

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

IGOR ALEXANDRE PASQUATTO

**APLICAÇÃO DE TÉCNICAS DE GEOPROCESSAMENTO NO
DESENVOLVIMENTO DE MAPAS DE FERTILIDADE DO SOLO**

PATO BRANCO

2022

IGOR ALEXANDRE PASQUATTO

**APLICAÇÃO DE TÉCNICAS DE GEOPROCESSAMENTO NO
DESENVOLVIMENTO DE MAPAS DE FERTILIDADE DO SOLO**

**Application of geoprocessing techniques in the development of fertility
maps of the soil**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do
título de Bacharel em Agronomia do Curso de
Bacharelado em Agronomia da Universidade
Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Henrique dos Santos
Felipetto

PATO BRANCO

2022



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

IGOR ALEXANDRE PASQUATTO

**APLICAÇÃO DE TÉCNICAS DE GEOPROCESSAMENTO NO
DESENVOLVIMENTO DE MAPAS DE FERTILIDADE DO SOLO**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do
título de Bacharel em Agronomia do Curso de
Bacharelado em Agronomia da Universidade
Tecnológica Federal do Paraná.

Data de aprovação: 28/novembro/2022

Henrique dos Santos Felipetto
Doutorado em Engenharia Agrícola
Universidade Tecnológica Federal do Paraná

Luís César Cassol
Doutorado em Ciência do Solo
Universidade Tecnológica Federal do Paraná

Daniel Carvalho Granemann
Doutorado em Agronomia
Universidade Tecnológica Federal do Paraná

PATO BRANCO

2022

Dedico este trabalho aos meus pais, Delton e Solange, pela paciência, amor, incentivo e compreensão.

AGRADECIMENTOS

Primeiramente agradeço a Deus por ter me proporcionado saúde, por ter me dado sabedoria e forças para chegar até este momento.

Agradeço aos meus pais, Delton e Solange pelos ensinamentos, amor, carinho, incentivo e todo apoio que me forneceram durante todos os anos, permitindo que eu alcançasse meus objetivos.

Aos meus irmãos, Maisa e Egon que me incentivaram nos estudos.

Ao meu orientador Prof. Dr. Henrique dos Santos Felipetto pela paciência, conhecimentos passados, orientações e momentos despendidos nessa monografia.

Ao Laboratório de Solos da UTFPR - Pato Branco (LabSolos) pelas análises efetuadas para esse trabalho.

A família Scolari por ter cedido parte de sua propriedade para realização do experimento.

Aos membros da banca avaliadora, Luís César Cassol e Daniel Carvalho Granemann por terem se disponibilizado a fazer parte deste momento.

RESUMO

O estudo mostra técnicas de geoprocessamento por meio de um plugin chamado Smart-Map pelo software QGIS, realizando um comparativo entre métodos de interpolação, e desta forma visando produtores que desejam adquirir técnicas de agricultura de precisão (AP), para obter melhores rendimentos nas suas propriedades. O objetivo desse trabalho foi realizar a elaboração de mapas de atributos químicos, visando uma análise cruzada entre os dados obtidos para poder elaborar tomadas de decisões mais concretas e específicas, com análises focados em dois métodos estatísticos, sendo pelo método de Krigagem Ordinária e Machine Learning, diminuindo então o custo de produção e aumentando a margem de lucro dos produtores. O atual trabalho foi realizado no município de Marmeleiro – PR, em uma área de 9,8 ha, nas coordenadas -26,2524097 de latitude Sul, -53,1089066 de longitude Oeste, com altitude média de 650 metros. Supõe-se que tenha uma melhora na produtividade grãos assimilados ao mapa de fertilidade elaborado, e com o auxílio da agricultura de precisão resultando uma diminuição de custos de produção, se reduz assim os impactos ambientais causados por excesso, e também aumenta a rentabilidade do produtor.

Palavras-chave: agricultura de precisão; produtividade; análise espacial; krigagem ordinária; *machine learning*.

ABSTRACT

This study shows geoprocessing techniques through a plugin called Smart-Map by the software QGIS, making a comparison among the interpolation methods, aiming at producers who want to acquire precision agriculture techniques to obtain better income in their properties. The goal of this work is to realize the elaboration of the maps of chemical attributes aspiring a cross analysis among the obtained data, then it is possible taking factual and specific decisions, with focused analysis in two statistical methods, "Ordinary Kriging" and "Machine Learning", decreasing the production cost and increasing the profits of the producers. The research was realized in the city of Marmeleiro – PR. The área has 9,8 acres, in the coordinates -26.2524097 of South latitude, -53.1089066 in the West longitude, with medium altitude of 650 meters. It may have a progress in the productive of grains which may be incorporated to the fertility map that was elaborated. With the assistance of the precision agriculture it may decrease some costs of production, reducing the environment impacts caused by the excesses and it also increases the profitability of the producer.

Keywords: precision agriculture; productivity; spatial analysis; kriging; machine learning.

LISTA DE FIGURAS

Figura 1 – Local do experimento, imagem de satélite disponibilizada pelo Google Satellite com área demarcada pelo software QGIS	17
Figura 2 – Grid de distribuição espacial dos pontos de amostragem do solo	18
Figura 3 – Esquema ilustrativo das coletas do solo	19
Figura 4 – Mapas interpolados de Matéria Orgânica (MO) por <i>Machine Learning</i> (ML) e Krigagem Ordinária (KO) obtidos pelo plugin <i>Smart-Map</i>	22
Figura 5 – Validação Cruzada (MO) de ML e KO obtidos pelo plugin <i>Smart-Map</i>	22
Figura 6 – Mapas interpolados de Fósforo (P) por <i>Machine Learning</i> (ML) e Krigagem Ordinária (KO) obtidos pelo plugin <i>Smart-Map</i>	23
Figura 7 – Validação Cruzada (P) de ML e KO obtidas através do software QGIS.	24
Figura 8 – Mapas interpolados de Potássio (K) por <i>Machine Learning</i> (ML) e Krigagem Ordinária (KO) obtidos pelo plugin <i>Smart-Map</i>	24
Figura 9 – Validação Cruzada (K) de ML e KO obtidos pelo plugin <i>Smart-Map</i>	25
Figura 10 – Mapas interpolados de Cálcio (Ca) por <i>Machine Learning</i> (ML) e Krigagem Ordinária (KO) obtidos pelo plugin <i>Smart-Map</i>	26
Figura 11 – Validação Cruzada (Ca) de ML e KO obtidos pelo plugin <i>Smart-Map</i>	26
Figura 12 – Mapas interpolados de Magnésio (Mg) por <i>Machine Learning</i> (ML) e Krigagem Ordinária (KO) obtidos pelo plugin <i>Smart-Map</i>	27
Figura 13 – Validação Cruzada (Mg) de ML e KO obtidos pelo plugin <i>Smart-Map</i>	27

LISTA DE TABELAS

Tabela 1 – Dados de fertilidade obtidos através das análises de solo	21
Tabela 2 – Comparativo ML x KO	28
Tabela 3 – Resumo dos laudos das análises do solo: experimento em Marmeleiro - PR	33

SUMÁRIO

1	INTRODUÇÃO	9
1.1	OBJETIVOS	10
1.1.1	Objetivo Geral	10
1.1.2	Objetivos Específicos	10
2	REFERENCIAL TEÓRICO	11
2.1	Agricultura de precisão	11
2.2	Sensoriamento Remoto	12
2.3	Geoprocessamento	13
2.4	Geoestatística	14
2.5	Mapa de fertilidade	14
2.6	<i>Machine Learning</i> (ML)	15
2.7	Krigagem Ordinária (KO)	16
3	MATERIAIS E MÉTODOS	17
3.1	Local do experimento	17
3.2	Amostragem de solo	17
3.3	Análise de dados	19
4	RESULTADOS E DISCUSSÃO	21
4.1	ANÁLISE DO SOLO	21
4.2	MATÉRIA ORGÂNICA (MO)	21
4.3	FÓSFORO (P)	23
4.4	POTÁSSIO (K)	23
4.5	CÁLCIO (Ca)	25
4.6	MAGNÉSIO (Mg)	25
4.7	ANÁLISES DE MAPAS DE FERTILIDADE E VALIDAÇÃO CRUZADA . . .	28
5	CONSIDERAÇÕES FINAIS	29
	REFERÊNCIAS	30

1 INTRODUÇÃO

No Brasil o uso de mapas digitais está cada vez mais popular, as instituições públicas e privadas de pesquisas e planejamentos, agricultores e afins, buscam informações para planejamento e uso racional das terras, aumentando o aspecto socioeconômico, conservando e protegendo recursos naturais, entre outros (MENDONÇA-SANTOS; SANTOS, 2003).

Para a realização de mapas digitais na agricultura, é levado em consideração atributos químicos do solo (Ca, P, Mg entre outros). É levado em consideração o custo para realizar o levantamento, a acessibilidade das áreas, porém com técnicas quantitativas para predição espacial é possível fazer estimativas e previsões em áreas com difícil acesso (MENDONÇA-SANTOS; SANTOS, 2003).

A realização de mapas digitais com atributos do solo consegue auxiliar produtores com a aplicações de taxas variáveis de insumos agrícolas, porém é necessário que a realização destes mapas seja precisa. Para isso, os mapas podem ser interpolados pelo método de Krigagem Ordinária, o qual é uma técnica mais utilizado para realização de mapas de agricultura digital, porém deve ser levado em consideração que há alguns problemas quanto ao uso deste método, sendo o principal a necessidade de um numero grande de amostras para que seja gerada as informações de semivariância (PEREIRA *et al.*, 2022).

Portanto, o presente estudo busca novos métodos de análises e interpolação, sendo assim usado a técnica de Machine Learning, o qual vem sendo utilizado como uma alternativa ao sistema citado acima, busca identificar e quantificar padrões entre os dados disponíveis para realizar as previsões dos atributos. Vários modelos são utilizados nesta técnica, e neste experimento foi utilizado o Support Vector Machine (SVM). Porém para realização das análises nessa técnica, é necessário ter conhecimentos em linguagem de programação de códigos abertos (PEREIRA *et al.*, 2022).

Porém, o atual trabalho é realizado através do software QGIS, o qual é uma ferramenta de sistemas de informações geográficas (SIG), sendo um software de código aberto e livre, e que pode ser realizado diversas análises de forma gratuita. As análises utilizadas neste experimento foram realizadas pelo plugin Smart-Map, que consegue realizar mapeamentos digitais de atributos do solo, e realizar então as interpolações e validações cruzadas de Krigagem Ordinária e também de Machine Learning (PEREIRA *et al.*, 2022).

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Aplicar técnicas de geoprocessamento para avaliar os parâmetros do solo, visando a produção de mapas de fertilidade do solo em propriedade rural localizada no município de Mar-meleiro – PR.

1.1.2 Objetivos Específicos

- Analisar as amostras georreferenciadas de solo coletadas na propriedade rural.
- Elaborar mapas de atributos químicos para regularização de fertilidade do solo
- Realizar uma análise de solo composta com técnicas de agricultura de precisão visando a produção de mapas de fertilidade.
- Comparar os métodos de interpolação Machine Learning e Krigagem Ordinária e definir o melhor método a ser aplicado na propriedade rural.

2 REFERENCIAL TEÓRICO

2.1 Agricultura de precisão

A agricultura de precisão (AP) é um sistema baseado na variação espacial de propriedades do solo e das plantas encontradas nas lavouras, visando a otimização do lucro, sustentabilidade e proteção do ambiente. Iniciou-se nos anos de 1980 na Europa, onde surgiu o primeiro mapa de produtividade e nos Estados Unidos foi feita a primeira adubação com doses variadas (MAPA, 2009). No Brasil os primeiros trabalhos realizados com a agricultura de precisão começaram na década de 1990, e então foram ganhando espaços entre empresas agrícolas que visam a produção de culturas anuais no país (WILDA, 2014).

Segundo Wilda (2014) a agricultura de precisão é um conjunto de tecnologias que tem objetivo tornar o manejo agrícola mais eficiente pelas intervenções sítio específica, visando o aumento de produção, otimização de insumos agrícolas, redução de contaminação de alimentos e meio ambiente.

Pode ser utilizado de maneiras diferentes, com diferentes objetivos, como por exemplo, alguns buscam o aumento de produtividade enquanto outros a redução de insumos, utilizando estratégias que analisam tanto os aspectos de produtividade, o solo de modo geral, infestações de ervas daninhas, doenças e pragas. No Brasil a AP é usualmente utilizada nas aplicações de fertilizantes e corretivos em taxa variável. Quanto mais completo seu banco de dados, ou seja, quanto maior quantidade de informações a respeito da lavoura, melhor será o diagnóstico e consequentemente a estratégia de recomendação será mais efetiva (MAPA, 2009).

A agricultura de precisão baseia-se em quatro etapas básicas, as quais seriam: amostragem com obtenção da informação georreferenciada sobre o estado de fertilidade do solo ao longo do talhão de cultivo, o processamento e gerenciamento dos dados, a aplicação in situ dos insumos agrícolas requeridos e a avaliação dos resultados (SARAIVA; CUGNASCA; HIRAKAWA, 2000).

De acordo com Saraiva, Cugnasca e Hirakawa (2000), a obtenção da informação georreferenciada baseia-se nos dados de: coletas do solo, para verificação de parâmetros físicos e químicos; de colheita, para análise de dados de produção; e também, de fatores que interferem na produtividade, como ervas daninhas, pragas e entre outros, com um nível de detalhamento que seja possível ter variabilidade espacial em campo.

Pelo autor supracitado, o processamento e gerenciamento dos dados se dá pela seleção dos dados, analisando os mais relevantes, corrigindo erros de coleta de dados e de posicionamento, e depois se avalia os dados através da geoestatística. Além disso, são gerados mapas (colheita, parâmetros físicos e químicos do solo) que podem ser cruzados com os dados da produção com os fatores de produção, e assim criar um mapa de recomendação de aplicação de insumos agrícolas.

A etapa da aplicação in situ dos insumos seria a aplicação localizada baseado nos mapas produzidos pelo processamento dos dados obtidos, porém é preciso de maquinário adequado para realizar a aplicação em taxa variável ao longo do talhão, podendo assim, trabalhar as áreas com maior necessidade de aplicação, e diminuir a aplicação em áreas onde não precisam tanta correção (SARAIVA; CUGNASCA; HIRAKAWA, 2000).

A etapa de avaliação, pode ser feita ao longo do ciclo, avaliando as folhas das plantas, o comportamento de crescimento e entre outros. Porém, a cada nova safra, novos dados são disponíveis, auxiliando o agricultor a tomar novas decisões visando o aumento de produtividade e diminuição do custo de produção (SARAIVA; CUGNASCA; HIRAKAWA, 2000).

2.2 Sensoriamento Remoto

O sensoriamento remoto foi muito utilizado na 1ª e 2ª Guerra Mundial, no planejamento de missões com fins militares, e por volta dos anos 1960 foi lançada a primeira espaçonave não tripulada ao espaço. Logo em seguida deu-se início aos experimentos espaciais tripulados, o que fez com que se desenvolvesse uma série de sensores com o objetivo de obter informações sobre a superfície terrestre (ROSA; BRITO, 2013).

No Brasil, teve impulso com o projeto RADAMBRASIL por volta dos anos 70, feito pelo governo brasileiro para realizar pesquisas de recursos naturais. Na época foi utilizado o radar de visada lateral (SLAR – side-looking airborne radar) o que demonstrou um avanço tecnológico, já que era um sensor ativo, a imagem podia ser obtida tanto durante o período de dia quanto a noite, pois as micro-ondas penetravam nas nuvens (CPRM, 1996).

O conceito de Elachi é o que mais faz sentido para a definição de sensoriamento remoto, a qual se refere na obtenção de informações a partir da detecção e mensuração das mudanças que um determinado objeto impõe aos campos de força que o circundam, sejam estes campos eletromagnéticos, acústicos ou potenciais. Porém, alguns estudiosos como Schowengerdt, em 1997, definiu sensoriamento remoto como a obtenção de medidas de propriedades de objetos da superfície terrestre a partir do uso de dados adquiridos de aviões e satélites (NOVO, 2010).

Segundo Rosa e Brito (2013), sensoriamento remoto pode ser definido como uma forma de obter informações de um objeto ou alvo, sem que haja contato físico com o mesmo, utilizando radiação eletromagnética gerada por fontes naturais como o Sol e a Terra, ou por fontes artificiais.

Os sensores sonares permitem a detecção de objetos submersos a partir da mensuração das alterações que estes provocam no campo acústico, a transmissão de um pulso sonoro e a recepção do som refletido determina sua distância. Porém os sistemas foram evoluindo e os equipamentos de sensoriamento mais sofisticados trabalham com pulsos de diferentes frequências, o que permitem um mapeamento mais detalhado dos fundos dos oceanos. Há também os sismógrafos, os quais conseguem distinguir a velocidade de propagação de ondas elásticas nas rochas e estruturas geológicas (NOVO, 2010).

Com isso, podemos definir que sensoriamento remoto é um conjunto de técnicas, equipamentos para processamento de dados, equipamentos de transmissão de dados colocado a bordo de aeronaves, espaçonaves, ou outras plataformas, com objetivos de estudar eventos, fenômenos e processos que ocorrem na superfície do planeta Terra a partir do registro e da análise das interações entre a radiação eletromagnética e as substâncias que o compõe em suas mais diversas manifestações (NOVO, 2010)

2.3 Geoprocessamento

No Brasil, teve início nos anos de 1980 a partir do professor Jorge Xavier da Silva, na UFRJ. Logo após, em 1982 para ser mais exato, veio ao Brasil o dr. Roger Tomlinson, o qual foi responsável pela criação do primeiro SIG (*Geographic Information System*), incentivando grupos de pesquisas a desenvolver SIGs (CÂMARA; DAVIS; MONTEIRO,).

O geoprocessamento é um conjunto de técnicas matemáticas e computacionais para a análise de informações geográficas, através de um sistema de coordenadas (ROSA; BRITO, 2013). Existem também as geotecnologias, que são um conjunto de tecnologias para a coleta, processamento, análise e disponibilização de informações com referência geográfica, e são compostas por hardware, software e *peopleware*, onde juntando as três, forma-se um instrumento fortíssimo para suporte e principalmente para a tomada de decisão (ROSA; BRITO, 2013).

Segundo Moreira (2011) em sua obra, diz o seguinte paragrafo a respeito do geoprocessamento:

O geoprocessamento é um conjunto de tecnologias voltadas à coleta e ao tratamento de informações espaciais para um objetivo específico, ou seja, uma informação atrelada a um atributo geográfico, e é utilizada em diversas áreas da ciência, como cartografia, geografia, agricultura e floresta e a geologia.

Segundo Rosa e Brito (2013), o geoprocessamento pode ser definido como conjunto de tecnologias destinadas a coleta e tratamento de informações espaciais, assim como o desenvolvimento de novos sistemas e aplicações, com diferentes níveis de sofisticções. Ele pode ser aplicado a profissionais que trabalham no âmbito de cartografia digital, processamento digital de imagens e sistemas de informações geográficas.

Os programas que servem para o processamento digital de imagens, utilizando procedimentos e técnicas destinadas a manipulação numérica de imagens digitais com finalidade corrigir distorções e melhorar o poder de discriminação dos alvos são chamados de ERDAS, PCI, SITIM, ENVI, e muitos outros. Já os programas para obter informação geográfica são sistemas destinados à aquisição, armazenamento, manipulação, análise e apresentação de dados referenciados espacialmente são chamados de ArcGIS, ArcVIEW GIS, MapINFO, SGI entre outros (ROSA; BRITO, 2013).

O objetivo é servir de instrumento eficiente para todas as áreas do conhecimento que fazem uso de mapas, possibilitando integrar em uma única base de dados, vários aspectos de uma região, cruzando os dados obtidos de diferentes fontes, gerando novos tipos de informações, para gerar relatórios, documentos gráficos, mapas etc (ROSA; BRITO, 2013).

2.4 Geoestatística

Surgiu na África do Sul, com o estudioso chamado Krige (1951), que de acordo com seus estudos, notou que para encontrar o sentido nas variâncias em estudo era preciso levar em conta as distâncias entre as amostras, surgindo assim o conceito de geoestatística ou a chamada teoria das variáveis regionalizadas, a qual leva em consideração a localização geográfica e a dependência espacial (GREGO; OLIVEIRA; VIEIRA, 2014).

A geoestatística tem objetivo a caracterização espacial de uma variável de interesse por meio do estudo de sua distribuição e variabilidade espaciais, com determinadas das incertezas associadas (YAKAMOTO; LANDIM, 2013). É o conjunto de todos os valores possíveis da variável de interesse, que define a distribuição e variabilidade espacial dessa variável dentro de um dado domínio em espaço bidimensional e tridimensional (YAKAMOTO; LANDIM, 2013).

Com ela, podemos estimar valores de uma certa localização que não foi medida, utilizando uma função de correlação espacial entre os dados sem viés e com variância mínima. Para isso podemos utilizar os métodos de interpolação por krigagem, a qual consiste em ponderar os vizinhos mais próximos do ponto a ser estimado, seguindo critérios criados para não ser superestimado, para que os estimadores tenham menor variância dentre os estimadores não tendenciosos (GREGO; OLIVEIRA; VIEIRA, 2014).

Segundo Molin (2002), há uma grande importância para a agricultura de precisão, pois ajuda na definição de unidades de manejo a partir de mapas de produtividades.

2.5 Mapa de fertilidade

Atualmente tem se tornado mais popular a geração de mapas individuais da fertilidade do solo, para isso, deve-se realizar amostragem de solo no talhão para que determine a qualidade do solo com maior precisão (MAPA, 2009).

Segunda Wilda (2014), os mapas de fertilidade são fundamentais na agricultura de precisão, pois tem o propósito de buscar informações mais precisas sobre o manejo agrícola a ser aplicado e diminuir os gastos com insumos agrícolas. Para Richetti (2012), os gastos com fertilizantes é o que abrange a maior parcela dos custos de produção da soja.

Para elaborar um mapa de fertilidade, o GPS é utilizado para demarcar os pontos de coleta e então são coletadas subamostras ao redor desse ponto, para em seguida destinar para análise em laboratório. Após as análises, utiliza-se a técnica de interpolação, uma vez que

as amostras de solo possuem discrepância, mesmo em análises de curto intervalo (GREGO; OLIVEIRA; VIEIRA, 2014)

Com a análise do solo onde será realizado o plantio, pode-se notar se há falta ou excesso de algum nutriente, porém pode também notar em análises foliares, mas ela acaba sendo uma análise mais complementar, feito para verificar o balanço nutricional e eficiência das estratégias de adubação.

No entanto, a planta não depende somente dos nutrientes do solo que são disponibilizados, mas também as partes físicas como por exemplo a distribuição granulométrica ou textura do solo, a capacidade de troca catiônica, capacidade de armazenamento de água, tendência a compactação (GREGO; OLIVEIRA; VIEIRA, 2014)

Sendo assim, com o mapa podemos ter uma amostragem detalhada e com precisão do solo, ver as relações macro e micronutrientes disponíveis, podendo ser gerado recomendações de adubação, e obter cruzamento de dados dos mapas de colheita com o de fertilidade. Pode ser adotado estratégias para realizar uma recomendação de correção de nutrientes do solo, sendo adubações corretivas ou de manutenção, reduzindo os custos do produtor, os impactos ambientais, e aumento do rendimento.

2.6 Machine Learning (ML)

Esta técnica consiste basicamente na capacidade dos computadores de aprenderem com base em dados, podem ser divididos em algoritmos de classificação e regressão, em aprendizado supervisionado e não supervisionado. Cada um deles tem sua particularidade, em classificação gera resultados categóricos e já a regressão gera predição de valores contínuos. Já os supervisionados para cada amostra de entrada é apresentado um resultado esperado de saída, alguns algoritmos supervisionados podem ser: K-Nearest Neighbors (K-NN), Support Vector Machine (SVM), Redes Neurais Artificiais (RNA), dentre outros. E os não supervisionados apenas as amostras de entradas são apresentadas ao algoritmo (QUEIROZ *et al.*, 2022).

O presente método utiliza de dados para fazer predições, como fertilidade do solo, severidade de doenças, dosagem de um fertilizante, entre outros (QUEIROZ *et al.*, 2022).

O Machine Learning usa o banco de dados que contém as observações (amostras ou exemplos) e as características, as observações são organizadas em linhas no banco de dados, e as características são organizadas em colunas, sendo assim o formato padrão desse método (QUEIROZ *et al.*, 2022).

Atualmente, esta técnica de análise está sendo incorporada em estudos sendo utilizados de forma alternativa a Krigagem Ordinária em mapeamentos digitais de atributos de solo, se baseia nos dados de atributos e tenta assimilar padrões entre os dados e desta forma realizar previsões. Para a realização deste tipo de análise, vários fatores devem ser levados em conta, como variáveis ambientais e climáticas, dados de solo e plantas, imagem de satélite, mapas de

rendimentos e modelos de elevação digital. Dito isso, o software QGIS com o plug-in Smart-Map, consegue realizar estas análises de forma eficiente, e automática (QUEIROZ *et al.*, 2022).

O Machine Learning pode ter grande capacidade de ajuste, porém alguns problemas podem apresentar, devido à alta quantidade de características e dados observados, podendo ocorrer modelos de validação cruzadas superajustadas, tendo que realizar a redução da dimensionalidade ou a seleção de características mais importantes para construir o modelo (QUEIROZ *et al.*, 2022).

2.7 Krigagem Ordinária (KO)

A krigagem vem do termo em francês Krigeage e do inglês kriging é um processo geoestatístico de estimativa de valores de variáveis distribuídas no espaço e/ou tempo, com base de valores adjacentes quando considerados interdependentes pela análise variográfica. Pode ser comparado com os métodos tradicionais de estimativa por médias ponderadas ou por médias móveis, mas a diferença fundamental é que somente a krigagem apresenta estimativas não tendenciosas e a mínima variância associada ao valor estimado (YAKAMOTO; LANDIM, 2013). A krigagem não necessita ter sua média populacional conhecida e seu erro de variância é o mínimo, e para que isso ocorra, há condição que a soma dos pesos seja igual a 1 (PINTO; ROCHA; RAMOS, 2021)

De forma geral, a krigagem é uma predição espacial do valor de uma variável regionalizada em um local não observado, dentro da área de interesse, são levados em consideração os pontos próximos (vizinhos), e assim consegue fazer a estimativa. Sabendo disso, podemos notar que é um método que leva em considerações características espaciais, que é necessário ter vizinhos para realizar estimações de pontos onde não se há parâmetros, e caso não houver continuidade espacial, não há necessidade de realizar o processo de interpolação (OLIVEIRA; GREGO; BRANDÃO, 2015).

Segundo Yakamoto e Landim (2013), a krigagem devido sua facilidade e seus resultados serem eficientes, considera um estimador de sucesso. Não somente a krigagem, mas toda estimativa geoestatística tem como objetivo a modelagem espacial em estudo, determinando então a variabilidade espacial da variável em interesse.

A fórmula utilizada para realização da Krigagem Ordinária, é feita pela equação 1.

$$Z^*(x) = \sum_{i=1}^n \lambda_i Z(x_i) \quad (1)$$

Onde: $Z^*(x)$ é o valor a ser estimado, i é o peso dado a cada um dos valores observados da variável no lugar X , $Z(x_i)$ é o valor em pontos amostrados perto do local a ser interpolado.


3 MATERIAIS E MÉTODOS

3.1 Local do experimento

O presente trabalho foi realizado na propriedade rural da família Scolari, está situada no município de Marmeleiro – PR (Figura 1), nas coordenadas geográficas centrais -289412.68 de latitude Sul, 7094652.17 de longitude Oeste no sistema de referência WGS 84 / UTM zone 22S, e altitude média 650 m, em uma demarcação de 9,8 hectares.

De acordo com a Classificação Climática de Köppen, o clima é subtropical, sendo verões quentes e úmidos, geadas não são frequentes, e sem estação de seca definida, a precipitação média anual é entre 2.000 a 2.500 mm.

Figura 1 – Local do experimento, imagem de satélite disponibilizada pelo Google Satellite com área demarcada pelo software QGIS




Fonte: Autoria própria (2023).

3.2 Amostragem de solo

Para determinar as características químicas do solo da propriedade do estudo, foi necessário realizar coletas de amostras em determinados pontos. Com base no mapa da propriedade foram determinados os pontos de amostragem para a coleta de amostras de solo (Figura 2). Os pontos foram determinados no software QGIS, buscando uma distribuição espacial uniforme, abrangendo toda a área da propriedade com pontos equidistantes. Essa distribuição possibilita que as interpolações tenham maior índice de sucesso devido aos espaçamentos equidistantes e distribuídos na área do estudo. No levantamento de campo, utilizou-se técnicas de agricultura de precisão para realizar as coletas de solo, onde as amostras foram georreferenciadas por meio do software QGIS, e localizadas com a ajuda de um GPS (*Global Positioning System*).

Os materiais utilizados para coleta de amostras de solo em campo foram: GPS para coleta nos pontos georreferenciados, sacos de 3l, etiquetas de identificação, pá e facão.

Figura 2 – Grid de distribuição espacial dos pontos de amostragem do solo



Sistema de Referência: WGS 84 / UTM zone 22S	
Data: Outubro/2022	Elaborado pelo autor (2022).


Fonte: Autoria própria (2023).

A amostragem de solos consistiu em 40 pontos georreferenciados, considerando a profundidade de 0-20 cm da superfície do solo, e cada amostra foi composta por quatro subamostras (Figura 3) que foram misturadas e colocadas em sacos plásticos de aproximadamente 500 gramas.

As amostras coletadas em campo foram encaminhadas ao Laboratório de Solos da Universidade Tecnologia Federal do Paraná no Câmpus Pato Branco, para realização de análise químicas do solo. Seguindo como base Pavan *et al.* (1992), as amostras foram submetidas a secagem em estufa com temperatura de aproximadamente 40 °C, e triturado em moinho tipo martelo. Após esse procedimento, foram extraídas informações de matéria orgânica (MO), potássio (K), fósforo (P), pH (CaCl_2), alumínio (Al^{3+}), SMP, $\text{H}^+\text{+Al}$, cálcio (Ca), magnésio (Mg), soma de base (SB), percentagem de saturação de base ($\text{V}(\%)$) e Sat. Al (%).

As análises químicas das amostras de solo foram compilados em planilha eletrônica. Posteriormente, os parâmetros foram padronizados para a unidade de medida miligrama por decímetro cúbico (mg/dm^3). Essa padronização foi necessária para realizar as interpolações através do QGIS utilizando o plugin Smart-Map.

Figura 3 – Esquema ilustrativo das coletas do solo



Fonte: Autoria própria (2023).

3.3 Análise de dados

Foi utilizado o software QGIS com o plug-in Smart-Map, que fazem as funções de amostragem, interpolação e confecção de mapas de variáveis, permitindo visualização das variáveis coletadas a campo, e também realiza as análises de Krigagem Ordinária e Machine Learning.

Desta forma, com o objetivo de comparar os dois métodos de interpolação foi utilizado a validação cruzada, análise presente para ambos os métodos do Smart-Map (SEIDEL; OLIVEIRA, 2014).

Para determinar a eficiência do método, foi analisado as validações cruzadas, tanto visualmente quanto de modo estatístico. Na análise estatística dois parâmetros foram analisados, sendo o coeficiente de variação (R^2) e a raiz do erro quadrático médio (RMSE).

O R^2 representa a fração da variância total nos dados observados que pode ser explicada pelo modelo. O R^2 varia entre 0 e 1, sendo que quanto maior o número, melhor a concordância entre modelo e observação e sua fórmula pode ser observada na Fórmula do coeficiente de variação (R^2) Equação 2.

$$R^2 = 1 - \frac{\sum_{k=1}^n (x_k - \hat{x}_k)^2}{\sum_{k=1}^n (x_k - \bar{x})^2}$$

(2)

O RMSE possui uma unidade igual à dimensão dos valores observados e preditos, e seu valor representa uma medida do desvio médio entre observado e predito, sendo descrito na Fórmula da raiz do erro quadrático médio (RMSE) Equação 3.3.

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (x_k - \hat{x}_k)^2} \quad (3)$$

Onde o $\hat{x}_k$ representa o valor estimado do atributo do solo no ponto k, $\bar{x}$ é a média dos n pontos amostrados do atributo do solo, x_k é o valor observado do atributo do solo no ponto k, e o n é o número de pontos amostrados.

4 RESULTADOS E DISCUSSÃO

4.1 ANÁLISE DO SOLO

Após as análises laboratoriais, foi elaborado uma tabela de nutrientes, transformados de cmolc/dm^3 para mg/dm^3 , para padronização dos dados, foi georreferenciado cada ponto com seus devidos valores de nutrição. Com os dados já tabelados, foi realizado um comparativo com o NEPAR (2019), os dados médios encontrados na propriedade Scolari foram comparados as médias apresentadas pelo autor, visando um embasamento na fertilidade do solo (Tabela 1).

Tabela 1 – Dados de fertilidade obtidos através das análises de solo

Característica do solo	Valor médio calculado	Valor médio do Paraná	Dados obtidos pelas análises do solo e comparados com valores adaptados de NEPAR (2019)
MO (g/dm^3)	33	15,5 a 24,13	
P (mg/dm^3)	9	9 a 12	
Ca (mg/dm^3)	1129	220,44 a 400,8	
Mg (mg/dm^3)	393	60,78 a 121,56	
K (mg/dm^3)	149	50,83 a 82,11	

análises do solo e comparados com valores adaptados de NEPAR (2019)

Fonte: Autoria própria (2023).

Com os dados tabelados, foi exportado para o modo “.csv” para o software QGIS e lido com o plug-in Smart-Map. Este plug-in realiza a leitura dos dados, e dentro dele, foi realizado o grid de interpolação com tamanho de pixel X e Y em 1, criando então 494 colunas, e 303 linhas. Com isso, foi possível estabelecer a interpolação dos mapas e também as validações cruzadas.

Com os dados das coletas, foi possível gerar mapas de análise dos parâmetros de matéria orgânica (MO), potássio (K), fósforo (P), magnésio (Mg) e cálcio (Ca). Observou-se através do estudo de Sobral (2015), que a matéria orgânica e o cálcio estão na média, o potássio está muito abaixo da média, e o magnésio, o fósforo e a capacidade de troca de cátions (CTC) estão acima da média.


Para cada parâmetro analisado nas amostras de solo, gerou-se um mapa de comparação entre os métodos de Krigagem Ordinária e *Machine Learning*, assim como, foi realizada a validação cruzada de cada método com o objetivo de comparar ambos os modelos.

4.2 MATÉRIA ORGÂNICA (MO)

Os mapas interpolados de matéria orgânica (Figura 3) são detalhados, porém visualmente não há como notar se a Krigagem Ordinária ou *Machine Learning* consegue interpolar de forma mais eficiente os dados obtidos pelas coletas do solo.

Como dito anteriormente, as métricas analisadas nesse presente trabalho seriam o R^2 e o RMSE. Analisando os dados de validação cruzada dos métodos (Figura 4), observa-se que o *Machine Learning* apresentou um maior R^2 , de 0.474, apresentando uma melhor concordância


Figura 4 – Mapas interpolados de Matéria Orgânica (MO) por *Machine Learning* (ML) e Krigagem Ordinária (KO) obtidos pelo plugin *Smart-Map*



Fonte: Autoria própria (2023).

Figura 5 – Validação Cruzada (MO) de ML e KO obtidos pelo plugin *Smart-Map*

Validação Cruzada - Mat. Orgânica (MO)




Fonte: Autoria própria (2023).

dos dados em comparação a Krigagem Ordinária. O RMSE do método *Machine Learning*, de 5.557, apresentou um valor menor que a Krigagem Ordinária de 6.284. Dessa forma, quando analisado o parâmetro matéria orgânica, o método *Machine Learning* conseguiu ler e interpretar os dados com maior eficiência e precisão em comparação com Krigagem Ordinária.

4.3 FÓSFORO (P)

Nota-se que os mapas interpolados de Fósforo (P) (Figura 5) apresentaram alguns erros com a leitura pelo método de *Machine Learning*, não conseguindo realizar a leitura dos dados corretamente, e desta forma fazendo com que visualmente o mapa não tenha seu detalhamento correto. No método Krigagem Ordinária, o mapa interpolado ficou detalhado, podendo entender de maneira mais fácil os locais onde há necessidade de adubação.

Figura 6 – Mapas interpolados de Fósforo (P) por *Machine Learning* (ML) e Krigagem Ordinária (KO) obtidos pelo plugin *Smart-Map*



Fonte: Autoria própria (2023).


E para a análise de validação cruzada (Figura 6), devido ao erro do sistema de ML, a KO apresentou uma melhor resposta tanto no coeficiente de determinação (R^2), quanto no RMSE. A Krigagem Ordinária apresentou valor R^2 : 0.268 e RMSE: 3.363. Os valores de R^2 e RMSE do método *Machine Learning* foram inferiores ao de Krigagem Ordinária, com 0.010 e 3.363, respectivamente. Com isso, a KO teve um desempenho melhor, analisou os dados e interpolou de forma mais eficiente em comparação com o método de ML.

4.4 POTÁSSIO (K)

Os mapas interpolados de potássio (K) (Figura 7), apresentaram desempenho semelhante ao fósforo. Os dados interpolados de ML não foram eficientes, e desta forma, não teve

Figura 7 – Validação Cruzada (P) de ML e KO obtidas através do software QGIS.


Validação Cruzada - Fósforo (P)



Fonte: Autoria própria (2023).

uma variância amostral tão grande quanto a KO, que conseguiu detalhar melhor os pontos com mínima e máxima de potássio das amostras coletadas.

Figura 8 – Mapas interpolados de Potássio (K) por *Machine Learning* (ML) e Krigagem Ordinária (KO) obtidos pelo plugin *Smart-Map*




Fonte: Autoria própria (2023).

Já para a validação cruzada (Figura 8), podemos notar que novamente a Krigagem Ordinária teve um melhor resultado comparado ao *Machine Learning*, com o R^2 de 0.256 contra R^2 de 0.097 do ML. Também mostra que a Krigagem Ordinária conseguiu ler melhor os dados obtidos pelas análises, e o RMSE comprova isso, o RMSE da KO foi de 46.607 contra o RMSE

de 52.838 do ML.

Figura 9 – Validação Cruzada (K) de ML e KO obtidos pelo plugin *Smart-Map*

Validação Cruzada - Potássio (K)



Fonte: Autoria própria (2023).

4.5 CÁLCIO (Ca)


Como visto em potássio (K) e fósforo (P), o cálcio (Ca) houve as mesmas divergências ocorridas em *Machine Learning*, não sendo possível uma interpolação detalhada, já em Krigagem Ordinária, a interpolação ficou bem detalhada, com um bom entendimento do mapa de fertilidade, diferente do ML em que os dados não foram lidos de maneira correta, e com isso houve uma “padronização” dos dados (Figura 9).

Com isso, podemos verificar também nas validações cruzadas (Figura 10), que o RMSE da Krigagem Ordinária tem um valor menor, dando a entender que houve uma melhor leitura e desenvolvimento dos dados neste tipo de método, porém seu R^2 foi menor pois não houve tanta variância amostral. No método de *Machine Learning*, com o RMSE podemos notar que não houve uma leitura tão eficiente dos dados, porém o R^2 foi melhor, a explicação disto foi devido que, em ML não houve uma leitura correta, e fez com que o intervalo dos dados fosse menor, havendo maior tendência nos dados lidos.

4.6 MAGNÉSIO (Mg)

O mesmo ocorrido em Ca, K e P, para o magnésio (Figura 11) notamos que no método *Machine Learning* não houve uma leitura dos dados de modo correto, fazendo com que o mapa de interpolação seja descrito somente com um intervalo de dados, sendo a média para a interpolação total. No mapa do método de Krigagem Ordinária, nota-se que há uma melhor dis-


Figura 10 – Mapas interpolados de Cálcio (Ca) por *Machine Learning* (ML) e Krigagem Ordinária (KO) obtidos pelo plugin *Smart-Map*



Fonte: Autoria própria (2023).

Figura 11 – Validação Cruzada (Ca) de ML e KO obtidos pelo plugin *Smart-Map*

Validação Cruzada - Cálcio (Ca)




Fonte: Autoria própria (2023).

tribuição dos dados pela interpolação, o método conseguiu realizar uma melhor leitura, fazendo com que a interpolação ficasse mais completa.

Como visto anteriormente, podemos verificar também nas validações cruzadas (Figura 12), que o RMSE da Krigagem Ordinária tem um valor menor, dando a entender que houve uma melhor leitura e desenvolvimento dos dados neste tipo de método, porém seu R^2 foi menor pois não houve tanta variância amostral. No método de *Machine Learning*, com o RMSE foi possível

Figura 12 – Mapas interpolados de Magnésio (Mg) por *Machine Learning* (ML) e Krigagem Ordinária (KO) obtidos pelo plugin *Smart-Map*




Fonte: Autoria própria (2023).

observar que não houve uma leitura eficiente dos dados, porém o R^2 foi melhor, a explicação disto foi devido que, em ML não houve uma leitura correta, e fez com que o intervalo dos dados fosse menor, havendo maior tendência nos dados.

Figura 13 – Validação Cruzada (Mg) de ML e KO obtidos pelo plugin *Smart-Map*

Validação Cruzada - Magnésio (Mg)



Fonte: Autoria própria (2023).

4.7 ANÁLISES DE MAPAS DE FERTILIDADE E VALIDAÇÃO CRUZADA

Com os mapas e validações cruzadas geradas, observou-se que os mapas de fertilidade do solo do método de Krigagem Ordinária foram mais eficientes para este estudo. O método apresentou ser mais apropriado para a agricultura de precisão, pois é possível realizar uma melhor aplicação de nutrientes no solo em pontos georreferenciados, resultando em menor custo de aplicação e aumento no rendimento de aplicação.

O método *Machine Learning* apresentou melhor resultado apenas no parâmetro de matéria orgânica, o qual possibilitou uma melhor interpolação e mostrou-se eficaz. Contudo, não se provou eficiente para o estudo, uma vez que os mapas interpolados e os valores de R^2 e RMSE não apresentaram eficientes ao estudo.

Tabela 2 – Comparativo ML x KO

	<i>Machine Learning</i>		Krigagem Ordinária	
	R^2	RMSE	R^2	RMSE
Cálcio (Ca)	0,594	275,224	0,313	220,894
Fósforo (P)	0,010	3,832	0,268	3,363
Magnésio (Mg)	0,671	98,561	0,103	91,413
Mat. Orgânica (MO)	0,474	5,557	0,354	6,284
Potássio (K)	0,097	52,838	0,256	46,607

Fonte: Autoria própria (2023).

Esses resultados podem ser observados na Tabela 2, os valores de R^2 do método de Krigagem Ordinárias foram superiores ao *Machine Learning* nos parâmetros P e K. Apesar do R^2 do método de *Machine Learning* apresentar valores superiores nos parâmetros Ca, Mg e MO, o método de KO também apresentou valores inferiores de RMSE nos parâmetros Ca, P, Mg e K.

5 CONSIDERAÇÕES FINAIS

Com base nas validações cruzadas, podemos notar que Machine Learning obteve melhor conjunto de dados somente na matéria orgânica, que se notou um menor desvio padrão, e também teve R^2 superior comparado a Krigagem Ordinária. Porém, notou-se que o restante dos parâmetros teve resultados mais satisfatórios no método de Krigagem Ordinária, tanto em vista os mapas de interpolação, quanto pelos dados gerados de RMSE, que foram menores que o método de Machine Learning. A respeito do R^2 , os resultados para Krigagem Ordinária não foram tão satisfatórios, porém o sistema conseguiu ler os dados e fazer essa interpretação, portanto são resultados embasado nas análises de solo, já em Machine Learning, os R^2 de alguns parâmetros são maiores, porém devido ao erro de leitura, não podem ser considerados confiáveis.

Com os mapas feitos e analisados, podemos notar que o plug-in Smart-Map dentro do software QGIS, não consegue analisar algumas métricas de dados no modo ML, enquanto KO consegue realizar a validação cruzada e a interpolação sem ter erros durante o uso.

Desta forma, o plugin Smart-Map foi adequado para a comparar os dois métodos, tendo em vista que o método de Krigagem Ordinária (KO) mostrou ser mais eficiente para a aplicação de nutrientes na propriedade, uma vez que apresenta detalhadamente os pontos onde é necessário fazer as correções. A KO gera mapas mais detalhados em comparação ao método de ML.

O método ML não foi apropriado para a análise de fertilidade do solo, pois não conseguiu ler os dados de forma correta, podendo ser notado em quatro dos cinco nutrientes em estudo, os quais seriam, potássio, cálcio, fósforo e magnésio. Notou-se ao gerar o mapa de interpolação que a leitura realizada dos dados foi um intervalo curto de banda, como por exemplo, o cálcio que teve a legenda mínima de 640 mg/dm³ e a máxima de 1400 mg/dm³ em Krigagem Ordinária, em Machine Learning a interpolação utilizou um intervalo de banda que ficou entre 1152,99 mg/dm³ e 1153 mg/dm³. Com isso, os mapas interpolados com Machine Learning e as validações cruzadas geradas são falhas e não devem ser levadas em consideração para a agricultura de precisão. Não foi possível realizar uma análise estatística com eficácia devido à falta de dados que não foram compreendidos pelo sistema. Porém como observa-se nas validações cruzadas, alguns nutrientes em Machine Learning obtiveram um valor de R^2 melhor, e também um RMSE com valores menores, mas sabendo que, não houve a leitura correta dos dados, sabemos que não podem ser levados em consideração.

Já em Krigagem Ordinária, o método foi eficaz para este estudo, apresentou uma melhor leitura dos dados obtidos das amostras de solo coletadas e gerou mapas de interpolação mais detalhados. Com isso, os mapas de fertilidades ficaram bem demonstrativos e fáceis de serem compreendidos, com demarcações notórias.

REFERÊNCIAS

- CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. Introdução à ciência da geoinformação. p. 345. Disponível em: http://www.faed.udesc.br/arquivos/id_submenu/1423/_introducao_a_ciencia_de_geoinformacao___inpe.pdf. Acesso em: 27 out. 2022.
- CPRM, S. G. do B. **CPRM**. 1996. Url<http://www.cprm.gov.br/publique/Geologia/Sensoriamento-Remoto-e-Geofisica/RADAM-D-628.html>.
- GREGO, C. R.; OLIVEIRA, R. P. d.; VIEIRA, S. R. Geoestatística aplicada a agricultura de precisão. In: _____. **Agricultura de precisão - resultados de um novo olhar**. Embrapa, 2014. Disponível em: <http://www.alice.cnptia.embrapa.br/alice/handle/doc/1002010>. Acesso em: 27 out. 2022.
- MAPA, M. **Agricultura de precisão**. [S.l.], 2009. 31 p. Disponível em: https://www.gov.br/agricultura/pt-br/assuntos/insumos-agropecuarios/arquivos-publicacoes-insumos/agric_precisao.pdf. Acesso em: 09 nov. 2022.
- MENDONÇA-SANTOS, M. d. L.; SANTOS, H. d. Mapeamento digital de classes e atributos de solos: métodos, paradigmas e novas técnicas. Rio de Janeiro: Embrapa Solos., 2003.
- MOLIN, J. Definição de unidades de manejo a partir de mapas de produtividade. **Engenharia Agrícola**, Jaboticabal, v. 22, n. 1, p. 83–92, 2002.
- MOREIRA, M. A. Fundamentos do sensoriamento remoto e metodologia de aplicação. **Viçosa. Editora UFV**, 2011.
- NEPAR, N. E. P. **Manual de adubação e calagem para o estado do Paraná**. [S.l.]: Sociedade Brasileira de Ciência do Solo Curitiba, 2019.
- NOVO, E. M. L. d. M. Sensoriamento remoto: princípios e aplicações. Editora Blucher, 2010.
- OLIVEIRA, R. P. d.; GREGO, C. R.; BRANDÃO, Z. N. **Geoestatística aplicada na agricultura de precisão utilizando o Vesper**. Brasília - DF: Embrapa, 2015.
- PAVAN, M. A. *et al.* **Manual de análise química de solo e controle de qualidade**. [S.l.]: Iapar Londrina, 1992. v. 76.
- PEREIRA, G. W. *et al.* Smart-map: an open-source qgis plugin for digital mapping using machine learning techniques and ordinary kriging. **Agronomy**, MDPI, v. 12, n. 6, p. 1350, 2022.
- PINTO, Y. G.; ROCHA, M. M. d.; RAMOS, G. Z. **Comparação entre krigagem ordinária e krigagem lognormal, aplicadas a uma base de dados de cobre da Mina Sequeirinho**. 2021.
- QUEIROZ, D. M. d. *et al.* **Agricultura digital**. 2. ed. [S.l.]: Oficina de Textos, 2022. 224 p.
- RICHETTI, A. Viabilidade econômica da cultura da soja na safra 2012/2013, em mato grosso do sul. Dourados: Embrapa Agropecuária Oeste., 2012.
- ROSA, R.; BRITO, J. L. S. **Introdução ao geoprocessamento**. [S.l.], 2013. 142 p. Acesso em: 09 nov. 2022.
- SARAIVA, A. M.; CUGNASCA, C. E.; HIRAKAWA, A. R. Aplicação em taxa variável de fertilizantes e sementes. In: _____. [S.l.]: Universidade Federal de Viçosa, 2000.

SEIDEL, E. J.; OLIVEIRA, M. S. d. Novo índice geoestatístico para a mensuração da dependência espacial. **Revista Brasileira de Ciência do Solo**, SciELO Brasil, v. 38, p. 699–705, 2014. Acesso em: 09 nov. 2022.

WILDA, L. R. M. **Amostragem georreferenciada e aplicação à taxa variável de corretivos e fertilizantes: dinâmica da fertilidade do solo em lavoura de grãos do Cerrado**. 2014. Tese (Doutorado), 2014.

YAKAMOTO, J. K.; LANDIM, P. M. B. Geoestatística: Conceitos e aplicações. **São Paulo: Oficina de Textos**, 2013.

**ANEXO A – Resumo dos laudos das análises do solo: experimento em
Marmeleiro - PR**

Tabela 3 – Resumo dos laudos das análises do solo: experimento em Marmeleiro - PR

Pontos	MO (g/dm ³)	P (mg/dm ³)	K (mg/dm ³)	Ca (mg/dm ³)	Mg (mg/dm ³)
1	39	15	227	1363	425
2	21	5	98	1142	365
3	29	6	74	1202	547
4	25	8	82	1042	450
5	17	8	129	882	316
6	24	4	106	1082	377
7	20	6	94	902	267
8	23	6	94	1102	365
9	28	23	196	1423	559
10	25	11	98	822	280
11	28	4	86	1263	413
12	32	28	227	1743	669
13	34	5	106	942	340
14	31	6	149	1082	340
15	27	9	207	1403	583
16	32	10	246	1263	523
17	43	11	227	1242	365
18	31	12	196	1463	535
19	11	13	180	1303	353
20	43	20	375	1643	608
21	35	12	180	1303	450
22	35	4	172	1323	511
23	40	4	227	862	328
24	36	14	86	1082	365
25	35	7	94	1042	316
26	34	4	109	1263	425
27	28	4	176	641	243
28	38	10	207	1323	438
29	47	9	125	1423	377
30	35	8	109	1142	365
31	38	4	86	982	316
32	50	6	188	962	413
33	31	12	121	1162	413
34	38	8	188	1202	353
35	39	11	102	1202	304
36	47	5	109	1182	353
37	40	6	168	1002	316
38	38	4	121	521	231
39	42	7	117	762	304
40	36	4	63	481	219

Fonte: Autoria própria (2023).