇÃO

A Ciência do Solo é considerada uma disciplina em desenvolvimento que surgiu em meados do século XIX ao incorporar áreas básicas – química, física, biologia – e áreas específicas – geoestatística, hidrologia, ecologia – com o objetivo de solucionar problemas ambientais e aumentar a produção da agricultura (Hatermink, 2015). Apesar de muitos benefícios não serem quantificados, é possível encontrar na literatura artigos que demonstram o avanço da Ciência do Solo ao longo da história e a sua contribuição para o bem-estar da humanidade (Philip, 1974; Hatermink et al., 2001; Camargo et al., 2010; Brevik e Cerdà, 2017).

Hatermink (2016) faz uma revisão onde destaca a necessidade de um conceito universal para o 'solo'. Em pesquisa, o autor encontra 81 definições diferentes para este recurso descritas em livros e artigos, desde o nascimento da Ciência do Solo. Isso ocorre porque em sua essência, o seu significado é intimamente ligado ao conhecimento do pesquisador que o conceitua e a forma como o solo está inserido na sua área de atuação (Certini e Ugolini, 2013).

Considerado por muitos como o “Pai da Pedologia”, o pesquisador russo Vasily V. Dokuchaev foi responsável por criar um importante conceito do que é o solo, talvez o mais aceito e difundido até os dias atuais. Por meio de pesquisas, Dokuchaev percebeu a intrínseca conexão entre os tipos de solos e as características naturais dos seus determinados locais de ocorrência. Dessa forma, o autor afirmou que: “os solos são produtos de interações extremamente complexas dos efeitos do clima local (*c*), organismos (*o*), relevo (*r*), composição e estrutura do material de origem (*p*) e tempo (*t*)”. Em 1941, Hans Jenny formalizou o conhecimento estabelecido por Dokuchaev, ao criar um modelo que descreve os fatores relacionados à formação do solo, conhecido como CLORPT (Equação 1). Jenny (1941) adicionou reticências à fórmula admitindo que fatores ainda desconhecidos influenciam na formação dos solos e futuramente podem ser adicionados aos demais.

$$S = f(cl, o, r, p, t, \dots) \quad (1)$$

Amundson (2021) avalia a importância que o modelo descrito por Jenny (1941) tem no século XXI. Neste trabalho, o autor relata que, apesar de inúmeros livros a respeito de processos de formação do solo serem desenvolvidos ao longo dos anos, o trabalho de Jenny (1941) permanece sendo a maior referência em termos de pedologia quantitativa. Isto porque, segundo Amundson (2021), o modelo CLORPT possibilita uma reflexão sobre os processos naturais e como os humanos estão impactando os fatores de formação do solo. Para o autor, é inevitável que futuramente as atividades humanas sejam consideradas nos modelos quantitativos ligados a formação dos solos.

Apesar dos conceitos ainda indefinidos a respeito do que é o solo, é indiscutível a sua importância global e a necessidade de um ramo da ciência exclusivo para estudá-lo. Dominati et al. (2014) elencaram onze serviços ecossistêmicos os quais são extremamente influenciados pelo solo separando-os em “Serviços de Provisão”, “Serviços de Regulação” e “Serviços Culturais” (Tabela 1).

Tabela 1

Serviços ecossistêmicos que recebem contribuição do solo de acordo com Dominati et al. (2014).

Serviços de Provisão

1. Fornecimento de alimentos, madeira, fibras e energia.
2. Suporte a infraestruturas humanas e animais.

Serviços de Regulação

3. Mitigação de enchentes.
4. Filtragem de nutrientes e contaminantes.
5. Armazenamento de carbono e regulação de gases de efeito estufa.
6. Desintoxicação e reciclagem de resíduos.
7. Regulação de populações de pragas e doenças.

Serviços Culturais

8. Recreação.
 9. Estética
 10. Patrimônio geológico e arqueológico.
 11. Identidade cultural.
-

Fonte: Adaptado de Dominati et al. (2014).

Em contrapartida, o uso excessivo e imprudente deste recurso causa impactos ambientais irreversíveis, como processos erosivos, por exemplo. Apesar de se tratar de um fenômeno natural, ações antrópicas de revolvimento, desmatamento e alteração na cobertura da terra aumentam as taxas de erosão (Wallink, 1999). Segundo dados da Organização das Nações Unidas para Alimentação e Agricultura (FAO, 2015), as atividades agrícolas são desenvolvidas em apenas 11% do total da superfície terrestre. Além disso, estima-se que aproximadamente 75 bilhões de toneladas dos horizontes superficiais de solos que já foram alterados são erodidos anualmente para outras porções da paisagem. De acordo com Milliman e Farnsworth (2011), 46 bilhões de toneladas de sedimentos chegam aos oceanos, em decorrência do mau uso do solo. Conforme Yi et al. (2008), esses sedimentos possuem os mais diversos componentes que constituem o solo, como: nutrientes, metais pesados, carbono orgânico e minerais que se dissolvem e poluem os ecossistemas aquáticos.

2.2. FÓSFORO NO SOLO E SUA IMPORTÂNCIA PARA AS PLANTAS

A demanda por P cresce proporcionalmente a necessidade de produzir alimentos, pois a maioria dos solos ao redor do mundo são pobres, disponibilizam baixos teores de P para as plantas e necessitam de fertilização com insumos agrícolas (Nyborg et al., 1999). Entretanto, o P é um recurso não-renovável e, por esse motivo, é frequente tema de debate nas últimas décadas, sendo chamado de *"The Disappearing Nutrient"* (Gilbert, 2009).

Ainda, outro agravante é a alta reatividade do P no solo, uma vez que sua concentração é determinada por interações de sorção e dessorção (Wang et al., 2012). Esses processos são influenciados por particularidades de cada classe de solo, como pH, compostos amorfos de Al e óxidos de Fe, carbonato de cálcio (CaCO₃) e matéria orgânica, além da composição granulométrica e quantidade de argila presente no solo (Börling et al., 2001; Audette et al., 2016). Óxidos de Fe e Al de baixa cristalinidade apresentam área superficial específica elevada, responsáveis por grande parte da imobilização do P através de adsorção específica entre grupos hidroxila (OH) coordenados por íons de Fe e íons de fosfato (Borggaard, 1990; Schwertmann et al., 1986).

O P é extremamente necessário para as plantas, contribuindo para o seu crescimento celular, metabolismo, formação de moléculas de energia (como ATP, por exemplo), formação de frutos e sementes, sendo essencial em todos os estágios de desenvolvimento, desde a germinação até a maturidade (Razaq et al., 2017). Apesar deste elemento ser encontrado em abundância no meio ambiente, somente uma parcela inorgânica solúvel é possível de ser absorvida pelas plantas. As demais formas existentes de P permanecem biologicamente indisponíveis (Cordell, 2010).

A adoção da agricultura de precisão possibilitou ao agricultor resolver problemas ligados à fertilidade utilizando mapas temáticos de uma propriedade de interesse no solo. Para isso se fez necessário também, o desenvolvimento de maquinário e de tecnologias que apliquem insumos em taxa variável, agindo diretamente sobre a variabilidade espacial do solo (Werner et al., 2007). Esses mapas temáticos são gerados a partir de um conjunto de amostras que precisa ser representativo de toda a área em questão (McBratney et al., 2003). Assim, se faz necessário o conhecimento de métodos de amostragem capazes de expressar, com precisão, o teor de P disponível para as plantas, pois isso servirá como informação para que seja aplicado somente a dose necessária em cada local.

Durante décadas, pensava-se que o processo natural de conversão do P em formas indisponíveis para as plantas fosse irreversível. Porém, com o enfrentamento da problemática acerca do assunto, atualmente é possível afirmar que o processo de imobilização do P no solo é reversível, e assim, tornando-o novamente disponível para as plantas (FAO, 2008). Do ponto de vista agrônomo, significa dizer que o solo atua como um reservatório de P, e as plantas podem utilizar esse nutriente provido de fertilizações realizadas em anos anteriores (Cordell, 2010). Esse fato auxilia a entender e otimizar o manejo de adubações contendo P, pois além deste ser um recurso não-renovável, os fertilizantes são potenciais poluentes do ambiente e de corpos d'água (McDowell et al., 2015).

O uso equivocado de fertilizantes tem sido frequentemente associado à contaminação e a baixa qualidade de fontes de água (Mateo-Sagasta e Burke, 2015). Segundo McDowell et al. (2003), isso ocorre principalmente pela aplicação exagerada de insumos nos solos, tornando-os excessivamente

enriquecidos em P e conseqüentemente, incapazes de reter todas as partículas de nutrientes. O excesso de P nos solos aumenta a quantidade erodida deste nutriente por escoamento superficial, o que é potencializado por práticas agrícolas inadequadas e sistemas de plantio convencional, como por exemplo: ausência de cobertura vegetal, compactação por máquinas e/ou animais e falta de terraços (McDowell et al., 2015).

2.3. MAPEAMENTO DIGITAL DE SOLOS

O mapeamento digital de solos (MDS) vêm se tornando uma ramificação de sucesso na Ciência do Solo (Minasny e McBratney, 2016). Ao colocar as palavras-chave “digital”, “soil” e “mapping” no portal de busca de periódicos Scopus é possível observar o crescimento constante da temática nos últimos anos conforme aumentam o número de documentos publicados (Figura 1). No total foram encontrados 3000 mil documentos, desde 1975, ano em que foram encontrados 2 trabalhos, até 2020, quando foram encontrados 334 trabalhos.




Fig. 1. Número de postagens de documentos na plataforma Scopus utilizando como busca as palavras-chave “digital”, “soil” e “mapping”.

Também na plataforma de periódicos Scopus foram encontrados 249 documentos publicados no Brasil entre o ano de 1990 e 2020, e 585 documentos nos Estados Unidos (EUA) (Figura 2). Em ambos os países se nota o avanço da

temática com o passar do tempo, apesar de que no Brasil, a evolução é modesta em comparação aos EUA. Para Mendonça-Santos e Santos (2007) o principal motivo disso ocorrer é a dificuldade de encontrar dados de solo no Brasil. Para os autores, é necessário um órgão público que reúna os dados de solos existentes e sistematize todos de forma universal. Assim, técnicas como mapeamentos com áreas de referência (Lagacherie et al., 1995) e funções de pedotransferência podem ser utilizados para mapear grandes áreas e propriedades normalmente não encontradas em relatórios tradicionais de solo.




Fig. 2. Número de postagens de documentos na plataforma Scopus utilizando como busca as palavras-chave “*digital*”, “*soil*” e “*mapping*”. Brasil como país afiliado (a); Estados Unidos como país afiliado (b).

O Repositório Brasileiro Livre para Dados Abertos do Solo (FEBR, www.ufsm.br/febr) foi criado recentemente com o objetivo de organizar e otimizar o uso dos dados gerados em pesquisas de diferentes locais no Brasil, e também incentivar os pesquisadores a compartilharem essas informações. Este recurso irá tornar possível a execução de inúmeros trabalhos, auxiliando, em especial, os pesquisadores brasileiros a desenvolverem nacionalmente os temas que envolvem o MDS.

Segundo Lagacherie e McBratney (2006) o MDS é definido como “a criação e população de sistemas de informação espacial do solo por modelos numéricos que inferem as variações espaciais e temporais dos tipos e classes de solo a partir da observação do solo e do conhecimento de variáveis ambientais relacionadas”. O surgimento de mais pesquisas na área pode ser explicado por alguns fatores. O primeiro é a necessidade de ter mapas acurados, pois mapas de solos produzidos por métodos convencionais muitas vezes não estão em escalas detalhadas e apresentam problemas de imprecisão quanto aos limites espaciais de propriedades e classes de solo (McBratney et al., 2003). De

acordo com Grunwald et al. (2011), os levantamentos convencionais são trabalhosos, caros e demorados. O segundo fator é o avanço da tecnologia que possibilitou o surgimento de computadores robustos e facilitou a obtenção de geoinformações (Zhang et al., 2017).

Usando como base os fatores de formação descritos por Dokuchev e o modelo CLORPT (Equação 1) criado por Jenny (1941), McBratney et al. (2003) desenvolveram o SCORPAN (Equação 2), um novo modelo capaz de realizar a predição de classes de solo ou propriedades por meio de uma função de predição espacial. No SCORPAN houve a adição de dois fatores, e assim, o solo passou a ser uma função do próprio solo (s); do clima (c); dos organismos (o); do relevo (r); do material de origem (p); do tempo (a); e das coordenadas geográficas das observações (n). Várias décadas se passaram desde a criação do CLORPT, porém, McBratney et al. (2003) mantiveram as reticências na equação, sugerindo que outros fatores podem ser adicionados no futuro.

$$S = f(s, c, o, r, p, a, n, \dots) \quad (2)$$

Pensando em quantificar a influência da antropização na formação dos solos, Grunwald et al. (2011) sugeriram uma equação que adiciona, por exemplo, a contaminação causada por atividades humanas (Equação 3). Este modelo ficou conhecido como STEP-AWBH, em que a propriedade do solo (SA) é uma função do próprio solo (S); de atributos topográficos (T); de propriedades geológicas e geográficas (E); do material de origem (P); de propriedades atmosféricas (A ; exemplo: radiação, temperatura, precipitação); de propriedades ligadas a água (W ; exemplo: escoamento superficial, infiltração); de propriedades bióticas (B ; exemplo: modificação da cobertura da terra, vegetação, organismos); e consequências antrópicas (H ; exemplo: emissão de gases do efeito estufa, contaminações do solo).

$$SA = (S, T, E, P, A, W, B, H) \quad (3)$$

2.4. AMOSTRAGEM NO MAPEAMENTO DIGITAL DE SOLOS

Em qualquer área da ciência, a coleta de dados é a etapa mais crucial, visto que irá interferir em todas as etapas seguintes do projeto (Schmidt et al., 2014). Assim, de Gruijter et al. (2006) discutem no livro *Sampling for Natural Resource Monitoring* os principais conceitos que norteiam os métodos de amostragem no MDS. Os seguintes parágrafos foram redigidos tendo este livro como base principal. Esses autores distinguem três modos de selecionar locais de amostragem: por conveniência, probabilística ou proposital. A amostragem por conveniência é utilizada em casos onde há dificuldade de acesso e locomoção na área a ser mapeada, e o mapeador é obrigado a limitar suas coletas nas proximidades de estradas ou locais de fácil acesso. Este tipo de amostragem é barato e rápido de ser realizado, entretanto tem menor valor estatístico.

A amostragem proposital engloba os métodos utilizados nesse presente estudo. Trata-se de desenhos amostrais que tentam selecionar os pontos de maneira que um propósito seja atendido da melhor forma. Por exemplo, quando se planeja realizar um mapa por krigagem, um grid regular ou uma amostragem de cobertura espacial podem reduzir a variância do erro de predição. Da mesma forma, quando a intenção é utilizar covariáveis ambientais na predição, considerá-las no desenho amostral pode ser benéfico. No caso da amostragem proposital, é preciso saber qual modelagem preditiva será utilizada para atender seu critério desde a coleta dos dados.

Por fim, a amostragem de probabilidade, ao contrário dos modos anteriores, seleciona os pontos de forma aleatória. de Gruijter et al. (2006) destacam a importância de conhecer as probabilidades de seleção dos pontos amostrais, pois isso serve como base para a inferência estatística dos dados.

Recentemente, Brus (2019) fez uma revisão dos métodos de amostragem descritos por de Gruijter et al. (2006), complementando com o progresso conquistado na última década. Brus (2019) argumenta que o termo “probabilístico” é corriqueiramente utilizado de forma errada em trabalhos de amostragem encontrados na literatura. Isso porque para ser probabilística deve atender a dois critérios essenciais: o primeiro é que todos os locais na área a ser mapeada devem ter probabilidade positiva de serem selecionados, nenhuma

parte da população pode ser excluída; o segundo é que a probabilidade de seleção de cada ponto deve ser conhecida. Todas as demais formas de amostragem que não atendem a esses requisitos são tratadas pelo autor como “amostragens não-probabilísticas”, caso inerente ao grid regular e otimizações (Conditioned Latin Hypercube Sampling (cLHS), por exemplo).

A etapa de amostragem geralmente é cara e trabalhosa. Portanto, é preciso que o método de amostragem utilizado seja eficiente e atenda às necessidades do projeto. No entanto, segundo Heuvelink et al. (2006) um conflito se estabelece nos esquemas de amostragem, pois não há como um desenho amostral beneficiar igualmente ambas as abordagens de mapeamento existentes (determinística e geoestatística). Modelos determinísticos geralmente se beneficiam de amostras que captam a relação entre a propriedade do solo e as covariáveis ambientais, enquanto modelos geoestatísticos apresentam melhores resultados quando calibrados a partir de formas de amostragem que distribuam de maneira mais uniforme os pontos no espaço geográfico (Hengl et al., 2003). Porém, é difícil estimar o peso que cada um desses requisitos tem, e além disso, o quanto as características de cada área influenciam esses pesos (Heuvelink et al., 2006).

Com o objetivo geral de melhor representar a variabilidade espacial dos atributos e classes de solo em um conjunto limitado de amostras, soluções têm sido propostas para o MDS, como: cLHS (Minasny e McBratney, 2006); cobertura do espaço por k-means (Brus et al., 2007); amostragem Kennard-Stone (Kennard e Stone, 1969); amostragem de superfície de resposta (Lesch, et al., 1995); amostragem por recozimento simulado espacial (Samuel-Rosa, 2016), entre outros. Para a escolha do melhor método, Wadoux e Brus (2020) sugerem comparar amostragens utilizando índices de qualidade (estatísticas de erro). Entretanto, os autores enfatizam a importância de ter um banco de dados independente e aleatório para a validação.

3. MATERIAL E MÉTODOS

3.1. ÁREA DE ESTUDO

Este estudo foi realizado em uma área de produção agrícola de 160 hectares (ha) localizada no município de Tupanciretã, região norte do Estado do Rio Grande do Sul, Brasil (Fig. 1).

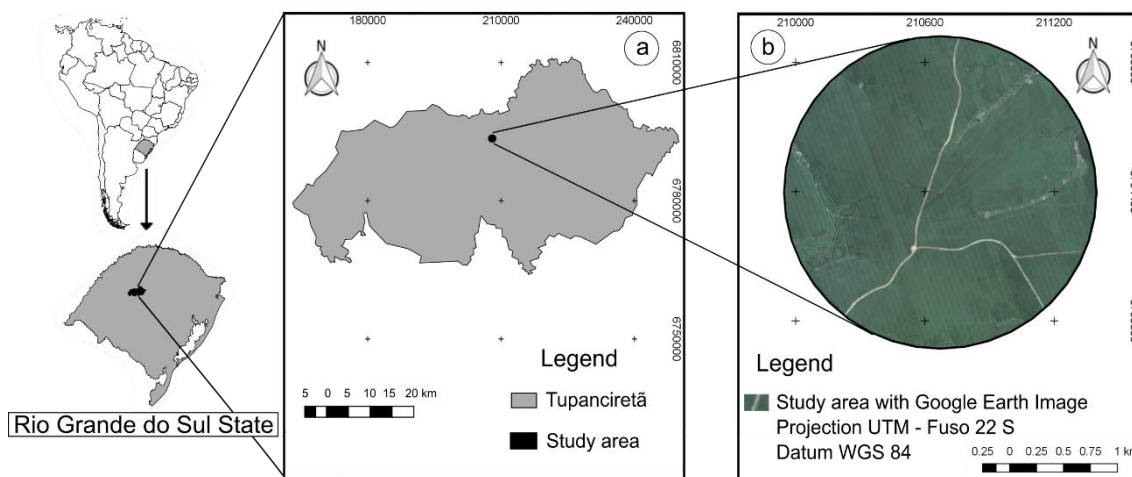


Fig. 1. Localização da área de estudo no município de Tupanciretã, RS, Brasil (a); Indicação detalhada área de estudo (b).

Na área ocorrem os seguintes grupos de solos: Nitisols, Regosols, Leptsols, Cambisols e Planosols (Fig. 2b) (Soligo, 2021). O mapa de solos (Fig. 2b) foi utilizado para analisar dados de distribuição de P em cada classe de solo. A área possui sistema de irrigação por meio de pivô central. Devido a ocorrência de solos rasos, Leptsols (~45%), os quais apresentam retenção de água limitada, a irrigação das culturas é feita diariamente em períodos de estiagem. O clima da região é subtropical úmido com verões quentes (Cfa) e temperatura média acima de 22°C (Alvares et al., 2013). A geologia da região é constituída por rochas vulcânicas básicas, intermediárias e ácidas da Formação Serra Geral (Wildner et al., 2008). A altitude da área varia entre 430 e 500 m com média de 480 m (Fig. 2a). O relevo varia entre plano a suave ondulado e ondulado. A cobertura da terra é composta por lavouras anuais (milho (*Zea mays* L.) e soja (*Glycine max* L.) no verão; trigo (*Triticum sativum* L.), aveia (*Avena sativa* L.) e nabo (*Brassica rapa* L.) no inverno) manejadas sob sistema de plantio direto.

Algumas atividades de agricultura de precisão são desenvolvidas na área de estudo. O proprietário da área realiza aplicações de calcário, e também de adubos em taxa variável conforme indicação de mapas de produtividade e teores de nutrientes providos de análises de solo. Por aproximadamente vinte anos, a aplicação de P nesta área ocorreu na linha de semeadura. Entretanto, mais recentemente, o produtor optou por aplicar este nutriente a lanço em toda a área.

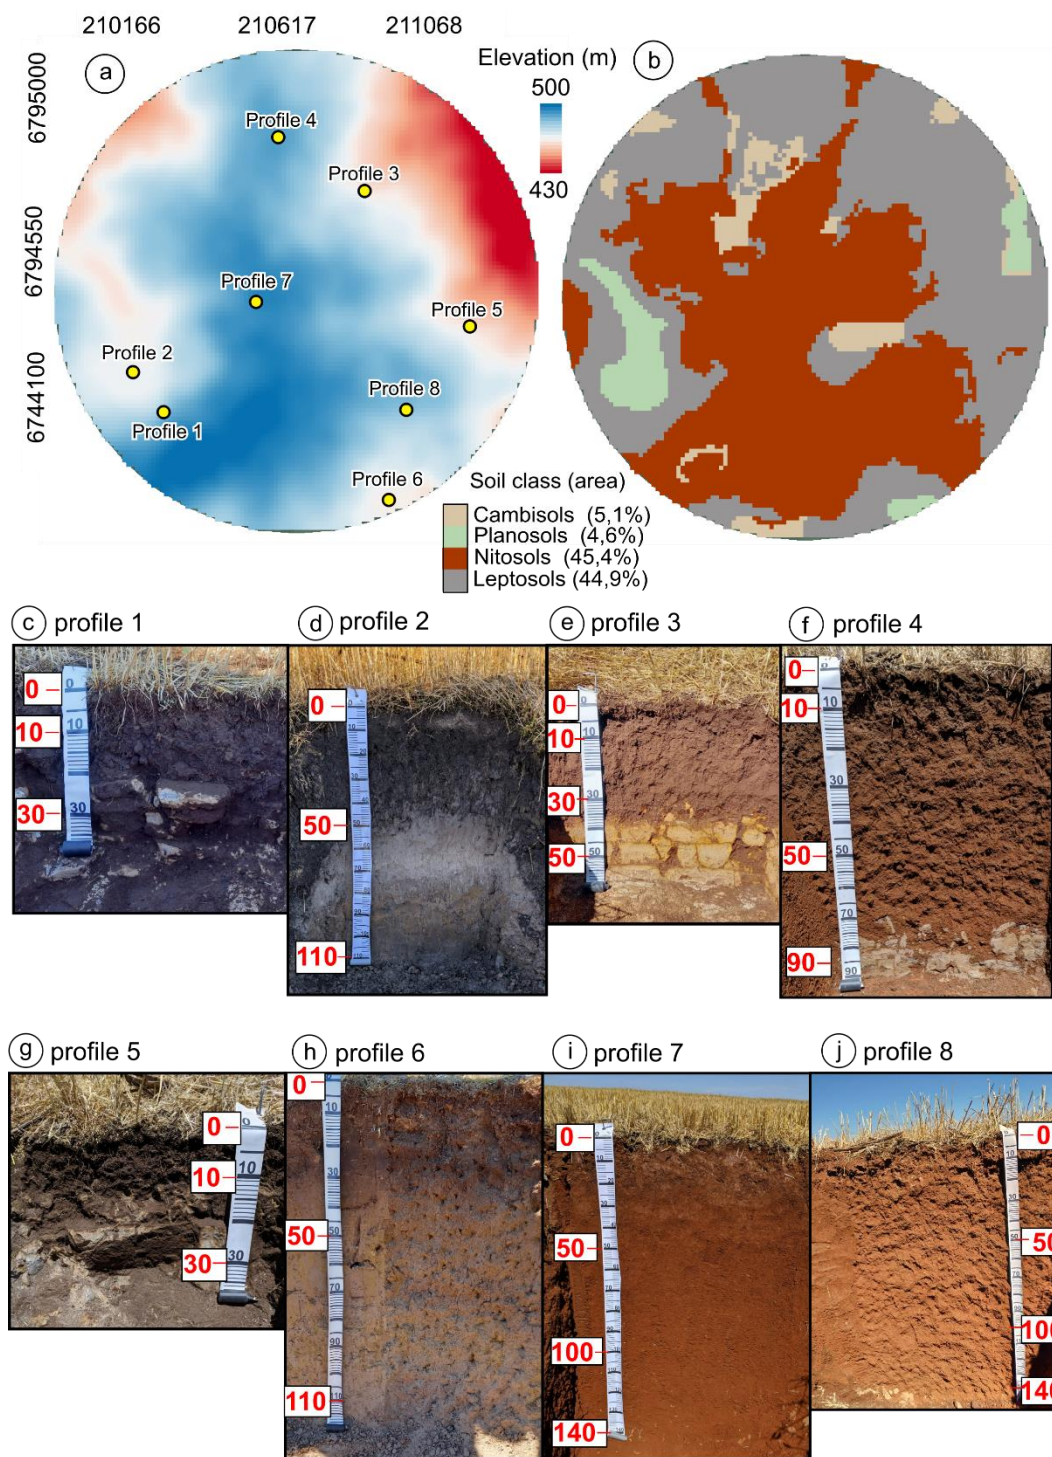


Fig. 2. Distribuição dos perfis descritos na área de estudo com imagem da elevação (ELEV) ao fundo, conforme mapa realizado por Soligo (2021) (a); mapa temático das classes de solo (b); e fotos dos perfis com profundidade em centímetros: perfil 1 (c); perfil 2 (d); perfil 3 (e); perfil 4 (f); perfil 5 (g); perfil 6 (h); perfil 7 (i); e perfil 8 (j).

3.2. OBTENÇÃO DE COVARIÁVEIS DO TERRENO

Os atributos do terreno que representam o relevo foram derivados do digital elevation model (DEM) gerado pelo *Advanced Land Observing Satellite* (ALOS) com resolução de 12.5 x 12.5 m. Um total de 16 atributos do terreno foram calculados no software *System for Automated Geoscientific Analysis - SAGA GIS* (Olaya, 2004). Os atributos do terreno com alto grau de correlação ($r > 0.7$) foram desconsiderados e os selecionados são apresentados na Tabela 1. Foi priorizado o fator “ r ” do modelo *Scorpan* (McBratney et al., 2003) para a seleção de atributos a serem utilizados, por dois motivos: fácil acesso à informação, e falta de dados disponíveis na área de estudo em alta resolução que representem os demais fatores.

Tabela 1

Covariáveis de terreno.

Variable origin	Variable predictor	Unity	Abreviation	Mean (range)
DEM	Basic drainage level	m	BDL	463 (436 - 486)
	Drainage network distance	m	DND	14.48 (0 - 43.51)
	Elevation	m	ELEV	478 (436 - 499)
	LS factor	-	LS	0.83 (0 - 4.92)
	Relative slope position	%	RSP	0.66 (0 - 1)
	Topographic wetness index	-	TWI	7.30 (4.78 - 19.28)
	Valley depth	m	VD	6.32 (0 - 25.11)
	Vertical distance drainage network	m	VDDN	30.60 (0.15 - 48.94)

m = meters; - = dimensionless

3.3. DESIGN DE AMOSTRAGEM

Três bancos de dados foram obtidos, cada um derivado de um design de amostragem diferente. Cada banco de dados foi composto por 160 pontos amostrais, resultando na densidade amostral de um ponto por hectare. Um quarto método de amostragem gerou um banco de dados de validação, composto por 50 pontos, o qual foi utilizado na etapa de validação externa das predições espaciais. Detalhes sobre os designs amostrais são descritos abaixo. Todos os métodos de amostragem foram implementados no ambiente R (R Core Team, 2020).

3.3.1. Grid regular - RG

O primeiro método de amostragem é um regular grid simples com distâncias iguais entre pontos vizinhos (100 x 100 m). Este método é popularmente utilizado para ajuste de variograma e predição espacial de propriedades e atributos do solo por empresas de agricultura de precisão (Cherubin et al., 2014) e em trabalhos acadêmicos, pois proporciona maior praticidade de coleta uma vez que os locais de amostragem estão dispostos em linha reta (Fig. 3a).

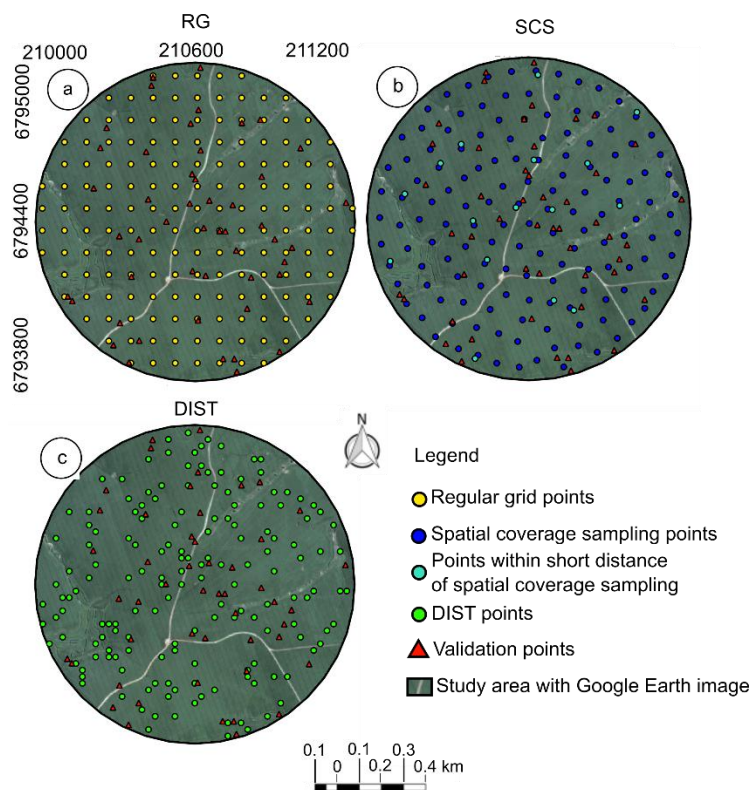


Fig. 3. Distribuição espacial dos pontos de calibração e pontos de validação. RG e validação (a); Spatial coverage sampling e validação (b); DIST e validação (c).

3.3.2. *Spatial Coverage Sampling* - SCS

O segundo design de amostragem flexibiliza um RG tornando seu padrão de distribuição espacial irregular (Fig. 3b), a fim de minimizar a Mean squared shortest distance (MSSD) entre os pontos (Eq. 1). O algoritmo utilizado para isso foi o *k-means* que inicialmente une as células raster em clusters de forma aleatória. Posteriormente, as células raster são realocadas de um cluster para outro considerando a maior proximidade dos valores das coordenadas geográficas X e Y com a média do cluster. Essa interação acontece repetidas vezes, e é interrompida quando o MSSD não pode ser mais reduzido. Em seguida, o centróide é definido como o local a ser amostrado no campo. Uma explicação abrangente do MSSD e *k-means* é fornecido por Brus et al. (2007) e Walvoort et al. (2010).

$$\text{MSSD} = \frac{1}{N} \sum_i^N \min_j (D_{ij}^2) \quad (1)$$

em que N é o número de células raster e $\min_j (D_{ij}^2)$ o mínimo da distância quadrada entre a última célula do conjunto (i) e os centróides dos agrupamentos.

Este método de amostragem foi gerado por meio do pacote 'spcosa' (Walvoort et al., 2010), empregando a função "Sample". Foram reservados 10% do número total de pontos amostrais para serem alocados a curtas distâncias. Neste estudo foi utilizado a distância de 20 metros entre os pontos conforme metodologia descrita por Wadoux et al. (2019) (Fig. 3b).

3.3.3. *Spatial simulated annealing* - DIST

O terceiro design de amostragem seleciona os locais de coleta de forma que os pontos representem a distribuição marginal das covariáveis no histograma (DIST; Fig. 3c). Para esse processamento, as covariáveis utilizadas foram: ELEV, VD, RSP, LS, TWI e BDL. Essas covariáveis foram selecionadas por meio de *Principal component analysis* (PCA) a partir do conjunto total de covariáveis (Table 1), e também utilizando o conhecimento do especialista, conforme sugerido por McKenzie e Ryan (1999). Para que a seleção dos pontos

de amostragem seja considerada confiável, a função *objective* (obj) deve chegar a um estado de energia estável por várias interações. No caso deste estudo, houve a estabilização em aproximadamente 100 mil interações ou “jitters”. O processamento ocorreu por meio do pacote ‘spsann’ (Samuel-Rosa, 2016).

3.3.4. Validação externa

O método de validação empregado neste estudo utiliza um banco de dados independente, gerado de forma aleatória e estratificada. Segundo Brus et al. (2011), este tipo de validação é necessário para garantir a qualidade das métricas de acurácia dos mapas. Para gerar a aleatorização dos pontos na paisagem, foi utilizado como estrato o mapa de classes de declividade. Desta forma, a área ficou dividida em 3 classes de declividade, sendo os pontos alocados em cada classe (Tabela 2).

Tabela 2

Distribuição dos pontos do conjunto de validação externa nas três classes de declividade

Slope class*	Slope (%)	Area (ha)	Validation points
Plan	0 a 3	13	5
Smooth wavy	3 a 8	64	18
Wavy	8 a 20	83	27

* Classes de declividade conforme intervalos propostos no Sistema Brasileiro de Classificação de Solos (Santos et al., 2018).

3.4. OBTENÇÃO DE DADOS ANALÍTICOS DO SOLO

Em todos os pontos de amostragem foram coletadas amostras de solo na profundidade de 0-10 cm. As amostras foram secas, destorroadas e passadas em peneiras de 2 mm. O teor de P disponível foi extraído por meio do extrator Mehlich-1 e determinado por espectrofotometria à 882 nm, seguindo a metodologia preconizada por Teixeira et al. (2017). Além do teor de P disponível, foi determinada a granulometria do solo (frações areia, silte e argila) devido a

sua forte relação com a capacidade de troca aniônica e teor de P disponível no solo. A granulometria foi determinada pelo método da pipeta com dispersão química com solução de NaOH 1 mol L⁻¹ e agitação mecânica, conforme Teixeira et al. (2017). A classificação textural dos pontos amostrais foi realizada por meio de triângulo textural gerado para cada método de amostragem utilizando o pacote 'soiltexture' implementado no R por Moeys (2018).

3.5. MODELAGEM ESTATÍSTICA ESPACIAL

Dois métodos de predição espacial foram testados na predição espacial do P disponível: ordinary kriging (OK) e kriging with external drift (KED). O primeiro é amplamente utilizado no desenvolvimento de mapas de propriedade do solo para fins de agricultura de precisão (Cherubin et al., 2014; Shen et al., 2019). O segundo é indicado quando existem fatores externos que influenciam na variabilidade da propriedade do solo alvo do estudo, conforme a Equação Universal de Distribuição de Solos (Burrough, 1986) (Eq. 2).

$$Z = Z^* + \varepsilon' + \varepsilon'' \quad (2)$$

em que Z é o valor predito da variável alvo; Z^* é o componente determinístico do modelo; ε' é o componente stochastic or geoestatistical do modelo; e ε'' é o erro associado às predições.

A OK utiliza somente a parte estocástica da equação para diminuir a variância do erro, enquanto que a KED inclui uma ou mais funções de deriva externa (fatores de formação do solo) admitindo que parte da variância pode ser explicada por elas (Webster e Oliver, 2007). Assim, sabendo da existência de variabilidade pedológica na área, a qual é condicionada pela variação dos atributos do terreno, os mesmos foram adicionados como deriva externa no modelo KED.

O pacote 'georob' (Papritz, 2020) foi utilizado na implementação dos modelos no R (R Core Team, 2020). Foi constatada distribuição não-normal dos dados de P disponível pelo teste Shapiro-Wilk ($\alpha = 0.05$). Diante disso, o argumento turning.psi do georob foi ajustado para 2, o qual considera a média

ponderada entre o valor da mediana e o valor médio dos dados para realizar as predições. Os parâmetros iniciais de interpolação (efeito pepita, variância e alcance) foram definidos conforme o semivariograma experimental e posteriormente estimados por meio do algoritmo Máxima Verossimilhança Restrita (REML), por ser um método eficiente para estimar parâmetros de modelos lineares (Marchant e Lark, 2007). Posteriormente foi realizada a predição espacial do P disponível.

3.6. AVALIAÇÃO DA ACURÁCIA DAS PREDIÇÕES

A avaliação da qualidade das predições foi feita a partir do pacote hydroGOF (Zambrano-Bigiarini, 2020) e com as seguintes estatísticas: root mean squared error (RMSE) (equação 3), mean error (ME) (equação 4), mean absolut error (MAE) (equação 5) e Nash-Sutcliffe efficiency (NSE) (equação 6; Moriasi et al., 2007).

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (3)$$

$$ME = \frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j) \quad (4)$$

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (5)$$

$$NSE = 1 - \left(\frac{\sum_{j=1}^n (y_j - \hat{y}_j)^2}{\sum_{j=1}^n (y_j - \bar{y})^2} \right) \quad (6)$$

em que \hat{y} é o valor predito; y é o valor observado; \bar{y} é o valor médio observado; n é o número de amostras com $j = 1, 2, 3, \dots, n$, e $\alpha(s_j)$ é um indicador definido da seguinte forma:

4. RESULTADOS

4.1. CARACTERIZAÇÃO DOS DADOS DE P DISPONÍVEL

Segundo Shapiro-Wilk, os bancos de dados de cada método de amostragem utilizados neste estudo não possuem distribuição normal para os teores de P a 5% de probabilidade (Fig. 4). A mediana e média das amostras do RG foi de 37,1 e 48,8 mg dm⁻³, respectivamente, com amplitude variando de 4,7 a 220,4 mg dm⁻³ (Fig. 4a). Os teores de fósforo da amostragem SCS apresentaram mediana de 23,8 mg dm⁻³ e média de 30,7 mg dm⁻³, onde a amplitude variou entre 2,3 a 164,4 mg dm⁻³ (Fig. 4b). O último banco de dados contendo teores de P pela amostragem DIST apresentaram mediana e média de 22,5 e 30,3 mg dm⁻³, respectivamente, com amplitude entre 2,4 e 171,7 mg dm⁻³ (Fig. 4c). Os coeficiente de variação (CV) para o RG, SCS e DIST foram 84%, 85% e 81%, respectivamente.

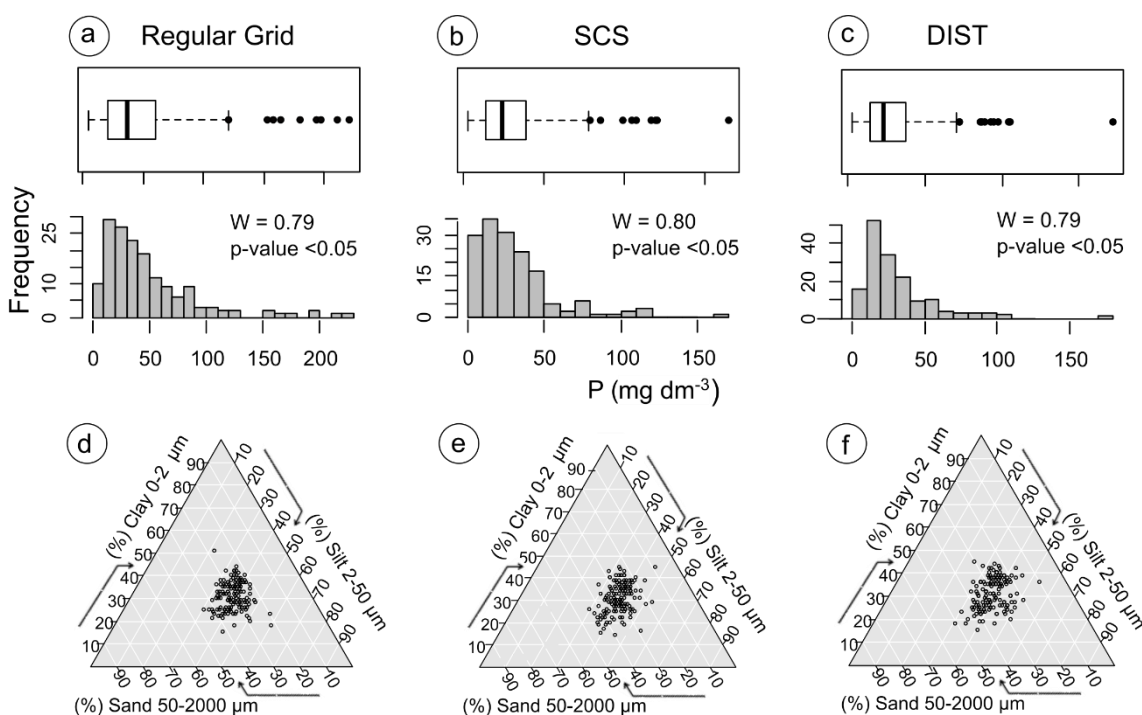


Fig. 4. Análise exploratória dos bancos de dados contendo histograma, boxplot e triângulo textural. Teores de P do RG (a); teores de P da SCS (Spatial Coverage Sampling) (b); teores de P da amostragem DIST (Spatial simulated annealing)(c); triângulo textural com amostras do RG (d); triângulo textural com amostras da SCS (e); e Triângulo textural com amostras da DIST (f). W = desvios de normalidade.

Os três métodos de amostragem resultaram em uma estimativa parecida da granulometria do solo na área de estudo (Fig. 4d, 4e, 4f). A textura das amostras se enquadram entre as classes franca, argila e francoargilosa, onde os teores da fração argila variam de aproximadamente 20 a 60%.

Ao relacionar o mapa de classes de solo (Soligo, 2021) com os mapas de P disponível foi possível obter a estatística descritiva para cada uma das classes de solo encontradas na área (Tabela 3). Observou-se que as classes de solo com maior média de teor de P disponível foram o Leptosols, Nitosols e Cambisols, e as menores médias foram encontrados para o Planosols. Além disso, é possível observar menor CV nos teores de P disponível quando subdivididos por classes de solo (Tabela 3) em comparação com os CV's obtidos dos bancos de dados de cada método de amostragem. Os teores médios de argila foram superiores nos solos mais desenvolvidos como Nitosols e Planosols. Já o teor médio de Fe_0 foi maior nos Nitosols e Cambisols, intermediário nos Leptosols e menor nos Planosols. Os maiores teores de P disponível ocorrem em grupos de solos com maior teor de Fed (Tabela 3).

Tabela 3

Estatística descritiva referente aos valores de P disponível para cada classe de solo encontrada na área.

Soil class	P mg dm ⁻³						Clay mean %	Fed g kg ⁻¹
	Mean	Minimum	Maximum	Amplitude	SD	CV (%)		
Nitosol	30,4	12	55	43	7,2	24	32,1	35.7
Leptosol	31,3	9	58	49	9,3	30	28,6	27.5
Cambisol	29,1	11	53	42	9,1	31	28,7	29.7
Planosol	24,5	4	48	44	7,3	24	30,4	20.3

SD = Standart deviation; CV = Coefficient of variation; Fed= teor de ferro extraído por ditionito.

4.2. AJUSTES DE MODELOS

O modelo ajustado por REML capturou estrutura da variabilidade espacial nos teores de P disponível dos três métodos de amostragem (Fig. 5). O modelo esférico promoveu o melhor ajuste em todos os casos.

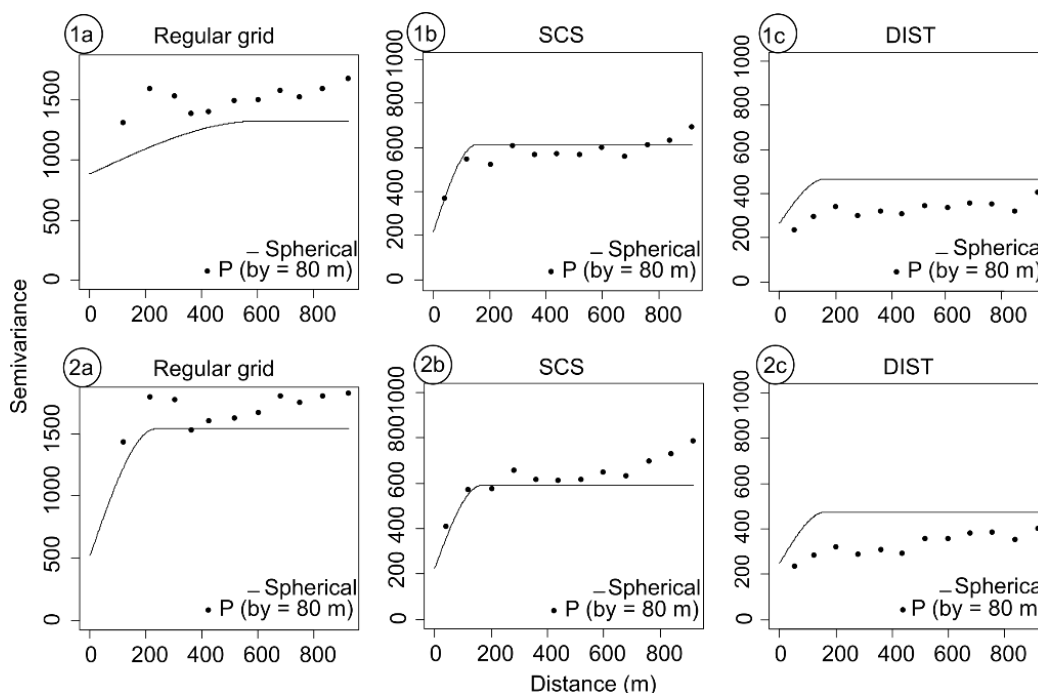


Fig. 5. Semivariogramas ajustados por Máxima Verossimilhança Restrita (REML) para os teores de P disponível nos diferentes métodos de amostragem, no qual: 1 = predição por KED; 2 = predição por OK; a = RG; b= SCS (Spatial Coverage Sampling); e c = DIST (Spatial simulated annealing).

O ajuste por REML não considera o experimental semivariogram, e sim, todos os pares de pontos que existem (Marchant e Lark, 2007). Por esse motivo é possível observar na figura 5 a linha de alguns ajustes passarem distantes dos par de pontos médios naquela determinada distância (80 metros). Em outras palavras, o ajuste ocorreu utilizando outros pares de pontos do banco de dados.

Os Graus de dependência espacial (DSD) encontrados nos ajustes foram moderados, conforme classificação proposta por Cambardella et al. (1994) (Tabela 4). No geral, os ranges variaram de 150 a 600 m aproximadamente, sendo que os maiores valores foram encontrados para o RG. Entretanto, o nugget também foi maior para o RG, indicando maior variância não explicada de curto alcance em relação aos outros dois métodos de amostragem.

A amostragem SCS e DIST apresentaram valores próximos quanto aos parâmetros do semivariograma. Além disso, o tipo de krigagem teve maior efeito nas amostras provenientes do grid regular (Tabela 4). De modo geral, a KED dobrou o SDI, passando de 33 na OK para 66 no KED. O efeito pepita aumentou de 522 m na OK para 884 m na KED, a variância explicada passou de 1016 para 442 e o alcance diminuiu cerca de 400 metros (Tabela 2). Para os dados de SCS, o nugget e o alcance na OK foram reduzidos em KED detrimento do aumento da

variância explicada e do SDI. O oposto aconteceu para os dados de DIST, em que a variância explicada diminui, junto com o DSI (Tabela 4).

Tabela 4

Parâmetros de ajuste dos modelos esféricos de cada método de amostragem, ajustados por REML para os teores de P disponível no solo.

Model	Sampling	Parameters			SDI (%)	DSD
		Nugget	Variance	Range (m)		
KED	RG	884.3	442.4	611.1	66.6	M
KED	SCS	217.7	393.3	151.9	35.6	M
KED	DIST	265.7	201.2	163.3	56.9	M
OK	RG	522.7	1016.4	234.9	33.9	M
OK	SCS	227.0	362.9	164.2	38.4	M
OK	DIST	250.2	224.8	163.5	52.6	M

SDI = Spatial dependence index; DSD = Degree of spatial dependence; KED = krigagem com deriva externa; OK = krigagem ordinária; SCS = Spatial Coverage Sampling; DIST = Spatial simulated annealing.

4.3 PREDIÇÃO ESPACIAL E ESTATÍSTICAS DE AVALIAÇÃO DE ACURÁCIA

Os mapas de P disponível mostram que existe dissimilaridade entre as predições espaciais derivadas de cada método de predição e designer de amostragem (Fig. 6). Os mapas gerados a partir do RG para os dois modelos de predição apresentaram maiores valores de P disponível, onde se observa sítios com teores de P maiores que 100 mg dm^{-3} (Fig 6) comparado ao demais métodos de amostragem. O maior efeito do modelo para o RG (parâmetros) se refletiu no mapa, que apresenta áreas grandes e bem definidas de teor alto de P. Esse efeito foi consideravelmente suavizado na KED.

Apesar da SCS e DIST resultarem em mapas parecidos em ambos os modelos, a SCS pareceu ser mais afetada pelo modelo, principalmente pelo aumento do alcance. Além disso, as covariáveis parecem ter um controle maior em SCS do que nos outros – observado pelos diferentes sítios com concentrações altas e baixas de P (reflexos dos atributos do terreno) formados no mapa (Fig. 6).

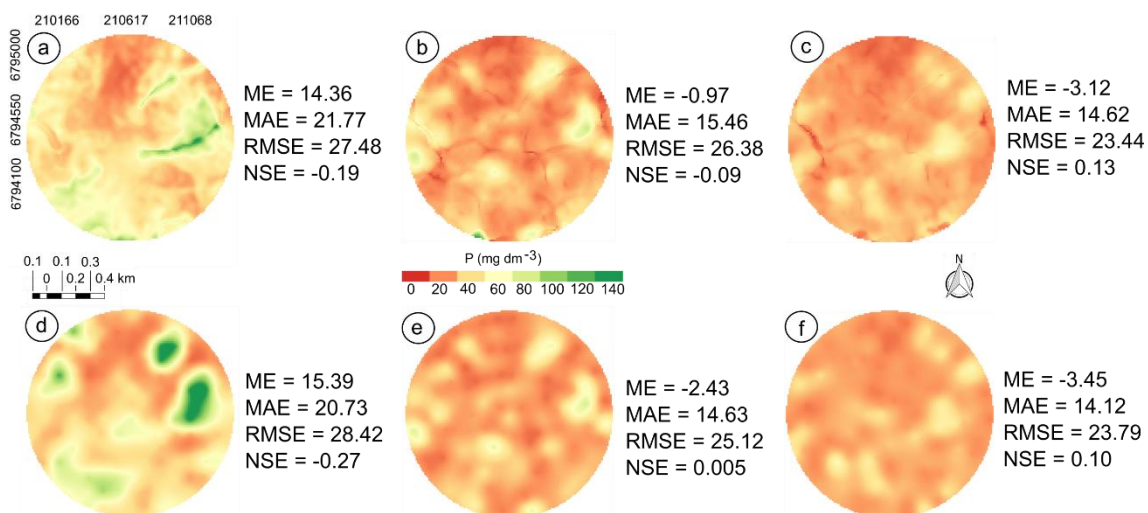


Fig. 6. Espacialização do teor de P disponível nos diferentes métodos de amostragem. RG combinado com KED (a); SCS combinado com KED (b); DIST combinado com KED (c); RG combinado com OK (d); SCS combinado com OK (e); DIST combinado com OK (f). ME = mean error (mg dm⁻³); MAE = mean absolute error (mg dm⁻³); RMSE = root mean squared error (mg dm⁻³); e NSE = Nash-Sutcliffe efficiency (adimensional).

O mapa gerado com o designer amostral DIST apresentou os menores erros (ME, MAE e RMSE), e maior eficiência do modelo (NSE) em comparação aos outros métodos de amostragem, em ambos os modelos preditivos (Fig. 6). Em contrapartida, a amostragem por RG retornou previsões menos acuradas, com erros maiores e eficiência baixa do modelo. A amostragem SCS apresentou resultados intermediários, sendo superior em relação ao RG, mas inferior a amostragem DIST, que utiliza covariáveis.

Ao comparar as combinações entre modelos de previsão e design's de amostragem, a pior combinação foi o modelo OK com o design amostral RG, enquanto a melhor combinação foi o modelo KED com o design amostral DIST (Fig. 6). A amostragem RG superestimou muito os dados (ME = 15 e 14 mg dm⁻³). Os demais métodos de amostragem subestimaram levemente, (ME entre 0 e -3 mg dm⁻³). Em relação aos métodos de amostragem, o RMSE e MAE foram mais alto na RG e menores na DIST. Enquanto a OK foi ligeiramente superior a KED para SCS, para RG aconteceu o contrário, a KED foi levemente melhor. Entretanto, o tipo de krigagem parece não ter efeito para a amostragem DIST (métricas praticamente iguais em OK e KED).

5. DISCUSSÃO

Os conjuntos de dados de P disponível para o RG, SCS e DIST apresentaram CV muito alto, (maiores que 65%) conforme o critério estabelecido por Vanni (1998) sendo de 84%, 85% e 81%, respectivamente, indicando elevada heterogeneidade. Essa variação está relacionada ao fato do P disponível ter baixa mobilidade no solo, sendo isso maximizado em condições de solos com variação nos teores de argila e óxidos de ferro (Mallarino e Wittry, 2004; Nanni et al., 2011; Sana et al., 2014). Somado a isso, o histórico de manejo da área, como a correção e a forma como as fontes de P são aplicadas no solo também influencia para aumento da variabilidade do P na paisagem (Momtaz et al., 2017). No presente estudo, a sucessiva aplicação na linha de semeadura de fertilizantes contendo P, associado a variabilidade de classes de solos e teores de argila e ferro na área (Tabela 3), condicionam distinta capacidade de adsorção de P (Rheinheimer et al., 2003), refletindo no aumento da variabilidade espacial do P disponível na paisagem. O maior teor de argila e Fe_0 observado nos grupos de solos Nitisols e Leptosols, os quais predominam em ~90% da área, contribuem para a baixa mobilidade de P no solo. Os íons de P possuem afinidade com grupos funcionais de óxidos de ferro sendo adsorvidos e permanecendo estáveis nessas estruturas (Bortuluzzi et al., 2015).

Cherubin et al. (2015) compararam dados de potássio (K) com dados de P, e constataram a menor variabilidade espacial de K. Segundo esses autores, esse fato pode estar relacionado a dinâmica do elemento no solo, a adubação a lanço, a ciclagem elevada provida por restos culturais e a sua mobilidade superior no solo em relação ao P. Além disso, as atividades agrícolas sem práticas conservacionistas desencadeia processos erosivos superficiais (Deuschle et al., 2019), resultando no transporte e acúmulo de sedimentos ricos em P ao longo da paisagem (Bender et al., 2018; Tiecher et al., 2020), influenciando na variabilidade deste nutriente no solo.

Ao observar a tabela 3 é possível identificar que p teores de P foram significativamente menores em comparação aos CV's dos conjuntos de dados dos três métodos de amostragem (item 3.1.), que abrangem toda a área de estudo. Segundo Vanni (1998), CV menor que 35% indica que o conjunto de dados é homogêneo. Isso sugere que subdividir a área considerando as classes de solo resultará em glebas com menor variação de P disponível, o que sugere que mapas de solo podem ser bons preditores de P.

Em todos os cenários de combinação de design de amostragem e modelos de predição avaliados nesse trabalho, o DSD foi moderado (Table 4). Segundo Kravchenko (2003), a dependência espacial em grau forte e moderado contribui para a melhoria na qualidade da krigagem, gerando mapas mais precisos em relação aos graus de dependência fracos. Isso se deve a menor interferência do componente aleatório na estabilidade dos modelos preditivos. De acordo com Cambardella et al. (1994) propriedades que apresentam grau forte de graus de dependência geralmente são influenciadas por fatores intrínsecos do solo, como é o caso da granulometria e mineralogia, que variam menos no espaço, enquanto as que apresentam graus de dependência fraco são intensamente influenciadas por ações antrópicas de cultivo e adição de fertilizantes, como é o caso do P.

O DSD depende diretamente dos parâmetros do semivariograma. Observa-se na tabela 4, que o range obtido pelo RG foi superior as demais amostragens. O range é dependente do tamanho da área e do número de observações, sendo maior em casos onde as distâncias entre os pontos são maiores (Webster, 1985). A distância única de 100 m de um ponto para outro do RG fez com que esse método de amostragem apresentasse ranges maiores em comparação aos outros dois métodos. Souza et al (1998) e Cherubin et al. (2015) obtiveram resultados semelhantes ao analisar diferentes densidades de amostragem, onde pontos amostrados com maior distância entre si também apresentaram ranges superiores.

O range representa a distância máxima que pontos amostrais vizinhos são utilizados para a interpolação por krigagem (Trangmar et al. 1985). Em termos práticos significa dizer que o modelo foi capaz de reconhecer a estrutura de dependência espacial até o valor máximo apresentado pelo range. Essa constatação está de acordo com o descrito por Webster e Oliver (2007), que pontos de amostragem acima dos valores de alcance apresentam aleatoriedade e são independentes entre si.

Entretanto, apesar do alcance ter sua importância no planejamento do estudo e auxiliar a definir a densidade amostral (McBratney e Webster 1983), nem sempre ranges maiores significam maior acurácia das predições, sendo preciso analisar os outros componentes do semivariograma, como por exemplo, o nugget. O nugget representa uma variância ao acaso (aleatória) que não foi

capturada pelo método de amostragem. No caso do presente estudo, o nugget foi menor para as amostragens por SCS e DIST em ambos os modelos, enquanto o RG apresentou valores maiores para esse parâmetro (Tabe 4). Os três métodos de amostragem deste estudo possuem densidade amostral semelhante, porém, possivelmente por manter intervalos iguais em toda a distribuição de pontos, a variância não explicada (nugget) pelo RG foi superior aos outros métodos de amostragem. As características intrínsecas de cada método de amostragem, como a SCS possuir pontos a curtas distâncias (Fig. 3b) e a DIST considerar atributos do terreno na alocação dos pontos (Fig. 3c), proporcionaram um arranjo espacial capaz de reduzir a influência da variância não explicada nos modelos.

Cambardella e Karlen (1999) demonstraram em estudo que a densidade da amostragem ideal varia de local para local e, no caso de atributos químicos, depende também da fertilidade do solo. Como a área desse estudo é antropizada devido ao uso do solo para fins agrícolas, a variação de elementos químicos é elevada, mesmo em distâncias pequenas na paisagem, o que pode ter contribuído para a distância mínima de 100 m entre os pontos do RG ter apresentado efeito pepita elevado. Nanni et al. (2011) encontraram valores de nugget para fósforo que variam de 690 para uma densidade amostral de 1 ponto por ha, até o efeito pepita puro, onde não há qualquer quantificação de estrutura espacial, para uma densidade amostral de 7.2 pontos por ha. Enquanto que para K, os modelos ainda conseguiram encontrar dependência espacial para essa última densidade de pontos. Mallarino e Wittry (1997) sugerem amostragens com densidade inferior a 0.8 ha para a modelagem de P no solo. Dessa forma, pressupõe-se que, amostragens com pontos mais próximos são fundamentais para a predição de P, pois auxiliam o modelo a entender a variabilidade que há em um curto espaço no campo.

Observa-se nos mapas preditos (Fig. 6), que independente do design amostral, há formação de diferentes sítios com concentrações altas e baixas de P, ocasionados principalmente pela aplicação desuniforme de fertilizantes e pela perda de solo e água por processos erosivos. Nas áreas de Planossolos, devido a logística operacional, o proprietário optou por não adicionar fertilizantes fosfatados na mesma frequência e intensidade que adiciona nas demais áreas.

As diferenças percebidas entre os mapas temáticos obtidos nos três métodos de amostragem se devem ao fato de cada algoritmo utilizado para alocar os pontos amostrais seguir um critério distinto, tornando os métodos independentes entre si. Segundo Guarçoni et al. (2006) as amostras de solo quando independentes, mesmo que coletadas próximas, podem representar a variabilidade espacial de maneiras diferentes, o que pode ser acentuado em predições de atributos com elevada variação a curtas distâncias, como é o caso do P disponível. Esses resultados corroboram aqueles encontrados por Cherubin et al. (2015).

O uso de estatísticas de erro é recomendado para avaliar a acurácia de predições espaciais (Wadoux e Brus, 2020). O MAE representa a magnitude média do erro das predições. O ME também analisa a média entre valores preditos e observados, entretanto, os sinais negativos ou positivos dos erros não são removidos, e assim, eles se anulam. A RMSE também mede a magnitude do erro de predição. A diferença entre o MAE e o RMSE está na atribuição dos pesos dos erros. Como o RMSE eleva ao quadrado os valores de erros encontrados, essa métrica impõe pesos relativamente altos a erros maiores. Por esse motivo, para a modelagem de atributos com alta variabilidade como é o caso do P neste presente trabalho (CV em torno de 80%, item 3.1.), o RMSE possivelmente apresenta dados mais realistas.

Por fim, a Nash-Sutcliffe efficiency (NSE) é uma estatística normalizada que mede a eficiência de um modelo. Esta métrica varia de -1 a 1, sendo que valores acima de 0 significam maior eficiência em representar a variabilidade espacial do atributo estudado. Mais detalhes sobre as estatísticas de erro utilizadas nesse trabalho podem ser encontrados em Gupta et al. (1998) e Moriasi et al. (2007). Ao analisar o NSE na figura 6, observa-se que em todas as formas de amostragem, os resultados ficaram distantes de 1, indicando baixa eficiência dos modelos na predição de P disponível, o que explica os altos valores de erro retornados das predições. Possivelmente, isso está relacionado com a complexa dinâmica que o P possui na paisagem, sendo difícil capturar sua variabilidade.

O RMSE resultante foi maior que o MAE em todas as formas de amostragem. Esses resultados demonstram que algumas amostras com alto valor de P disponível (Fig. 4) podem ter afetado as predições espaciais. Grandes

amplitudes de teores de P disponível (Fig. 4), bem como a sua forte relação com as demais propriedades do solo, também contribuem para aumentar o valor de RMSE. Esta explicação está de acordo com os resultados encontrados por Hosseini et al. (2017), que ao analisar a influência de diferentes propriedades do solo, verificaram que ao utilizar a matéria orgânica como um parâmetro para prever P, os resultados de RMSE obtidos foram inferiores.

O mapa gerado com o design amostral SCS capturou maior parte da variabilidade espacial do P em comparação ao design amostral RG (Fig. 6). Possivelmente, o fato da SCS alocar os pontos a distâncias menores e a RG não, favoreceu a SCS a capturar a variabilidade do P disponível em curtas distâncias. Wadoux et al. (2019) compararam SCSs com e sem pontos a curtas distâncias. Esses autores constataram que incluir pontos a curtas distâncias é uma estratégia robusta para diminuir o erro total das previsões e a variação espacial entre os pontos de amostragem. Stein (1999) e Lark e Marchant (2018) também evidenciaram melhorias no aprendizado de modelos ao reservar uma porcentagem do total de pontos para serem alocados a curtas distâncias.

O método de amostragem DIST apresentaram os menores valores de MAE e RMSE, bem como o modelo com maior NSE (Fig. 6). Isso demonstra a influência que os fatores de formação do solo, neste caso o relevo, possuem sobre a distribuição do P disponível na paisagem. Alguns estudos também demonstraram que ao combinar um design de amostragem que utiliza covariáveis com um modelo preditivo de krigagem ou *random forest* (RF), é possível obter mapas mais acurados (Chu et al. 2010; Domenech et al., 2017; Castro-Franco et al., 2015). Especificamente, Domenech et al. (2017) recomenda a otimização da amostragem por covariáveis em três situações gerais: (i) quando tem disponibilidade de um DEM; (ii) o formato da área não é regular; e (iii) a área possui evidências que há variação topográfica. A área deste estudo (item 2.1.) se enquadra nessas situações.

Ao comparar os dois modelos preditivos, OK e KED, a amostragem DIST obteve melhor desempenho, ainda que modesto, combinado ao KED em relação à OK (Fig. 6). No caso deste design de amostragem, a modelagem com atributos do terreno possibilitou redução dos erros e a maior eficiência do modelo. Isso demonstra que a melhor abordagem encontrada neste trabalho não só utiliza os atributos de terreno no método de amostragem, mas também na construção da

função de predição espacial. Como o DIST é um algoritmo de amostragem baseado na distribuição de covariáveis ambientais na paisagem, esses resultados eram esperados.

Entretanto, o mesmo não ocorreu para o SCS. Neste caso, o SCS obteve melhores resultados associados à predição por OK, sem o uso de atributos de terreno (Fig. 6e). Dessa forma, os atributos de terreno atrapalham o aprendizado do modelo, uma vez que este é um método de amostragem com preceitos puramente geoestatísticos e baseados na distância entre os pontos no campo (Brus, 2019). Isso indica que ao utilizar uma spatial coverage sampling com pontos a curtas distâncias e otimizadas pelo critério MSSD, os resultados são melhores se não houver adição em nenhum momento de covariáveis ambientais na modelagem. Esta informação pode ser útil para mapear locais que não dispõem de variáveis auxiliares, como um DEM de qualidade ou dados do solo pré-existent. Por fim, mais estudos são necessários a fim de introduzir no algoritmo optimDIST, no formato de covariáveis, outras informações do solo que estejam relacionadas como teor de P disponível. Por exemplo, mapas dos teores de ferro pedogênico e de baixa cristalinidade, granulometria do solo (areia, silte e argila), classes de solo, bem como mapas de susceptibilidade magnética (Peluco et al., 2013) podem auxiliar o algoritmo a selecionar pontos amostrais de forma mais precisa.

Apesar do design amostral DIST ter retornado resultados superiores aos demais design's, por meio das estatísticas de erro é possível perceber que o melhor resultado encontrado ainda possui grandes erros que dificultam a sua aplicabilidade na agricultura de precisão. Possivelmente, esses grandes erros estão atrelados não aos design's de amostragem em si, mas a densidade amostral, que necessita ser maior para capturar com precisão a variabilidade de um atributo complexo, como é o caso do P. Em todos os mapas gerados, o RMSE resultante, por exemplo, foi aproximadamente 25 mg dm^{-3} de P disponível. Ao analisar esse dado em termos práticos, percebe-se que é um valor muito superior ao nível crítico indicado pelo manual de adubação e calagem do estado do Rio Grande do Sul para solos com classe de argila de 26 a 40% (até 4 mg dm^{-3}). Desta forma, estudos futuros que objetivam entender a dinâmica do P na paisagem se fazem necessários, a fim de que esse conhecimento possa ser

aplicado com eficiência no MDS, e conseqüentemente, na agricultura de precisão.

Ao analisar os resultados obtidos neste estudo, não é recomendável utilizar RG, visto que, existem design's mais eficientes que não necessitam de covariáveis ambientais. Este é o caso da SCS. Além disso, para áreas que tem disponibilidade de DEM, é recomendado a utilização de um design amostral que insira covariáveis desde a etapa de alocação dos pontos amostrais, desde que estas covariáveis tenham relação com a propriedade alvo a ser predita.

6. CONCLUSÕES

Conclui-se neste estudo que:

Modelos calibrados com dados derivadas do design amostral grid regular resultaram em mapas de P disponível menos acurados.

O design amostral Spatial Coverage Sampling obteve melhor resultado em capturar a estrutura de variação espacial quando combinado com krigagem ordinária em comparação a krigagem com deriva externa.

O mapa mais acurado foi gerado a partir da amostragem Spatial Simulated Annealing combinado com o modelo krigagem com deriva externa.

REFERÊNCIAS BIBLIOGRÁFICAS

- Alvares, C.A., Stape, J.L., Sentelhas, P.C., Gonçalves, J.L.M., Sparovek, G., 2013. Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*. 22, 711-728.
- Alovisi, A.M.T., Cassol, C.J., Nascimento, J.S., Soares, N.B., Junior, I.R.S., Silva, R.S., Silva, J.A.M., 2020. Soil factors affecting phosphorus adsorption in soils of the Cerrado, Brazil. *Geoderma Regional*. 22, e00298.
- Bender, M.A., Santos D.R., Tiecher T., Minella J.P.G., Barros C.A.P., Ramon R., 2018. Phosphorus dynamics during storm events in a subtropical rural catchment in southern Brazil. *Agriculture Ecosystems & Environment*. 261, 93-102.
- Bortoluzzi, E.C., Pérez, C.A.S., Ardisson, J.D., Tiecher, T., Caner, L., 2015. Occurrence of iron and aluminum sesquioxides and their implications for the P sorption in subtropical soils. *Applied Clay Science*. 104, 196-204.
- Bouma, J., 2021. Comment on "Soil based, field specific fertilizer recommendations are a pipe-dream" by A.G.T. Schut and K.E. Giller. *Geoderma*. 387, 114795.
- Brus, D.J., Kempen, B., Heuvelink, G.B.M., 2011. Sampling for validation of digital soil maps. *Eur. J. Soil Sci*. 62, 394-407.
- Brus, D.J., 2019. Sampling for digital soil mapping: a tutorial supported by r scripts. *Geoderma*. 338, 464-480.
- Brus, D.J., de GRUIJTER, J.J., van GROENIGEN, J.W., 2007. Designing spatial coverage samples using the k-means clustering algorithm, in: Lagacherie, P., McBratney, A.B., Voltz, M. (Eds.). *Digital Soil Mapping. An Introductory Perspective*. Elsevier, pp. 183-192.
- Burrough, P.A., 1986. *Principles of Geographical Information Systems for Land Resources Assessment*, first ed. Oxford University Press, Oxford.
- Camargo, L.A., Marques, J., Pereira, G.T., Alleoni, L.R.F., 2013. Spatial correlation between the composition of the clay fraction and contents of available phosphorus of an Oxisol at hillslope scale. *Catena*. 100, 100-106.
- Cambardella, C.A., Karlen, D.L., 1999. Spatial analysis of soil fertility parameters. *Precision Agriculture*. 1, 5-14.
- Cambardella, C.A., Moorman, T.B., Novak, J.M., Parkin, T.B., Karlen, D.L., Turco, R.F., Konopka, A.E., 1994. Field-scale variability of soil properties in Central Iowa Soils. *Soil Science Society of American Journal*. 58, 1501-1511.
- Castro-Franco, M., Costa, J.L., Peralta, N., Aparicio, V., 2015. Prediction of soil properties at farm scale using a model based soil sampling scheme and random forest. *Soil Sci*. 180, 74-85.

Cherubin, M.R., Santi, A.L., Eitelwein, M.T., Amado, T.J.C., Simon, D.H., Damian, J.M., 2015. Dimension of the sampling grid to characterize the spatial variability of phosphorus and potassium in an Oxisol. *Pesq. agropec. bras.* 50, 168-177.

Cherubin, M.R., Santi, A.L., Eitelwein, M.T., Menegol, D.R., Da Ros, C.O., Pias, O.H.C., Berghetti, J., 2014. Eficiência de malhas amostrais utilizadas na caracterização da variabilidade espacial de fósforo e potássio. *Ciência Rural.* 44, 425-432.

Chu, H.-J., Lin, Y.-P., Jang, C.-S., Chang, T.-K., 2010. Delineating the hazard zone of multiple soil pollutants by multivariate indicator kriging and conditioned Latin hypercube sampling. *Geoderma.* 158, 242-251.

Dalmolin, R.S.D., Pedron, F., de A., Almeida, J.A., Curcio, G.R., 2017. Soils of the Araucária Plateau, in: Curi, N. (Ed.), *Pedologia: Soils of Brazilian Biomes.* Sociedade Brasileira de Ciência do Solo, Viçosa, pp. 353-406

de Gruijter, J.J., Bierkens, M.F.P., Brus, D.J., Knotters, M., 2006. *Sampling for Natural Resource Monitoring*, first ed. Springer, Berlin.

Deuschle, D., Minella, J.P.G., Hörbe, T.A.N., Londero A.L., Schneider F.J.A., 2019. Erosion and hydrological response in no-tillage subjected to crop rotation intensification in southern Brazil. *Geoderma.* 340, 157-163.

Domenech, M.B., Castro-Franco, M., Costa, J.L., Amiotti, N.M., 2017. Sampling scheme optimization to map soil depth to petrocalcic horizon at field scale. *Geoderma.* 290, 75–82.

Guarçoni, M.A., Alvarez V.V.H., Novais, R.F., Cantarutti, R.B., Leite, H.G., Freire, F.M., 2006. Definition of the dimension of the individual soil and determination of the number of simple samples necessary for its representation. *R. Bras. Ci. Solo.* 30, 943-954.

Gupta, H.V., Sorooshian, S., Yapo, P.O., 1998. Toward improved calibration of hydrologic models: multiple and noncommensurable measures of information. *Water Resour.* 34, 751-763.

Hengl, T., Heuvelink, G.B. & Stein, A. 2004. A generic framework for spatial prediction of soil variables based on regression-kriging. *Geoderma.* 120, 75-93.

Kennard, R., Stone, L., 1969. Computer aided design of experiments. *Technometrics.* 11, 137-148.

Knotters, M., Brus, D.J. & Voshaar, J.O. 1995. A comparison of kriging, co-kriging and kriging combined with regression for spatial interpolation of horizon depth with censored observations. *Geoderma.* 67, 227-246.

Kravchenko, A.N., 2003. Influence of spatial structure on accuracy of interpolation methods. *Soil Science Society of American Journal*. 67, 1564-1571.

Lark, R., Marchant, B., 2018. How should a spatial-coverage sample design for a geostatistical soil survey be supplemented to support estimation of spatial covariance parameters? *Geoderma*. 319, 89-99.

Lesch, S.M., Strauss, D.J., Rhoades, J.D., 1995. Spatial prediction of soil salinity using electromagnetic induction techniques 2. An efficient spatial sampling algorithm suitable for multiple linear regression model identification and estimation. *Water Resour.* 31, 387-398.

Liu, X., Zhang, W., Zhang, M., Ficklin, D.L. & Wang, F., 2009. Spatio-temporal variations of soil nutrients influenced by an altered land tenure system in China. *Geoderma*. 152, 23-34.

Mallarino, A.P., Wittry, D.J., 1997. Use of DGPS, yield monitors, soil testing and variable rate technology to improve phosphorus and potassium management, in: *Proceedings of The Integrated Crop Management Conference (Iowa State University Extension, Ames, Iowa, USA)*, 267-275.

Mallarino, A.P., Wittry, D., 2004. Efficacy of grid and zone soil sampling approaches for site-specific assessment of phosphorus, potassium, pH, and organic matter. *Precision Agriculture*. 5, 131-144.

Marchant, B.P., Lark, R.M., 2007. Robust estimation of the variogram by residual maximum likelihood. *Geoderma*. 140, 62-72.

Matos-Moreira, M., Lemerrier, B., Dupas, R., Michot, D., Viaud, V., Akkal-Corfini, N., Gascuel-Oudoux, C. (2017). High-resolution mapping of soil phosphorus concentration in agricultural landscapes with readily available or detailed survey data. *European Journal of Soil Science*. 68, 281-294.

McBratney, A.B., Field, D.J., Koch, A., 2014. The dimensions of soil security. *Geoderma*. 213, 203-213.

McBratney, A.B., Odeh, I.O.A., Bishop, T.F.A., Dunbar, M.S., Shatar, T.M., 2000. An overview of pedometric techniques for use in soil survey. *Geoderma*. 97, 293-327.

McBratney, A.B., Santos, M.L.M., Minasny, B., 2003. On digital soil mapping. *Geoderma*. 117, 3-52.

McBratney, A.B., Webster, R., 1983. How many observations are needed for regional estimation of soil properties? *Soil Sci.* 135, 177-183.

McKenzie, N.J., Ryan, P.J., 1999. Spatial prediction of soil properties using environmental correlation. *Geoderma*. 89, 67-94.

Minasny, B., McBratney, A.B., 2010. Methodologies for Global Soil Mapping, first ed. Springer, Netherlands.

Minasny, B., McBratney, A.B., 2006. A conditioned Latin hypercube method for sampling in the presence of ancillary information. *Comput. Geosci.* 32, 1378-1388.

Momtaz, H. R., Ghasemi, N., Sepehr, E., & Mousavifard, S. M., 2017. Spatial distribution of soil-available phosphorus and single-point phosphorus buffering index in the Khoy region, Iran. *Soil Use and Management.* 33, 13-24.

Moriasi, D.N., Arnold, J.G., Van Liew, M.W., Bingner, R.L., Harmel, R.D., Veith, T.L., 2007. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. *Transactions Of The Asabe.* 50, 885-900.

Moura-Bueno, J.M., Dalmolin, R.S.D., Horst-Heinen, T.Z.; Ten Caten, A., Vasques, G.M., Dotto, A.C., Grunwald, S., 2020. When does stratification of a subtropical soil spectral library improve predictions of soil organic carbon content? *Science Of The Total Environment*, 737.

Moeys, J., 2018. Functions for Soil Texture Plot, Classification and Transformation. R package version 1.5.1.

Nanni, M.R., Povh, F.P., Damattê, J.A.M., Oliveira, R.B., Chicati, M.L., Cezar, E., 2011. Optimum size in grid soil sampling for variable rate application in site-specific management. *Sci. Agric.* 68, 386-392.

Olaya, V., 2004 A Gentle Introduction to SAGA GIS. Gottingen, Germany: The SAGA User Group.

Page, T., Haygarth, P.M., Beven, K.J., Joynes, A., Butler, T., Keeler, C., Wood, G.A., 2005. Spatial variability of soil phosphorus in relation to the topographic index and critical source areas: sampling for assessing risk to water quality. *Journal of Environmental Qualit.*, 34, 2263-2277.

Papritz, A., 2020. georob: Robust Geoostatistical Analysis of Spatial Data. R package version 0.3-13.

Peluco, R.G., Júnior, J.M., Siqueira, D.S., Cortez, L.A., Pereira, G.T., 2013. Magnetic susceptibility in the prediction of soil attributes in two sugarcane harvesting management systems. *Eng. Agríc.* 33, 1134-1143.

Core Team, R., 2020. R: A language and environment for statistical computing. R Foundation for Statistical Computing.

Rheinheimer, D.S., Anghinoni, I., Conte, E., 2003. Phosphorus sorption as a function of initial content and soil management systems. *R. Bras. Ci. Solo.* 27, 41-49.

- Samuel-Rosa, A., 2016. *spsann: Optimization of Sample Configurations using Spatial Simulated Annealing*. R package version 2.0-0.
- Sana, R.S., Anghinoni, I., Brandão, Z.N., Holzschuh, M.J., 2014. Spatial variability of physical-chemical attributes of the soil and its effects on cotton productivity. *R. Bras. Eng. Agríc. Ambiental*. 18, 994-1002.
- Santos, H.G., Jacomine, P.K.T., Anjos, L.H.C., Oliveira, V.A., Lumberras, J.F., Coelho, M.R., Almeida, J.A., Araujo-Filho, J.C., Oliveira, J.B., Cunha, T.J.F., 2018. *Brazilian system of soil classification, fifth ed.* Embrapa, Brasília.
- Shen, Q., Wang, Y., Wang, X., Liu, X., Zhang, X., Zhang, S., 2019. Comparing interpolation methods to predict soil total phosphorus in the Mollisol área of Northeast China. *Catena*. 174, 59-72.
- Souza, L.S., Cogo, N.P., Vieira, S.R., 1998. Variability of phosphorus, potassium and organic matter in the soil, in relation to management systems. *R. Bras. Ci. Solo*. 22, 77-86.
- Stein, M.L., 1999. *Interpolation of Spatial Data: Some Theory for Kriging*, first ed. Springer, New York.
- Teixeira, P.C., Donagemma, G.K, Fontana, A., Teixeira, W.G., 2017. *Manual of soil analysis methods*, third ed. Embrapa, Brasília.
- Tiecher, T., Brunetto, G., Rheinheimer, D.S., Gatiboni, L.C., Comin, J.J., Schmitt, D.J., Tiecher, T.L., Ambrosini, G., 2021. Phosphorus accumulation in a southern Brazilian Ultisol amended with pig manures for nine years. *Scientia Agricola*. 78, e20190157.
- Trangmar, B.B., Yost, R.S., Uehara, G, 1985. Application of geostatistics to spatial studies of soil properties. *Adv. Agron*. 38, 45-93.
- Vanni, S.M., 1998. *Regression models: applied statistics*, first ed. Legmar Informática, São Paulo.
- Wadoux, A.M.J.-C.; Brus, D.J., 2020. How to compare sampling designs for mapping? *Eur. J. Soil Sci*. 72, 35-46.
- Wadoux, A.M.J.-C., Marchant, B.P., Lark, R.M., 2019. Efficient sampling for geostatistical surveys. *Eur. J. Soil Sci*. 70, 975-989.
- Walvoort, D.J.J., Brus, D.J., de Gruijter, J.J., 2010. An R package for spatial coverage sampling and random sampling from compact geographical strata by k-means. *Computers & Geosciences*. 36, 1261-1267.
- Webster, R., 1985. Quantitative spatial analysis of soil in the field, in: Stewart, B.A. (Ed.), *Advances in soil science*. Springer, New York, pp. 1-70.

Webster, R., Oliver, M.A., 2007. Geostatistics for environmental scientists, second ed. Wiley, Chichester.

Wildner, W., Ramgrab, G.E., Lopes, R.C., Iglesias, C.M.F., 2008. Geological map of the State of Rio Grande do Sul. Serviço Geológico do Brasil, Porto Alegre - Brazil (Escala 1:750.000)

Ye, X., Bai, J., Lu, Q., Zhao, Q., Wang, J., 2013. Spatial and seasonal distributions of soil phosphorus in a typical seasonal flooding wetland of the Yellow River Delta, China. *Environ. Earth Sci.* 71, 4811–4820.

Yu, X., Keitel, C., Dijkstra, F.A. (2021). Global analysis of phosphorus fertilizer use efficiency in cereal crops. *Global Food Security*, 29, e100545.

Zambrano-Bigiarini, M., 2020. hydroGOF: Goodness-of-fit functions for comparison of simulated and observed hydrological time series. R package version 0.4-0.

Zamuner, E.C., Picone, L.I., Echeverria, H.E., 2008. Organic and inorganic phosphorus in Mollisol soil under different tillage practices. *Soil & Tillage Research.* 99, 131-138.

Zhang, S., Zhang, X., 2014. The influence of spatial resolution on the prediction of soil organic matter distribution in a mollisol watershed of northeast China. *Nat. Environ. Pollut. Technol.* 13, p. 669–676.

APÊNDICES

PERFIL 1**PROJETO** - Levantamento Tupanciretã**PERFIL N°** - 1**DATA** - 17/11/20**CLASSIFICAÇÃO** - Neossolo Litólico**LOCALIZAÇÃO, MUNICÍPIO, ESTADO E COORDENADAS** - Município de Tupanciretã, Rio Grande do Sul; -28.948945, -53.972407**CLIMA:** Cfa (Subtropical úmido)**SITUAÇÃO E DECLIVE** - Perfil descrito em trincheira. 7°, 12% de declividade**FORMAÇÃO GEOLÓGICA** - Formação Serra Geral**CRONOLOGIA** - Mesozoico (Cretáceo)**MATERIAL ORIGINÁRIO** - Rochas Vulcânicas**PEDREGOSIDADE** - Pedregoso a muito pedregoso**ROCHOSIDADE** - Ausente**RELEVO LOCAL** - Plano**EROSÃO** - Laminar e sulcos**DRENAGEM** - Bem drenado**VEGETAÇÃO PRIMÁRIA** - Floresta subtropical e subperenifólia**USO ATUAL** - Agricultura**DESCRITO E COLETADO POR** - Fabrício Pedron.**DESCRIÇÃO MORFOLÓGICA**

A	0 – 20 cm; (10 YR 2/2, úmida); francoargilosa; moderada blocos angulares e subangulares pequenos a médios; friável a firme; plástico e muito pegajoso; abrupta e plana; raízes muitas.
R	20 – 30+ cm; maciça médio a grande; muito friável a extremamente friável; não plástico e não pegajoso; raízes poucas.

OBSERVAÇÕES: Horizonte A apresenta fragmentos de saprolito de até 5 cm (maioria duros).

Camada R apresenta elevado fraturamento horizontal e vertical, blocos de até 20 cm que quebram com batidas de picareta, mas não cortam com a pá.

CARACTERIZAÇÃO GRANULOMÉTRICA – Perfil 1

Horizonte		Amostra seca ao ar (%)			Composição Granulométrica g.kg ⁻¹			Silte/Argila
Símbolo	Profundidade (cm)	Calhaus > 20mm	Cascalho 20-2mm	Terra fina < 2mm	Areia total	Silte	Argila	
A	0 – 20	0	0	100	323	397	280	1,41



PERFIL 2**PROJETO** - Levantamento Tupanciretã**PERFIL N°** - 2**DATA** - 17/11/20**CLASSIFICAÇÃO** - Planossolo Háplico**LOCALIZAÇÃO, MUNICÍPIO, ESTADO E COORDENADAS** - Município de Tupanciretã, Rio Grande do Sul; -28.947780, -53.973297**CLIMA:** Cfa (Subtropical úmido)**SITUAÇÃO E DECLIVE** - Perfil descrito em barranco de canal de drenagem. Menos que 3% de declividade.**FORMAÇÃO GEOLÓGICA** - Formação Serra Geral**CRONOLOGIA** - Mesozoico (Cretáceo)**MATERIAL ORIGINÁRIO** - Rochas Vulcânicas**PEDREGOSIDADE** - Ausente**ROCHOSIDADE** - Ausente**RELEVO LOCAL** - Plano**EROSÃO** - Não aparente**DRENAGEM** - Mal drenado**VEGETAÇÃO PRIMÁRIA** - Floresta subtropical e subperenifólia**USO ATUAL** - Agricultura**DESCRITO E COLETADO POR** – Jean Moura-Bueno.**DESCRIÇÃO MORFOLÓGICA**

Ap	0 – 15 cm; (10 YR 3/1, úmida); argila; moderada granular muito pequenos a pequenos e blocos subangulares pequenos; friável; ligeiramente plástico e ligeiramente pegajoso; clara e plana; raízes abundantes.
A1	15 – 35 cm; (10 YR 2/1, úmida); argilossiltosa; moderada blocos subangulares muito pequenos a médios; friável; ligeiramente plástico e pegajoso; clara e plana; raízes comuns.
A2	35 – 50 cm; (10 YR 2,5/1, úmida); muito argilosa; forte blocos subangulares médios a grandes e colunar médios a grandes; muito firme; plástico e pegajoso; clara e plana; raízes poucas.
EA	50 – 67 cm; (10 YR 4/1, úmida); franco-argilossiltosa; moderada blocos subangulares pequenos a médios; firme; plástico e pegajoso; clara e plana; raízes raras.
E	67 – 80 cm; (10 YR 6/2, úmida); franco-argilossiltosa; moderada blocos subangulares pequenos a médios; firme; plástico e pegajoso; clara e plana; raízes raras.
Btg	80 – 110+ cm; (10 YR 4/1, úmida); muito argilosa; forte blocos subangulares pequenos a médios; firme; plástico e pegajoso; raízes raras; mosqueados (10 YR 5/6, úmida).

OBSERVAÇÕES: Horizonte Btg com presença de mosqueados (10 YR 4/6, úmida) e estrutura maciça que se desfaz em blocos subangulares.

CARACTERIZAÇÃO GRANULOMÉTRICA – Perfil 2

Horizonte		Amostra seca ao ar (%)			Composição Granulométrica g.kg ⁻¹			Silte/Argila
Símbolo	Profundidade (cm)	Calhaus > 20mm	Cascalho 20-2mm	Terra fina < 2mm	Areia total	Silte	Argila	
Ap	0 – 15	0	0	100	98	373	529	0,70
A1	15 – 35	0	0	100	156	401	443	0,90
A2	35 – 50	0	0	100	51	299	650	0,46
EA	50 – 67	0	0	100	195	416	389	1,06
E	67 – 80	0	0	100	151	554	295	1,87
Btg	80 – 110+	0	0	100	80	332	598	0,13



PERFIL 3**PROJETO** - Levantamento Tupanciretã**PERFIL N°** - 3**DATA** - 17/11/20**CLASSIFICAÇÃO** - Neossolo Regolítico**LOCALIZAÇÃO, MUNICÍPIO, ESTADO E COORDENADAS** - Município de Tupanciretã, Rio Grande do Sul; -28.943059, -53.966144**CLIMA:** Cfa (Subtropical úmido)**SITUAÇÃO E DECLIVE** - Perfil descrito em trincheira. 4º, 9% de declividade**FORMAÇÃO GEOLÓGICA** - Formação Serra Geral**CRONOLOGIA** - Mesozoico (Cretáceo)**MATERIAL ORIGINÁRIO** - Rochas Vulcânicas**PEDREGOSIDADE** - Ligeiramente pedregoso (0 a 3%)**ROCHOSIDADE** - Ausente**RELEVO LOCAL** - Ondulado**EROSÃO** - Laminar**DRENAGEM** - Bem drenado**VEGETAÇÃO PRIMÁRIA** - Floresta subtropical e subperenifólia**USO ATUAL** - Agricultura**DESCRITO E COLETADO POR** – Jean Moura-Bueno.**DESCRIÇÃO MORFOLÓGICA**

Ap	0 – 5 cm; (5 YR 3/2, úmida); francoargilosa; moderada granular e blocos subangulares muito pequenos a pequenos; solta e friável; plástico e pegajoso; clara e plana; raízes muitas.
A1	5 – 17 cm; (5 YR 3/3, úmida); francoargilosa; forte blocos angulares e subangulares pequenos a grandes; firme, muito firme e extremamente firme; plástico e pegajoso; clara e plana; raízes comuns.
A2	17 – 36 cm; (5 YR 3/4, úmida); francoargilosa; moderada blocos subangulares médios a grandes; friável e firme; plástico e pegajoso; abrupta e plana; raízes comuns.
Cr	36 – 65 cm; transição abrupta e irregular; raízes poucas.
R	65+ cm;

OBSERVAÇÕES: Horizonte A1 possui blocos compactados, extremamente firmes com tamanhos variando de 5 a 10 cm.

Horizonte Cr corta com facilidade com a pá, apresenta-se muito fraturado, com rachaduras de até 0,5 cm preenchidas com solo. A distância entre fraturas

CARACTERIZAÇÃO GRANULOMÉTRICA – Perfil 3

Horizonte		Amostra seca ao ar (%)			Composição Granulométrica g.kg ⁻¹			Silte / Argila
Símbolo	Profundidade (cm)	Calhaus > 20mm	Cascalho 20-2mm	Terra fina < 2mm	Areia total	Silte	Argila	
Ap	0 – 5	0	0	100	209	449	342	1,31
A1	5 – 17	0	0	100	241	406	353	1,15
A2	17 – 36	0	0	100	282	382	336	1,13




PERFIL 4**PROJETO** - Levantamento Tupanciretã**PERFIL N°** - 4**DATA** - 17/11/20**CLASSIFICAÇÃO** - Nitossolo Vermelho**LOCALIZAÇÃO, MUNICÍPIO, ESTADO E COORDENADAS** - Município de Tupanciretã, Rio Grande do Sul; -28.941599, -53.968708**CLIMA:** Cfa (Subtropical úmido)**SITUAÇÃO E DECLIVE** - Perfil descrito em trincheira. 7% de declividade**FORMAÇÃO GEOLÓGICA** - Formação Serra Geral**CRONOLOGIA** - Mesozoico (Cretáceo)**MATERIAL ORIGINÁRIO** - Rochas Vulcânicas**PEDREGOSIDADE** - Ausente**ROCHOSIDADE** - Ausente**RELEVO LOCAL** - Suave ondulado**EROSÃO** - Laminar**DRENAGEM** - Bem drenado**VEGETAÇÃO PRIMÁRIA** - Floresta subtropical e subperenifólia**USO ATUAL** - Agricultura**DESCRITO E COLETADO POR** - Fabrício Pedron.**DESCRIÇÃO MORFOLÓGICA**

Ap	0 – 5 cm; (5 YR 3/2, úmida); francoargilosa; moderada granular muito pequenos a pequenos e blocos subangulares muito pequenos a pequenos; friável a firme; plástico e ligeiramente pegajoso; abrupta e plana; raízes muitas.
A	5 – 16 cm; (5 YR 2,5/3, úmida); francoargilosa; forte blocos subangulares pequenos a médios; extremamente firme; plástico e pegajoso; clara e plana; raízes muitas.
AB	16 – 38 cm; (5 YR 3/3, úmida); argila; moderada blocos angulares pequenos a grandes e blocos subangulares pequenos a médios; friável a firme; plástico e pegajoso; clara e plana; raízes comuns.
B1	38 – 60 cm; (5 YR 3/4, úmida); argila; moderada blocos angulares e subangulares pequenos a médios; friável; plástico e pegajoso; clara e plana; raízes comuns.
B2	60 – 75 cm (70 – 80 cm); (5 YR 3/4, úmida); argila/muito argilosa; moderada blocos angulares e subangulares pequenos a médios; friável a firme; ligeiramente plástico e ligeiramente pegajoso; abrupta e irregular.
Cr	75+ cm (70 – 80+ cm).

OBSERVAÇÕES: Horizontes Bi1 e Bi2 com 1 e 2% de fragmentos de saprólito, respectivamente.

CARACTERIZAÇÃO GRANULOMÉTRICA – Perfil 4

Horizonte		Amostra seca ao ar (%)			Composição Granulométrica g.kg ⁻¹			Silte / Argila
Símbolo	Profundidade (cm)	Calhaus > 20mm	Cascalho 20-2mm	Terra fina < 2mm	Areia total	Silte	Argila	
Ap	0 – 5	0	0	100	325	370	309	1,19
A	5 – 16	0	0	100	293	321	386	0,83
AB	16 – 38	0	0	100	261	328	411	0,79
B1	38 – 60	0	0	100	199	278	524	0,53
B2	60 – 75	0	0	100	145	254	601	0,42



PERFIL 5**PROJETO** - Levantamento Tupanciretã**PERFIL N°** - 5**DATA** - 17/11/20**CLASSIFICAÇÃO** – Neossolo Litólico**LOCALIZAÇÃO, MUNICÍPIO, ESTADO E COORDENADAS** - Município de Tupanciretã, Rio Grande do Sul; -28.946810, -53.962950**CLIMA:** Cfa (Subtropical úmido)**SITUAÇÃO E DECLIVE** - Perfil descrito em trincheira. 5° e 10% de declividade**FORMAÇÃO GEOLÓGICA** - Formação Serra Geral**CRONOLOGIA** - Mesozoico (Cretáceo)**MATERIAL ORIGINÁRIO** - Rochas Vulcânicas**PEDREGOSIDADE** - Pedregosa**ROCHOSIDADE** - Ausente**RELEVO LOCAL** - Ondulado**EROSÃO** - Laminar e sulcos**DRENAGEM** - Bem drenado**VEGETAÇÃO PRIMÁRIA** - Floresta subtropical e subperenifólia**USO ATUAL** - Agricultura**DESCRITO E COLETADO POR** - Fabrício Pedron.**DESCRIÇÃO MORFOLÓGICA**

A	0 – 15 cm (13 – 17 cm); (10 YR 2/2, úmida); francoargilosa; moderada blocos subangulares pequenos a médios; firme; plástico e pegajoso; abrupta e irregular; raízes abundantes.
R	15 – 40+ cm (13 – 17 cm).

OBSERVAÇÕES: Camada R possui rocha parcialmente alterada, dura, quebra com dificuldade com golpes de picareta. Fraturas de até 2 mm preenchidas com solo. A distância entre as fraturas varia entre 5 a 10 cm.

CARACTERIZAÇÃO GRANULOMÉTRICA – Perfil 5

Horizonte		Amostra seca ao ar (%)			Composição Granulométrica g.kg ⁻¹			Silte / Argila
Símbolo	Profundidade (cm)	Calhaus > 20mm	Cascalho 20-2mm	Terra fina < 2mm	Areia total	Silte	Argila	
A	0 – 15	0	0	100	275	462	263	1,75



PERFIL 6**PROJETO** - Levantamento Tupanciretã**PERFIL N°** - 6**DATA** - 17/11/20**CLASSIFICAÇÃO** - Planossolo Háplico**LOCALIZAÇÃO, MUNICÍPIO, ESTADO E COORDENADAS** - Município de Tupanciretã, Rio Grande do Sul; -28.951371, -53.965578**CLIMA:** Cfa (Subtropical úmido)**SITUAÇÃO E DECLIVE** - Perfil descrito em barranco de canal de drenagem. Menos que 3% de declividade**FORMAÇÃO GEOLÓGICA** - Formação Serra Geral**CRONOLOGIA** - Mesozoico (Cretáceo)**MATERIAL ORIGINÁRIO** - Sedimentos**PEDREGOSIDADE** - Ausente**ROCHOSIDADE** - Ausente**RELEVO LOCAL** - Plano**EROSÃO** - Não aparente**DRENAGEM** - Mal drenado**VEGETAÇÃO PRIMÁRIA** - Floresta subtropical e subperenifólia**USO ATUAL** - Agricultura**DESCRITO E COLETADO POR** – Fabrício Pedron.**DESCRIÇÃO MORFOLÓGICA**


Ap	0 – 5 cm; (10 YR 2,5/1, úmida); franca; moderada granular e blocos subangulares muito pequenos a pequenos; friável; plástico e pegajoso; abrupta e plana; raízes abundantes.
A	5 – 30 cm; (10 YR 3,5/2, úmida); franco argilossiltosa; forte blocos angulares médios a grandes; extremamente firme; plástico e pegajoso; clara e plana; raízes muitas.
Btg	30 – 55 cm; (10 YR 4/2, úmida); franco siltosa; moderada blocos angulares a subangulares pequenos a grandes; firme; plástico e pegajoso; clara e plana; raízes comuns; mosqueado (10 YR 4/6, úmida).
Cg1	55 – 75 cm; (10 YR 4/1, úmida); franco argilossiltosa; moderada blocos angulares a subangulares pequenos a grandes; firme; plástico e pegajoso; clara e plana; raízes poucas; mosqueado (10 YR 4/6, úmida).
2Cg1	75 – 100 cm; (10 YR 5/1, úmida); franca; moderada blocos angulares a subangulares pequenos a grandes; friável a firme; não plástico e não pegajoso; clara e gradual; raízes raras; mosqueado (10 YR 5/8, úmida).
2Cg2	100-120+ cm; (10 YR 6/1, úmida); franco arenosa; maciça; friável; não plástico e não pegajoso; clara e gradual; mosqueado (10 YR 5/8, úmida).

OBSERVAÇÕES: Horizonte A apresenta estrutura modificada por compactação (adensamento).

Horizontes Btg, Cg1, 2Cg1 e 2Cg2 apresentam 2% de fragmento de sílica que variam de 0,5 a 3 cm.

CARACTERIZAÇÃO GRANULOMÉTRICA – Perfil 6

Horizonte		Amostra seca ao ar (%)			Composição Granulométrica g.kg ⁻¹			Silte / Argila
Símbolo	Profundidade (cm)	Calhaus > 20mm	Cascalho 20-2mm	Terra fina < 2mm	Areia total	Silte	Argila	
Ap	0 – 5	0	0	100	297	454	249	1,82
A	5 – 30	0	0	100	189	522	289	1,80
Btg	30 – 55	0	0	100	180	266	555	0,47
Cg	55 – 75	0	0	100	190	498	312	1,59
2Cg1	75 – 100	0	0	100	504	388	108	3,59
2Cg2	100 – 120+	0	0	100	532	342	125	2,73



PERFIL 7**PROJETO** - Levantamento Tupanciretã**PERFIL N°** - 7**DATA** - 17/11/20**CLASSIFICAÇÃO** – Nitossolo Vermelho**LOCALIZAÇÃO, MUNICÍPIO, ESTADO E COORDENADAS** - Município de Tupanciretã, Rio Grande do Sul; -28.945984, -53.969499**CLIMA:** Cfa (Subtropical úmido)**SITUAÇÃO E DECLIVE** - Perfil descrito em trincheira. 0 a 3% de declividade**FORMAÇÃO GEOLÓGICA** - Formação Serra Geral**CRONOLOGIA** - Mesozoico (Cretáceo)**MATERIAL ORIGINÁRIO** - Rochas Vulcânicas**PEDREGOSIDADE** - Ausente**ROCHOSIDADE** - Ausente**RELEVO LOCAL** - Plano**EROSÃO** - Laminar**DRENAGEM** - Bem drenado**VEGETAÇÃO PRIMÁRIA** - Floresta subtropical e subperenifólia**USO ATUAL** - Agricultura**DESCRITO E COLETADO POR** – Jean Moura-Bueno.**DESCRIÇÃO MORFOLÓGICA**

Ap	0 – 8 cm; (5 YR 3/1,5, úmida); franco argilosa; moderada granular muito pequenos e blocos subangulares pequenos; friável; plástico e pegajoso; clara e plana; raízes abundantes.
A1	8 – 20 cm; (5 YR 3/2, úmida); argila; moderada blocos subangulares pequenos a médios; muito friável; plástico e pegajoso; clara e plana; raízes comuns.
A2	20 – 30 cm; (5 YR 3/4, úmida); argila; moderada blocos subangulares pequenos a médios; firme; plástico e pegajoso; gradual e plana; raízes poucas.
AB	30 – 55 cm; (2,5 YR 3,5/4, úmida); argila; moderada blocos subangulares pequenos a médios; firme; ligeiramente plástico e pegajoso; gradual e plana; raízes raras.
BA	55 – 75 cm; (2,5 YR 3/7, úmida); argila/muito argilosa; moderada blocos subangulares pequenos a médios; firme; ligeiramente plástico e pegajoso; gradual e plana; raízes raras.
B1	75 – 105 cm; (2,5 YR 3/8, úmida); muito argilosa; moderada blocos subangulares pequenos a médios; friável; ligeiramente plástico e pegajoso; difusa e plana; raízes raras.
B2	105 – 125 cm; (2,5 YR 3,5/6, úmida); muito argilosa; moderada blocos subangulares pequenos a médios; friável; ligeiramente plástico e pegajoso; difusa e plana; raízes raras.

BC	125+; (2,5 YR 4/6, úmida); argila/muito argilosa; moderada blocos subangulares pequenos a médios; friável; ligeiramente plástico e pegajoso; raízes raras.
----	--

CARACTERIZAÇÃO GRANULOMÉTRICA – Perfil 7

Horizonte		Amostra seca ao ar (%)			Composição Granulométrica g.kg ⁻¹			Silte/Argila
Símbolo	Profundidade (cm)	Calhaus > 20mm	Cascalho 20-2mm	Terra fina < 2mm	Areia total	Silte	Argila	
Ap	0 – 8	0	0	100	262	357	381	0,93
A1	8 – 20	0	0	100	233	340	427	0,79
A2	20 – 30	0	0	100	203	326	471	0,69
AB	30 – 55	0	0	100	173	299	528	0,56
BA	55 – 75	0	0	100	141	263	596	0,44
B1	75 – 105	0	0	100	102	194	704	0,27
B2	105 – 125	0	0	100	114	245	641	0,38
BC	125+	0	0	100	136	261	603	0,43



PERFIL 8**PROJETO** - Levantamento Tupanciretã**PERFIL N°** - 8**DATA** - 17/11/20**CLASSIFICAÇÃO** – Nitossolo Vermelho**LOCALIZAÇÃO, MUNICÍPIO, ESTADO E COORDENADAS** - Município de Tupanciretã, Rio Grande do Sul; -28.948991, -53.964971**CLIMA:** Cfa (Subtropical úmido)**SITUAÇÃO E DECLIVE** - Perfil descrito em trincheira. 6° e 6% de declividade**FORMAÇÃO GEOLÓGICA** - Formação Serra Geral**CRONOLOGIA** - Mesozoico (Cretáceo)**MATERIAL ORIGINÁRIO** - Rochas Vulcânicas**PEDREGOSIDADE** - Ausente**ROCHOSIDADE** - Ausente**RELEVO LOCAL** – Suave ondulado**EROSÃO** - Laminar**DRENAGEM** - Bem drenado**VEGETAÇÃO PRIMÁRIA** - Floresta subtropical e subperenifólia**USO ATUAL** - Agricultura**DESCRITO E COLETADO POR** – Fabrício Pedron.**DESCRIÇÃO MORFOLÓGICA**

Ap	0 – 5 cm; (5 YR 3/2, úmida); franco argilosa; moderada blocos subangulares pequenos a grandes; friável e firme; plástico e pegajoso; abrupta e plana; raízes abundantes.
A	5 – 25 cm; (5 YR 3/2, úmida); argila; moderada blocos subangulares pequenos a grandes; friável e firme; plástico e pegajoso; clara e plana; raízes muitas.
AB	25 – 48 cm; (2,5 YR 3/4, úmida); argila; moderada blocos subangulares pequenos a grandes; friável; plástico e pegajoso; gradual e plana; raízes comuns.
BA	48 – 70 cm; (2,5 YR 4/4, úmida); muito argilosa; moderada blocos subangulares pequenos a grandes; friável; plástico e pegajoso; gradual e plana; raízes poucas.
B1	70 – 103 cm; (2,5 YR 3/4, úmida); muito argilosa; moderada blocos subangulares pequenos a grandes; friável; plástico e pegajoso; gradual e plana; raízes raras.
B2	103 – 130 cm; (2,5 YR 3/4,5, úmida); muito argilosa; moderada blocos subangulares pequenos a grandes; friável; plástico e pegajoso; gradual e plana; raízes raras.
B3	130 – 150 cm; (2,5 YR 3/6, úmida); argila; moderada blocos subangulares pequenos a grandes; friável; plástico e pegajoso; abrupta e plana; raízes raras.
Cr	150+ cm.

CARACTERIZAÇÃO GRANULOMÉTRICA – Perfil 8

Horizonte		Amostra seca ao ar (%)			Composição Granulométrica g.kg ⁻¹			Silte / Argila
Símbolo	Profundidade (cm)	Calhaus > 20mm	Cascalho 20-2mm	Terra fina < 2mm	Areia total	Silte	Argila	
Ap	0 – 5	0	0	100	250	363	387	0,93
A	5 – 25	0	0	100	189	326	485	0,67
AB	25 – 48	0	0	100	158	343	499	0,68
BA	48 – 70	0	0	100	112	210	678	0,30
B1	70 – 103	0	0	100	85	187	728	0,25
B2	103 – 130	0	0	100	87	283	630	0,44
B3	130 – 150	0	0	100	108	335	557	0,60

