



MAPEAMENTO DE FÓSFORO E POTÁSSIO COM KRIGAGEM E APRENDIZADO DE MÁQUINA EM AGRICULTURA DE PRECISÃO

Julia M. OLIMPIO¹; Ana J. L. RODRIGUES²; Sabrina de F. V. da COSTA³; Cleber K. de SOUZA⁴

RESUMO

O avanço das geotecnologias na agricultura tem proporcionado práticas mais eficientes e sustentáveis. O mapeamento digital de atributos do solo é uma ferramenta essencial para otimizar o uso de insumos e aumentar a produtividade. Sendo assim, este trabalho tem como objetivo integrar técnicas geoestatística e *Machine Learning* para o mapeamento de atributos do solo. O estudo foi realizado no IFSULDEMINAS – *Campus Inconfidentes*. Foram coletados 160 pontos georreferenciados. Os dados foram analisados no RStudio e processados no QGIS. A comparação entre os métodos foi realizada através de validação cruzada, utilizando os indicadores R^2 e RMSE. Os resultados indicam que a krigagem ordinária é mais eficaz na detecção de microvariações no solo, essencial para intervenções localizadas, como a aplicação de fertilizantes. Já o modelo de aprendizado de máquina mostrou-se eficiente em gerar distribuições homogêneas, úteis para recomendações gerais. A combinação das duas abordagens pode otimizar as práticas de agricultura de precisão, oferecendo tanto uma visão detalhada quanto uma abordagem mais ampla para o manejo de nutrientes.

Palavras-chave: Interpolação espacial; Geoestatística; Machine Learning; SIG; Variabilidade espacial

1. INTRODUÇÃO

O uso de geotecnologias tem impulsionado a modernização da agricultura, promovendo práticas de manejo mais eficientes e sustentáveis. Entre essas tecnologias, os mapas digitais de atributos do solo se destacam por permitir diagnósticos detalhados da variabilidade edáfica, orientando a aplicação localizada de insumos (Mendes *et al.*, 2020).

A agricultura de precisão depende da análise espacial do solo, cuja variabilidade natural exige métodos de interpolação. Técnicas geoestatísticas como a krigagem ordinária são amplamente utilizadas por considerarem a estrutura espacial dos dados (Machado *et al.*, 2021), embora sua eficácia dependa de uma boa densidade amostral.

Nesse cenário, algoritmos de Machine Learning vêm se consolidando como alternativas eficazes, com maior flexibilidade na modelagem de dados complexos, sobretudo em regiões com amostragem escassa (Tavares *et al.*, 2019).

Ferramentas de código aberto, como o QGIS, integradas a pacotes do R e ao ambiente RStudio, viabilizam a aplicação de metodologias integradas de análise espacial, interpolação e validação, possibilitando workflows acessíveis, eficientes e reprodutíveis.

¹Discente, IFSULDEMINAS – *Campus Inconfidentes*. E-mail: juliamaiolini01@gmail.com

²Discente, IFSULDEMINAS – *Campus Inconfidentes*. E-mail: ana.lopes@alunos.ifsuldeminas.edu.br

³Discente, IFSULDEMINAS – *Campus Inconfidentes*. E-mail: sabrina.viana@alunos.ifsuldeminas.edu.br

⁴Orientador, IFSULDEMINAS – *Campus Inconfidentes*. E-mail: cleber.souza@ifsuldeminas.edu.br

(Muenchow *et al.*, 2017). Além disso, o sensoriamento remoto e o geoprocessamento ampliam o potencial de monitoramento e análise de áreas agrícolas.

Diante desse contexto, este trabalho tem como objetivo propor uma abordagem integrada entre geoestatística e aprendizado de máquina para o mapeamento digital de atributos do solo, visando maior acurácia preditiva e eficiência no manejo químico do solo.

3. MATERIAL E MÉTODOS

A área experimental encontra-se localizada na Fazenda-Escola do Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais (IFSULDEMINAS) – *Câmpus Inconfidentes*, no município de Inconfidentes, Estado de Minas Gerais, com coordenadas geográficas de latitude 22°18'25,8" S e longitude 46°19'30,2" W. O local está inserido na zona rural do município, caracterizada por um relevo suavemente ondulado e pela predominância de atividades agropecuárias.

A amostragem do solo foi realizada por meio de um grid regular (17 m x 17 m) gerado no software QGIS, totalizando 160 pontos amostrais. A navegação até o ponto de coleta foi realizada com auxílio de sistema global de navegação por satélite (GNSS) onde foram coletadas quatro subamostras na camada de 0 a 20 cm.

As coletas seguiram as diretrizes da agricultura de precisão, com o objetivo de representar adequadamente a variabilidade espacial da área. O material coletado foi acondicionado em sacos plásticos identificados e, posteriormente, enviado ao Laboratório de Solos do IFSULDEMINAS – *Câmpus Inconfidentes*, para análise química.

De posse dos resultados, os mesmos foram organizados em planilhas eletrônicas e, em seguida, analisados no RStudio e os mapas gerados foram processados no software QGIS. Para a interpolação dos dados, foram aplicados dois métodos: Krigagem Ordinária (KO), baseada em semivariância, e Machine Learning (ML), utilizando Modelos Aditivos Generalizados (GAM) do pacote “mgcv”.

A eficiência de ambos os métodos foi avaliada por meio da técnica de validação cruzada, utilizando dois indicadores estatísticos: Coeficiente de Determinação (R^2): que mede a proporção da variância explicada pelo modelo, variando entre 0 e 1 e Raiz do Erro Quadrático Médio (RMSE): que avalia a diferença média entre os valores observados e estimados, fornecendo o desvio padrão dos erros de predição.

As interpolações foram realizadas com uma resolução espacial regular, utilizando pixels de 1m x 1m, gerando mapas de fertilidade para os atributos analisados.

4. RESULTADOS E DISCUSSÃO

A análise dos mapas de fósforo e potássio disponível (Figura 1) oferece importantes *insights*

sobre as variações espaciais desses nutrientes no solo, fundamentais para o planejamento de práticas de manejo agrícola.




Figura 1. Mapas de distribuição espacial do fósforo e potássio disponíveis no solo, gerados pelos métodos de krigagem e aprendizado de máquina (Machine Learning). Inconfidentes, MG, 2025.

Fonte: Autores, 2025

A Krigagem, como técnica de interpolação espacial, mostrou-se altamente eficaz na

identificação das variações locais, destacando áreas com alta concentração de fósforo, superiores a 18 mg dm^{-3} , e valores inferiores a 8 mg dm^{-3} . Esse método mostrou-se sensível à variabilidade espacial, permitindo a identificação precisa de unidades de gestão diferenciadas. Essa característica é particularmente relevante para a agricultura de precisão, onde intervenções localizadas, como a aplicação de fertilizantes por taxa variável, são fundamentais.

Por outro lado, o modelo de aprendizado de máquina apresentou uma distribuição mais homogênea, suavizando as variações espaciais e dificultando a detecção de microvariações. Esse comportamento é típico dos algoritmos de ML, que tendem a generalizar padrões com base em múltiplas variáveis, como observado nas distribuições de fósforo e potássio.

No caso do potássio disponível, a Krigagem revelou uma distribuição espacial mais detalhada. Essas informações são valiosas para a aplicação precisa de fertilizantes, especialmente em áreas onde o potássio é um nutriente limitante. Em contraste, o modelo de ML suavizou as variações, criando uma distribuição mais contínua, o que pode dificultar a identificação de zonas que necessitam de intervenções específicas para otimizar a fertilização.

5. CONCLUSÃO

O modelo de aprendizado de máquina suaviza variações espaciais, sendo útil em áreas de baixa densidade amostral, mas limitado para identificar microvariações importantes.

A krigagem identificou áreas críticas de potássio e zonas de alta concentração, enquanto o modelo de ML apresentou uma distribuição homogênea, dificultando intervenções localizadas.

A krigagem é indicada para áreas com alta variabilidade espacial, enquanto o ML é mais adequado para visões gerais em regiões com dados limitados.

REFERÊNCIAS

MACHADO, L. A. Z.; SOARES, F. L.; PEREIRA, R. S.; SILVA, J. R. A.; ALMEIDA, C. R. Comparação de métodos de interpolação espacial na estimativa de atributos do solo para fins agrícolas. **Pesquisa Agropecuária Tropical**, v. 51, e68440, 2021.

MENDES, W. S.; DEMATTÊ, J. A. M.; BARROS, A. S.; SALAZAR, D. F. U.; AMORIM, M. T. A. Geostatistics or machine learning for mapping soil attributes and agricultural practices. **Revista Ceres**, Viçosa, v. 67, n. 4, p. 330–336, 2020. DOI: <https://doi.org/10.1590/0034-737X202067040010>.

MUENCHOW, J.; SCHRATZ, P.; BRENNING, A. RQGIS: integrating R with QGIS for statistical geocomputing. **The R Journal**, [S.l.], v. 9, n. 2, p. 409–428, 2017. Disponível em: <https://journal.r-project.org/articles/RJ-2017-067/>. Acesso em: 29 jul. 2025.

TAVARES, R. C.; TEIXEIRA, D. B.; MONTANARI, R. Aprendizado de máquina na predição de atributos físicos e químicos do solo em áreas agrícolas. **Revista de Informática Aplicada**, v. 15, n. 1, p. 25–36, 2019.