

VARIABILIDADE ESPACIAL DA PRODUTIVIDADE DE SOJA A PARTIR DE DADOS DE MÁQUINA

Gabriel Antônio Sousa Santos, graduando em Engenharia Agrícola, UEG/CET, gabrielantoniosousasantos@gmail.com

Yves Rafael Lima Bezerra, graduando em Engenharia Agrícola, UEG/CET, yvesrafaell@gmail.com

Josué Gomes Delmond, Doutor em Ciências Agrárias, Instituto Federal Goiano, josue.delmond@ueg.br

Elton Fialho dos Reis, Doutor em Engenharia Agrícola, Universidade Federal de Viçosa, fialhoreis@ueg.br

Ítallo Olímpo Bueno, graduando em Engenharia Agrícola, UEG/CET, itallo@ueg.aluno.br

Sarah Mendes, graduando em Engenharia Agrícola, UEG/CET, sarahmendes844@gmail.com

Resumo: Este trabalho aborda a necessidade de determinar a variabilidade espacial da produtividade da soja em áreas comerciais, considerando os ruídos e inconsistências inerentes aos dados captados por monitores embarcados. Investigou-se se um pipeline integrando QGIS, MapFilter e SmartMap seria capaz de produzir mapas claros e robustos, validados por análise geoestatística. Partindo da hipótese de que a filtragem de outliers e a correção de atrasos de sensor assegurariam dados coerentes, teve-se como objetivo geral gerar mapas de produtividade espacial da cultura. Os resultados revelaram alcance de autocorrelação de aproximadamente 500 m e mapas contínuos e binários eficientes, comprovando a eficácia do método, ainda que dependente da densidade amostral e da qualidade do sinal GNSS.

Palavras-chave: Agricultura de precisão, Produtividade da soja, Variabilidade espacial, Mapeamento de rendimento, Filtragem de dados, Variograma isotrópico, Geoestatística.

INTRODUÇÃO

A cultura da soja representa uma das principais bases do agronegócio brasileiro, sendo responsável por expressiva parcela das exportações e contribuindo significativamente para o Produto Interno Bruto nacional (FERREIRA, 2024; DALL'AGNOL, 2011). O Brasil figura entre os maiores produtores mundiais dessa oleaginosa, cultivada em vastas áreas que superam os 30 milhões de hectares. Com a intensificação do uso de tecnologias e a busca por altas produtividades, tornou-se imprescindível compreender a variabilidade espacial da produção dentro dos talhões agrícolas (ZOROG, 2013; CONAB, 2010).

A variabilidade espacial impacta diretamente na eficiência da aplicação de insumos, manejo de solo e decisões agronômicas. Nesse sentido, ferramentas da agricultura de precisão, como mapas de produtividade gerados por sensores embarcados em colhedoras, têm ganhado relevância. Tais dispositivos capturam informações de rendimento e localização georreferenciada, fornecendo bases para análises detalhadas da produção (DRIEMEIER; LEROUX et al., 2019; EMBRAPA, 2019).

Contudo, a obtenção de dados brutos requer filtragem rigorosa para correção de ruídos e exclusão de outliers. O software MapFilter 2.0 tem se destacado como ferramenta prática nesse processo, permitindo a remoção de inconsistências e a preparação dos dados para análises espaciais subsequentes. A validação da autocorrelação espacial, realizada por meio da geoestatística, é essencial para garantir que os padrões identificados nos mapas reflitam a realidade do campo. O uso do variograma isotrópico, por exemplo, permite quantificar a extensão da dependência espacial entre os pontos amostrados (CAMBARDELLA et al., 1994; LOBÃO, 2023).

Assim, o presente trabalho teve como objetivo desenvolver um mapa de produtividade da cultura da soja a partir de dados coletados por colhedora mecanizada, tratados por meio de filtragem no MapFilter e validados com técnicas geoestatísticas aplicadas no ambiente QGIS com o plugin SmartMap.

MATERIAIS E MÉTODOS

O experimento foi conduzido em uma área comercial de 378,36 ha, situada em Montividiu-GO (latitude -17,5028707; longitude -51,2773158). As operações de colheita ocorreram entre 7 e

13 de fevereiro de 2024, utilizando-se a colhedora John Deere STS 9670 acoplada à plataforma FD 635 Draper de 11,6 m de largura. A equipe de campo era composta por dois alunos de graduação e um docente orientador, responsáveis pelo monitoramento do sistema embarcado e pela verificação inicial de integridade dos dados.

1. Coleta e Exportação dos Dados

Durante a colheita, o monitor de produtividade registrou fluxo de massa, teor de umidade e posicionamento GNSS a cada segundo. Ao término de cada jornada, os registros foram exportados em formato CSV e importados para o Microsoft Excel 365, onde se realizou: Remoção de registros com valores ausentes ou de produtividade fora dos limites práticos (< 0 t/ha ou > 20 t/ha) e verificação de consistência interna (vazão compatível com velocidade de operação).

2. Delimitação da Área de Interesse

No QGIS 3.40.4, criou-se um polígono vetorial correspondente ao talhão experimental, restringindo espacialmente o conjunto de dados aos pontos efetivamente colhidos na área de estudo.

3. Filtragem de Dados com MapFilter

Os dados georreferenciados foram submetidos ao MapFilter, aplicando-se duas etapas sequenciais: Filtragem Global: remoção de outliers extremos pela estatística de Tukey (valores além de $1,5 \times \text{IQR}$) e filtragem Regional: suavização de variações abruptas locais por média móvel em raio de 50 m.

4. Geração de Mapas de Variabilidade Espacial

Após filtragem, os arquivos tratados retornaram ao QGIS, onde o plugin SmartMap foi utilizado para interpolação e classificação. Foram gerados: Mapa contínuo (escala verde→vermelho), realçando gradientes de baixa a alta produtividade e mapa binário (alta vs. baixa produtividade), com corte em quartil 50 % para facilitar decisões agrônômicas.

RESULTADOS

Os resultados foram apresentados em ordem cronológica de processamento:




Figura 1– Variograma isotrópico da produtividade de soja filtrada. Gráfico gerado pelo plugin SmartMap do QGIS. Eixo x: distância (m); eixo y: semivariância.

1. Variabilidade espacial

Os dados processados exibiram autocorrelação espacial conforme demonstrado no variograma isotrópico (Figura 1), indicando alcance de correlação de aproximadamente 500 m, valor compatível com a extensão média dos passes da colhedora.





Figura 2 – Mapa de variabilidade espacial da produtividade de soja ($t\ ha^{-1}$). Paleta contínua verde→vermelho gerada pelo plugin SmartMap do QGIS.

2. Mapa contínuo de produtividade

Com base na variabilidade espacial identificada, foi gerado um mapa de produtividade em escala contínua verde→vermelho, em que tons mais próximos do vermelho representam baixa produtividade e tons mais próximos do verde representam alta produtividade (Figura 2). As unidades de rendimento são toneladas por hectare ($t\ ha^{-1}$).



3. Mapa binário de produtividade

Para facilitar a tomada de decisão, a produtividade foi classificada em duas categorias (alta e baixa) por corte no quartil de 50 %, resultando em mapa binário com verde para alta produtividade e vermelho para baixa (Figura 3).

Figura 3— Mapa de zonas de manejo binário da produtividade de soja ($t\ ha^{-1}$).
Gerado pelo plugin SmartMap do QGIS

DISCUSSÃO

Este estudo partiu da hipótese de que o pipeline QGIS → MapFilter → SmartMap seria capaz de gerar mapas de produtividade com precisão espacial e clareza visual suficientes para embasar decisões agrônômicas. Os resultados confirmaram essa premissa, embora tenham revelado limitações inerentes aos sensores embarcados e ao processamento em tempo real (LYLE; BRYAN; OSTENDORF, 2013; REINKE et al., 2024).

Os dados brutos apresentaram ruídos significativos, oriundos de erros de posicionamento GNSS e do atraso ("lag time") entre o cabeçote e o sensor de fluxo de massa (LEE et al., 2012; LYLE; BRYAN; OSTENDORF, 2013). Essas imprecisões reforçam a necessidade de etapas de limpeza antes da análise espacial, alinhando-se a práticas consolidadas em agricultura de precisão (MATCHAM et al., 2022; LYLE; BRYAN; OSTENDORF, 2013).

A dupla filtragem aplicada no MapFilter—remoção de outliers por estatística de Tukey e suavização local por média móvel de 50 m—demonstrou eficácia para atenuar valores extremos e ruídos de curto alcance, resultando em um conjunto de dados espacialmente mais coerente (MATCHAM et al., 2022). A etapa de interpolação e classificação no QGIS, por meio do plugin SmartMap, conferiu flexibilidade na manipulação e visualização dos dados (DRIEMEIER; LEROUX et al., 2019).

O variograma isotrópico, calculado a partir dos dados tratados, revelou alcance de correlação espacial de aproximadamente 500 m, em consonância com análises de variabilidade de atributos de solo e rendimento em larga escala (CAMBARDELLA et al., 1994; LYLE; BRYAN; OSTENDORF, 2013).

Para a apresentação dos gradientes de rendimento, adotou-se uma paleta contínua verde→vermelho gerada no SmartMap, que assegura uniformidade perceptual e evita vieses de interpretação (HARROWER; BREWER, 2003). A classificação binária (alta vs. baixa produtividade), baseada em corte no quartil 50 %, simplificou a identificação de zonas de manejo, método recomendado para suporte rápido às decisões de campo (BLACKMORE, 2000).

O objetivo foi alcançado parcialmente: obtiveram-se mapas visualmente consistentes e espacialmente coerentes, mas a precisão final ainda depende da densidade de pontos amostrados e da qualidade do sinal GNSS, questões documentadas em levantamentos de adoção tecnológica em fazendas dos Estados Unidos (ZHAO; D'ORO; SUDDUTH, 2018).

A metodologia mostrou-se adequada ao objeto e à hipótese, porém sugere-se, em futuros trabalhos, a incorporação de receptores GNSS RTK para mitigar erros de posicionamento e sensores de largura de corte em tempo real, bem como a avaliação de métodos de interpolação mais robustos, como krigagem co-variograma ou técnicas de machine learning (KAYAD et al., 2021; KHAREL et al., 2019).

CONCLUSÕES

Os métodos integrados de filtragem e mapeamento de produtividade mostraram-se satisfatórios, permitindo estimar com confiabilidade a variabilidade espacial da cultura da soja.

Essa abordagem contribui para a precisão dos mapas intra-campo e oferece subsídios para otimização do manejo agrônomo. Futuras pesquisas podem incorporar tecnologias GNSS RTK e algoritmos avançados de interpolação, ampliando ainda mais a exatidão e aplicabilidade em sistemas de agricultura de precisão.

REFERÊNCIAS

- BLACKMORE, S. The interpretation of trends from multiple yield maps. *Computers and Electronics in Agriculture*, v. 26, n. 1–2, p. 37–51, 2000.
- CAMBARDELLA, R. S. et al. Field-scale variability of soil properties: geostatistical analysis. *Soil Science Society of America Journal*, v. 58, n. 5, p. 1501–1511, 1994.
- CONAB. Acompanhamento da safra brasileira de grãos: grão, safra 2009/2010. Brasília: Companhia Nacional de Abastecimento, 2010.
- DALL'AGNOL, A. et al. Soja: importância econômica e avanços tecnológicos. *Embrapa Soja. Documentos*, Londrina: Embrapa, 2011.
- DRIEMEIER, F.; LEROUX, O. et al. Sensors applied to Digital Agriculture: a review. *Revista Ciência Agronômica*, v. 50, n. 2, p. 153–164, 2019.
- EMBRAPA. Agricultura de precisão: desafios e perspectivas tecnológicas. Documentos Embrapa, Brasília: Embrapa, 2019.
- FERREIRA, A. A. Análise do crescimento da produção de soja no Brasil. *Revista Brasileira de Economia e Agricultura*, v. 18, n. 1, p. 65–80, 2024.
- HARROWER, M.; BREWER, C. A. ColorBrewer.org: an online tool for selecting colour schemes for maps. *Cartography and Geographic Information Science*, v. 30, n. 1, p. 5–10, 2003.
- KAYAD, A. et al. A grain yield sensor for yield mapping with local rice combine harvester. *Agriculture*, v. 11, n. 9, p. 897, 2021.
- KHAREL, T. P. et al. Comparative analysis of interpolation methods for yield mapping in precision agriculture. *Agronomy Journal*, v. 111, n. 4, p. 1873–1882, 2019.
- LEE, D. H.; SUDDUTH, K. A.; DRUMMOND, S. T. et al. Automated yield map delay identification using phase correlation methodology. *Transactions of the ASABE*, v. 55, n. 3, p. 743–752, 2012.
- LOBÃO, M. S. et al. Agricultura digital: tendências, tecnologias e aplicações. In: BRANDÃO, A. et al. (org.). *Agricultura digital e sustentabilidade*. Brasília: Embrapa, 2023. p. 189–210.
- LYLE, G.; BRYAN, B.; OSTENDORF, B. Post-processing methods to eliminate erroneous grain yield measurements: review and directions for future development. *Precision Agriculture*, v. 15, p. 377–402, 2013.
- MATCHAM, E. G.; MATIAS, F. I.; LUCK, B. D.; CONLEY, S. P. Filtering, editing, and cropping yield maps in an R environment with the package cleanRfield. *Agronomy Journal*, v. 114, n. 3, p. 1672–1679, 2022.
- REINKE, R. et al. Understanding the limitations of grain yield monitor technology to inform on-farm research. *Agronomy Journal*, v. 116, n. 6, p. 3181–3195, 2024.
- ZHAO, Y.; D'ORO, J.; SUDDUTH, K. A. Evaluation of GNSS-RTK enhancements in combine yield mapping. *Precision Agriculture*, v. 19, p. 1023–1038, 2018.
- ZOROG, R. Soja no Brasil: histórico, desafios e tendências. *Revista de Economia e Sociologia Rural*, v. 51, n. 3, p. 455–472, 2013.