



ALEXANDRE DOS SANTOS BOTELHO

**DEFINIÇÃO DE UNIDADE DE GESTÃO DIFERENCIADA NO MANEJO
DA CULTURA DO MILHO SAFRINHA**

LAVRAS –MG

2022

ALEXANDRE DOS SANTOS BOTELHO

**DEFINIÇÃO DE UNIDADE DE GESTÃO DIFERENCIADA NO MANEJO DA
CULTURA DO MILHO SAFRINHA**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Agronomia, para a obtenção do título de Bacharel.

Prof. Dr. Adão Felipe dos Santos
Orientador

LAVRAS – MG

2022

ALEXANDRE DOS SANTOS BOTELHO

**EFICIÊNCIA NO DELINEAMENTO DE ZONAS DE MANEJO UTILIZANDO
PLATAFORMAS DIGITAIS**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Agronomia, para a obtenção do título de Bacharel

APROVADO em: 15 / 09 / 2022

Dr. Adão Felipe dos Santos

Eng. Agrônomo Thiago Orlando Costa Barboza

Eng. Agrônomo Marcelo Araújo Junqueira Ferraz

Prof. Dr. Adão Felipe dos Santos
Orientador

LAVRAS – MG

2022

SUMÁRIO

1.	INTRODUÇÃO	5
2.	MATERIAL E MÉTODOS	8
2.1.	OBTENÇÃO DOS DADOS	8
2.2.	LOCAL DE OBTENÇÃO DOS DADOS	8
2.3.	ANÁLISE DE DADOS.....	9
3.	RESULTADOS E DISCUSSÃO	14
4.	CONCLUSÃO	26
5.	REFERÊNCIAS.....	27

1 INTRODUÇÃO

O milho (*Zea mays* L.) é um dos cereais mais plantados mundialmente, sendo também uma das principais culturas produzidas no Brasil, ocupando o segundo lugar no ranking de produção no país (CONAB, 2019). Isso se dá por ser um vegetal de grande valor nutritivo e energético, tanto para consumo humano quanto para consumo animal (MAPA, 2018). É rico em fibras, proteínas e carboidratos, bem como vitaminas do complexo A e B, sais minerais, fosfatos, cálcio, ferro, óleo e quantidades consideráveis de açúcares, celulose, gorduras e calorias (ABIMILHO, 2019). Além disso, a produção de milho também se destaca pela grande quantidade de produtos os quais podem ser extraídos dele, tais como polímeros, bebidas, combustíveis e etc. (MIRANDA, 2018).

O Brasil é o terceiro maior produtor mundial de milho, ficando atrás apenas dos Estados Unidos e China, respectivamente (FIESP, 2022). Segundo dados da Conab (2022), a previsão para a safra 2021/22 é de uma produção total de 113,3 milhões de toneladas do cereal, um acréscimo de 30,1% em relação à safra anterior – apesar da forte queda na produtividade provocada pelo severo déficit hídrico nos anos de 2021 e 2022.

O milho de segunda safra tem fundamental importância nos sistemas de produção de grãos no Brasil, tornando viável a rotação de cultura, formação de palhada e compondo renda para os produtores – sendo uma das principais culturas utilizadas para tal finalidade, normalmente em sucessão com a soja. Estima-se que a área destinada para o cultivo do milho safrinha foi de 16.378,6 mil hectares, 9,2% superior à área destinada à mesma atividade na safra anterior (CONAB, 2022). Apesar do grande aumento do custo de produção, a antecipação da colheita da soja e as cotações registradas para o milho impulsionaram os produtores para alcançarem tal patamar de área plantada, sendo a maior área já registrada para o cultivo do cereal no país (CONAB, 2022).

Entretanto, na época em que o milho segunda safra é plantado, há um histórico de ocorrência de adversidades climáticas que comprometem a produtividade, causando menor rendimento. Para o ano de 2022, registrou-se queda de produtividade em relação às estimativas iniciais em vários estados do país, cuja produtividade foi 35% menor que a estimativa inicial, em 3,9 ton ha⁻¹ (CONAB, 2022). Nesse contexto, o emprego de softwares e imagens orbitais podem facilitar o monitoramento da cultura no campo e auxiliar no planejamento agrícola (TRENTIN, 2010).

Ligada ao uso de softwares e imagens orbitais, as tecnologias aplicadas pela Agricultura de Precisão (AP) e Agricultura Digital (AD) possibilitam analisar, prever e gerenciar perdas produtivas. Dessa forma, o mapeamento da variabilidade espacial dos cultivos, em especial o vigor da cultura e a produtividade, a nível de unidade produtiva ou talhão, tornou-se essencial para o gerenciamento localizado (ARAÚJO et al., 2005). Uma das tecnologias mais utilizadas para tal finalidade é o mapa de produtividade, pois auxilia na caracterização da variabilidade espacial da produção e identificação de áreas homogêneas (MOLIN, 2002). Contudo, a AP fundamentou-se, em seu início, no estudo do manejo da variabilidade dos nutrientes num esquema de amostragem de solo em malha para identificar todas as causas das variabilidades da produtividade (LUCHIARI JUNIOR et al., 2004). Mas estudos relataram insucesso nessa proposta (SCHEPERS, 2000). Assim, buscando a otimização da relação de número de amostras de solo em relação ao custo da amostragem, Varvel et al. (1999) mostraram que imagens aéreas de solo descoberto poderiam ser utilizadas para orientar a amostragem, pois identificaram relação do padrão de distribuição de nutrientes e matéria orgânica com os mapas obtidos após esquema intensivo de amostragem em malha fina. A partir deste estudo, técnicos e provedores de serviços de amostragem de solo começaram a considerar a metodologia de uso de imagens orbitais para orientação das amostragens (JUNIOR et al., 2011). A partir daí, novas abordagens, como zonas homogêneas de manejo, mostraram-se propícias para indicar os locais mais adequados para direcionar as amostragens (DOERGE, 1999; FLEMING; WESTFALL; WIENS, 1999).

O conceito de zonas homogêneas de manejo, ou apenas Zonas de Manejo (ZM), do ponto de vista de Luchiari Junior et al. (2000), diz respeito às áreas de iguais eficiência de uso de insumos, produção potencial e risco de impacto ambiental. Para tal, estes autores utilizaram para mapas de produtividade, mapas de classificação do solo, mapas de condutividade elétrica aparente do solo, bem como imagens de dossel de planta e de solo descoberto para delinear zonas homogêneas de manejo e direcionar as amostragens. Em concordância, Shanahan et al. (2000) utilizaram procedimento parecido para analisar o efeito de diferentes densidades de plantio em função de características do terreno na produtividade do milho.

Em um contexto onde há risco de adversidades climáticas que possam comprometer no cultivo do milho de segunda safra, e sendo a AP uma forma de monitorar e gerenciar as perdas produtivas, a utilização de mapas de produtividade em conjunto com o delineamento de ZMs pode ser uma forma de otimizar o processo de identificação de variabilidade espacial

e gerenciamento da produção. No entanto, apesar de haver grande número de trabalhos sobre o tema, ainda há pouca adoção dessas tecnologias pelos produtores (INAMASU et al., 2011). Isso pode estar relacionado ao fato de que escolher as variáveis que melhor representem a variabilidade da lavoura nem sempre é uma tarefa fácil. Segundo Molin (2015), a metodologia adotada está associada também ao conjunto de dados utilizado. Desse modo, o uso de ZM nas propriedades pode não ser trivial, pois é necessário não só coletar e processar dados, mas também saber quais dados utilizar e qual tipo de processamento é mais adequada para cada cenário.

Uma forma de democratizar o uso de mapas de produtividade e as ZM é através do uso de plataformas digitais e aplicativos. Conforme pontuam QUEIROZ et al. (2022), essas ferramentas vêm contribuindo para a otimização do sistema de produção, facilitando a análise de dados e auxiliando o agricultor no manejo e tomada de decisão. Muitas delas, com interface amigável e gratuitas, fornecem importantes dados das lavouras, tais como índices de vegetação, mapas de produtividade e ZMs.

Uma das plataformas disponíveis no mercado é a OneSoil. Nela, através de aplicativos móvel e Web, é possível fazer um cadastro gratuito e monitorar áreas através de dados climáticos e mapas de índices de vegetação e de produtividade, bem como com a geração de ZMs e mapas de aplicação de insumos em taxa variável. Tal ferramenta se mostra útil para facilitar a tomada de decisão de produtores rurais e profissionais da agronomia, auxiliando no manejo da área e otimização de recursos.

Diante do exposto, objetivou-se comparar o delineamento de ZMs para a cultura do milho safrinha entre duas diferentes formas: através da plataforma digital OneSoil, que utiliza técnicas de Machine Learning (ML) para prever a produtividade com base no histórico de NDVI, e pelo plugin Smart-map, do software QGIS, através da análise de mapas de produtividade e de elevação do terreno.

2 MATERIAL E MÉTODOS

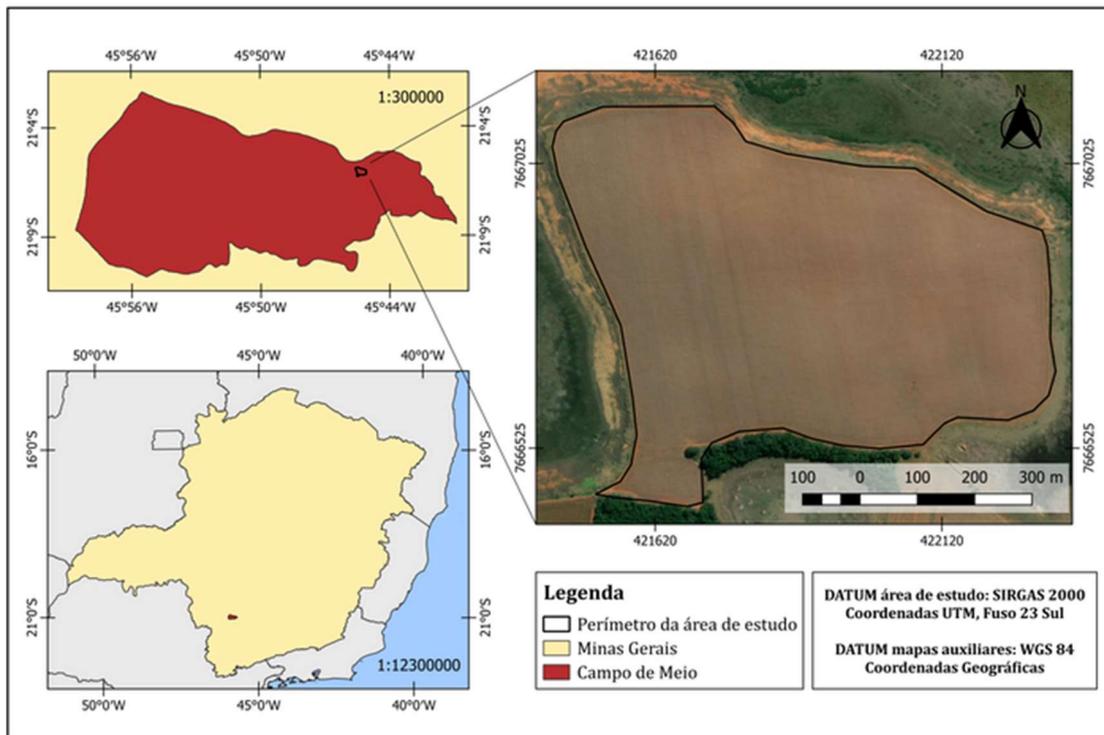
2.1 OBTENÇÃO DOS DADOS

Os dados foram obtidos através de uma colhedora John Deere, modelo S540, equipada com o monitor GS3. Para os anos avaliados, de 2020 e 2021, cultivou-se milho na segunda safra, nos períodos compreendidos entre 16 de março de 2020 a 14 de setembro de 2020 e 14 de março de 2021 a 14 de setembro de 2021, respectivamente. As colheitas foram feitas na última semana de cada cultivo.

2.2 LOCAL DE OBTENÇÃO DOS DADOS

Os dados foram obtidos de uma área comercial localizada no município de Campo de Meio, Minas Gerais, Brasil, nas coordenadas geográficas 21°05'53" Sul e 56°45'08" Oeste a uma altitude média de 771m. A área de estudo apresenta aproximadamente 40,02 hectares e corresponde ao cultivo de soja com sucessão de milho ou sorgo na segunda safra. O perímetro da área (FIGURA 1) foi delimitado a partir do software QGIS (Qgis Development Team, 2022).

Figura 1 — Mapa de localização da área de estudo



Fonte: O autor (2022).

2.3 ANÁLISE DE DADOS

Os dados foram processados através da linguagem R, no software Rstudio (Rstudio Development Team, 2022). Fez-se inicialmente a leitura dos dados advindos do monitor no formato de camada de texto delimitado (csv), cujas colunas eram: DISTANCE (distância percorrida pela máquina de um registro de dado para outro); SWATHWIDTH (largura da plataforma); TIME (hora no momento do registro do dado); VRYIELDMASS (peso inicial da massa de grãos na umidade real); MOISTURE (umidade inicial do grão) e ELEVATION (elevação). Após leitura, fez-se a conversão do csv em camada vetorial de pontos no formato *shapefile*, onde calculou-se a latitude e longitude para cada ponto, armazenando-as na tabela de atributos da camada vetorial. Logo, converteu-se a camada vetorial em um *dataframe*, sendo assim possível a seleção das variáveis de interesse: latitude, longitude, elevação, peso inicial e umidade da massa de grãos.

Após a seleção das variáveis de interesse, criou-se uma nova variável referente à produtividade, onde os valores de umidade foram corrigidos a 13% (adaptado de GOUVEIA, 2022). Calculou-se a produtividade final, em ton ha⁻¹, pela equação 1:

$$PF = \frac{VRYIELDMASS(100 - MOISTURE)}{(100 - UD)} \quad (1)$$

Onde:

PF = Produtividade final corrigida a 13% de umidade;

VRYIELDMASS = Peso inicial da massa de grãos na umidade real;

MOISTURE = Umidade inicial (real do grão);

UD = Umidade desejada (13%).

Visando a identificação e caracterização dos erros dos dados de produtividade gerados, aplicou-se a metodologia de Tukey (1977) que determina limites para eliminação de dados discrepantes. Procedendo-se à eliminação de pontos cujos valores de produtividade estivessem fora dos limites estabelecidos, finalizou-se o processo de filtragem. Os limites foram calculados pelas equações 2 e 3:

$$LS = QS + 1,5(QS - QI) \quad (2)$$

$$LI = QI - 1,5(QS - QI) \quad (3)$$

Onde:

LI = Limite inferior;

LS = Limite superior;

QS = Quartil Superior (terceiro quartil);

QI = Quartil Inferior (primeiro quartil).

Aplicada a metodologia de filtragem ao conjunto de dados, construiu-se histogramas de distribuição de densidade e fez-se a visualização de forma espacializada por meio de um mapa de pontos, além da análise descritiva para cada caso, antes e depois da filtragem. Na análise descritiva obteve-se os valores de de mínimo, média, mediana, máximo, quartis inferior e superior, desvio padrão, variância e assimetria. Doravante, criou-se uma nova camada de texto delimitado (csv) com os dados filtrados para posterior análise geoestatística.

Após análise exploratória e filtragem dos dados, procedeu-se com as análises de geoestatística através do Smart-map, no QGIS. Mediante o plugin, é possível: (a) interpolação de dados através da krigagem ordinária; (b) interpolação de dados através de algoritmos de aprendizado de máquina (*Support Vector Machine*) e (c) delimitação de zonas de manejo através do algoritmo de classificação por agrupamento *Fuzzy k-means* (PEREIRA et al., 2022).

A análise geoestatística foi utilizada para avaliar a dependência espacial dos atributos avaliados, após o procedimento de filtragem, por meio do ajuste dos variogramas. A equação 4 descreve o cálculo para a obtenção das semivariâncias (SILVA et al., 2020).

$$\hat{\gamma}(h) = \frac{1}{2}N(h) \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (4)$$

Onde:

$\hat{\gamma}(h)$ - Semivariância em função da distância de separação (h) entre pares de pontos;

h - Distância de separação entre pares de pontos;

N(h) - Número de pares experimentais de observações Z(x_i) e Z(x_i + h) separados por uma distância h.

O semivariograma normalmente é representado pelo gráfico de $\hat{\gamma}(h)$ versus h , isto é, como a semivariância do atributo versus a distância (VIEIRA, 1997).

Para interpolar os dados filtrados de produtividade de grãos da safra 2020, 2021 e de elevação, fez-se o carregamento das camadas de texto delimitado para o QGIS e selecionou-se as variáveis de interesse dentro do Smart-map. Em seguida, definiu-se o tamanho do pixel do raster do produto a ser gerado na interpolação em 5 metros, delimitando também o raster com base no polígono de contorno da área.

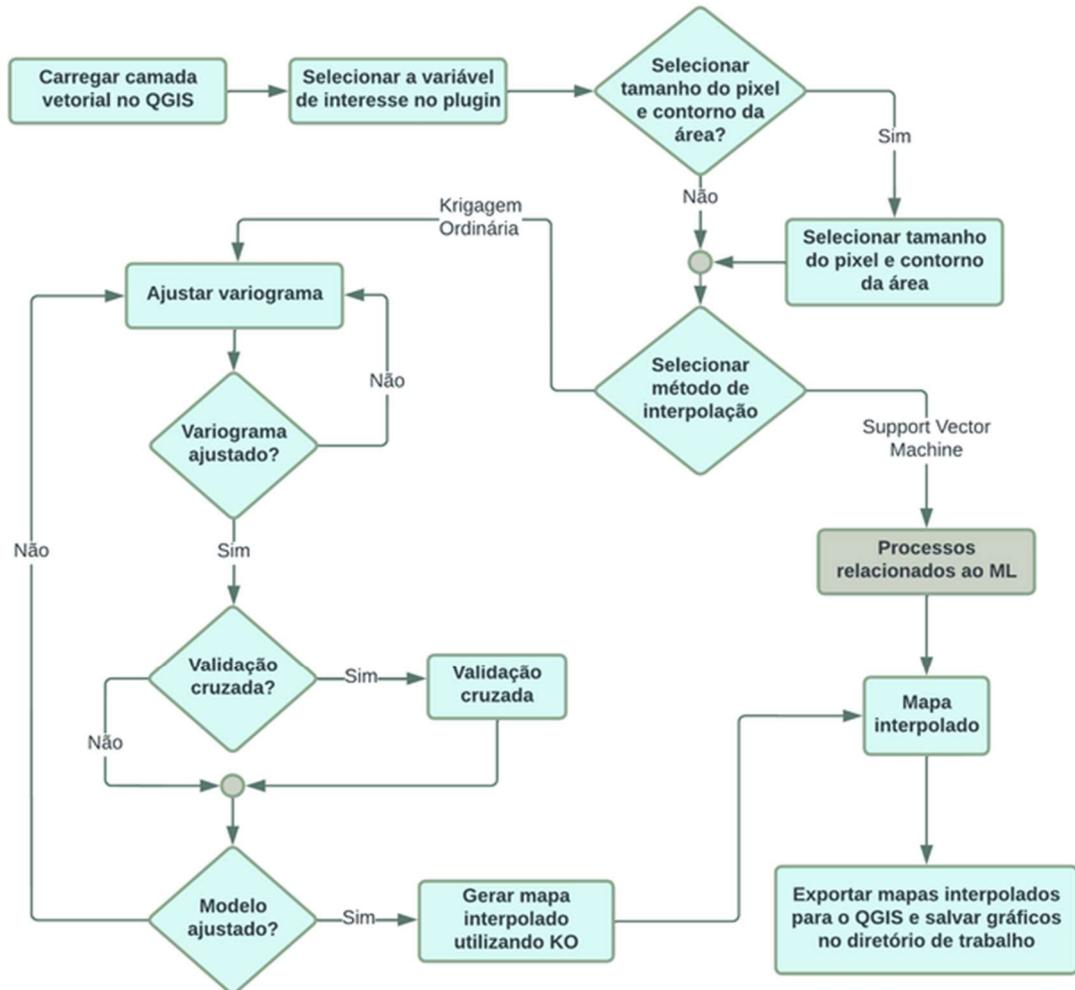
No plugin, só é possível prosseguir nas análises caso o número de amostras seja igual ou inferior a 5000 observações. Neste caso, dada a grande densidade de dados, foi necessário fazer uma reamostragem – que é feita na própria ferramenta através da média dos vizinhos mais próximos.

Após a reamostragem, prossegue-se na etapa da escolha do método de interpolação. No plugin é possível escolher dois métodos: por krigagem ordinária (KO) ou por *Machine Learning* (ML). Para esta análise, adotou-se o método de krigagem ordinária.

Tipicamente, três modelos são testados para ajustar a curva do variograma: o modelo esférico, o gaussiano e o exponencial. Além desses, também foram testados os modelos linear e linear com patamar. Os valores de efeito pepita (C_0); contribuição da semivariância C_1 ; patamar (C_0+C_1) e alcance (A) foram obtidos com o ajuste visual na aba de interpolação. Os modelos foram então comparados com base em seus parâmetros e adotou-se aquele com menor valor de raiz quadrada do erro médio (RMSE) e maior coeficiente de determinação (R^2). Assim, a partir do modelo de dependência espacial adotado, foi possível prever os valores de produtividade e de elevação para os pontos não amostrados.

Ajustados os parâmetros, ainda é possível calcular e visualizar o gráfico da validação cruzada na janela de interpolação, sendo essa a última etapa antes de gerar o mapa interpolado. A figura 2 apresenta o fluxograma das principais etapas de processamento do Smart-map.

Figura 2 — Fluxograma das principais etapas de processamento do Smart-map.



Fonte: Adaptado de PEREIRA et al., 2022.

Outro importante parâmetro em análises geoestatísticas é o índice de dependência espacial (IDE), calculado calculado segundo a equação 5. O cálculo e classificação foram conformes proposto por Cambardella et al. (1994), onde o IDE é dividido em três classes: forte dependência espacial para $IDE < 0,25$; dependência espacial moderada para $0,25 \leq IDE \leq 0,75$ e baixa dependência espacial para $IDE > 0,75$.

$$IDE = \frac{C_0}{C_0 + C_1} \quad (5)$$

Em que:

IDE: Índice de dependência espacial;

C_0 : Efeito pepita;

C_1 : Contribuição da semivariância.

Após a modelagem, procedeu-se com a criação de Zonas de Manejo no Smart-map. No plugin há esta opção, que funciona independentemente da etapa de krigagem. Para tal, após gerados os mapas interpolados, selecionou-se as três variáveis interpoladas (PROD20, PROD21 e ELEV) e procedeu-se com a etapa de análise utilizando o método Fuzzy k-means.

Para definir o número ideal de classes, o plugin calcula o Índice de Performance Fuzzy (FPI - *Fuzzy Performance Index*) e a Entropia de Classificação Normal (NCE - *Normalized Classification Entropy*), que são amplamente recomendados na literatura para definir o número adequado de Zonas de Manejo (Pereira et al., 2022). Dessa forma, calculou-se o FPI e o NCE no Smart-map e gerou-se o gráfico de FPI/NCE e o mapa temático clusterizado.

A plataforma OneSoil, com base em seu algoritmo, identifica zonas de produtividade relativa com base em dados de NDVI. A partir disso, gera mapas de aplicação de insumos em taxa variada por zonas. Após fazer o upload do contorno da área de estudo para a plataforma Web e aguardar um período de processamento de 4 horas, teve-se acesso a um relatório sobre os mapas de produtividade, teor de matéria orgânica e relevo, bem como aos mapas de ZM e taxa de variação de insumos. Fez-se o download da camada vetorial das ZM, que foram classificadas e estilizadas dentro do QGIS.

3 RESULTADOS E DISCUSSÃO

Os dados brutos de produtividade foram avaliados de forma descritiva (TABELA 1). Nota-se que para ambas as variáveis de estudo, os valores de assimetria são próximos de 0, bem como valores de média e mediana próximos entre si – o que indica ajuste próximo à distribuição normal.

Tabela 1 — Análise descritiva dos dados brutos de produtividade de grãos da safra 2020 e 2021.

Parâmetros	Atributos	
	PROD20	PROD21
Mínimo	0,0000	0,0000
Média	3,0387	1,0423
Mediana	3,1043	1,0063
Máximo	7,5080	5,4578
Quartil inferior	2,3683	0,5258
Quartil Superior	3,7866	1,5214
Desvio Padrão	1,1316	0,6815
Variância	1,2804	0,4644
Assimetria	-0,4025	0,3309

Fonte: O autor (2022).

No entanto, apesar de conveniente, a distribuição normal não é uma exigência da geoestatística. Em se tratando de dados obtidos da natureza, espera-se que o ajuste entre a distribuição teórica e a real seja apenas aproximado (GOOVERTS, 1997). Mas de acordo com Webster (1985), é interessante que a distribuição não apresente caudas muito alongadas, pois atrapalharia as análises. Este fato também justifica a metodologia de filtragem utilizada.

Calculados os limites, procedeu-se com a filtragem dos dados, sendo 1.8055 ton ha⁻¹ o limite inferior e 5.8285 ton ha⁻¹ o limite superior para os dados de produtividade de grãos da safra 2020 e 0.02802 ton ha⁻¹ o limite inferior e 3.0148 ton ha⁻¹ o limite superior para os dados de produtividade de grãos da safra 2021. Antes da filtragem, os valores mínimos de produtividade de 2020 e 2021 eram nulos, sendo, portanto, não representativos da realidade; enquanto os valores máximos eram de 7,5080 e 5,4578 ton ha⁻¹, respectivamente, consideravelmente maiores que os limites superiores. A aplicação do filtro, portanto, alterou a densidade das classes em função da eliminação dos valores discrepantes, melhorando o ajuste da tendência dos dados e deixando-os mais próximos de uma distribuição normal – o que

pode ser confirmado pelos valores de assimetria, sendo para o ano de 2020 de -0,4025 antes da filtragem e 0,3481 após a filtragem. Para o ano de 2021, o valor de assimetria sobe de 0,3309 antes da filtragem para 0,3704 após a filtragem, todavia, apresentou menores valores de desvio padrão, de 0,6815 antes da filtragem e de 0,6092 após aplicação do filtro, além de também menores valores de variância, sendo 0,4644 nos dados brutos e 0,3712 após filtro. A análise descritiva pode ser visualizada na tabela 2.

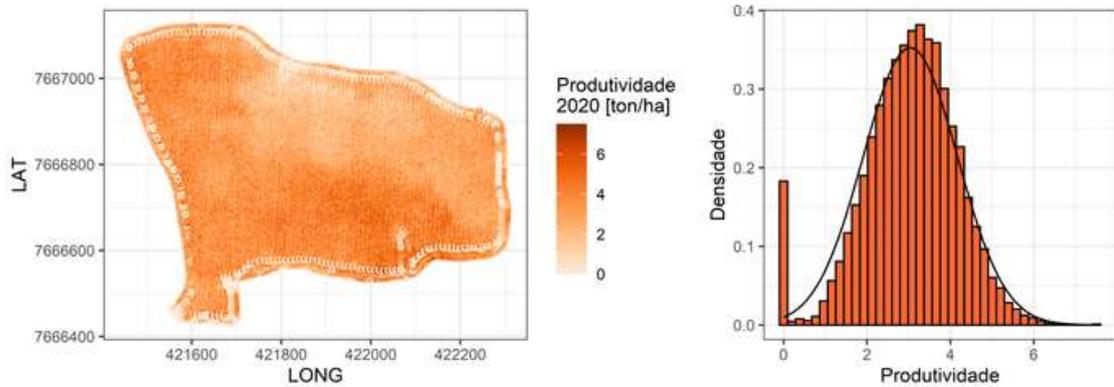
Tabela 2 — Análise descritiva dos dados filtrados de produtividade de grãos da safra 2020 e 2021.

Parâmetros	Atributos	
	PROD20	PROD21
Mínimo	1,8056	0,0282
Média	3,3050	1,1536
Mediana	3,2586	1,1002
Máximo	5,8181	3,0143
Quartil inferior	2,6527	0,6783
Quartil Superior	3,8720	1,5777
Desvio Padrão	0,8352	0,6092
Variância	0,6976	0,3712
Assimetria	0,3481	0,3704

Fonte: O autor (2022).

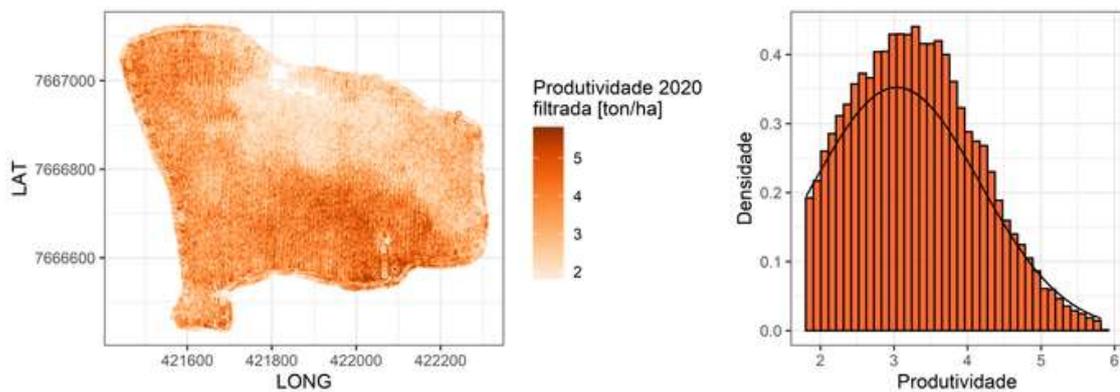
Além disso, construiu-se histogramas de distribuição de densidade e fez-se a visualização de forma espacializada por meio de um mapa de pontos, a fim de comparar os dados antes e após a filtragem. As figuras 3 e 4 são referentes, respectivamente, aos dados brutos e aos dados filtrados de produtividade de 2020; enquanto as figuras 5 e 6 são referentes respectivamente, aos dados brutos e aos dados filtrados de produtividade de 2021. Nota-se que os dados brutos apresentam considerável densidade de dados em valores nulos ou próximos a 0, o que indica erro na coleta dos dados. Nesse sentido, o processo de filtragem atuou principalmente na eliminação de dados nulos e na normalização da distribuição, eliminando principalmente os pontos localizados nas extremidades da distribuição de frequência dos mapas. Nota-se também que após a filtragem, em ambos os anos, houve melhor contraste entre as regiões de alta e de baixa produtividade.

Figura 3 — Visualização em forma vetorial e distribuição da densidade dos dados de produtividade do ano de 2020.



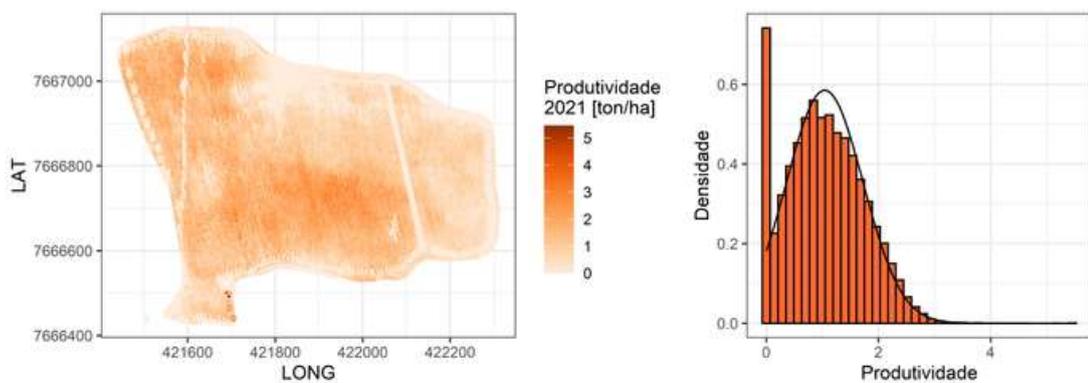
Fonte: O autor (2022).

Figura 4 — Mapa temático e distribuição da densidade dos dados filtrados de produtividade de grãos do ano de 2020



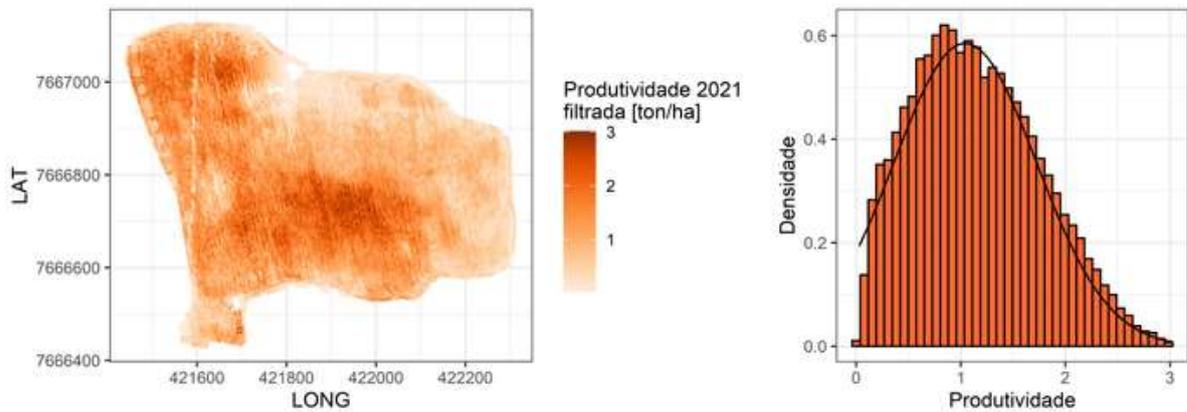
Fonte: O autor (2022).

Figura 5 — Visualização em forma vetorial e distribuição da densidade dos dados de produtividade do ano de 2021.



Fonte: O autor (2022).

Figura 6 — Mapa temático e distribuição da densidade dos dados filtrados de produtividade de grãos do ano de 2021.



Fonte: O autor (2022).

Os modelos adotados por atributo e seus principais parâmetros estão presentes na tabela 3.

Tabela 3 — Principais parâmetros dos semivariogramas ajustados para os dados de produtividade de grãos da safra 2020 e 2021 (PROD20 e PROD21) e para elevação (ELEV), respectivamente

Atributo	Parâmetros do ajuste							
	Modelo	C0	C1	C0+C1	A	RMSE	R ²	IDE
PROD20	Linear com patamar	0,049	0,684	0,733	282,409	0,001	0,999	0,067
PROD21	Linear com patamar	0,019	0,419	0,438	235,072	0,000	0,999	0,043
ELEV	Gaussiano	0,080	35,795	35,875	316,376	1,593	0,999	0,002

C0: efeito pepita; C1: contribuição da semivariância; C0+C1: patamar; A: Alcance; RMSE: raiz quadrada do erro médio; R²: coeficiente de determinação; IDE: índice de dependência espacial.

Fonte: O autor (2022).

Observa-se que houve bom ajuste dos modelos, que apresentaram baixos valores de RMSE e altos valores de R², sendo que para os dados de produtividade de 2020 e 2021 ajustou-se o modelo linear com patamar e na variável elevação ajustou-se o modelo gaussiano. Quanto ao índice de dependência espacial, conforme a classificação de Cambardella et al (1994), há forte dependência espacial dos atributos interpolados.

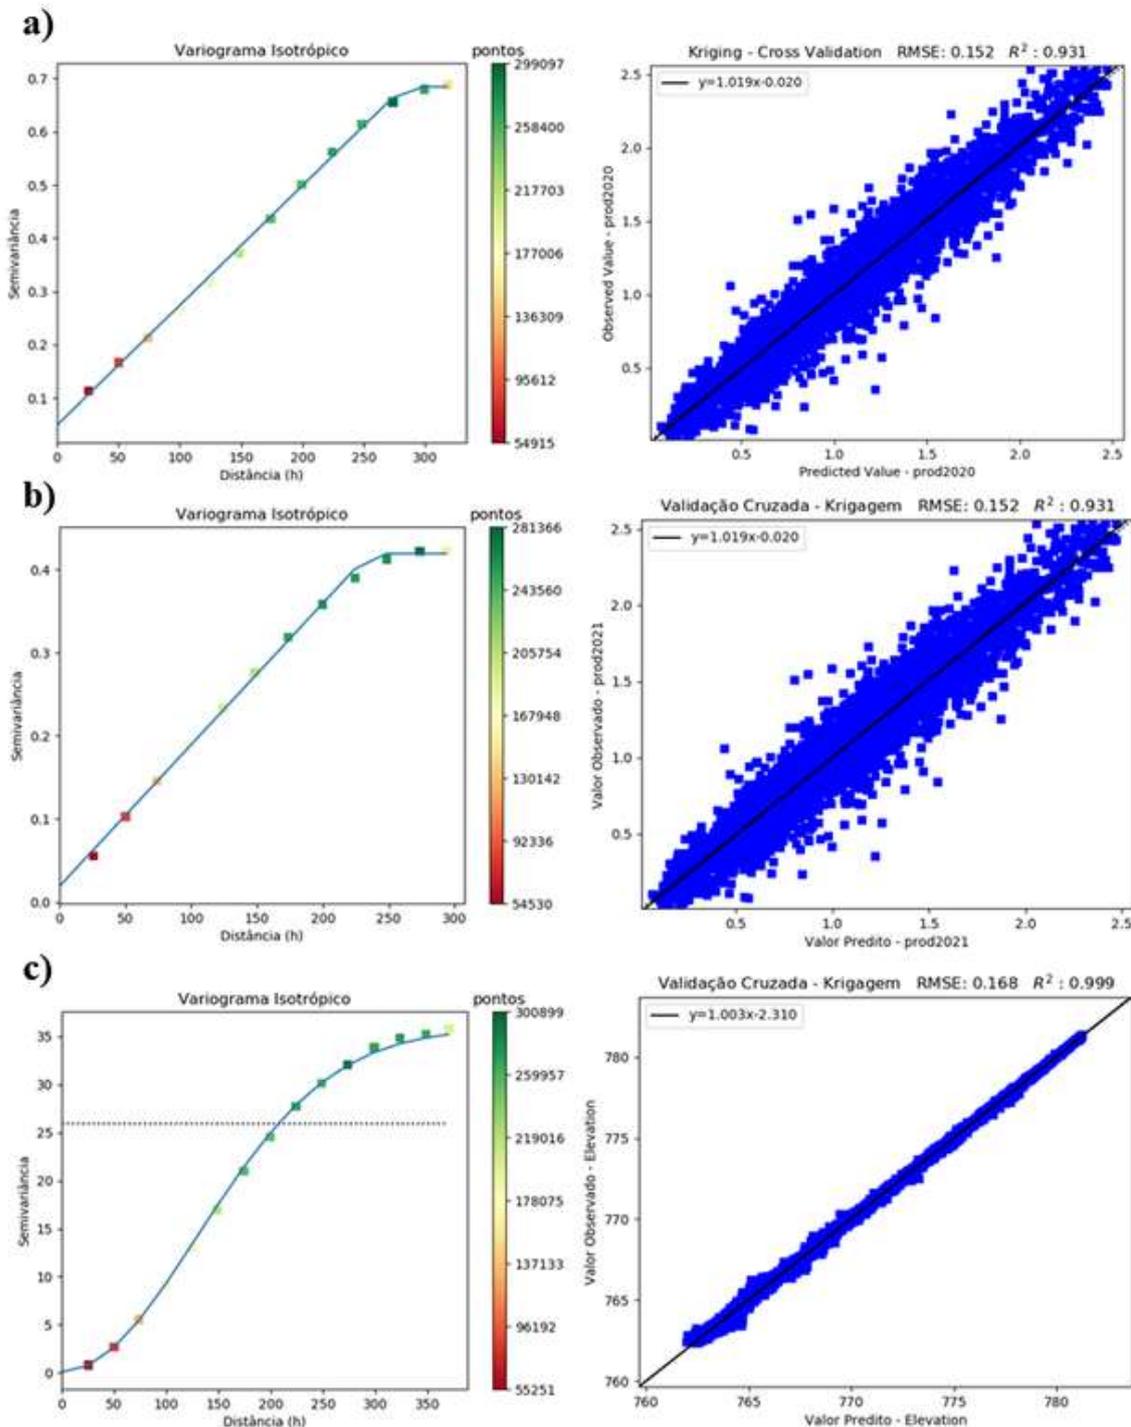
Para ambos atributos avaliados vê-se baixos valores de efeito pepita (C0), que diz respeito à variabilidade não explicada do deslocamento do variograma em relação a origem.

Isso pode ser explicado pelo fato de haver grande densidade de dados (5000 pontos em 40,02ha), diminuindo assim a distância entre as amostras e, portanto, diminuindo a incerteza causada pelas variações do atributo que não podem ser mensuradas na escala de amostragem adotada (VIEIRA, 2000). Outro ponto que pode ter contribuído para isso é o fato do plugin fazer uma reamostragem dos pontos, atribuindo um valor médio às amostras em relação à sua vizinhança, suavizando a distribuição dos dados ao longo do espaço.

Com relação ao alcance, que remete à máxima distância que uma variável está correlacionada espacialmente (SALVIANO et al., 1998), houve variação da produtividade nas diferentes safras, sendo 282,409m para 2020 e 235,072m para 2021. Isso pode ser explicado porque no ano de 2021 houve maior heterogeneidade dos dados, que pode ter sido causada pelas adversidades ambientais, refletidas nos baixos valores de produtividade. Já a elevação apresentou um maior alcance, de 316,376m - que se dá por conta de ser um atributo que normalmente não varia bruscamente no espaço.

Na figura 7 estão representados os gráficos do semivariograma e validação cruzada para produtividade de grãos da safra 2020 (PROD20), produtividade de grãos da safra 2021 (PROD21) e para elevação (ELEV), respectivamente.

Figura 7 — Gráfico do semivariograma experimental e gráfico de correspondência da validação cruzada para (a) produtividade de grãos da safra 2020 (PROD20), (b) produtividade de grãos da safra 2021 (PROD21) e (c) elevação (ELEV).



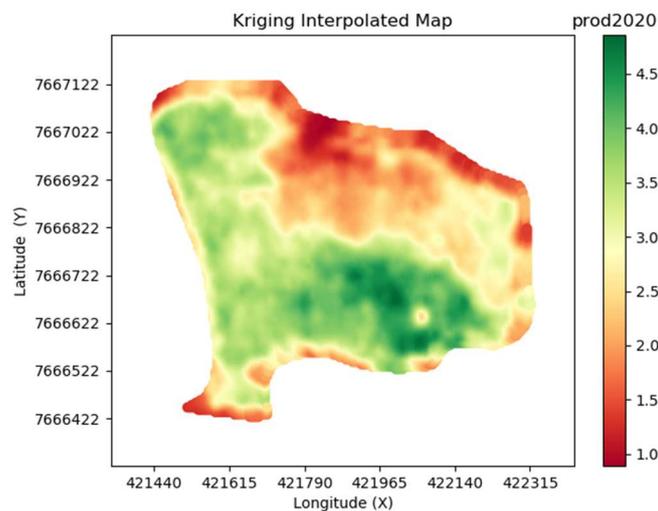
Fonte: O autor (2022).

A validação cruzada compara valores estimados pelo interpolador com valores com os valores reais, podendo ser avaliada por ferramentas estatísticas como a análise de correlação

linear (MENEGATTI e MOLIN, 2004). Nota-se que, apesar de serem dados de anos diferentes, as produtividades de 2020 e 2021 apresentaram os mesmos valores de RMSE e R^2 na validação cruzada, de 0,152 e 0,931, respectivamente. Houve uma diminuição dos parâmetros em relação aos valores preditos pelo ajuste dos variogramas, mas ainda assim houve bom ajuste para todos os atributos avaliados.

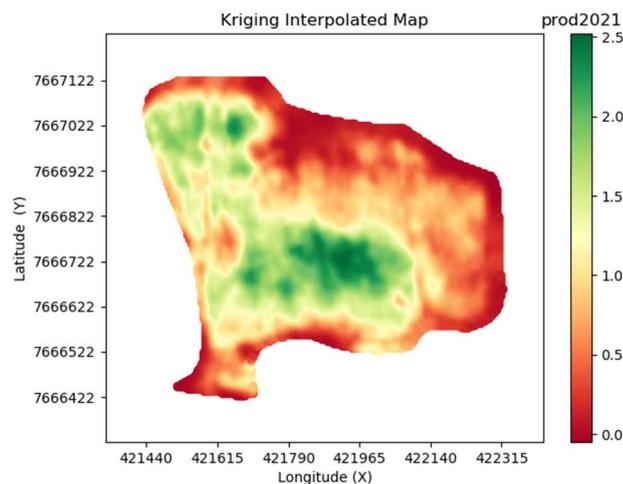
Definidos os semivariogramas, realizou-se a krigagem ordinária e gerou-se os mapas interpolados para a produtividade de grãos da safra 2020 (PROD20), produtividade de grãos da safra 2021 (PROD21) e para elevação (ELEV), respectivamente nas figuras 8, 9 e 10.

Figura 8 — Mapa temático da variabilidade espacial da produtividade de grãos da safra 2020 (PROD20).



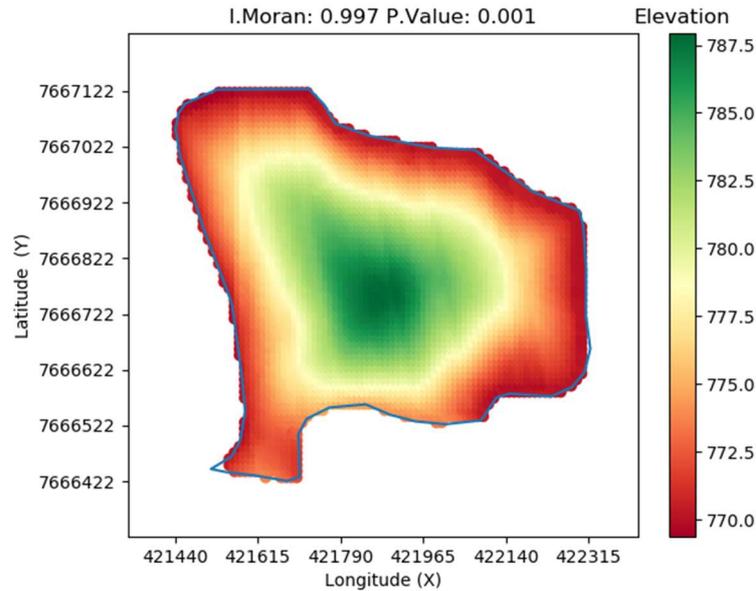
Fonte: O autor (2022).

Figura 9 — Mapa temático da variabilidade espacial da produtividade de grãos da safra 2021 (PROD21).



Fonte: O autor (2022).

Figura 10 — Mapa temático da variabilidade espacial da elevação do terreno (ELEV)

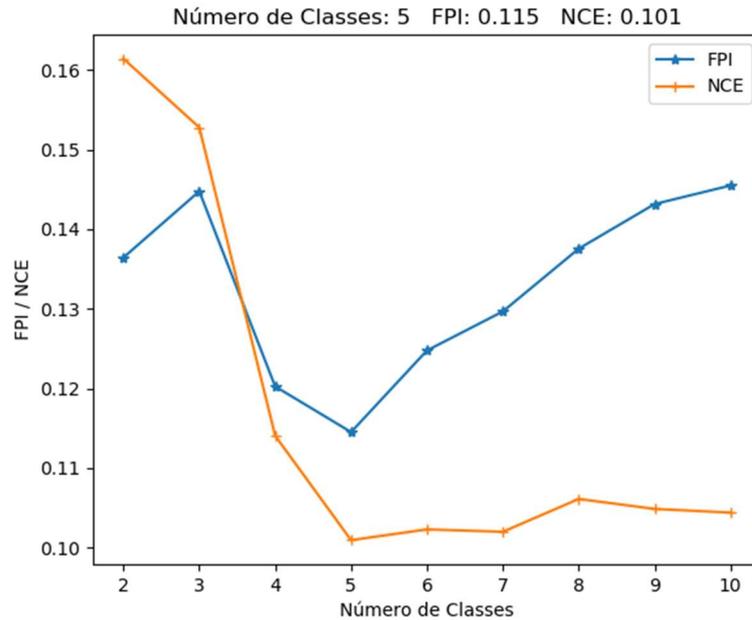


Fonte: O autor (2022).

Observando os mapas interpolados, nota-se que a produtividade de grãos do ano de 2021 diminuiu consideravelmente em relação à produtividade de grãos do ano de 2020. Todavia, apesar da diminuição de produtividade em termos absolutos, o padrão de variabilidade de áreas mais e menos produtivas se repetiu nos diferentes cultivos. A drástica diminuição de produtividade pode estar associada às intempéries climáticas que prejudicaram o cultivo no Centro-Sul do Brasil na safra 20/21 de forma geral, conforme foi comentado no 12º Boletim de acompanhamento da safra 21/22 da CONAB (2022). E quanto ao mapa de elevação, nota-se que há maiores valores ao centro do terreno e decai à medida que se aproxima das bordaduras.

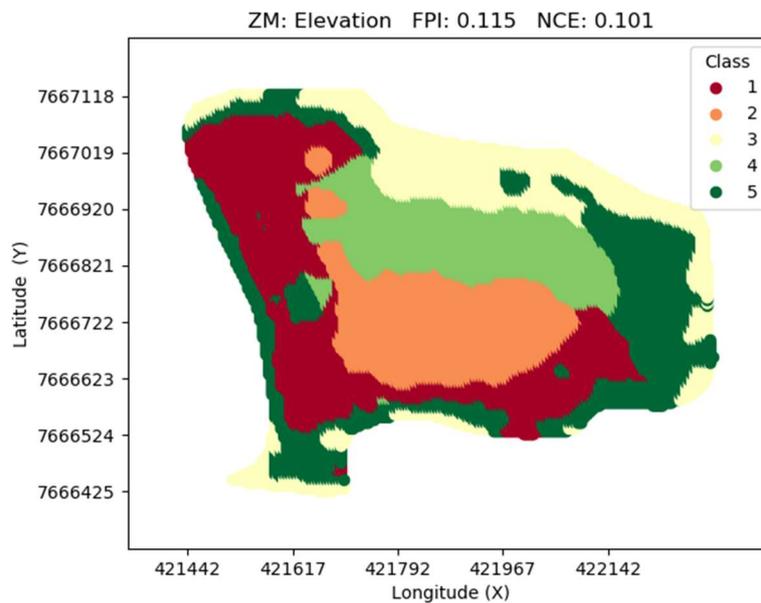
Em relação ao gráfico FPI/NCE, o FPI diz respeito ao grau de separação entre as classes, enquanto o NCE indica o grau de desorganização criado por número de classes (BROCK et al., 2005). Ambos índices variam de 0 a 1, onde valores próximos a 0 indicam que há distinção entre as classes, já valores próximos a 1 indicam que há pouca distinção entre as classes (Santos, 2016). O número ótimo de classes ocorre quando os dois índices são mínimos, simultaneamente (Song et al., 2009). Os mínimos valores para FPI e NCE foram observados, simultaneamente, para a geração das zonas de manejo com base na produtividade de grãos da safra 2020 (PROD20), produtividade de grãos da safra 2021 (PROD21) e elevação (ELEV) em 5 classes (FIGURA 11). Por essa razão, o mapa final será dividido também em 5 classes. (FIGURA 12).

Figura 11 — Índice de Performance Fuzzy (FPI) e Entropia de Classificação Normal (NCE) para geração das Zonas de Manejo com base na produtividade de grãos da safra 2020 (PROD20), produtividade de grãos da safra 2021 (PROD21) e elevação (ELEV).



Fonte: O autor (2022).

Figura 12 — Mapa temático das Zonas de Manejo gerados com base com base no gráfico Índice de Performance Fuzzy (FPI) e Entropia de Classificação Normal (NCE).

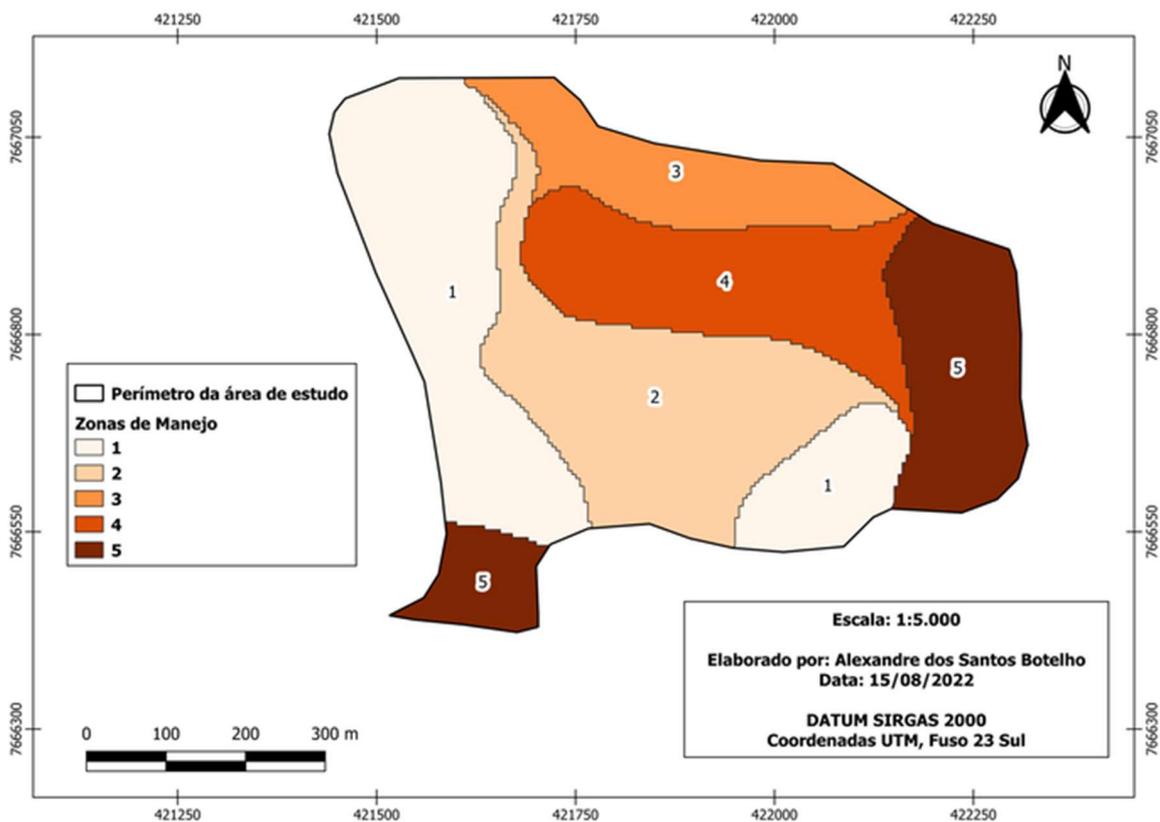


Fonte: O autor (2022).

É possível observar no mapa temático gerado no Smart-map (FIGURA 12) que foram geradas classes de tamanho não significativo dentro de outras classes maiores.

Matematicamente, isso é possível de acontecer, mas operacionalmente não é viável, pois pode aumentar custos de produção com aumento do tempo de parada de máquinas para regulagem de implementos para ajuste da dose de insumos, ou mesmo ocasionar erros de aplicação ao redor dessas classes pelo tempo de resposta da máquina não se ajustar à mudança abrupta do monitor, aumentando a fonte de variabilidade espacial na lavoura. A fim de suavizar o mapa e eliminar tais pontos discrepantes, utilizou-se a ferramenta *Rank Filter*, no QGIS (ZANELLA, 2017), com modo de busca circular, raio de busca de 10 pixels e filtro de 50% de frequência (FIGURA 13).

Figura 13 — Mapa temático das Zonas de Manejo após filtragem no Rank Filter e poligonização.

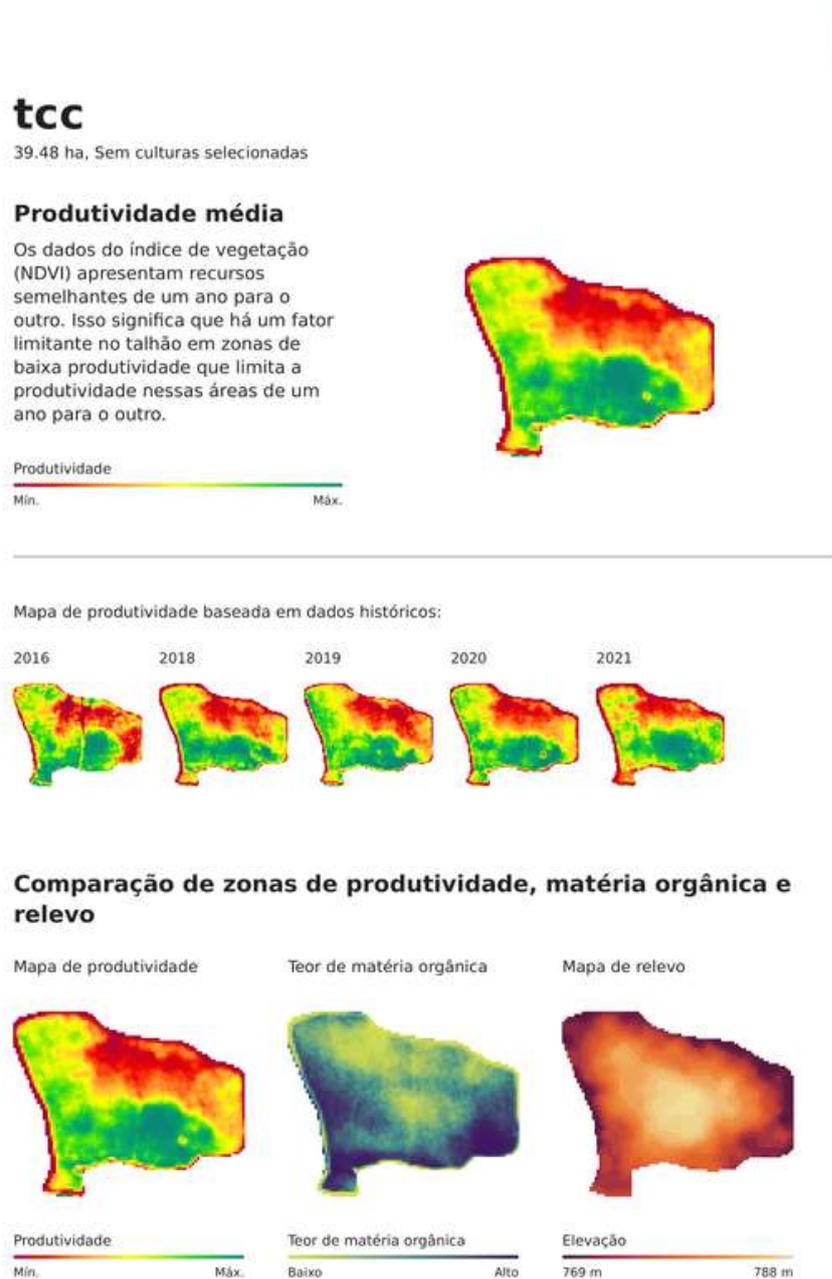


Fonte: O autor (2022).

Após o acesso ao relatório sobre os mapas de produtividade, teor de matéria orgânica e relevo da plataforma (FIGURA 14), comparou-se visualmente os mapas de produtividade obtidos através do Smart-map com os obtidos pela plataforma OneSoil. Apesar da plataforma apresentar dados de produtividade relativos e não em valores absolutos, não sendo também possível baixar o raster dos mapas por ela produzidos e submetê-los a análises estatísticas e fazer a comparação dos dados, o contraste de produtividade é muito semelhante com os mapas

obtidos com dados de produtividade reais. Isso se dá pelo fato de que o NDVI tem sido utilizado para prever a produtividade de culturas agrícolas, uma vez que possui correlação com a produtividade (BOLTON; FRIEDL, 2013). Assim sendo, apesar de apresentar menos recursos que um SIG como o QGIS, a plataforma OneSoil mostrou ser viável para análise dos dados de produtividade.

Figura 14 — Relatório de comparação de zonas de produtividade, matéria orgânica e relevo fornecido pela plataforma OneSoil.



Fonte: O autor (2022).

Após o download dos vetores das ZMs da plataforma, no QGIS, classificou-se as zonas de manejo em categorias (FIGURA 15). Diferentemente do mapa gerado com base no gráfico FPI/NCE, que como resultado apresentou 5 diferentes classes, neste mapa o número de classes foi igual a 3.

Não sendo possível a comparação dos resultados em termos quantitativos, qualitativamente é possível afirmar que 3 classes é um número razoável, pois visualmente é possível identificar uma zona de baixa produtividade ao norte da área, uma zona de transição mais ao centro e uma zona de menor produtividade mais ao sudeste do talhão. Assim sendo, dada a facilidade de obtenção dos mapas oferecidos pela OneSoil, há um grande potencial de utilização. Por outro lado, ao contrário do QGIS, que é um SIG de código-fonte aberto e toda a documentação das ferramentas é aberta à comunidade, as metodologias adotadas pela plataforma são passíveis de questionamento.

4 CONCLUSÃO

Os mapas de produtividade de grãos das safras 2020/2021 e de elevação do terreno, apresentaram forte dependência espacial, sendo que todos eles apresentaram valores de IDE < 0,25; alto R^2 , sendo todos próximos a 1; e baixos valores de RMSE. Portanto, conclui-se que houve bom ajuste dos modelos.

Os mapas de produtividade apresentados pela plataforma OneSoil são semelhantes aos mapas de produtividade gerados com dados da colhedora. Nesse sentido, a plataforma se apresenta como uma ferramenta viável para análise do histórico de produtividade e das zonas produtivas.

As Zonas de Manejo apresentaram diferentes números de classes entre si, sendo pela metodologia FPI/NCE 5 classes, e 3 classes pela plataforma

Em termos operacionais, quanto menor o número de divisões de uma área produtiva, maior o rendimento das operações em campo. Nesse sentido, as ZMs geradas pela OneSoil são mais otimizadas que as geradas pelo Smart-map. Todavia, a metodologia adotada pela plataforma é passível de questionamento, ao contrário do Smart-map, que é de código-aberto e está documentado e validado na comunidade científica na forma de artigo. Assim sendo, não é possível concluir se, apesar de mais otimizada, se é mais representativa.

As duas metodologias utilizadas para delinear ZMs mostraram-se viáveis. Todavia, a metodologia utilizada no QGIS por intermédio do Smart-map é mais morosa e demanda conhecimento especializado, não sendo acessível como a OneSoil, no entanto, é mais confiável e gera resultados mais precisos.

5. REFERÊNCIAS

ABIMILHO. Associação Brasileira das indústrias do milho. **O cereal que enriquece a alimentação humana**. 2019. 1p. Disponível em: <http://www.abimilho.com.br/milho/cereal>. Acesso em: 21 de setembro de 2022.

BOLTON, D. K., M. A. FRIEDL. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics. *Agricultural and Forest Meteorology*. v. 173, p. 74-84, 2013.

BROCK, A. et al. Definição de zonas de manejo baseadas na produtividade para rotações milho-soja. **Revista de Agronomia**, v. 97, n. 4, p. 1115-1128, 2005.

CAMBARDELLA, C.A.; MOOMAN, T.B.; NOVAK, J.M.; PARKIN, T.B.; KARLEM, D.L.; TURVO, R.F.; KONOPA, A.E. Field scale variability of soil properties in central Iowa soil. **Soil Science Society of America Journal**, v.47, p.1501-1511, 1994. <https://doi.org/10.2136/sssaj1994.03615995005800050033x>.

CONAB - Companhia Nacional de Abastecimento. **Acompanhamento de safra brasileira: grãos, décimo segundo levantamento**, setembro de 2022. Brasília, 2022. Disponível em: https://www.conab.gov.br/info-agro/safra/graos/boletim-da-safra-de-graos/item/download/44171_1d9f893d78f593b07d41887104acc43f. Acesso em: 21 de setembro de 2022.

CONAB. **Primeiro levantamento da safra 2019/20 de grãos indica produção de 245 milhões de t**. Disponível em: <https://www.brasilagro.com.br/conteudo/safra-de-graos-201920-indica-producao-de-245-milhoes-detoneladas.html#:~:text=A%20produ%C3%A7%C3%A3o%20agr%C3%ADcola%20brasileira%20deve,alta%20de%200%2C4%25>. 2019. Acesso em: 21 de setembro de 2022.

DOERGE, T. A. **Management Zones Concepts**. Norcross, 1999.

DOERGE, T. Management zone concepts. SSMG-2. In: Site specific management guidelines. Norcross: Potash and Phosphate Institute, 1999. 4p

FIESP. **Safra Mundial de Milho 2022/23 – 5º Levantamento do USDA**. setembro de 2022. Brasília, 2022. Disponível em: <https://www.fiesp.com.br/indices-pesquisas-e>

publicacoes/safra-mundial-de-milho-2/attachment/file-20220913140113-boletimmilhosetembro2022/

FLEMING, K. L.; WESTFALL, D. G.; WIENS, D. W. **Field test management zones for VRT**. Norcross, 1999.

GOOVAERTS, P. **Geostatistics for natural resources evaluation**. New York: Oxford University Press, 1997. 483p.

GOUVEIA, L. C. **ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA NA DEFINIÇÃO DE ZONAS HOMOGÊNEAS EM ÁREA DE PRODUÇÃO DE GRÃOS**. Trabalho de conclusão de curso, Universidade Federal de Uberlândia. Uberlândia, p. 23. 2022.

INAMASU, R. Y.; NAIME, J. M.; RESENDE, A. V.; BOSSOI, L. H.; BERNARDIA, C. C. **Agricultura de precisão: um novo olhar**. São Carlos, SP: Embrapa Instrumentação, 2011. 334 p.

LUCHIARI JUNIOR, A.; SHANAHAN, J.; LIEBIG, M.; SCHLEMMER, M.; SCHEPERS, J. S.; FRANCIS, D.; PAYTON, S. Strategies for Establishing Management Zones for Site Specific Nutrient Management. In: INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE, 5., 2000, Minneapolis. **Proceedings...** Minneapolis: University of Minnesota, 2000.

MAPA. Ministério da Agricultura e do Abastecimento. Secretaria Executiva. **Milho para o estado do Paraná, ano safra 2018/2019**. Brasília: SPI, 2018. 14p. (Documento Básico).

MENEGATTI, L. A. A.; MOLIN, J. P. Remoção de erros em mapas de produtividade via filtragem de dados brutos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.8, p.126- 134, 2004.

MIRANDA, R. A. **Uma história de sucesso da civilização: A Granja**, v. 74, n. 829, p. 24-27, jan. 2018.

MOLIN, Jose P. Definição de unidades de manejo a partir de mapas de produtividade. **Engenharia Agrícola**, v. 22, n. 1, p. 83-92, 2002

MOLIN, José Paulo; DO AMARAL, Lucas Rios; COLAÇO, André. **Agricultura de precisão**. Oficina de Textos, 2015.

Pereira, 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>.

QGIS Development Team, (2020). (QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://qgis.osgeo.org>.

QUEIROZ, D. M. et al. **Agricultura digital**. 2ª edição atualizada e ampliada. - 2. ed. -- São Paulo: Oficina de Textos, 2021.

ROQUE, C. G.; CENTURION, J. F.; PEREIRA, G. T.; BEUTLER A. N.; FREDDI O. d. S.; ANDRIOLI I. Mapeamento da produtividade e perímetro do tronco de clones de seringueira em argissolo vermelho amarelo. **Scientia Forestalis**. n. 70, p. 59-66, abril 2006.

RStudio Team (2022). RStudio: Integrated Development for R. RStudio, PBC, Boston, MA. Disponível em: <http://www.rstudio.com/>.

SALVIANO, A.A.C.; VIEIRA, S.R.; SPAROVEK, G. Variabilidade espacial de atributos de solo e de *Crotalaria juncea* (L.) em área severamente erodida. **Revista Brasileira de Ciência do Solo**, Viçosa, v.22, p.115- 122, 1998.

SCHEPERS, J. S.; SHANAHAN, J. F.; LUCHIARI JUNIOR, A. Precision agriculture as a tool for sustainability. In BALAZS, E. (Ed.). **Biological Resource Management: Connecting Science and Policy**. Springer, 2000. p. 129-135

SHANAHAN, J.; DOERGE, T.; SYNEDER, C.; LUCHIARI JUNIOR, A.; JOHNSON, J. Feasibility of variable rate management of corn hybrids and seeding rates in the great plains. In: INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE, 5., 2000, Minneapolis. **Proceedings...** Minneapolis: University of Minnesota, 2000

SONG, X.; WANG, J.; HUANG, W.; LIU, L.; YAN, G.; PU, R. The delineation of agricultural management zones with high resolution remotely sensed data. **Precision Agriculture**, v.10, p.471-487, 2009.

TRENTIN, R. **Estimativa de um índice de estresse hídrico para a cultura da canede-açúcar com base na temperatura foliar**. 2010. 81 p. Dissertação (Mestrado em Agronomia) – Universidade Federal de Viçosa, Viçosa.

TUKEY, J. W. **Exploratory Data Analysis**. Addison-Wesley, Reading, MA. 1977. Pereira, G.W.

VARVEL, G. E.; SCHLEMMER, M. R.; SCHEPERS, J. S. Relationship between spectral data from aerial image and soil organic matter and phosphorus levels. **Precision Agriculture**, v. 1, p. 291-300, 1999. <http://dx.doi.org/10.1023/A:1009973008521>

VIEIRA, S.R. Variabilidade espacial de argila, silte e atributos químicos em uma parcela experimental de um Latossolo Roxo de Campinas, SP. **Bragantia**, Campinas, v.56, p.181-190, 1997.

WAGNER, G. L. **A producers view-charting the course for site-specic agriculture**. Bloomington: SOILTEQ, 1999. Charting the Course for Site-Speci- c Agriculture - Presentation and Executives Summaries.

WEBSTER, R. Quantitative spatial analysis of soil in the field. **Advances in Soil Science**, New York, v.3, p.1-70, 1985.

ZANELLA, M. A. *et al.* UTILIZAÇÃO DO SOFTWARE LIVRE QGIS PARA OBTENÇÃO DE MAPAS DE PRODUTIVIDADE E GERAÇÃO DE ZONAS DE MANEJO. *In: XXI ENCONTRO LATINO AMERICANO DE INICIAÇÃO CIENTÍFICA, XVII ENCONTRO LATINO AMERICANO DE PÓS-GRADUAÇÃO E VII ENCONTRO DE INICIAÇÃO À DOCÊNCIA – UNIVERSIDADE DO VALE DO PARAÍBA.* 2017. Anais eletrônicos [...] Paraíba, 2017.