

Análise e sugestão de abordagem para filtragem de mapas de produtividade para a cultura do algodão

Analysing and suggesting an approach for filtering yield maps for the cotton crop

Eduardo Antonio Speranza¹, Carlos Manoel Pedro Vaz², Julio Cezar Franchini dos Santos³, Ricardo Yassushi Inamasu⁴, Ivani de Oliveira Negrão Lopes⁵, Ladislau Marcelino Rabello⁶

¹ Analista, Embrapa Agricultura Digital, Campinas (SP), Brasil, eduardo.speranza@embrapa.br

² Pesquisador, Embrapa Instrumentação, São Carlos (SP), Brasil, carlos.vaz@embrapa.br

³ Pesquisador, Embrapa Soja, Londrina (PR), Brasil, julio.franchini@embrapa.br

⁴ Pesquisador, Embrapa Instrumentação, São Carlos (SP), Brasil, ricardo.inamasu@embrapa.br

⁵ Pesquisador, Embrapa Soja, Londrina (PR), Brasil, ivani.negrao@embrapa.br

⁶ Pesquisador, Embrapa Instrumentação, São Carlos (SP), Brasil, ladislau.rabelo@embrapa.br

RESUMO

Este trabalho propõe uma abordagem para a filtragem de mapas de produtividade para a cultura do algodão considerando a inclusão de uma etapa de pré-processamento a partir de dados relacionados à trajetória da colheitadeira, eliminando dados que podem ter sido obtidos de maneira equivocada e, consequentemente, atrapalhar o processo de filtragem considerando os valores de produtividade e os vizinhos mais próximos de cada ponto. O objetivo principal de uma abordagem como esta é melhorar a qualidade final dos mapas obtidos, proporcionando maior assertividade na utilização desses mapas em processos de tomada de decisão em agricultura de precisão. Os experimentos foram conduzidos considerando um conjunto de 130 mapas de produtividade de algodão de primeira safra, em duas safras distintas. Os resultados mostraram que a pré-filtragem considerando informações da trajetória da colhedora permite uma melhor eficácia do processo de filtragem executado diretamente na variável de produtividade.

Palavras-chaves: colheitadeira; qualidade de mapas; tomada de decisão.

ABSTRACT

This work proposes an approach for filtering yield maps for cotton crop, thereby considering the inclusion of a pre-processing step based on data related to the harvester's trajectory, excluding incorrectly obtained data that may have been obtained in a wrong way and, consequently, hindering/disrupt the filtering process considering the productivity/throughput values and the nearest neighbors of each point. The main goal of an approach like this is to improve the final quality of the maps obtained, providing greater assertiveness in the use of these maps in decision-making processes in precision agriculture. The experiments were conducted considering a set of 130 first-crop cotton yield maps, in two different seasons. The results showed that pre-filtering considering information from the harvester's trajectory allows for better efficiency of the filtering process carried out directly on the yield attribute.

Keywords: harvester; map quality; decision making.

<https://doi.org/10.4322/978-65-86819-38-0.1000005>

 Este é um capítulo publicado em acesso aberto (Open Access) sob a licença Creative Commons Attribution-NonCommercial-NoDerivatives, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que sem fins comerciais, sem alterações e que o trabalho original seja corretamente citado.

1 INTRODUÇÃO

Dentre os diferentes tipos de dados disponibilizados por sensores proximais e remotos que podem ser utilizados em agricultura de precisão, os mapas de rendimento ou produtividade da cultura, obtidos ao longo dos anos a partir de sistemas de mapeamento instalados nas colheitadeiras, se destacam por serem indicativos de grande parte da variabilidade espacial presente na lavoura (Maldaner et al., 2019) e também por indicarem pontos de interesse para investigação e diagnóstico de fatores limitantes ou potencializadores da produtividade. Esses sistemas são compostos por monitores e processadores conectados a um receptor GNSS¹ para medição de posicionamento e velocidade, sensores de fluxo de massa, sensor de umidade e sensor de seção da plataforma, possibilitando a obtenção de mapas de produtividade com alta densidade de pontos.

Apesar de a evolução do sistema de mapeamento ter acontecido de maneira rápida ao longo dos anos no mercado, tanto no que diz respeito aos sensores, quanto aos softwares de comunicação e operação, a qualidade das informações coletadas ainda depende da calibração manual dos sensores. Caso a calibração dos sensores não seja realizada de forma adequada, podem ser gerados mapas com erros inerentes ao processo, que, no entanto, podem ser corrigidos a partir de técnicas de pós-processamento.

A literatura apresenta um vasto levantamento de erros que podem ocorrer nesse processo e prejudicar a obtenção dos mapas, como: erros nas coordenadas coletadas; mudanças de velocidade durante o trajeto; desconhecimento da largura de plataforma do equipamento; dados inválidos coletados em manobras de cabeceira; utilização de muitas colheitadeiras em um mesmo talhão com calibragens distintas, dentre outros (Sudduth; Drummond, 2007). Adicionalmente, diversas soluções baseadas em técnicas de pós-processamento têm sido apresentadas ao longo desse período para tentar resolver, ou ao menos amenizar, os erros proporcionados por esse processo de mapeamento e melhorar a qualidade dos mapas. Uma das primeiras iniciativas, o software Yield Editor, foi desenvolvida por Sudduth e Drummond (2007) com o objetivo de eliminar diversos tipos de erros obtidos em mapas de produtividade. Porém, requer um conhecimento avançado do usuário, pois necessita de análises visuais e determinação de diversos parâmetros para o seu correto funcionamento, o que torna o processo extremamente moroso. Seguindo essa mes-

ma linha, Maldaner et al. (2018) desenvolveram o software MapFilter. Criado inicialmente para filtragem de mapas de produtividade, o MapFilter pode realizar esse pré-processamento em qualquer conjunto de dados com alta densidade de pontos, pois se utiliza de metodologias gerais de geoestatística para realizar o processo. Nesse caso, o usuário, além dos dados em forma de mapa, fornece informações relacionadas à filtragem geral, como a variação dos limites; e informações relacionadas à filtragem local, como a distância para dependência espacial. O algoritmo utilizado pelo MapFilter procura reduzir o coeficiente de variação (CV) dos dados presentes no mapa para um valor ótimo. Assim, apesar de ser uma solução bem mais simples que o YieldEditor, o MapFilter também exige certo conhecimento estatístico por parte do usuário.

Com o objetivo de facilitar o trabalho de filtragem, permitindo a análise automatizada de mapas de produtividade, Vega et al. (2019) desenvolveram um novo protocolo para esse processo. Os autores utilizaram em sua solução o índice de Moran (Li et al., 2007) para identificar a autocorrelação espacial e *outliers* locais e globais presentes nas amostras. Essa metodologia proporciona resultados similares aos obtidos pelo MapFilter, porém possibilita a execução da filtragem em vários mapas ao mesmo tempo, por meio do uso de computação paralela. Nos experimentos realizados, essa solução reduziu, em média, 30% do tamanho do conjunto de dados removendo esses supostos erros. O principal parâmetro a ser determinado por essa solução é a distância a ser considerada para a dependência espacial entre as amostras que, por muitas vezes, depende de conhecimento do usuário com relação ao conjunto de dados que possui.

Apesar da eficiência demonstrada por essas soluções, é possível que, dependendo dos parâmetros informados, sejam excluídos alguns pontos que deveriam ser mantidos nos conjuntos de dados, e mantidos alguns pontos que deveriam ser excluídos. Isso pode acontecer devido à utilização apenas dos valores de produtividade em si e de sua localização para o processo de filtragem. Porém, esses dados são apenas uma pequena parte das informações que um monitor de colheita pode fornecer. Neste trabalho, é proposta uma abordagem de filtragem em que é incrementada uma etapa de pré-processamento ao processo de filtragem desenvolvido por Vega et al. (2019), com o intuito de eliminar pontos que estão fora da trajetória que se espera da colheitadeira e que poderiam prejudicar a análise posterior utilizando métodos estatísticos. Para tanto, foram utilizadas frequências identificadas nos dados referentes ao ângulo da colheitadeira durante a execução da colheita. O pré-

¹ GNSS: do inglês Global Navigation Satellite System, ou Sistema Global de Navegação por Satélite.

-processamento utilizando apenas esse campo (ângulo da colheitadeira) ocorreu devido aos seguintes motivos: disponibilidade dessa informação nos mapas utilizados nos experimentos; em talhões relativamente planos e com linhas de plantio regulares, como na cultura do algodão, é esperado que a colheitadeira opere em apenas duas direções, fazendo com que a maior parte dos pontos coletados corresponda a duas faixas angulares muito bem definidas, com diferença de 180 graus entre elas; o objetivo principal do trabalho, que é mostrar que dados obtidos pelos monitores de colheita que não a produtividade em si também podem ser úteis para a filtragem e obtenção de mapas com melhor qualidade.

2 MATERIAL E MÉTODOS

Os experimentos para este trabalho foram realizados a partir de 130 mapas contendo dados brutos (sem tratamento) de produtividade do algodão de primeira safra, referente às safras 2018/2019 e 2020/2021, fornecidos pela Fazenda São Francisco, localizada em Riachão das Neves, BA, coordenadas centrais O 45° 47' 44.805" e S 11° 40' 31.117" (Figura 1).

Esses mapas possuem os dados brutos coletados, ou seja, sem uma normalização pelo peso real aferido em cada talhão, o que pode proporcionar o aparecimento de valores muito acima ou abaixo da média real aferida. Para este trabalho, não foi considerada a quantidade de colheitadeiras utilizada durante a colheita de cada um dos talhões e, portanto, é possível que algumas diferenças de produtividade encontra-

das nos mapas sejam devidas a processos de calibração distintos dos sensores utilizados.

Os algoritmos utilizados para este experimento foram desenvolvidos usando a linguagem R (R-Project, 2022). Para a pré-filtragem proposta, considerando o ângulo da colheitadeira, foi proposto novo algoritmo considerando frequências de valores obtidas por meio de histograma. O único parâmetro a ser informado nesse algoritmo é o percentual mínimo exigido com relação à frequência máxima obtida por um intervalo do histograma, para que os dados referentes ao ângulo da colheitadeira sejam considerados válidos. Assim, se a maior frequência obtida por um intervalo for 100, e o usuário considerar um percentual mínimo de 40%, serão eliminados todos os pontos presentes no conjunto de dados que estejam em intervalos do histograma com frequência menor do que 40. Esse processo é realizado de maneira recursiva, com recálculo do histograma, até que não existam mais intervalos com frequência abaixo do percentual definido pelo usuário. Essa metodologia tem o objetivo de eliminar dados que foram gerados, por exemplo, por manobras de cabeceira e ao longo do percurso dentro do talhão, paradas para descanso, dentre outras, onde o operador deveria ter desligado o sensor para que os dados não fossem gerados. A Figura 2 exibe um exemplo do processo de pré-filtragem proposto, executado em um dos mapas utilizados neste trabalho.

Na Figura 2a já é possível observar dois intervalos de ângulos que ocorrem com muito maior frequência do que os outros (pelo menos 11) durante a operação da colheitadeira – entre 0 e 10 graus e entre 180 e 200




Figura 1. Localização do Experimento. Fonte da Imagem: Google Maps.

graus. Esses dois intervalos indicam praticamente a mesma angulação da colheitadeira, só que em sentidos opostos quando esta percorre o talhão. Na primeira iteração, após a eliminação dos 11 intervalos com frequência mais baixa, o histograma é recalculado e surgem dois novos pequenos intervalos, que podem ser considerados como subintervalos dos dois intervalos mais frequentes (Figura 2b). Finalmente, na última iteração, por terem frequência muito baixa, esses dois intervalos são eliminados, restando apenas os intervalos de maior frequência (Figura 2c). A partir desse resultado, é pressuposto que foram eliminados os pontos considerados como fora do trajeto

usual da colheitadeira e que podem prejudicar análises posteriores.

Para o processo de filtragem dos dados de produtividade após a pré-filtragem, o protocolo desenvolvido por Vega et al. (2019) foi utilizado, considerando algumas adaptações. O código-fonte do algoritmo que processa o protocolo, escrito em linguagem R, está disponível na seção de materiais suplementares da publicação original. As principais modificações realizadas estão relacionadas ao desempenho do algoritmo na execução de funções que calculam distâncias entre os pontos vizinhos, pois os exemplos utilizados pelos autores são de talhões de produção de algodão com cerca de 35 ha, com espaçamento irregular entre linhas partindo de 7 m até 30 m, e espaço entre os pontos na linha de aproximadamente 3 m. Os talhões utilizados neste experimento possuem cerca de 200 ha, com espaçamento entre linhas regular de aproximadamente 4 m e distância entre os pontos na linha de aproximadamente 2 m. Assim, o conjunto de dados utilizado neste experimento é substancialmente mais denso do que o que foi utilizado por Vega et al. (2019) para testar o protocolo desenvolvido.

Por causa dessa diferença de densidade, as modificações foram realizadas essencialmente na questão da eficiência da função *dnearneigh* do pacote *spdep* (Bivand, 2022) utilizado pelo algoritmo desenvolvido por Vega et al. (2019) para buscar os vizinhos mais próximos de cada amostra, considerando uma distância definida como parâmetro pelo usuário. O valor a ser atribuído a esse parâmetro depende da densidade de pontos dos mapas a serem analisados, e deve ser definido de forma que cada ponto a ser filtrado possua uma quantidade de vizinhos suficiente para análise. Originalmente, essa função faz uma busca sequencial pelos vizinhos e foi alterada para utilizar uma estrutura computacional conhecida como *kd-tree* (Bentley, 1975), extremamente eficiente para busca de vizinhos mais próximos, permitindo a filtragem dos 130 mapas pelo atributo de produtividade em um tempo aceitável. Essas alterações foram realizadas diretamente pelos desenvolvedores responsáveis por esse pacote. Assim, o protocolo proposto neste trabalho permitiu analisarmos a redução do coeficiente de variação de cada mapa original de produtividade, considerando três abordagens distintas: I) filtragem apenas pelo atributo de produtividade, como originalmente proposto por Vega et al. (2019); II) filtragem apenas pelo ângulo da colheitadeira a partir da eliminação de amostras com valores menos frequentes no histograma; e III) filtragem considerando a abordagem (II) (como uma pré-filtragem) e seus mapas de saída como entrada para execução da abordagem (I).




Figura 2. Exemplo de processo de pré-filtragem de amostras considerando a frequência de ocorrência de diferentes ângulos de operação da colheitadeira, com recálculo recursivo de (a) até (c).

3 RESULTADOS E DISCUSSÃO

Após a execução da filtragem dos 130 mapas de produtividade utilizando as três abordagens descritas na seção anterior, foi realizado o cálculo do coeficiente de variação resultante para cada um dos mapas originais, bem como para os mapas obtidos usando essas três abordagens (Figura 3).

Por meio do gráfico da Figura 3, é possível verificar que, na maioria dos casos, a utilização de metodologias de filtragem de mapas de produtividade pode reduzir substancialmente o coeficiente de variação desses mapas. Em média, a abordagem (I) proporcionou uma redução de aproximadamente 25%; a abordagem (II), uma redução de aproximadamente 3%; e a abordagem (III), uma redução de aproximadamente 24%. A abordagem (II), por si só, representa uma redução pequena, porém que pode ser importante pa-

ra evitar reduções mais drásticas que podem ocorrer com o uso exclusivo da filtragem por valores de produtividade, considerado na abordagem (I).

Uma outra forma de verificar o efeito das três diferentes abordagens de filtragem é constatando a porcentagem de redução de amostras contendo dados supostamente espúrios com relação ao conjunto de dados original (Figura 4).

Por meio do gráfico da Figura 4, também é possível verificar que, além do CV, abordagens de filtragem também podem reduzir substancialmente a quantidade de amostras dos mapas, considerando que as amostras eliminadas são supostamente espúrias. Em média, a abordagem (I) proporcionou uma redução de 17,1% na quantidade de amostras; a abordagem (II) proporcionou uma redução de 1,9% na quantidade de amostras; e a abordagem (III), uma redução




Figura 3. Gráfico exibindo os coeficientes de variação (CV) calculados para os 130 mapas de produtividade utilizados no experimento (numerados sequencialmente no eixo X), considerando os dados originais e as abordagens de filtragem (I), (II) e (III).




Figura 4. Gráfico que exibe a redução da quantidade de amostras (em %) em relação ao conjunto de dados original, considerando as três abordagens de filtragem utilizadas (eixo Y) para cada um dos mapas utilizados (numerados sequencialmente no eixo X).

de 11,7% na quantidade de amostras. Reduções substanciais da quantidade de amostras, desde que estas sejam realmente espúrias, podem proporcionar ganhos de eficiência e eficácia em atividades futuras a serem realizadas com esses mapas, como a interpolação espacial e o delineamento de zonas de manejo.

A Figura 5 mostra exemplos de mapas resultantes considerando as três abordagens para um dos talhões da safra 2019/2020, com cerca de 196 ha de área, onde o uso da pré-filtragem pelo ângulo de operação da colheitadeira se mostrou importante para eliminar pontos que podem prejudicar uma filtragem com base em vizinhos mais próximos.

Por meio da Figura 5 (itens a e c), é possível verificar o viés da abordagem (II) em eliminar apenas os pontos que estão fora da trajetória usual da colheitadeira, como pode ser verificado observando-se a linha em tom essencialmente vermelho (valores de produtividade próximos ou iguais a zero). A Figura 5b mostra o mapa filtrado utilizando-se exclusivamente os dados de produtividade, e uma redução de cerca de 50% no coeficiente de variação (CV) e 19,8% da quantidade de amostras do mapa. Essa redução no CV é praticamente a mesma que ocorre ao utilizar a abordagem (III), mas com uma redução de amostras menor, de

cerca de 15,7% (Figura 3d). Nesse caso, é possível observar que a pré-filtragem inicial evitou que alguns dados fossem eliminados do mapa final diretamente pela filtragem de produtividade (cerca de 4% das amostras), como os dois “buracos” gerados ao longo da linha eliminada por trajetória inválida que aparecem no resultado do mapa da Figura 5b e não aparecem no mapa da Figura 5d. A Figura 6 mostra mais detalhes de duas regiões do mapa da Figura 5d onde é possível verificar esse efeito.

A Figura 7 mostra outro exemplo similar ao exibido na Figura 5, também para um talhão da safra 2019/2020 com aproximadamente 195 ha de área, onde é possível verificar a influência da pré-filtragem proposta pela abordagem (III).

Da mesma forma que ocorre no exemplo anterior, a filtragem utilizando apenas dados de produtividade (Figura 7b) proporciona uma alta redução no coeficiente de variação do mapa resultante (cerca de 45%) e o aparecimento de muitos “buracos” que poderiam conter manchas indicativas de algo relacionado à variabilidade da área. Nesse exemplo também é possível observar, comparando-se as Figuras 7a e 7c, que a abordagem (II) novamente proporcionou apenas a retirada dos pontos fora da trajetória da colheitadeira-




Figura 5. Exemplo do processo de filtragem de mapa de produtividade, onde: (a) mapa com dados brutos originais (CV=0,26); (b) mapa filtrado considerando a abordagem (I) (CV=0,13 e redução de 19,8% das amostras); (c) mapa filtrado considerando a abordagem (II) (CV=0,21 e redução de 4,45% das amostras); e (d) mapa filtrado considerando a abordagem (III) (CV=0,13 e redução de 15,7% das amostras). As cores representam valores de produtividade entre 0 e 11 ton/ha, na escala Vermelho-Amarelo-Verde (RdYIGn).




Figura 6. Detalhes de duas regiões do mapa da Figura 5d onde se observam pontos que foram mantidos em virtude execução do pré-processamento pelo ângulo da colheitadeira (em amarelo) na abordagem (III) em comparação com os que seriam mantidos com a utilização direta da filtragem por produtividade realizada pela abordagem (I) (em vermelho).




Figura 7. Exemplo do processo de filtragem de mapa de produtividade, onde: (a) mapa com dados brutos originais ($CV=0,24$); (b) mapa filtrado considerando a abordagem (I) ($CV=0,13$ e redução de 17,13% das amostras); (c) mapa filtrado considerando a abordagem (II) ($CV=0,21$ e redução de 3,42% das amostras); e (d) mapa filtrado considerando a abordagem (III) ($CV=0,13$ e redução de 14,48% das amostras). As cores representam valores de produtividade entre 0 e 11 ton/ha, na escala Vermelho-Amarelo-Verde (RdYlGn).

ra, ocasionando também uma redução na dimensão dos “buracos” proporcionados pela abordagem (I) quando utilizada como pré-filtragem na abordagem (III) (Figura 7d).

O último exemplo mostra os processos executados em dados coletados de um talhão na safra 2021/2022, com aproximadamente 194 ha de área com um $CV=0,21$ e, portanto, já mais baixo em relação aos anteriores para o mapa original (Figura 8).

Nesse exemplo, apesar de a abordagem (I) proporcionar uma redução menor no coeficiente de variação com relação aos exemplos anteriores (cerca de 22%), é possível observar a eliminação de pontos importan-

tes do mapa, no canto inferior direito do talhão, que podem representar uma mancha de produtividade baixa de fato (Figuras 8a e 8b). O efeito causado pela abordagem (II) não é perceptível com relação ao mapa original (Figura 8c), porém a sua utilização como pré-processamento para a abordagem (III) mostra uma tendência de evitar alguns pontos eliminados pela abordagem (I), também no canto inferior direito do talhão, que proporcionaram a formação de buracos menores com relação aos que foram gerados pela abordagem (I) (Figura 8d). Essa tendência também pode ser observada pela quantidade de amostras eliminadas pela abordagem (III): cerca de metade




Figura 8. Exemplo do processo de filtragem de mapa de produtividade, onde: (a) mapa com dados brutos originais (CV=0,21); (b) mapa filtrado considerando a abordagem (I) (CV=0,16 e redução de 19,7% das amostras); (c) mapa filtrado considerando a abordagem (II) (CV=0,20 e redução de 1,1% das amostras); e (d) mapa filtrado considerando a abordagem (III) (CV=0,17 e redução de 11,2% das amostras). As cores representam valores de produtividade entre 0 e 11 ton/ha, na escala Vermelho-Amarelo-Verde (RdYIGn).

da quantidade que foi eliminada pela abordagem (I). De qualquer forma, apesar de uma melhora no mapa, os buracos ainda permanecem, o que dá a entender que, especificamente para mapas com manchas muito evidentes de baixas produtividades, é necessário um ajuste no parâmetro de distância dos vizinhos mais próximos para a função *dnearest*, utilizada tanto pela abordagem (I) quanto pela abordagem (III).

Considerando os três exemplos descritos, a utilização de pré-processamento nos mapas de colheita, eliminando dados que podem ter sido causados por erros operacionais ou por trajetórias indesejáveis das colheitadeiras antes de realizar o tratamento estatístico diretamente na variável de produtividade, mostrou-se promissora no sentido de evitar ajustes indevidos e, conseqüentemente, a eliminação de amostras representativas para a variabilidade espacial da lavoura. Assim, é importante que esse passo seja realizado quando esse tipo de dado está disponível. Entretanto, com a pré-filtragem eliminando apenas os pontos cujo ângulo da colheitadeira não está entre os mais frequentes, ainda não é possível afirmar que a permanência do CV alto em alguns mapas, mesmo após a execução desse pré-processamento, ocorre apenas

devido à variabilidade da produtividade. Assim, outras variáveis já destacadas, relacionadas à trajetória da colheitadeira e à própria operação de campo, devem ser avaliadas para que sejam obtidos resultados mais assertivos.

4 CONCLUSÕES

Este trabalho apresentou um experimento para filtragem de mapas de produtividade, considerando três abordagens distintas, utilizando apenas o dado de produtividade em si; apenas dados referentes ao ângulo de operação da colheitadeira (trajetória); e uma combinação das duas anteriores.

A abordagem de Vega et al. (2019) mostrou bom desempenho na redução do coeficiente de variação e a facilidade de execução em lote, uma vez que seu código-fonte foi preparado para operar dessa maneira. Entretanto, os exemplos utilizados pelos autores eram de mapas com densidade de pontos muito menor do que os mapas gerados para este experimento, o que demandou alterações no código-fonte para melhorar o desempenho dos algoritmos utilizados. Além disso, para os exemplos deste trabalho, essa aborda-

gem proporcionou a formação de “buracos” na maioria dos mapas resultantes, eliminando pontos que provavelmente deveriam continuar fazendo parte do mapa. Esses “buracos” podem aparecer tanto pela dificuldade em se determinar os parâmetros de distância para a dependência espacial, exigidos pelo algoritmo para os usuários, como também pela presença, nesses locais, de dados coletados indevidamente por erros operacionais ou manobras indesejadas realizadas pela colheitadeira.

Para tentar diminuir o efeito desses problemas, este trabalho propôs uma abordagem em que os dados referentes a erros operacionais pudessem ser eliminados antes da análise geoestatística dos dados de produtividade. Os resultados mostraram que a pré-filtragem eliminando amostras com ângulos de colheitadeira menos frequentes, ou seja, fora da direção convencional da colheita, permitem uma melhor eficácia do processo de filtragem executado diretamente na variável de produtividade.

Para melhorias nessa nova abordagem, é importante investigar a possibilidade de utilização de outras variáveis referentes à operação fornecidas pela colheitadeira, como as variações de distância e intervalos de tempo entre os pontos coletados. Uma outra possibilidade é utilizar abordagens de estimativa de produtividade considerando dados de sensoriamento remoto, como a desenvolvida por Morelli-Ferreira et al. (2021), para realizar uma pré-filtragem e eliminar pontos com valores inconscientes na resolução espacial obtida pelo satélite utilizado.

AGRADECIMENTOS

À Fazenda São Francisco, pelo fornecimento dos mapas de produtividade referentes a duas safras.

REFERÊNCIAS

- BENTLEY, J. L. Multidimensional binary search trees used for associative searching. **Communications of the ACM**, v. 18, n. 9, p. 509-517, 1975. DOI: <http://doi.org/10.1145/361002.361007>.
- BIVAND, R. R Packages for analyzing spatial data: a comparative case study with areal data. **Geographical Analysis**, v. 54, n. 3, p. 488-518, 2022. DOI: <http://doi.org/10.1111/gean.12319>.
- LI, H.; CALDER, C. A.; CRESSIE, N. Beyond Moran's I: testing for spatial dependence based on the spatial autoregressive model. **Geographical Analysis**, v. 39, n. 4, p. 357-375, 2007. DOI: <http://doi.org/10.1111/j.1538-4632.2007.00708.x>.
- MALDANER, L. F.; CORRÊDO, L. P.; TAVARES, T. R.; MENDEZ, L. G.; DUARTE, C.; MOLIN, J. P. Identifying and filtering out outliers in spatial datasets. In: **Proceedings of the 14th International Conference on Precision Agriculture**, Montreal: ISPA, 2018. p. 24-27.
- MALDANER, L. F.; WEI, M. C. F.; MOLIN, J. P. **Mapas de produtividade**. Agricultura de Precisão – Boletim Técnico 04. Piracicaba: ESALQ-USP, 2019.
- MORELLI-FERREIRA, F. MAIA, N. J. C.; TEDESCO, D.; KAZAMA, E. H.; CARNEIRO, F. M.; SANTOS, L. B.; SEBEN JUNIOR, G. F.; ROLIM, G. S.; SHIRATSUCHI, L. S.; SILVA, R. P. Comparison of machine learning techniques in cotton yield prediction using satellite remote sensing. **Preprints**, v. 2021120138, 2021. DOI: <http://doi.org/10.20944/preprints202112.0138.v2>.
- R-PROJECT, 2022. Disponível em: <https://www.r-project.org/>. Acesso em: 08 ago. 2022.
- SUDDUTH, K. A.; DRUMMOND, ST. Yield editor: Software for removing errors from crop yield maps. **Agronomy Journal**, v. 99, n. 6, p. 1471-1482, 2007.
- VEGA, A.; CÓRDOBA, M.; CASTRO-FRANCO, M.; BALZARINI, M. Protocol for automating error removal from yield maps. **Precision Agriculture**, v. 20, n. 5, p. 1030-1044, 2019. DOI: <http://doi.org/10.1007/s11119-018-09632-8>.