

**PROGRAMA DE PÓS-GRADUAÇÃO EM AGRICULTURA E
INFORMAÇÕES GEOESPACIAIS – PPGAIG**

SAMUEL PHILIPPE

**Krigagem Ordinária vs. *Support Vector Machine* no Smart-Map do QGIS:
Qual Método é Mais Acurado na Descrição Espacial da Produtividade da Soja?**

**PROGRAMA DE PÓS-GRADUAÇÃO EM AGRICULTURA E
INFORMAÇÕES GEOESPACIAIS – PPGAIG**

SAMUEL PHILIPPE

**Krigagem Ordinária vs. *Support Vector Machine* no Smart-Map do QGIS:
Qual Método é Mais Acurado na Descrição Espacial da Produtividade da Soja?**

Dissertação apresentada ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais - PPGAIG da Universidade Federal de Uberlândia - UFU, campus Monte Carmelo, como requisito para a obtenção do título de Mestre, sob orientação do Prof. Dr. Vinicius Francisco Rofatto e coorientação do Prof. Dr. George Deroco Martins.

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

P551
2025

Philippe, Samuel, 1989-
Krigagem Ordinária vs. Support Vector Machine no
Smart-Map do QGIS: Qual Método é Mais Acurado na
Descrição Espacial da Produtividade da Soja? [recurso
eletrônico] / Samuel Philippe. - 2025.

Orientadora: Vinicius Francisco Rofatto.
Coorientadora: George Deroco Martins.
Dissertação (Mestrado) - Universidade Federal de
Uberlândia, Pós-graduação em Agricultura e Informações
Geoespaciais.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.di.2025.225>

Inclui bibliografia.

Inclui ilustrações.

1. Agronomia. I. Rofatto, Vinicius Francisco ,1986-,
(Orient.). II. Martins, George Deroco ,1987-,
(Coorient.). III. Universidade Federal de Uberlândia.
Pós-graduação em Agricultura e Informações Geoespaciais.
IV. Título.

CDU: 631

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Agricultura e Informações Geoespaciais				
Defesa de:	Dissertação de Mestrado Acadêmico				
Data:	28/03/2025	Hora de início:	14:00	Hora de encerramento:	17:00
Matrícula do Discente:	32212AIG001				
Nome do Discente:	Samuel Philippe				
Título do Trabalho:	Krigagem Ordinária vs. Support Vector Machine no Smart-Map do QGIS: Qual Método é Mais Acurado na Descrição Espacial da Produtividade da Soja?				
Área de concentração:	Informações geoespaciais e tecnologias aplicadas à produção agrícola				
Linha de pesquisa:	Desenvolvimento e aplicações de métodos em informações geoespaciais				
Projeto de Pesquisa de vinculação:	Novas abordagens de medição e modelagem espacial para a agricultura				

Reuniu-se na sala virtual <https://conferenciaweb.rnp.br/sala/vinicius-francisco-rofatto>, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agricultura e Informações Geoespaciais, assim composta: Professores Doutores: Vinicius Francisco Rofatto (UFU), orientador do candidato; Marcelo Tomio Matsuoka (UFU); e Sebastião Nilce Souto Filho (Universidade Prof. Edson Antônio Velano - UNIFENAS).

Iniciando os trabalhos o presidente da mesa, Dr. Vinicius Francisco Rofatto, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao discente a palavra para a exposição do seu trabalho. A duração da apresentação do discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir o candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o candidato:

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Vinicius Francisco Rofatto, Coordenador(a)**, em 28/03/2025, às 17:18, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Sebastião Nilce Souto Filho, Usuário Externo**, em 28/03/2025, às 18:40, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Marcelo Tomio Matsuoka, Professor(a) do Magistério Superior**, em 01/04/2025, às 08:25, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **6216119** e o código CRC **592C2A5B**.

Referência: Processo nº 23117.020163/2025-63

SEI nº 6216119

AGRADECIMENTOS

Em primeiro lugar, agradeço a todas as forças do universo por sempre terem enviado energias positivas em minha direção, permitindo-me resistir e perseverar durante esse período difícil. Em segundo lugar, agradeço a mim mesmo pela coragem, determinação e paciência de seguir em frente, apesar das grandes dificuldades encontradas ao longo do meu caminho.

À memória do meu tio, Villa Philippe, por ter cuidado de mim como se eu fosse seu próprio filho.

Um agradecimento especial ao professor Laguerre, por me colocar no caminho da educação e por me mostrar os benefícios e a importância dela.

Ao meu amado filho, Sam Winner Philippe, que deu sentido à minha vida desde o dia em que veio ao mundo.

Aos meus orientadores, Professor Doutor Vinicius Francisco Rofatto e Professor Doutor George Deroco Martins, pelos conselhos, paciência e pelo conhecimento transmitido. Apesar das diferenças em nossas linguagens, que representaram um desafio para a nossa comunicação, eles não desistiram e me ofereceram seu apoio incondicional.

Aos meus amigos: James, Mackendy, Mackenson, Germinal, Wismy, Gessy e, especialmente, Monhel Pierre, por sua contribuição a este trabalho.

Sumário

RESUMO	5
ABSTRACT	5
INTRODUÇÃO	6
MATERIAL E MÉTODOS	7
Área de Estudo	7
Dados disponíveis.....	8
Delineamento Experimental	9
Krigagem Ordinária no Smart-Map	10
Support Vector Machine no Smart-Map.....	13
RESULTADOS	13
CONCLUSÃO	19
Referências.....	20

RESUMO

Um dos grandes desafios da agricultura de precisão é detectar a variabilidade espacial da unidade produtiva. Quanto maior a acurácia na descrição espacial da produtividade, menores serão os impactos ambientais e maiores os retornos econômicos. Para atingir esse objetivo, frequentemente realiza-se uma amostragem densa ao longo da lavoura, o que pode aumentar os custos de implementação de um sistema de gerenciamento agrícola. Algoritmos baseados em aprendizado de máquina (ML) e métodos geoestatísticos são capazes de descrever a variabilidade espacial, mesmo sob condições de amostragem reduzida. No entanto, esses modelos apresentam diversas variações que podem dificultar sua aplicação por parte dos usuários finais. Para suprir essa lacuna, o plugin Smart-Map foi desenvolvido para complementar o QGIS, com o objetivo de simplificar o uso desses métodos e facilitar sua aplicação prática. Entretanto, ainda não está claro na literatura qual desses métodos é mais eficaz. Nesse sentido, avaliamos a Krigagem Ordinária (KO) em comparação com o algoritmo ML *Support Vector Machine* (SVM) na predição da produtividade da soja, considerando diferentes níveis de amostragem: 100% (795 pontos), 80% (636 pontos), 60% (477 pontos) e 40% (318 pontos). Os resultados indicam que a KO teve um desempenho geral superior ao do algoritmo SVM, com média de R^2 de 0,6845 e RMSE de 0,609 tons/hectare, comparado a uma média de R^2 de 0,5315 e RMSE de 0,73 tons/hectare para o SVM. No nível de amostragem completo (100%), a KO apresentou os melhores resultados, com $R^2 = 0,819$ e RMSE = 0,47 tons/hectare, enquanto o SVM teve $R^2 = 0,704$ e RMSE = 0,599. Em condições de amostragem reduzida (40%), a KO manteve um desempenho relativamente consistente, enquanto o SVM apresentou uma queda significativa no R^2 para 0,394, com um aumento do RMSE para 0,903 tons/hectare. Esses resultados sugerem que, embora a KO exija um conhecimento mais especializado, ela é mais robusta em cenários de amostragem reduzida em comparação com o SVM, que poderia se beneficiar de informações adicionais além da posição do atributo de produtividade. Além disso, é possível que o SVM apresente um desempenho superior se o Smart-Map incorporasse outras funções de covariância (Kernel), como a Quadrática Racional, o que poderia proporcionar uma modelagem mais acurada da variabilidade espacial.

Palavras-chave: *Support Vector Machine*, Métodos Geoestatísticos, Densidade Amostral, Produtividade da Soja.

ABSTRACT

One of the major challenges in precision agriculture is detecting the spatial variability of the productive unit. The higher the accuracy in describing yield spatially, the lower the environmental impact and the greater the economic returns. To achieve this goal, dense sampling across the field is often conducted, which can increase the costs of implementing an agricultural management system. Machine learning (ML) algorithms and geostatistical methods can describe spatial variability even under reduced sampling conditions. However, these models exhibit various complexities that may hinder their application by end users. To bridge this gap, the Smart-Map plugin was developed to complement QGIS, simplifying the use of these methods and facilitating their practical application. However, it is still unclear in the literature which of these methods is more effective. In this study, we evaluated Ordinary Kriging (OK) compared to Support Vector Machine (SVM) in predicting soybean yield at different sampling levels: 100% (795 points), 80% (636 points), 60% (477 points), and 40% (318 points). The results indicate that OK generally outperformed SVM, with an average R^2 of 0.6845 and RMSE of 0.609 tons/hectare, compared to an average R^2 of 0.5315 and RMSE of 0.73 for SVM. At the full sampling level (100%), the OK showed the best results, with $R^2 = 0,819$ and RMSE = 0,47 tons/hectare, whereas SVM achieved $R^2 = 0,704$ and RMSE = 0,599 tons/hectare. Under reduced sampling conditions (40%), the OK maintained relatively consistent performance, while SVM experienced a significant drop in R^2 to 0.394, with an increase in RMSE to 0.903 tons/hectare. These findings suggest that although OK requires more specialized knowledge, it is more robust under reduced sampling scenarios compared to SVM, which could benefit from additional input attributes beyond yield position. Moreover, SVM performance could improve if Smart-Map incorporated other covariance functions, such as the Rational Quadratic, providing a more accurate modeling of spatial variability.

Keywords: *Support Vector Machine*, Geostatistical methods, Sampling density, Soybean yield.

Referência Bibliográfica

Philippe, Samuel. Krigagem Ordinária vs. Support Vector Machine no Smart-Map do QGIS: Qual Método é Mais Acurado na Descrição Espacial da Produtividade da Soja? Dissertação (Mestrado em Agricultura e Informações Geoespaciais) - Universidade Federal de Uberlândia, Monte Carmelo, 2025. DOI: <https://orcid.org/0009-0001-3020-4595>

INTRODUÇÃO

Atualmente, a população mundial ultrapassa os 8 bilhões e espera-se que continue a aumentar nos próximos anos e décadas. Estima-se que atingirá 9,6 bilhões em 2050 (ONU, 2021). Esse aumento da população terá um impacto direto sobre os recursos naturais e econômicos, especialmente na agricultura. A agricultura enfrenta uma pressão crescente devido à escassez de recursos, que já representa um desafio significativo para alimentar a população mundial. Portanto, é crucial que todos os países busquem soluções para aumentar a produtividade agrícola, enquanto asseguram a segurança alimentar para as gerações atuais e futuras. No entanto, esse aumento na produção de alimentos deve ser acompanhado por uma gestão sustentável das terras agrícolas, com o objetivo de mitigar ou, ao menos, retardar os impactos negativos na qualidade e quantidade dos recursos hídricos e do solo, na degradação das terras, nas emissões de gases de efeito estufa e na biodiversidade (Alfredo e Roberto, 2007; WEISS et al., 2020).

Dentro desse contexto, a Agricultura de Precisão (AP) surge como uma abordagem inovadora para otimizar a produção agropecuária, com foco no aumento do retorno econômico, na promoção da sustentabilidade e na minimização dos impactos ambientais das atividades agrícolas. A AP baseia-se na análise da variabilidade espacial e temporal dos sistemas de produção, empregando tecnologias e ferramentas específicas para gerenciar insumos de forma mais eficiente e direcionada (Zhang et al., 2002).

Um dos principais desafios da AP é detectar a variabilidade espacial dentro da unidade

produtiva. A descrição espacial da produtividade é essencial para reduzir os impactos ambientais e maximizar os retornos econômicos (Bongiovanni & Lowenberg-Deboer, 2004). A variabilidade espacial e temporal no campo é um dos principais desafios para a agricultura de precisão. Os agricultores enfrentam dificuldades em mapear essa variabilidade devido a fatores como limitações tecnológicas, custos elevados e a complexidade dos dados. Uma descrição imprecisa pode levar a decisões inadequadas na aplicação de insumos, resultando em desperdícios, perdas financeiras e impactos ambientais negativos, como contaminação do solo e da água. Além disso, a falta de dados detalhados pode comprometer a produtividade, afetando a eficiência do manejo agrícola. Métodos avançados, como sensores remotos, drones e análise de big data, podem ajudar a melhorar essa precisão. No entanto, a adoção dessas tecnologias ainda enfrenta barreiras, como capacitação técnica e infraestrutura. Assim, o desenvolvimento de estratégias acessíveis e eficazes é essencial para otimizar o uso dos recursos e aumentar a sustentabilidade agrícola (Pierce, F. J., e Nowak, P., 1999; McBratney, A., Whelan, B., Ancev, T., e Bouma, J. 2005; Zhang, N., Wang, M., & Wang, N., 2002). Neste sentido, para alcançar esse objetivo, frequentemente são realizadas amostragens densas ao longo da lavoura, o que pode aumentar significativamente os custos de implementação dos sistemas de gerenciamento agrícola.

Os custos elevados das amostragens densas na agricultura decorrem de fatores como tecnologia utilizada (sensores, drones, GPS), mão de obra

especializada para coleta e análise, e logística envolvida no transporte e processamento das amostras. A necessidade de equilibrar precisão e viabilidade econômica torna essencial a otimização da quantidade de pontos amostrais. Métodos como interpolação geoestatística e amostragem direcionada ajudam a reduzir custos sem comprometer a qualidade dos dados (Brus, D. J., e Heuvelink, G. B. M., 2007; McBratney, A. B., Mendonça Santos, M. L., e Minasny, B., 2003).

Para mitigar esses custos, métodos avançados, como algoritmos baseados em aprendizado de máquinas (Machine Learning – ML) e técnicas geoestatísticas, são empregados para descrever a variabilidade espacial. Entre essas técnicas, a Krigagem Ordinária (KO) como técnica geoestatística e o Support Vector Machine (SVM) são amplamente utilizadas. A KO, uma técnica de interpolação geoestatística, tradicionalmente se destaca por sua capacidade de modelar a variabilidade espacial com base em dados amostrais (Cressie, 1993). Por outro lado, o SVM, uma técnica de aprendizado de máquina, oferece uma abordagem alternativa que pode ser mais flexível e menos dependente de pressupostos específicos sobre a estrutura dos dados (Vapnik, 2010).

Embora ambas as técnicas mostrem potencial na predição da produtividade agrícola, uma técnica pode apresentar melhor acurácia que outra em algumas aplicações. Dada a potencial aplicação de técnicas de ML e geoestatística, o plugin Smart-Map, integrado ao software QGIS,

foi utilizado neste estudo para avaliar a eficácia da KO e o SVM na estimativa da produtividade da soja. A análise foi feita por meio do emprego das métricas estatísticas de coeficiente de determinação (R^2) e da raiz do erro quadrático médio (Root Mean Squared Error) – RMSE.

Após esta breve introdução, o próximo tópico apresenta informações sobre o local de estudo e os dados disponíveis. Em seguida, o delineamento experimental é descrito em detalhes. Posteriormente, os métodos de Krigagem Ordinária (KO) e Máquina de Vetores de Suporte (SVM) são discutidos. A avaliação desses métodos e algumas importantes discussões estão detalhadas na seção Resultados e Discussão. Finalmente, são elencadas as contribuições desta pesquisa para a comunidade científica.

MATERIAL E MÉTODOS

Área de Estudo

Os dados deste trabalho foram coletados no município de Patos de Minas (Figura 1), mais precisamente no bairro de Santana de Patos, com a localização dada pela latitude de 18° 51' 32" S e longitude 46° 29' 49" O (WGS84), e uma altitude média aproximada de 832 m. O clima da região se enquadra na categoria "Cwa" no sistema de classificação climática de Köppen, que corresponde a um clima subtropical úmido ou temperado ameno. Além disso, a temperatura média é de 20,4 °C e a precipitação média anual é de 1447,5 mm (Koppenbrasil, 2024).




Figura 1. Localização geográfica da área de estudo. Fonte: Autores, 2025

Dados disponíveis

A área tem uma superfície de cerca de 3,7 hectares. As sementes de soja foram plantadas em agosto de 2022 e, em seguida, foram colhidas em novembro 2022. Logo depois da colheita, os dados foram extraídos pela máquina coletora de grãos em formato “.csv”, sendo posteriormente convertidos para o formato shapefile para fins de processamento.

Considerando o período de vazio sanitário da soja em 2022 no estado de Minas Gerais, entre 1º de julho e 30 de setembro, é desaconselhado plantar soja devido ao elevado risco de infestação das lavouras por doenças e pragas (MAPA, 2022). No entanto, essa safra não teve fins comerciais, sendo cultivada com o objetivo experimental de comparar duas lavouras: uma submetida a tratamento com fertilizantes e a outra, não.

Nesta pesquisa, foram utilizados 795 pontos amostrais, cujos atributos incluem informações sobre a massa de produtividade,

medida em toneladas/hectare, e a respectiva localização espacial, representada pelas coordenadas cartesianas no sistema de projeção UTM (E, N). A distribuição espacial das amostras é apresentada na Figura 2. A coloração mais escura no gráfico indica maior produtividade, enquanto as tonalidades mais claras, próximas ao branco, indicam baixa produtividade. Observa-se que a produtividade é maior na região central da lavoura, enquanto nas bordas a produtividade é menor. Esse fenômeno é atribuído ao efeito de bordadura, comum em áreas de cultivo, onde as plantas próximas às bordas estão mais expostas a fatores externos, como variações microclimáticas e contaminação por poluentes.

Como as amostras foram distribuídas no campo, o equipamento utilizado e a precisão das coordenadas (GNSS) aumentaria a confiabilidade dos resultados. Isso também inclui a justificativa para a escolha dos tamanhos amostrais de 100%, 80%, 60% e 40%, para que fique claro como essas

reduções de pontos refletem condições de amostragem realistas.




Figura 2. Distribuição espacial das amostras com seus índices de produtividade.

Delineamento Experimental

A amostra total (100%, correspondente a 795 observações) foi reduzida para 80% (636

observações), 60% (477 observações) e 40% (318 observações) (Figura 3), com o objetivo de avaliar o efeito do tamanho da amostra na estimativa da produtividade pelos métodos KO e SVM.




Figura 3. Distribuição espacial das amostras reduzidas para (a) 80%, (b) 60% e (c) 40%.

A avaliação do desempenho da KO e do SVM foram realizadas para cada um dos cenários simulados na Figura 3. A técnica de validação cruzada K-fold, que está implementada no plugin Smart-Map, foi empregada para esse fim. A validação cruzada é o método mais simples e mais amplamente utilizado para estimar o erro de predição (Hastie, Tibshirani e Friedman, 2009). Neste tipo de validação, o conjunto de dados é dividido em K partes (ou folds) de tamanhos aproximadamente iguais. Em cada iteração, o modelo é treinado (ajustado) com K-1 subconjuntos e testado com o subconjunto restante, que não foi utilizado no processo de treinamento (ajustamento) (Figura 4). Esse processo é repetido K vezes, de modo que, em cada iteração, um subconjunto diferente seja usado para teste e os outros para treinamento. No caso, usamos o padrão K = 5 do Smart-Map (Pareira et al., 2022). Assim, após as K = 5 iterações, as métricas R² e RMSE de desempenho do modelo foram calculadas para cada iteração. Por fim, a média dessas métricas foi utilizada como uma estimativa do desempenho geral do modelo.

O RMSE mede a magnitude média dos erros de predição do modelo, ou seja, a diferença entre os valores observados reais e os valores previstos pelo modelo. Um valor de RMSE mais baixo indica que o modelo está, em média, mais próximo dos valores reais. O RMSE está na mesma unidade dos dados que estão sendo estimados (por exemplo, toneladas/hectare no caso de produtividade agrícola). O R² indica a proporção da variância dos dados que é explicada pelo modelo.

Em outras palavras, mede até que ponto as variações nos dados de saída são explicadas pelas variáveis de entrada do modelo. O ideal seria ter R² = 1, que significa que o modelo explica 100% da variação nos dados, ou seja, é um ajuste perfeito, enquanto R² = 0 significa que o modelo não consegue explicar nenhuma das variações observadas nos dados; essencialmente, o modelo é tão bom quanto a média dos dados. Se um modelo tiver um RMSE baixo e um R² próximo de 1, isso indica que o modelo está fazendo estimativas acuradas (baixa margem de erro) e que a maior parte da variação nos dados é explicada pelas variáveis do modelo. Por outro lado, um RMSE alto e um R² baixo sugerem que o modelo não está estimando bem e não captura bem a variabilidade dos dados.




Figura 3. Método de Validação Cruzada de K-Fold.
Fonte: Fernanda, 2020

Krigagem Ordinária no Smart-Map

O método de interpolação por Krigagem Ordinária é o método padrão do módulo Smart-Map. Esse método é reconhecido como a melhor abordagem para estimativa linear não enviesada e pode ser aplicado em diversos campos, como mineração, geotecnia, hidrogeologia, agricultura

de precisão, recursos florestais, entre outros (Jorge Kazuo Yamamoto, 2016, Camila et al., 2022). Flávio e Morel de Passos, 2012, conseguiram a estimação da produtividade da soja usando o modelo de interpolação por KO, considerando a situação de estimar o valor de um atributo contínuo Z^*x_0 para qualquer local não amostrado x_0 , usando os dados de Z que foram amostrados na área de estudo A (ESCRI, 2022; Sarangi e Madramootoo, 2005, Andre et al., 2022).

A KO é dependente do cálculo de semivariograma que permite analisar a dependência espacial da produtividade da soja. Neste sentido, foram testados diferentes modelos de semivariograma e escolhidos os que apresentaram menor RMSE. Os semivariogramas foram gerados para cada um dos cenários amostrais avaliados (Figura 4) e os detalhes dos seus parâmetros, a saber, o efeito pepita (Co), o patamar ($Co + C$) e o alcance (A), bem como as métricas de avaliação (R^2 e RMSE) são apresentados na Tabela 1. Os modelos de semivariograma no Smart-map são selecionados automaticamente por meio de algoritmos que analisam as características espaciais dos dados. O software ajusta diferentes tipos de modelos (esférico, exponencial, gaussiano etc.) aos dados amostrais e escolhe o que melhor se adapta com base em critérios como o menor erro de ajuste (geralmente, usando a validação cruzada). O ajuste envolve a análise da variância espacial em diferentes distâncias, garantindo que o modelo selecionado seja o mais representativo para descrever a dependência espacial das variáveis.

Os modelos de semivariograma selecionados para análise foram o exponencial e o esférico, este último ajustado com diferentes

porcentagens de alcance (100%, 80%, 60%, 40%). Ao se referir ao modelo exponencial, este apresenta valores de R^2 menores (0,680) e um RMSE superior (0,605), sugerindo que o ajuste não é tão eficiente quanto o dos modelos esféricos. Esse comportamento é típico em casos em que as variações espaciais não seguem um padrão exponencial. O modelo esférico, por sua vez, em diferentes percentuais de alcance, apresentou ajustes progressivamente mais adequados. O menor RMSE (0,135) e o maior R^2 (0,794) foram obtidos com o modelo esférico a 40% de alcance, indicando um ajuste superior.

O modelo esférico foi considerado o mais adequado ao cenário, pois apresentou melhor desempenho geral em termos de precisão e explicação da variância (menores RMSE e maiores R^2), especialmente em escalas espaciais de curta distância (alcance menor). Isso pode ser indicativo de um comportamento espacial em que a continuidade dos dados é bem representada por uma transição gradual até atingir o patamar. Pequenas amostras são mais suscetíveis a extrapolações imprecisas. Como o modelo esférico possui um alcance fixo, ele limita de forma eficaz a continuidade espacial, evitando projeções inapropriadas para além da distância máxima observada entre os dados.

O modelo exponencial é caracterizado por um crescimento suave do semivariograma à medida que a distância entre os pontos aumenta, sem atingir um alcance finito – o patamar é atingido de forma assintótica. Isso o torna mais apropriado para descrever variabilidades espaciais que se estendem por longas distâncias. Grandes amostras por sua vez, oferecem densidade e confiabilidade

na interpolação. Quando há muitas observações, a representação espacial das variáveis é mais completa, permitindo um ajuste preciso do modelo exponencial. Modelos que capturam comportamentos mais suaves e distantes (como o exponencial) dependem de informações contínuas

e confiáveis ao longo do espaço. Com maior quantidade de pontos, o efeito pepita – associado à variação de pequena escala – tende a ser mais bem distribuído, garantindo que a variação espacial de longa escala predomine, algo essencial para o modelo exponencial.




Figura 4. Semivariograma e modelos selecionados para diferentes tamanhos amostrais: exponencial para 100% (a), esférico para 80% (b), esférico para 60% (c) e esférico 40% (d).

Tabela 1: Semivariograma e seus parâmetros para cada cenário amostral.

Parâmetros	Exponencial (100%)	Esférico (80%)	Esférico (60%)	Esférico (40%)
Co	0,00	0,355	0,336	0,349
Co + C	1,239	1,282	1,376	1,412
A	43,733	53,624	54,643	49,369
RMSE	0,605	0,508	0,464	0,658
R ²	0,680	0,668	0,703	0,660

* Efeito pepita (Co); Variância estrutural (C); Patamar (Co + C); Alcance (A).

Support Vector Machine no Smart-Map

Neste estudo, foi utilizada também a técnica de *Support Vector Regression* (SVR), uma adaptação das Máquinas de Vetores de Suporte (SVM – *Support Vector Machine*) para problemas de regressão, com o objetivo de estimar a produtividade da soja a partir das coordenadas (E) e (N) dos pontos amostrados. A aplicação foi realizada por meio da ferramenta Smart-map, que implementa o SVR com kernel do tipo Radial Basis Function (RBF) como padrão fixo (Pereira et al., 2022).

A função de regressão gerada pelo SVR com kernel RBF é expressa por:

$$f(x) = \sum_{i=1}^n \alpha_i K(x, x_i) + b \quad (1)$$

onde α_i são os coeficientes determinados durante o treinamento, b é o viés (também chamado de termo de interceptação), n é o número total de amostras no conjunto de treinamento, x é o vetor de entrada (neste caso, composto pelas coordenadas E e N), e K é a função kernel RBF definida como:

$$K(x, x_i) = \exp(-\gamma |x - x_i|^2) \quad (2)$$

O parâmetro $\gamma > 0$ controla a largura da função RBF e, consequentemente, a influência dos pontos de treinamento na estimativa. Valores menores de γ resultam em modelos mais suaves, ao passo que valores maiores tornam o modelo mais sensível às variações locais. A adoção do kernel RBF é apropriada para dados com comportamento espacial não linear, como é comum em aplicações agrícolas, nas quais a produtividade pode ser influenciada por múltiplos fatores heterogêneos do ambiente – como tipo de solo, relevo,

compactação, teor de umidade, entre outros. Assim, o modelo SVR com kernel RBF permite capturar padrões complexos que não seriam adequadamente representados por modelos lineares (Foody e Mathur, 2006; Vapnik, 1995; Vapnik, 2010; Schölkopf e Smola, 2002; Christoph Römer, et al., 2011; Awad, M. e Khanna, R. 2015; Peijun Du et al., 2021; Z.H. Khalila e S.M. Abdullaeva, 2021).

Na implementação do algoritmo SVM pelo Smart-Map, de acordo com Pereira et al., 2022, os hiperparâmetros são otimizados por meio de um método de pesquisa em grade sistemática, permitindo o ajuste automatizado. Assim, os parâmetros foram otimizados com base nos valores de RMSE obtidos durante a validação cruzada.

RESULTADOS

Apresentamos, a seguir, os resultados comparativos entre KO e SVM para os diferentes tamanhos amostrais, conforme descrito na seção de Delineamento Experimental. As figuras a seguir incluem um gráfico de regressão entre os valores estimados e o valor conhecido da produtividade da soja para KO e SVM, bem como os mapas gerados para cada uma dessas técnicas.

A relação entre RMSE e R^2 é inversamente proporcional; ou seja, quando maior R^2 , menor tende a ser o RMSE, e vice-versa. O R^2 se refere ao coeficiente de determinação que mede a proporção da variação de Y em relação à média que é explicada pela regressão – sendo equivalente ao quadrado do coeficiente de correlação entre X e Y . Em princípio, a qualidade do ajuste será tanto

maior quanto mais o valor de R^2 se aproximar da unidade (FEUP, 1995).

A Figura 5 mostra que, no caso de se ter 795 pontos amostrais (dados originais), a KO apresentou $RMSE = 0.470$ e $R^2 = 0.819$, enquanto o SVM apresentou $RMSE = 0.599$ e o $R^2 = 0.704$. O gráfico de regressão revela que o SVM produz estimativas mais dispersas do que aquelas obtidas pela KO, ou seja, apresentando um resultado menos acurado que a KO. Esse resultado também pode ser observado por meio dos mapas gerados. Nota-se que o mapa gerado das estimativas via SVM é mais suavizado em comparação com o da KO. De modo geral, embora a KO tenha fornecido resultados melhores, destacamos que as tendências espaciais das estimativas são bem descritas por ambas as técnicas no caso de 795 pontos (amostral original, considerada aqui como amostra completa: 100%). Com a totalidade dos dados, ambos os métodos apresentaram bom desempenho, no entanto, a KO se destaca por sua capacidade de capturar variações espaciais locais.

Esse resultado indica que a KO é mais acurada na descrição espacial da produtividade da soja quando se dispõe de um grande conjunto de dados (795 pontos amostrais, com distribuição homogênea de pontos). Conforme destacado por Zhang et al. (2022), métodos geoestatísticos como a KO tendem a ser mais robustos em situações de alta densidade amostral, permitindo uma representação detalhada das variações espaciais. Os mapas gerados indicam que o SVM apresenta uma suavização maior das estimativas, ao contrário da KO, que é capaz de capturar variações mais locais na distribuição espacial. No entanto, na

presença de outliers, o SVM pode representar uma alternativa interessante para esse tipo de aplicação.

Liu et al. (2020) também observaram que métodos geoestatísticos, como a Krigagem, tendem a superar algoritmos de aprendizado de máquina na modelagem espacial, devido à capacidade de incorporar dependências espaciais. Em contrapartida, Silva et al. (2019) encontraram um desempenho superior do SVM em relação à krigagem em áreas com alta heterogeneidade espacial, uma vez que algoritmos de aprendizado de máquina são capazes de capturar padrões complexos quando há um grande volume de dados de treinamento (Liu, X., Zhang, F., Liu, Y., e Li, J., 2020; Silva, W. L., Santos, M. L., e Oliveira, R. F., 2019). Dessa forma, a escolha entre KO e SVM depende da estrutura espacial dos dados e da densidade amostral disponível.

Os resultados indicam, também, que a KO manteve um desempenho elevado em termos de acurácia mesmo com redução amostral para 60%, apresentando $R^2 = 0,720$ e $RMSE$ de 0,623 t/ha (Figuras 6 e 7).

Embora o SVM também tenha mantido um grau de acurácia compatível com a KO ($R^2 = 0,684$) e $RMSE = 0,652$, observa-se novamente uma suavização maior nos mapas gerados por esse método, quando comparado à KO. É importante destacar que, em regiões sem pontos amostrais disponíveis, o SVM tende a estimar valores mais baixos de produtividade, comportamento observado nas áreas destacadas por círculos vermelhos nas Figuras 6 e 7.




Figura 5. Gráficos de regressão e mapas de produtividade da soja para KO (a) e SVM (b) para tamanho amostral 100% (795 pontos).




Figura 6. Gráficos de regressão e mapas de produtividade da soja para KO (a) e SVM (b) para tamanho amostral 80% (636 pontos).




Figura 7. Gráficos de regressão e mapas de produtividade da soja para KO (a) e SVM (b) para tamanho amostral 60% (477 pontos).

A suavidade observada nas previsões via SVM deve-se, sobretudo, ao ajuste do hiperparâmetro γ , que controla o equilíbrio entre a maximização da margem e minimização dos erros de regressão nos dados de treinamento (Natalia G., 2023).

A Figura 8 mostra os resultados para o caso com 40% da amostra original, correspondente a 318 pontos amostrais. À medida que o número de pontos amostrais foi reduzido, o efeito de suavização tornou-se mais evidente nos mapas de

produtividade gerados pelo SVM. Observa-se uma menor sensibilidade às variações locais e uma possível perda de tendências locais. Esse comportamento pode ser atribuído ao número limitado de vetores de suporte disponíveis para o treinamento, o que impede que o SVM capture variações de produtividade em escalas mais finas. Quando os pontos de suporte estão muito espaçados, as superfícies resultantes tendem a ser excessivamente suavizadas, levando a estimativas menos detalhadas e menos precisas. Apesar dessas

limitações, o SVM evoluiu como um paradigma eficiente para lidar com problemas não lineares; contudo, ainda apresenta dificuldades em aplicações de interpolação espacial, nas quais a continuidade espacial é fundamental.

Por outro lado, a redução amostral mais acentuada afetou levemente o modelo de KO em termos de capacidade para detectar a variabilidade espacial da produtividade agrícola. A KO aproveita a estrutura de dependência espacial dos dados de produtividade por meio do semivariograma, o que a torna especialmente adequada em condições de dados esparsos. Isso se deve ao fato de que os métodos geoestatísticos foram projetados para lidar com a dependência espacial e realizar interpolações em áreas com amostragens limitadas. O SVM, por

outro lado, pode exigir um volume maior de dados bem distribuídos e espacialmente correlacionados para alcançar resultados precisos, especialmente em problemas com forte não linearidade (Li e Heap, 2011). Entretanto, a KO exige maior especialização para seu uso, ela se mostra maior robustez em cenários com baixa densidade amostral. Por outro lado, o SVM poderia se beneficiar de adaptações no plugin Smart-Map, como a inclusão de funções de covariância alternativas, para melhorar a acurácia sob condições de amostragem reduzida. O SVM também poderia ser aprimorado com a adição de outras variáveis como padrão de entrada, tais como informações de propriedade do solo, topografia do relevo, informações sobre umidade do solo, temperatura, radiação solar.







Figura 8. Gráficos de regressão e mapas de produtividade da soja para KO (a) e SVM (b) para tamanho amostral 40% (318 pontos).

Amostras %	Número de Observações	KO		SVM	
		RMSE	R ²	RMSE	R ²
100	795	0,470	0,819	0,599	0,704
80	636	0,599	0,722	0,616	0,694
60	477	0,623	0,720	0,652	0,684
40	318	0,708	0,630	0,903	0,394

Tabela 1 : Redução amostral e variação dos parâmetros de modelos.

Vários autores já estudaram o desempenho da KO e do SVM na agricultura. Ribeiro e Silva (2018) comparam KO e SVM na previsão espacial de propriedades do solo. Nesse estudo, SVM apresentou um desempenho superior – SVM (R: 0,92; RMSE: 0,15) e KO (R: 0,85; RMSE: 0,22) – com maior acurácia na estimativa de variáveis físicas e químicas do solo. Liu e Chen (2022) avaliaram o desempenho do SVM e da KO na predição de rendimentos de culturas. Os resultados mostraram que a KO foi mais eficiente em termos de rapidez computacional, enquanto o SVM foi ligeiramente melhor em termos de acurácia [SVM (R²: 0,89; RMSE: 0,18) e KO (R²: 0,87; RMSE: 0,20)]. Yuan e Liu (2023) compararam a KO e o SVM na estimativa de produtividade agrícola sob diferentes condições climáticas. Este estudo apontou que a KO apresentou melhor desempenho em ambientes com alta variabilidade climática, enquanto o SVM se destacou em ambientes mais estáveis. Feng, Wu e Wang (2021) mostraram que o SVM foi ligeiramente superior à KO na estimativa da produtividade do arroz.

CONCLUSÃO

Neste estudo de caso, estimamos a produtividade da soja utilizando as técnicas Krigagem Ordinária (KO) e Support Vector Machine (SVM), por meio do plugin Smart-Map para diferentes tamanhos amostrais. Os resultados indicam que o ajuste da função covariância na KO (análise pelo semivariograma) é dependente do tamanho das amostras de campo. Para amostras menores (318 pontos selecionados aleatoriamente), o modelo esférico mostrou-se mais adequado, enquanto para amostras maiores (795 pontos amostrais), o modelo exponencial é recomendado.

Em termos comparativos, embora a KO seja melhor que o SVM, ambas as técnicas conseguem capturar a tendência espacial da produtividade. A KO foi superior nos casos de baixa densidade amostral (< 400 pontos). Para amostras grandes (> 795 pontos), a Krigagem e o SVM apresentam desempenho semelhantes (Tabela 2). Entretanto, o SVM do Smart-Map tende a suavizar as predições, o que impede a captura de variações mais localizadas. No caso em questão, a aplicação do SVM requer mais amostras para ter o mesmo resultado da KO. Contudo, se a função kernel do SVM pudesse ser alterada no Smart-Map

– por exemplo, para uma função *Rational Quadratic* –, talvez as variações abruptas da variabilidade poderiam ser capturadas, de modo que o SVM teria resultados similares aos da KO. Ademais, destaca-se que, no Smart-Map, a KO exige um conhecimento mais especializado por parte do analista do que o SVM.

De modo geral, portanto, pode-se empregar o SVM como método alternativo à KO desde que o tamanho amostral seja adequado (amostras > 1000 pontos e bem distribuídos ao longo da região de estudo).

AGRADECIMENTOS

O autor agradece à CAPES pelo apoio financeiro, por meio da concessão de bolsa, durante o período de realização de seu mestrado. Agradece também à empresa LALLEMAND pelo fornecimento dos dados utilizados neste estudo. Estende, ainda, seus agradecimentos aos professores Dr. Vinicius Francisco Rofatto e Dr. George Deroco Martins, da Universidade Federal de Uberlândia (UFU), vinculados ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais, pela valiosa contribuição científica prestada na elaboração deste trabalho.

Referências

- Aleksandra, W. et al.** Estimating crop primary productivity with Sentinel-2 and Landsat 8 using machine learning methods trained with radiative transfer simulations. *Remote Sensing of Environment*, v.225, 2019, p. 441-457. DOI: <https://doi.org/10.1016/j.rse.2019.03.002>
- Andre, W. B. et al.** Comparison of geostatistical and machine learning models for predicting geochemical concentration of iron: case of the Nkout iron deposit (south Cameroon). *Journal of African Earth Sciences*, v.195, 2022, p.104662. DOI: <https://doi.org/10.1016/j.jafrearsci.2022.104662>
- Awad, M., & Khanna, R.** (2015). Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers. Apress
- Belgiu, M., & Drăguț, L.** (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31.
- Bongiovanni, R., Lowenberg-Deboer, J.** Precision Agriculture and Sustainability. *Precision Agriculture*, 5, 359-387 (2004). <https://doi.org/10.1023/B:PRAG.000040806.39604.a>
- Brus, D. J., & Heuvelink, G. B. M.** (2007). Optimization of sample patterns for universal kriging of environmental variables. *Geoderma*, 138(1-2), 86-95.
- Burges, C. J. C.** (1998). A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2), 121-167.
- Cambardella, C. A. et al.** Field-scale variability of soil properties in central Iowa soils. *Soil Science Society America Journal*, v.58, 1994, p.1501-1511. DOI: <https://doi.org/10.2136/sssaj1994.03615995005800050033x>
- Celia, R. G. et al.** (2014). Tecnologias desenvolvidas em Agricultura de Precisão. Disponível em <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1126469/1/Cap7-Tecnologias-desenvolvidas-em-agricultura-de-precisao.pdf> Acesso 27 de 5 março. 2023
- Chen, C., Wu, L., & Liu, H.** (2022). "Comparative analysis of geostatistical and machine learning methods for predicting crop yields in precision agriculture." *Journal of Agricultural and Food Chemistry*, 70(10), 3054-3067.
- Christoph, R. et al.** Robust fitting of fluorescence spectra for pre-symptomatic wheat leaf rust detection with Support Vector Machines. *Computers and Electronics in Agriculture*, v.79, 2011, p.180-188. DOI: 10.1016/j.compag.2011.09.011

- Clima Data.** Clima Patos de Minas. Disponível em: <https://pt.climate-data.org/americas-do-sul/brasil/minas-gerais/patos-de-minas-2893/#climate-table> Acesso em: 15 de março. 2023
- Cortes, C., & Vapnik, V.** (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.
- Cressie, N.** (1993). *Statistics for Spatial Data*. Wiley-Interscience.
- Dourado M., M. et al.** Krigagem ordinária para predição de vazões em locais sem dados: proposta de nova metodologia. *Research, Society and Development*, v. 11, n. 2, e54511225185, 2022. DOI:<http://dx.doi.org/10.33448/rsd-v11i2.25185>
- Embrapa.** Avaliação e Comparação de Estimadores de Krigagem para Variáveis Agronômicas – Uma Proposta. Jose R. P.de C. e Sidney R. V. — Campinas: Embrapa Informática Agropecuária, 2001.
- ESCRI.** How Kriging works. Disponível em: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/3d-analyst/how-kriging-works.htm> Acesso em: 10 de Julho, 2023
- Felipe, J. M.; Paulo, S. L.; Herder, J. F. S.** Análise de Métodos de Krigagem na Estimativa da Precipitação no Estado do Rio Grande do Norte. *Revista Brasileira de Geografia Física*, v.10, n.5, 2017, p.1668-1676.
- Feng, H., Wu, J., & Xu, L.** (2022). "Predicting rice yield using support vector machine and ordinary kriging methods: A case study in Southeast Asia." *Field Crops Research*, 271, 108238.
- Henrique Lost, F., F.** "Sensoriamento remoto para monitoramento de mosca branca, *Bemisia tabaci* biotipo B (Hemiptera: Aleyrodidae) em soja," Ph.D. Dissertation, Dept., Escola Superior de Agricultura, Universidade de São Paulo, Piracicaba, Brasil, 2019. 63 p.
- Carlos D., F.; Morel de Passos, C.** Correlação linear e espacial dos componentes de produção e produtividade da soja. *Semina: Ciências Agrárias*, Londrina, v. 33, n. 2, p. 541-552, abr. 2012. DOI: 10.5433/1679-0359.2012v33n2p541
- Carlos D., F. et al.** Interrelationship between cotton parameters and soil chemical properties in Central Brazil. *Revista de Ciências Agrárias*, 2018, 41(3): 633-646. DOI: <http://dx.doi.org/10.19084/RCA17197>
- Foody, G.M.; Mathur, A.** The use of small training sets containing mixed pixels for accurate hard image classification: Training on mixed spectral responses for classification by a SVM. *Remote Sensing of Environment*, v. 103, p. 179–189, 2006.
- Gomes de Melo, J., F.; Luciano, S.; Damian, D.A.** Geração de mapas de produtividade de milho (*Zea mays*) com índice de vegetação NDVI de imagens Landsat 8. *Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE.
- Jorge, K. Y.** Krigagem Ordinária: método de amplo uso. *Geo-Krigagem*. Disponível em: <https://geokrigagem.com.br/krigagem-ordinaria/> Acesso em: 7 de julho, 2023.
- Jose, R. R. de C.; Eduardo, D. A.** Análise espacial da precipitação pluviométrica na estação de São Paulo: Comparação de métodos de interpolação. *Eng. Agríc., Jaboticabal*, v.25, n.2, p.377-384, maio/ago. 2005.
- Kavita, J.; Pratistha, M.** Machine Learning Approaches to Predict Crop Yield Using Integrated Satellite and Climate Data. *International Journal of Ambient Computing and Intelligence*, v.13, 2022. DOI: 10.4018/IJACI.300799
- Khalil, Z.H.; Abdullav, S.M.** Neural network for grain yield predicting based multispectral satellite imagery: comparative study. *Science Direct*, v.186, 2021, p.269-278.
- Köppen Brasil.** Classificação climática de Köppen-Geiger para os municípios brasileiros [Internet]. 2024 [citado 2024 Mar]. Disponível em: <https://koppenbrasil.github.io/>.
- Li, J., & Heap, A. D.** (2011). A review of comparative studies of spatial interpolation methods in environmental sciences: Performance and impact factors. *Ecological Informatics*, 6(3-4), 228-241.
- Liu, X., Zhang, F., Liu, Y., & Li, J.** (2020). Comparing geostatistical and machine learning models for soil property mapping in complex terrain. *Geoderma*, 360, 114-147.
- Luiz S., A., et al.** Definição de zonas de produtividade em áreas manejadas com agricultura de precisão. *Agrária - Revista Brasileira de Ciências Agrárias*, v.8, n.3,

- p.510-515, 2013.
DOI:10.5039/agraria.v8i3a2489.
- Oliveira, P., L. et al.** Análise comparativa dos métodos de classificação SVM e Maxver-ICM Polarimétrico em imagem de radar ALOS PALSAR. *Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE, p.8223.
- McBratney, A., Whelan, B., Ancev, T., & Bouma, J.** (2005). Future directions of precision agriculture. *Precision Agriculture*, 6, 7-23.
- McBratney, A. B., Mendonça Santos, M. L., & Minasny, B.** (2003). On digital soil mapping. *Geoderma*, 117(1-2), 3-52.
- Mountrakis, G., Im, J., & Ogole, C.** (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247-259.
- ONU.** Population mondiale devrait atteindre 9,6 milliards en 2050. Disponível em: <https://www.un.org/fr/desa/un-report-world-population-projected-to-reach-9-6-billion-by-2050#:~:text=La%20population%20mondiale%20actuelle%20de,r%C3%A9vision%20de%202012%20%C2%BB%20lanc%C3%A9%20jeudi> Acesso em: 05 de março. 2023.
- Ouyang, Y., & Li, W.** (2019). "Comparison of support vector machines and ordinary kriging for predicting wheat yield based on remote sensing data." *Computers and Electronics in Agriculture*, 156, 81-90.
- Peijun, D et al.** Multiple Classifier System for Remote Sensing Image Classification: A Review. *Sensor*, v.12, 2012, p.4764-4792. DOI: 10.3390/s120404764
- G.W.; Valente, D.S.M.; Queiroz, D.M.d.; Coelho, A.L.d.F.; Costa, M.M.; Grift, T.** Smart-Map: An Open-Source QGIS Plugin for Digital Mapping Using Machine Learning Techniques and Ordinary Kriging. *Agronomy*, 2022, 12, 1350. <https://doi.org/10.3390/agronomy12061350>
- Pierce, F. J., & Nowak, P.** (1999). Aspects of precision agriculture. *Advances in Agronomy*, 67, 1-85.
- Pykrige.** Disponível em: <https://geostat-framework.readthedocs.io/projects/pykrige/en/stable/> Acesso em 17 de março. 2023
- Ribeiro, J. L., & Silva, A. M.** (2018). "Comparative study of kriging and support vector machines for spatial prediction of soil properties." *Computers and Electronics in Agriculture*, 155, 183-193.
- Scheid, L., A., S.; Luiz, R. G. G.** Fertilidade do solo e produtividade agrícola. Departamento de Ciência do Solo, Universidade Federal de Lavras, 2007.
- Sajid, A. H.; Rudra, R. P.; Parkin, G.** Systematic Evaluation of Kriging and Inverse Distance Weighting Methods for Spatial Analysis of Soil Bulk Density. *Canadian Biosystems Engineering*, v.55, 2013. DOI: <http://dx.doi.org/10.7451/CBE.2013.55.1.1>
- Sarangi, A., Cox, C. A., & Madramootoo, C. A.** Geostatistical Methods for Prediction of Spatial Variability of Rainfall in a Mountainous Region. *American Society of Agricultural Engineers*, Vol. 48(3): 943-954. 2005
- Schölkopf, B.; Smola, A.** Support Vector Machines and Kernel Algorithms. Disponível em: <https://alex.smola.org/papers/2002/SchSmo02b.pdf> Acesso em: 10 de Agosto, 2023.
- Scikit-Learn. SVM.** Disponível em: <https://scikit-learn.org/stable/modules/svm.html>
- Silva, W. L., Santos, M. L., & Oliveira, R. F.** (2019). Support vector machine versus kriging for crop yield estimation in heterogeneous fields. *Precision Agriculture*, 20(5), 958-975.
- Smola, A. J., & Schölkopf, B.** (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199-222.
- Vapnik, V. N.** *Statistics for Engineering and Information Science: The Nature of Statistical Learning Theory*. Second Edition, 2000, New York, USA. DOI: 10.1007/978-1-4757-3264-1
- Vapnik, V.** (2010). *The Nature of Statistical Learning Theory*. Springer; 2nd ed. Edição.
- Vapnik, V.** (1995). *The Nature of Statistical Learning Theory*. Springer.
- Vasit, S. et al.** Field-scale crop yield prediction using multi-temporal WorldView-3 and PlanetScope satellite data and deep learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, v.8, 2021, p.265-281.

DOI: <https://doi.org/10.1016/j.isprsjprs.2021.02.008>

- Wang, J. et al.** Training Data Selection for Support Vector Machines. *Lecture Notes in Computer Science*, 2005, p.554-564. DOI: 10.1007/11539087_71
- Waske, B., & Braun, M.** (2009). Classifications of remotely sensed data using support vector machines: Why and how. *Canadian Journal of Remote Sensing*, 35(6), 645-657.
- Weiss, M.** Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, vol. 236, no. 26, Ago. 2019. No. 111402. 19p.
- Yuan, Y., Sun, H., & Liu, X.** (2023). "Comparison of support vector machines and ordinary kriging for estimating crop yields under different climatic conditions." *Journal of Agricultural Science and Technology*, 25(3), 697-710.
- Zhang, N., Wang, M., & Wang, N.** (2002). Precision agriculture—a worldwide overview. *Computers and Electronics in Agriculture*, 36(2-3), 113-132.