

**AVALIAÇÃO DA FILTRAGEM E INTERPOLAÇÃO DE DADOS DE PRODUTIVIDADE
NA DEFINIÇÃO DE ZONAS DE MANEJO EM SISTEMAS DE AGRICULTURA DE
PRECISÃO**

**EVALUATION OF FILTERING AND INTERPOLATION OF PRODUCTIVITY DATA IN
DEFINING MANAGEMENT ZONES IN PRECISION AGRICULTURE SYSTEMS**

**EVALUACIÓN DEL FILTRADO E INTERPOLACIÓN DE DATOS DE PRODUCTIVIDAD
EN LA DEFINICIÓN DE ZONAS DE GESTIÓN EN SISTEMAS DE AGRICULTURA DE
PRECISIÓN**

 10.56238/revgeov16n5-302

Gabriela Kolben Passos

Graduanda em Ciência da Computação

Instituição: Universidade Tecnológica Federal do Paraná (UTFPR)

E-mail: gabrielapassos@alunos.utfpr.edu.br

Kelyn Schenatto

Doutora em Engenharia Agrícola

Instituição: Universidade Tecnológica Federal do Paraná (UTFPR)

E-mail: kschenatto@utfpr.edu.br

Thaliny de Oliveira Peloi

Mestranda em Tecnologias Computacionais para o Agronegócio

Instituição: Universidade Tecnológica Federal do Paraná (UTFPR)

E-mail: thalinypeloi@gmail.com

Claudio Leones Bazzi

Doutor em Engenharia Agrícola

Instituição: Universidade Tecnológica Federal do Paraná (UTFPR)

E-mail: bazzi@utfpr.edu.br

Ricardo Sobjak

Doutor em Engenharia Agrícola

Instituição: Universidade Tecnológica Federal do Paraná (UTFPR)

E-mail: ricardosobjak@utfpr.edu.br

André Sandmann

Doutor em Engenharia Agrícola

Instituição: Universidade Tecnológica Federal do Paraná (UTFPR)

E-mail: sandmann@utfpr.edu.br



RESUMO

A agricultura de precisão tem se consolidado como uma das principais estratégias tecnológicas para o aprimoramento do manejo agrícola, permitindo identificar a variabilidade espacial e temporal de fatores que influenciam a produtividade. Contudo, a qualidade dos dados obtidos por monitores de colheita é frequentemente comprometida por erros de medição e ruídos estatísticos, tornando o processo de filtragem uma etapa crítica para a geração de informações confiáveis. O presente estudo teve como objetivo avaliar a influência do processo de filtragem e dos métodos de interpolação dos dados de produtividade na definição das zonas de manejo (ZMs) em duas áreas agrícolas no município de Céu Azul (PR), considerando séries históricas de 11 anos das culturas de soja, milho e trigo. Foram comparados dados brutos e filtrados, interpolados pelos métodos do Inverso da Distância ao Quadrado (IDQ) e da Média Móvel (MM). As zonas de manejo foram definidas pelo método Fuzzy C-Means e avaliadas por índices de qualidade (FPI, MPE, VR e ICVI). Os resultados indicaram que os dados filtrados e interpolados pela Média Móvel apresentaram maior consistência, com redução de 3 a 15% no coeficiente de variação, além de melhor separação entre classes e organização das zonas. Concluiu-se que o processo de filtragem é determinante para a acurácia da delimitação de zonas de manejo, otimizando a tomada de decisão na aplicação de insumos.

Palavras-chave: Agricultura de Precisão. Filtragem de Dados. Interpolação Espacial. Zonas de Manejo. Monitor de Colheita.

ABSTRACT

Precision agriculture has emerged as a key technological approach to improve agricultural management, enabling the identification of spatial and temporal variability in yield-related factors. However, data quality from yield monitors is often compromised by measurement errors and statistical noise, making the filtering process a critical step for generating reliable information. This study aimed to evaluate the influence of data filtering and interpolation methods on the definition of management zones (MZs) in two agricultural areas located in Céu Azul, Brazil, using 11 years of soybean, corn, and wheat yield data. Raw and filtered data were interpolated using Inverse Distance Weighting (IDW) and Moving Average (MA) methods. Management zones were delineated through the Fuzzy C-Means algorithm and assessed using quality indices (FPI, MPE, VR, and ICVI). Results showed that filtered data interpolated by the Moving Average method exhibited greater consistency, reducing the coefficient of variation by 3 to 15%, and improving class distinction and spatial organization. It was concluded that data filtering significantly enhances the accuracy of management zone delineation, supporting more efficient site-specific input application.

Keywords: Precision Agriculture. Data Filtering. Spatial Interpolation. Management Zones. Yield Monitoring.

RESUMEN

La agricultura de precisión se ha consolidado como una de las principales estrategias tecnológicas para mejorar la gestión agrícola, permitiendo la identificación de la variabilidad espacial y temporal de los factores que influyen en la productividad. Sin embargo, la calidad de los datos obtenidos por los monitores de cosecha se ve frecuentemente comprometida por errores de medición y ruido estadístico, lo que convierte el proceso de filtrado en un paso crítico para generar información confiable. Este estudio tuvo como objetivo evaluar la influencia del proceso de filtrado y los métodos de interpolación en los datos de productividad al definir las zonas de manejo (ZM) en dos áreas agrícolas del municipio de Céu Azul (PR), considerando series históricas de 11 años de cultivos de soja, maíz y trigo. Se compararon datos brutos y filtrados, interpolados mediante los métodos de Distancia Cuadrada Inversa (IDQ) y Promedio Móvil (MA). Las zonas de manejo se definieron mediante el método Fuzzy C-Means y se evaluaron mediante índices de calidad (FPI, MPE, VR e ICVI). Los resultados indicaron que los datos filtrados e interpolados mediante el método de Promedio Móvil mostraron una mayor consistencia, con una reducción del 3 al 15 % en el coeficiente de variación, así como una mejor separación entre clases y organización de las zonas. Se concluye que el proceso de filtrado es crucial



para la precisión en la delimitación de las zonas de gestión, optimizando la toma de decisiones en la aplicación de insumos.

Palabras clave: Agricultura de Precisión. Filtrado de Datos. Interpolación Espacial. Zonas de Gestión. Monitor de Cosecha.



1 INTRODUÇÃO

A agricultura de precisão (AP) tem se destacado nas últimas décadas como uma abordagem inovadora voltada à sustentabilidade produtiva e econômica do setor agrícola. Fundamenta-se na coleta e análise espacial de dados, permitindo a compreensão detalhada da variabilidade dos talhões, possibilitando assim o manejo localizado de insumos e práticas agrícolas (KHAN et al., 2020; GETAHUN et al., 2024; BYABAZAIRE et al., 2023).

No contexto da agricultura moderna, o uso de dados georreferenciados provenientes de monitores de colheita, sensores de solo e imagens de sensoriamento remoto permite que produtores e técnicos tomem decisões com base em informações precisas, promovendo ganhos de produtividade e eficiência (BLACKMORE, 2000; DOERGE, 1999). Entretanto, apesar de seu potencial, a adoção da agricultura de precisão ainda enfrenta barreiras técnicas e econômicas, especialmente relacionadas ao alto custo dos equipamentos e à complexidade de tratamento e análise dos dados gerados.

O uso de mapas de produtividade obtidos por monitores de colheita representa um dos principais avanços da agricultura de precisão (BYABAZAIRE et al., 2023). Esses mapas, gerados a partir de dados georreferenciados, possibilitam identificar áreas de alta e baixa produtividade, subsidiando estratégias de manejo localizado, correção de solo e aplicação de fertilizantes em taxa variável (GETAHUN et al., 2024; BAZZI et al., 2021).

Um dos principais desafios observados na utilização de mapas de produtividade é a ocorrência de erros sistemáticos durante a coleta de dados, resultantes de falhas nos sensores, interferências de sinal GPS, variações na velocidade de colheita ou ajustes inadequados do maquinário (DOERGE, 1999; BECK et al., 2001). Esses erros comprometem a confiabilidade das análises e podem distorcer a representação da variabilidade espacial da produtividade (BLACKMORE, 2000).

Para que os mapas de produtividade sejam efetivos, é imprescindível que os dados brutos passem por um processo rigoroso de filtragem e interpolação, de modo a reduzir erros sistemáticos e aleatórios que podem distorcer a interpretação espacial (BECK et al., 2001). Dessa forma, a filtragem dos dados de produtividade surge como uma etapa essencial do pré-processamento, visando eliminar valores anômalos e inconsistentes. A aplicação de métodos estatísticos e computacionais para filtragem e interpolação busca reduzir a incerteza e aumentar a precisão na delimitação das zonas de manejo (ZMs), que são subdivisões de áreas agrícolas homogêneas utilizadas para a aplicação localizada de insumos e a otimização de recursos (SCHENATTO et al., 2017; GAVIOLI et al., 2019).

A interpolação espacial, por sua vez, desempenha papel central na geração de mapas contínuos a partir de dados pontuais (BETZEK et al., 2019). Esse processo consiste em estimar valores em pontos não amostrados com base nos valores conhecidos ao redor (SCHENATTO et al., 2016). Métodos como o Inverso da Distância ao Quadrado (IDQ) e a Média Móvel (MM) são amplamente utilizados na



agricultura de precisão para transformar dados amostrados em superfícies que representem de forma fidedigna a variabilidade espacial do campo (SCHENATTO et al., 2017).

O método IDQ assume que os valores próximos entre si apresentam maior similaridade do que aqueles distantes, ponderando as observações conforme a distância (BETZEK et al., 2019). Já a MM suaviza os dados a partir da média aritmética dos valores vizinhos, reduzindo flutuações abruptas e ruídos.

A escolha do método de interpolação afeta diretamente a precisão dos mapas gerados e a representatividade das zonas de manejo (BETZEK et al., 2019). Assim, compreender o impacto da filtragem e do método de interpolação na qualidade das zonas de manejo é fundamental para garantir resultados consistentes e confiáveis. Esse tipo de análise contribui diretamente para o avanço da agricultura digital e para o uso racional de insumos agrícolas, reduzindo custos e impactos ambientais.

O presente artigo tem como objetivo avaliar a influência do processo de filtragem e da interpolação dos dados de produtividade na definição de zonas de manejo em áreas agrícolas monitoradas, comparando o desempenho dos métodos IDQ e MM em dados brutos e filtrados, utilizando séries históricas de produtividade de soja, milho e trigo.

2 MATERIAL E MÉTODOS

O estudo foi conduzido em duas áreas experimentais localizadas no município de Céu Azul, estado do Paraná, Brasil. A primeira área, denominada Área A, possui uma área de 24 hectares, enquanto a segunda, denominada Área B, tem 17 hectares. Ambas as áreas experimentais podem ser observadas na Figura 1, onde a Área A está destacada em rosa e a Área B, em amarelo. As áreas apresentam histórico de cultivo de soja (*Glycine max*), milho (*Zea mays*) e trigo (*Triticum aestivum*) ao longo de 11 anos agrícolas, em sistema de rotação de culturas.

O clima da região é subtropical úmido, com precipitação média anual de 1.800 mm e temperatura média de 20 °C (INMET, 2024). Os solos são classificados como Latossolos Vermelhos Distroférricos, de textura argilosa.



Figura 1 - Áreas experimentais



Fonte: Autoria própria (2025)

As análises nas duas áreas foram realizadas utilizando o software AgDataBox (SOBJAK et al., 2024), um software que permite realizar uma análise detalhada de dados agrícolas, capaz de auxiliar a filtragem de dados, interpolação de dados e geração de zonas de manejo.

Os dados de produtividade iniciais foram coletados através de uma colhedora da marca CASE IH, equipada com sistema de monitoramento de colheita e GPS embarcado. Cada ponto de coleta representava a produtividade georreferenciada, com densidade superior a 12.000 pontos por área. Os dados foram submetidos a um processo de filtragem de dados para eliminar dados duplicados, observações negativas, nulas ou discrepâncias.

Após a filtragem, realizou-se a análise descritiva estatística dos conjuntos de dados filtrados e não filtrados, avaliando-se média, mediana, desvio padrão, variância amostral e coeficiente de variação (CV).

Após a análise descritiva dos dados filtrados e não filtrados, foi realizada a interpolação para estimar valores não amostrados, utilizando os métodos do inverso da distância ponderada (IDQ) e da média móvel (MM). Esses métodos foram aplicados separadamente em amostras filtradas e não filtradas, com o objetivo de comparar a influência do processo de filtragem. Logo após as interpolações utilizando IDQ e MM, foi realizada uma nova análise descritiva para verificar como esses métodos impactaram os dados, comparando os valores de média, mediana, desvio padrão, variância amostral e coeficiente de variação.

Em seguida, foi efetuado o cálculo dos índices de concordância baseados no Índice Kappa e Exatidão Global, para avaliar a similaridade das interpolações realizadas, utilizando as metodologias IDQ e MM. Os índices foram calculados para os dados filtrados e não filtrados, permitindo uma análise detalhada do resultado entre os dados interpolados anteriormente.

Os dados foram interpolados pelos métodos Inverso da Distância ao Quadrado (IDQ) e Média Móvel (MM), gerando superfícies contínuas de produtividade para cada cultura e ano agrícola.

A partir dos mapas interpolados, as zonas de manejo foram delimitadas por meio do método Fuzzy C-Means, que consiste em um dos métodos de agrupamento mais utilizados para delimitação



de zonas de manejo (ZERAATPISHEH et al., 2020; , LI et al., 2013, PACCIORETTI et al., 2020, ZHANG et al., 2013, MORAL et al., 2010, SCHENATTO et al., 2017). As zonas foram geradas com duas e três classes.

Este algoritmo, que incorpora a teoria da lógica fuzzy no algoritmo de divisão, usa um expoente de ponderação para controlar o grau de compartilhamento entre classes (Bezdek, 1981), permitindo que os indivíduos exibam adesão parcial em cada uma das classes, o que é importante ao lidar com a variabilidade contínua de fenômenos naturais (Burrough, 1989). Antes que um conjunto de dados possa ser formado, é necessário estabelecer uma medida apropriada de similaridade. A distância euclidiana é mais regularmente usada; esta medida dá peso igual a todas as variáveis medidas e é sensível a variáveis correlacionadas (Bezdek, 1981).

A fim de realizar uma análise mais profunda da produtividade ao longo da área, foi utilizada a técnica de Álgebra de Grids, que permitiu obter a interpolação média da produtividade das culturas, considerando todas as classes de manejo. Esse processo auxiliou a deixar mais claro a variabilidade da produtividade nas diferentes zonas de manejo.

Os índices FPI, MPE, VR e ICVI foram calculados para avaliar a consistência e a separação das zonas geradas. Valores de FPI e MPE próximos de 0 e VR elevado indicam melhor desempenho do método de interpolação e filtragem adotados.

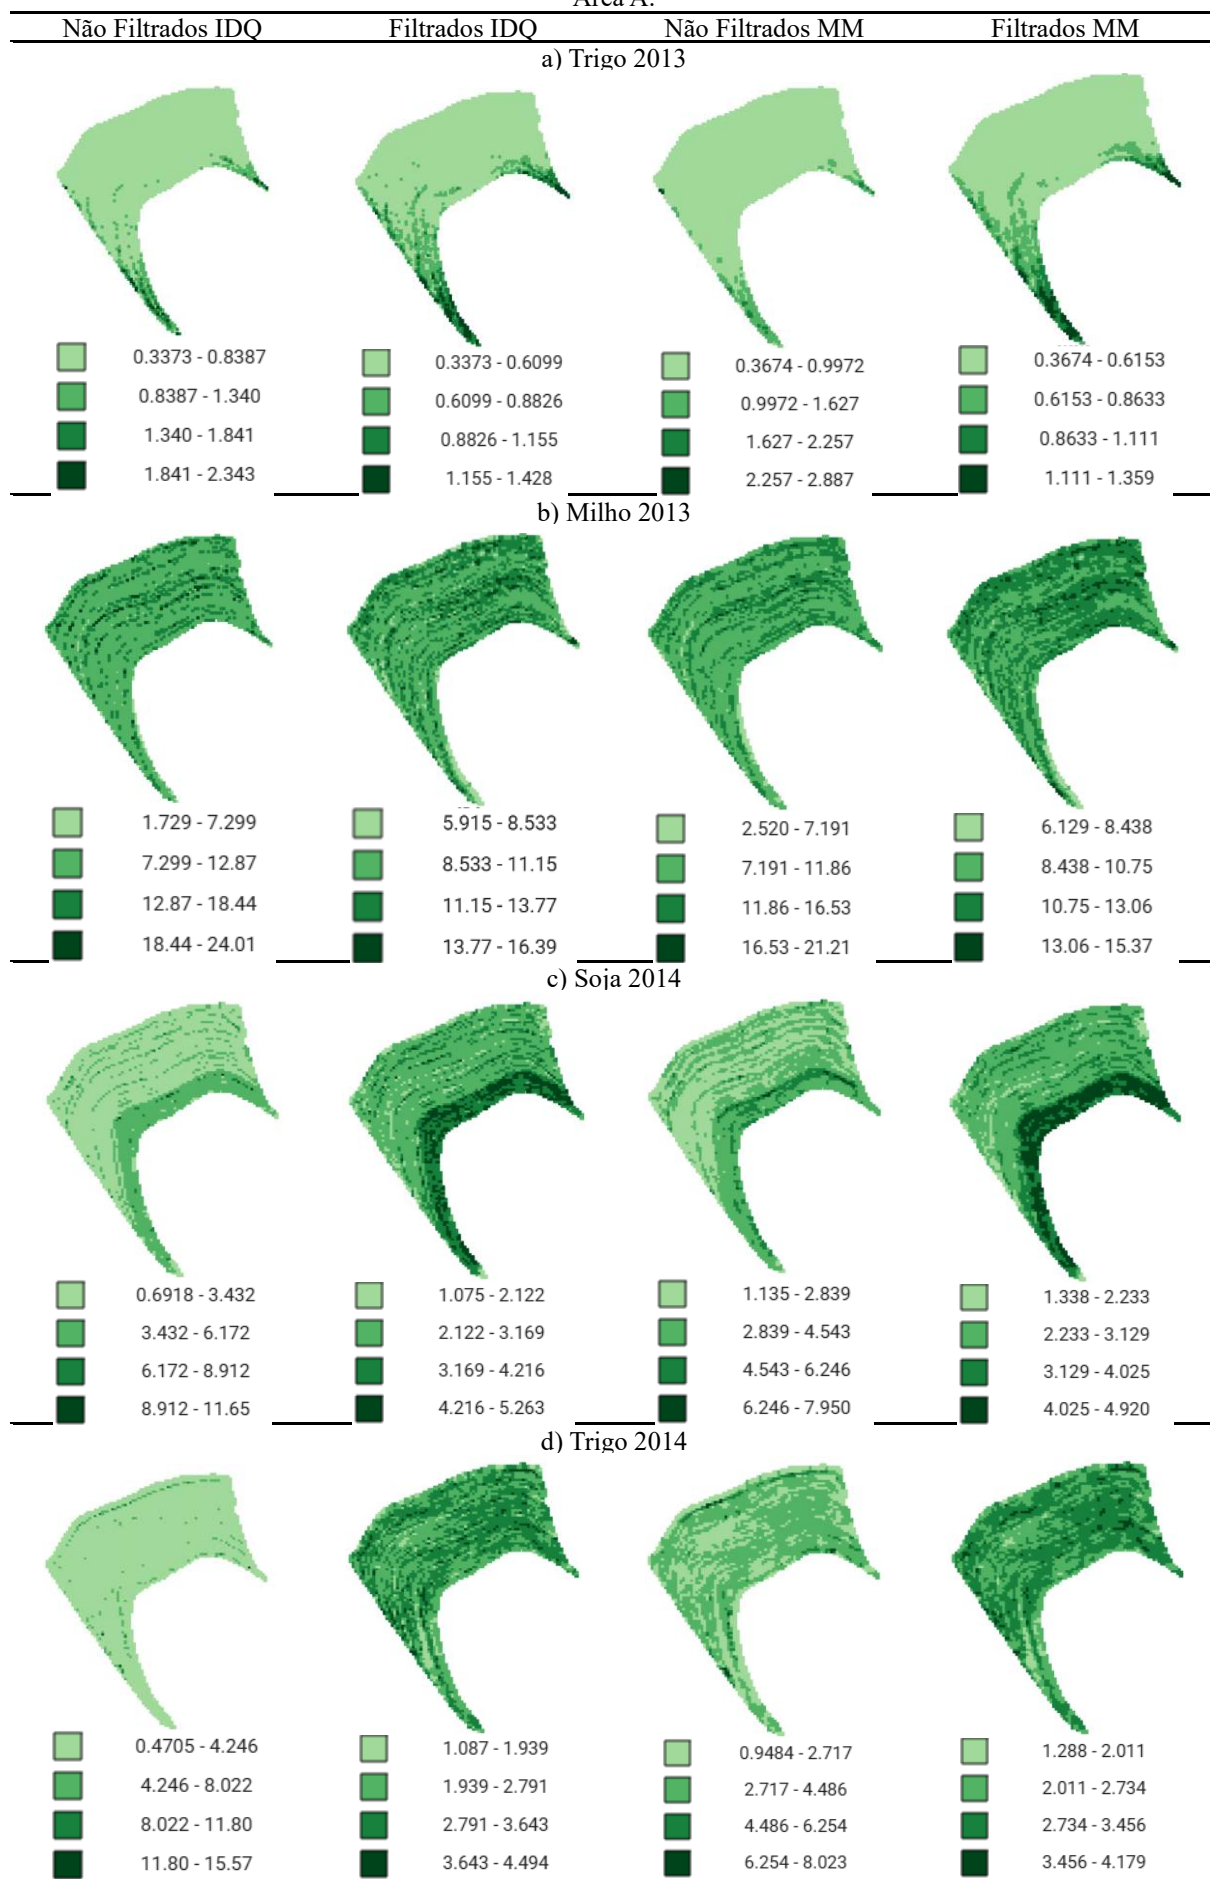
Além disso, realizou-se uma análise de variância (ANOVA) seguida do teste de Tukey ($p < 0,05$) para verificar diferenças estatísticas entre as médias de produtividade das zonas.

3 RESULTADOS E DISCUSSÃO

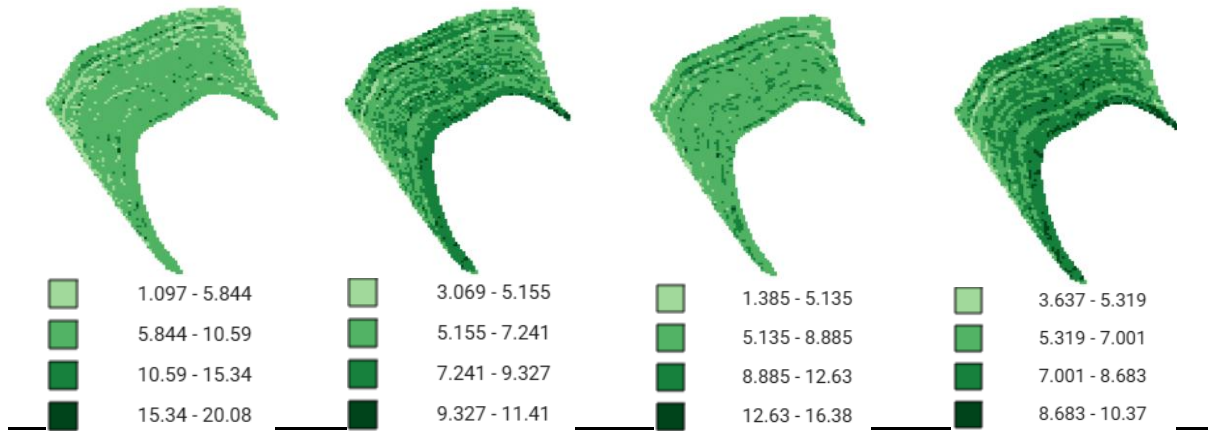
Para todos os anos de produtividade disponíveis nas duas áreas experimentais, foram gerados os mapas temáticos a partir da interpolação dos dados pelos métodos Inverso da Distância ao Quadrado e Média Móvel, aplicados aos dados brutos e aos dados submetidos ao processo de filtragem. As representações dessas interpolações podem ser observadas na Figura 2 para a Área A e na Figura 3 para a Área B.



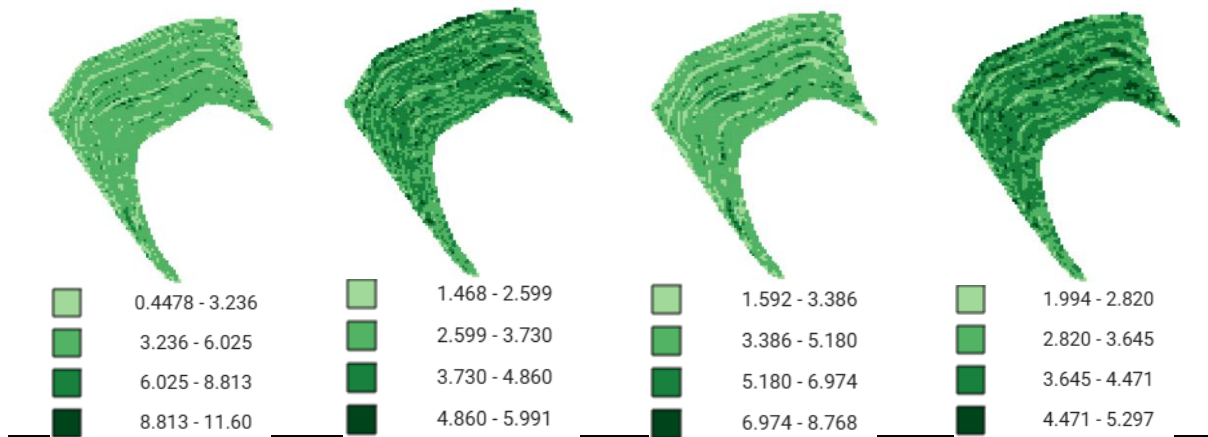
Figura 2: Mapa das interpolações dos dados utilizando os métodos IDQ e MM antes e após o processo de filtragem na Área A.



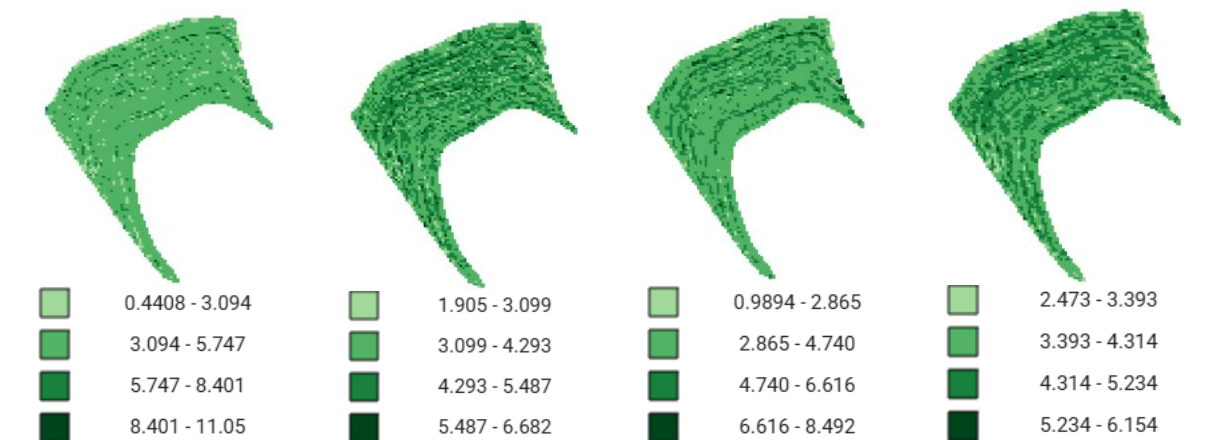
e) Milho 2016



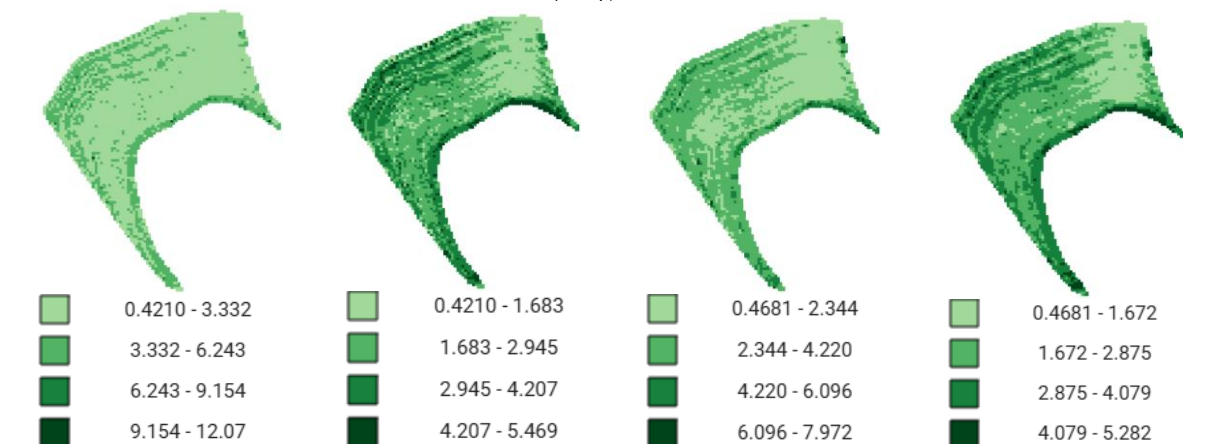
f) Soja 2016



g) Soja 2017



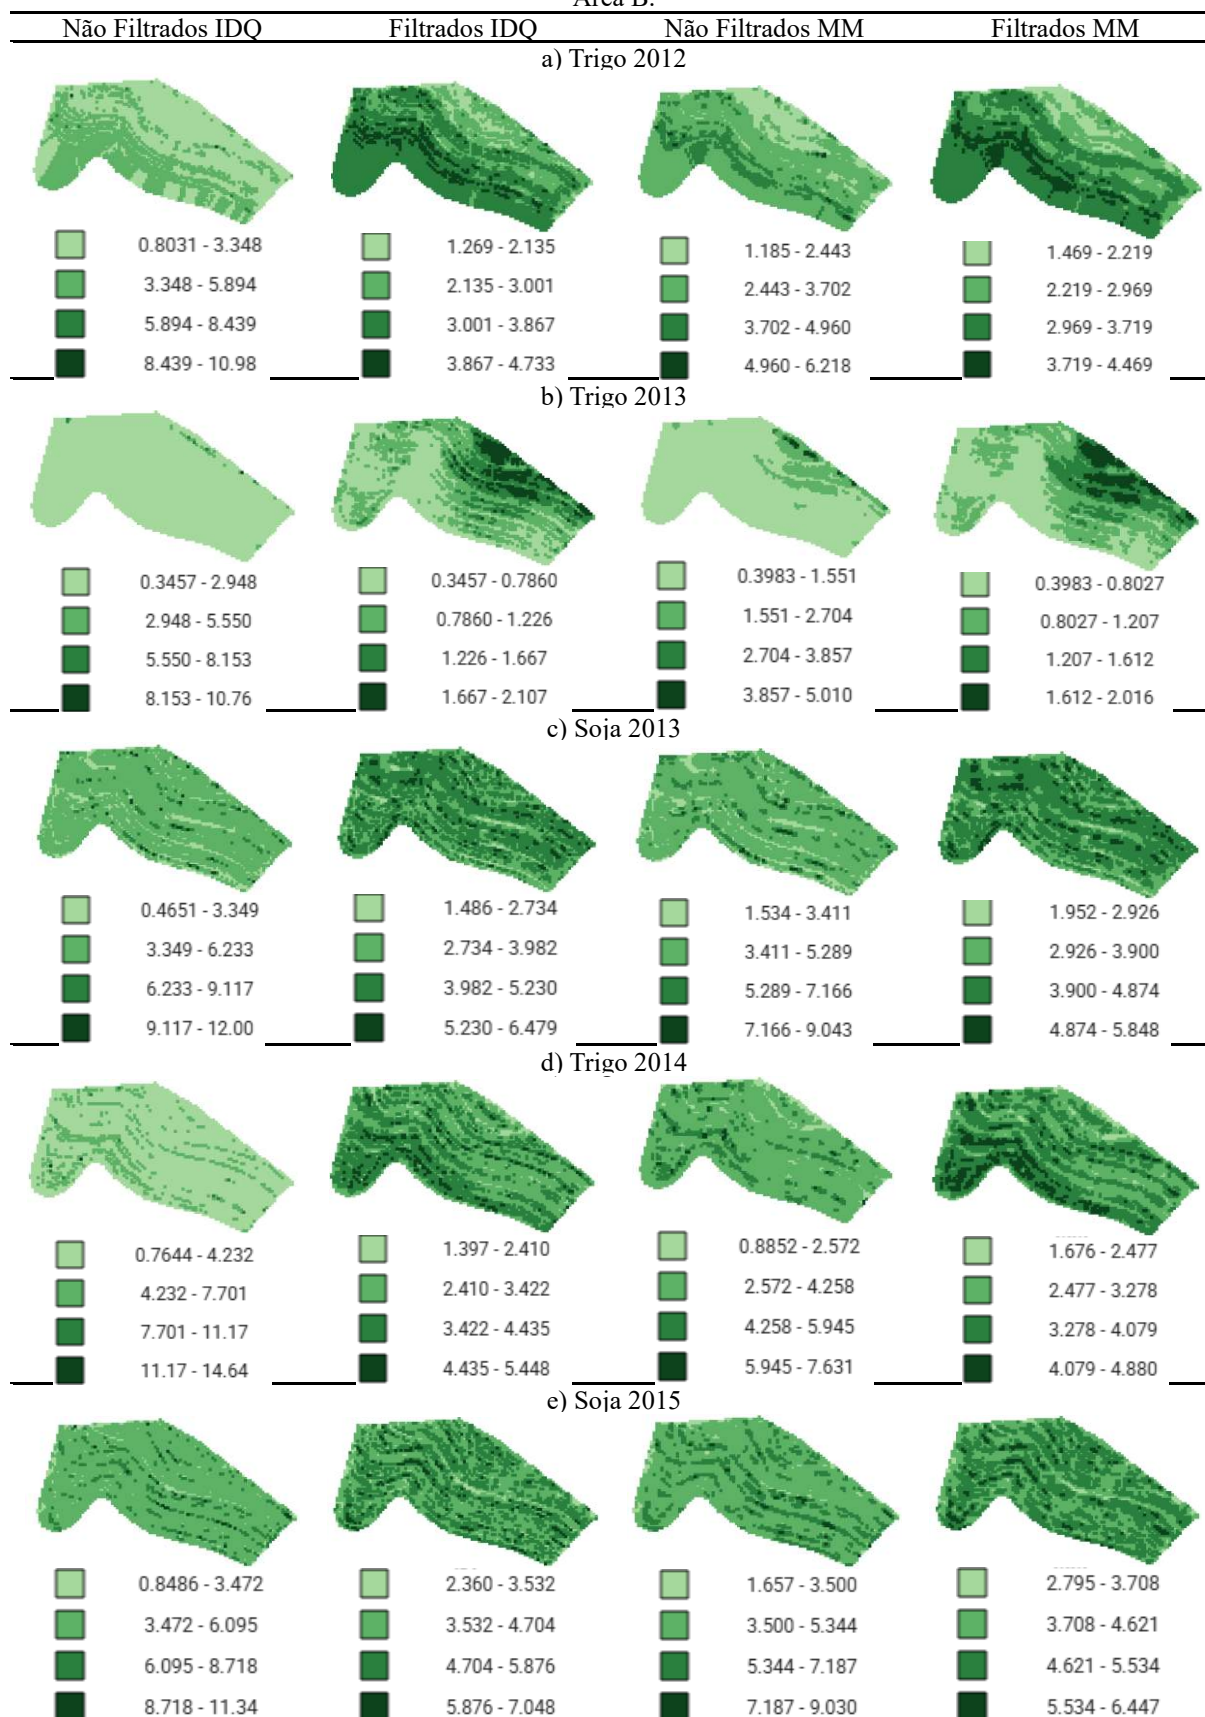
h) Trigo 2020



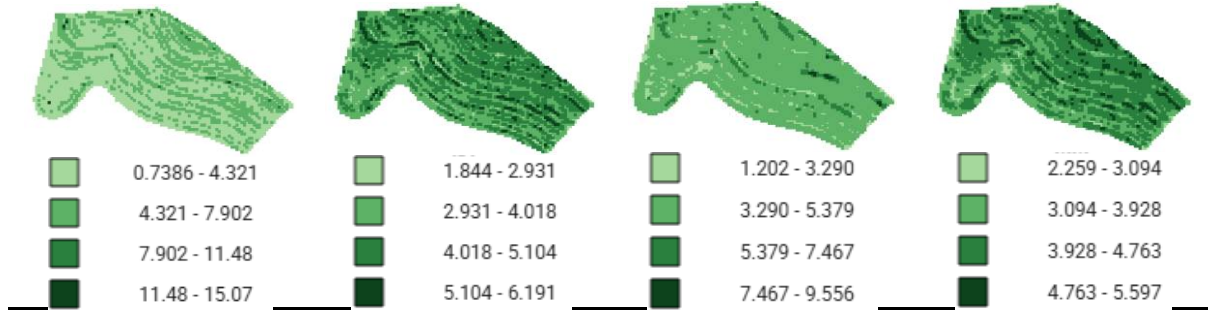
Fonte: Autores.



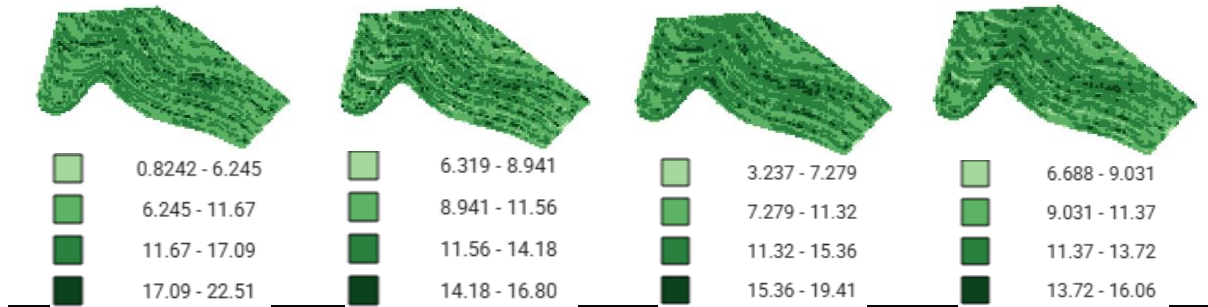
Figura 3: Mapa das interpolações dos dados utilizando os métodos IDQ e MM antes e após o processo de filtragem na Área B.



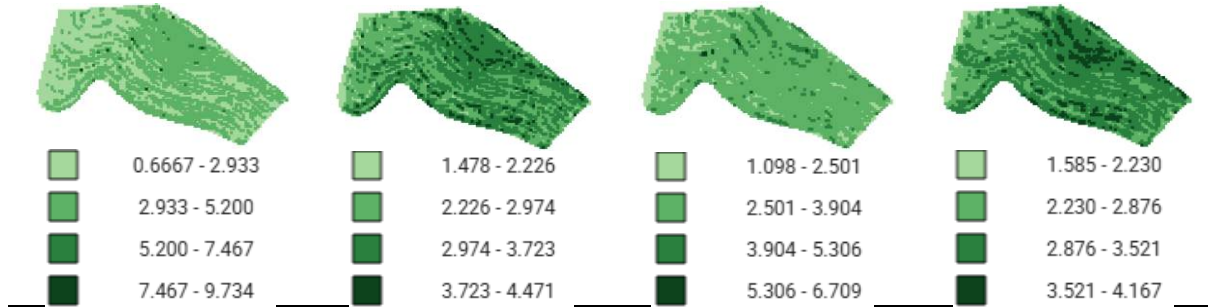
f) Trigo 2016



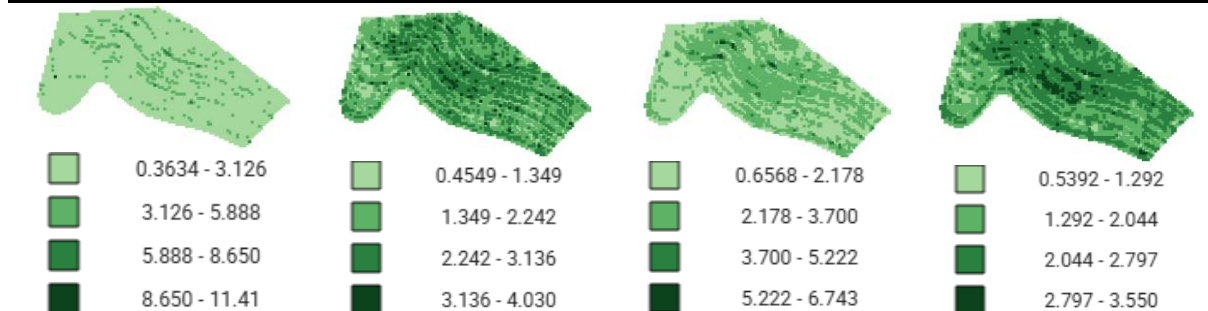
g) Milho 2017



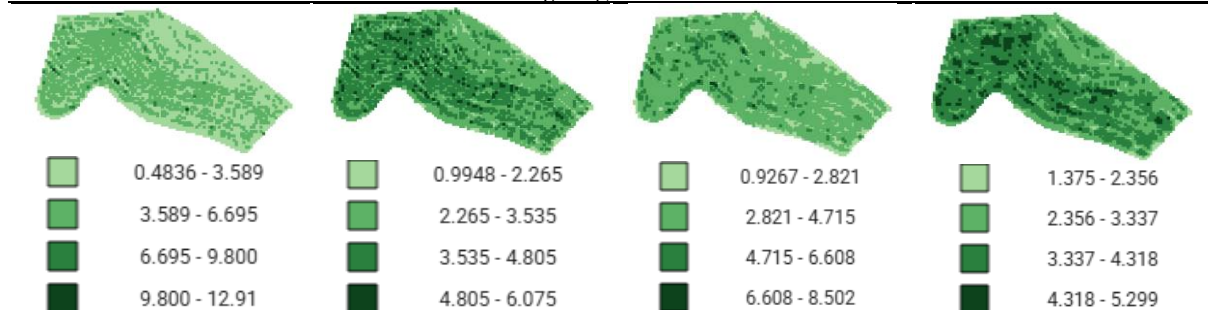
h) Soja 2018

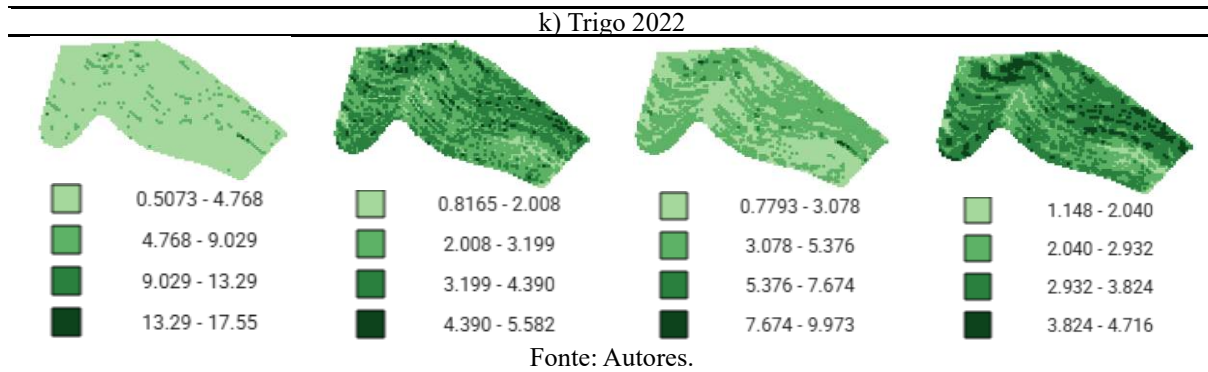


i) Trigo 2019



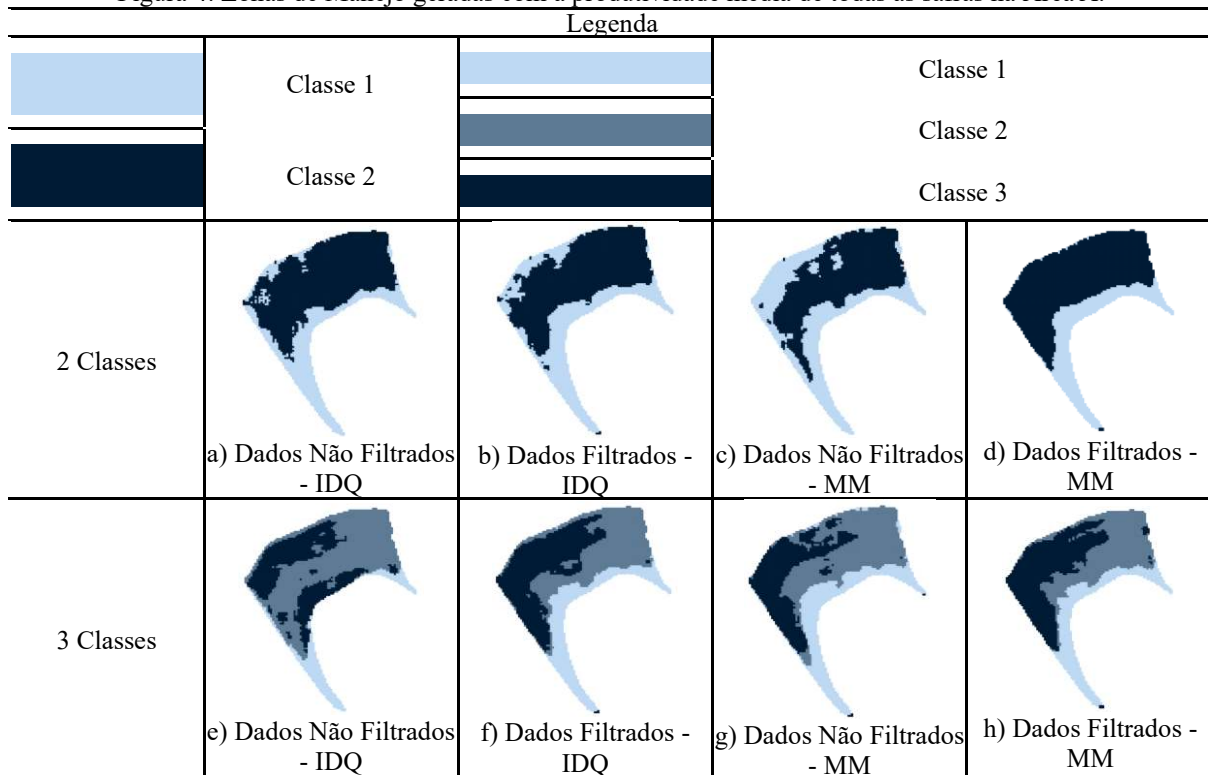
j) Trigo 2020





As zonas de manejo (ZMs) geradas a partir da produtividade média de todas as safras, considerando dados filtrados e não filtrados e os interpoladores IDQ e MM, são apresentadas na Figura 4 para a Área A e na Figura 5 para a Área B. Essas figuras demonstram visualmente como as diferentes combinações de filtragem e interpolação, juntamente com o número de classes (2 ou 3), influenciam a delimitação das ZMs.

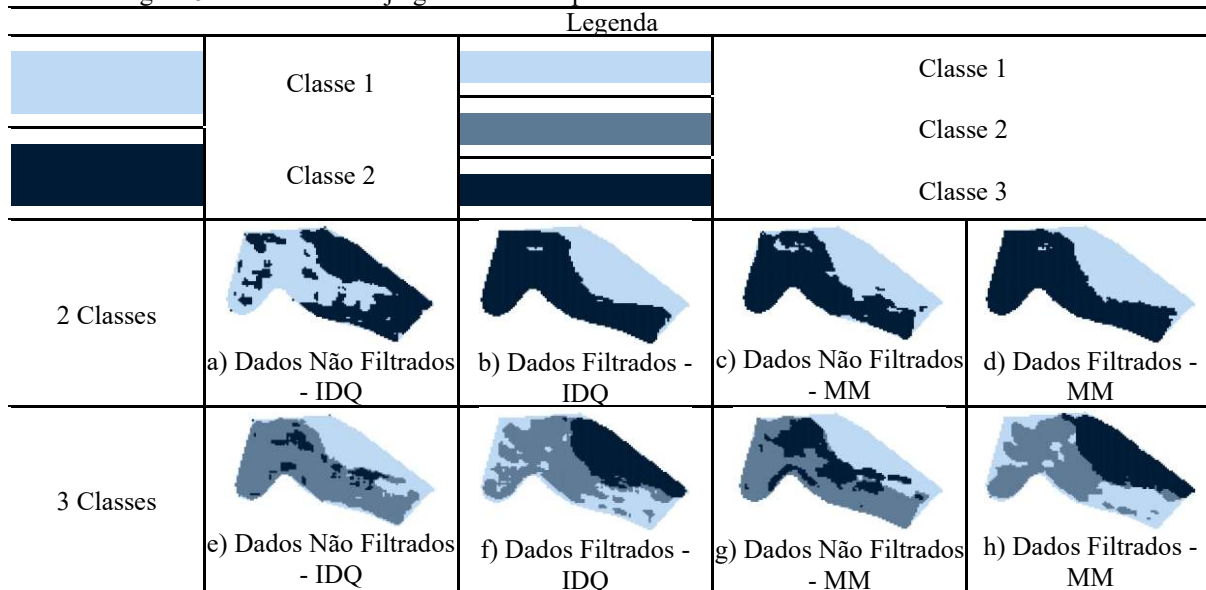
Figura 4: Zonas de Manejo geradas com a produtividade média de todas as safras na Área A.



Fonte: Autores.



Figura 5: Zonas de Manejo geradas com a produtividade média de todas as safras na Área B.



Fonte: Autores.

A qualidade das zonas de manejo foi avaliada utilizando os índices de qualidade Fuzziness Performance Index (FPI), Modified Partition Entropy (MPE), Redução da Variância (VR) e Improved Cluster Validation Index (ICVI), considerando que os índices FPI, MPE e ICVI variam de 0 a 1, sendo que mais próximo de 0 sugerem uma melhor qualidade das zonas de manejo geradas. Os resultados para a Área A e para a B são apresentados, respectivamente, na Tabela 1 e na Tabela 2.

O índice de desempenho Fuzzy (FPI) (Odeh et al., 1992; Boydell; Mcbratney, 2002) permite determinar o grau de separação entre as classes, ou seja, quando os valores se aproximam de 0, significa que as classes são distintas com menor grau de compartilhamento dos dados entre elas, enquanto que valores próximos a 1 indicam não haver classes distintas, apresentando elevado grau de compartilhamento dos membros entre as classes (Fridgen et al., 2004). Já o índice da partição da entropia modificada (MPE) (Bezdek, 1981) é uma estimativa da quantidade de desorganização criada por um número específico de agrupamentos (Fridgen et al., 2000). Valores de MPE próximos de 1 indicam que predomina a desorganização, enquanto que valores se aproximando de 0 indicam uma melhor organização (Odeh et al., 1992).

A redução de variância (Dobermann et al., 2003; Xiang et al., 2007) representa a redução do percentual da variância ao se dividir a área em ZMs. A expectativa é que a soma das variâncias dos dados das classes seja menor do que a variância total.



Tabela 1: Índices de qualidade das Zonas de Manejo geradas com os dados de produtividade média na Área A.

Classes	Zona de Manejo	FPI	MPE	VR	ICVI
2	Dados Não Filtrados - IDQ	0.53	0.59	7.56	0.84
	Dados Filtrados - IDQ	0.49	0.55	19.24	0.67
	Dados Não Filtrados - MM	0.52	0.58	6.09	0.89
	Dados Filtrados - MM	0.37	0.44	21.77	0.58
3	Dados Não Filtrados - IDQ	0.52	0.53	15.62	0.62
	Dados Filtrados - IDQ	0.48	0.51	17.57	0.67
	Dados Não Filtrados - MM	0.52	0.55	18.19	0.65
	Dados Filtrados - MM	0.46	0.48	22.37	0.67

Fonte: Autores.

Na área A verificou-se que, a melhor qualidade das zonas de manejo foi obtida com a utilização de dados filtrados interpolados pelo método MM, especialmente com 2 classes de manejo. Neste cenário, os valores de FPI, MPE e ICVI foram os mais baixos, indicando uma separação de classes mais nítida. Além disso, a redução da variância apresentou o resultado de 21.77%.

Tabela 2: Índices de qualidade das Zonas de Manejo geradas com os dados de produtividade média na Área B.

Classes	Zona de Manejo	FPI	MPE	VR	ICVI
2	Dados Não Filtrados - IDQ	0.76	0.80	24.67	0.67
	Dados Filtrados - IDQ	0.46	0.53	0.65	0.83
	Dados Não Filtrados - MM	0.58	0.64	0.11	0.91
	Dados Filtrados - MM	0.39	0.46	0.33	0.81
3	Dados Não Filtrados - IDQ	0.71	0.74	21.71	0.66
	Dados Filtrados - IDQ	0.65	0.66	24.87	0.67
	Dados Não Filtrados - MM	0.69	0.70	32.44	0.67
	Dados Filtrados - MM	0.59	0.60	28.45	0.67

Fonte: Autores.

Na Área B, similarmente à Área A, os dados filtrados interpolados por MM com 2 classes apresentaram os melhores resultados para FPI e MPE, embora não tenham apresentado bons resultados na VR. Quando consideradas três classes de manejo, os dados filtrados e interpolados por MM foi o cenário que apresentou menor FPI, MPE e teve uma redução da variância com melhores resultados (28,45%), o que indica uma organização das ZMs mais eficaz.

Por fim, foram analisadas as estatísticas descritivas das ZMs para ambas as áreas, incluindo a quantidade de pontos, média de produtividade, coeficiente de variação (CV), e os valores mínimo e máximo por cada classe. A Tabela 3 apresenta esses dados para a Área A, e a Tabela 4 para a Área B.



Tabela 3: Estatísticas por Zonas de Manejo avaliadas com os dados de produtividade média na Área A.

Classes	Zona de Manejo	NC	Qtde	Média	CV	Mín	Máx
2	Dados Não Filtrados - IDQ	1	1205	4.75a	11.91	2.6	6.74
		2	2331	4.44b	11.16	2.49	6.55
	Dados Filtrados - IDQ	1	1319	4.6a	7.64	3.39	5.69
		2	2217	4.27b	7.66	2.9	5.39
	Dados Não Filtrados - MM	1	1464	4.72a	9.94	3.07	6.18
		2	2072	4.49b	9.1	2.88	6.13
Dados Filtrados - MM	1	1003	4.63a	6.26	3.74	5.52	
	2	2553	4.31b	6.26	3.14	5.1	
3	Dados Não Filtrados - IDQ	1	397	4.64b	13.47	2.6	6.63
		2	1761	4.34c	10.5	2.49	6.54
		3	1378	4.79a	10.51	3.26	6.74
	Dados Filtrados - IDQ	1	787	4.68a	7.15	3.55	5.69
		2	1394	4.29c	7.79	2.9	5.39
		3	1355	4.33b	8.05	2.97	5.56
	Dados Não Filtrados - MM	1	927	4.87a	8.44	3.58	6.18
		2	1404	4.58b	8.65	3.43	6.13
		3	1205	4.38c	9.44	2.88	5.82
	Dados Filtrados - MM	1	736	4.69a	6.18	3.74	5.52
		2	1321	4.34b	5.77	3.46	5.1
		3	1479	4.31c	6.66	3.14	5.28

Nota: NC: Número da classe avaliada.

Fonte: Autores.

Para a Área A, observa-se que a filtragem dos dados reduziu ligeiramente a variabilidade, refletida nos menores valores de coeficiente de variação (CV). Além disso, a comparação entre os métodos evidencia que o MM apresentou, em geral, maiores valores de CV, indicando maior heterogeneidade dentro das zonas formadas.

A subdivisão da área em três zonas resultou em maior diferenciação entre as classes, conforme revelam os valores mais elevados de CV em relação às duas zonas. Esse comportamento sugere que a divisão em três zonas permite capturar melhor a variabilidade espacial da produtividade, ainda que aumente a complexidade de manejo.

Os valores mínimos e máximos registrados confirmam a ampla variabilidade produtiva existente na área, justificando a adoção de estratégias de manejo específicas.

A análise do teste de comparação de médias indicou a formação de classes de manejo estatisticamente distintas. Na área A, quando foi realizada a divisão em duas ou três classes observou-se que todas as zonas de manejo geradas apresentaram médias de produtividade distintas entre as classes, independente do método de interpolação utilizado e da utilização de dados filtrados ou não. O que pode-se considerar que independente do método de interpolação utilizado e da filtragem de dados ou não, foi possível gerar zonas de manejo com médias estatisticamente significativas.



Tabela 4: Estatísticas por Zonas de Manejo avaliadas com os dados de produtividade média na Área B.

Classes	Zona de Manejo	NC	Qtde	Média	CV	Mín	Máx
2	Dados Não Filtrados - IDQ	1	1699	4.22a	7.25	2.91	5.41
		2	2187	3.85b	8.52	2.44	5.16
	Dados Filtrados - IDQ	1	1513	3.92a	6.94	2.92	4.78
		2	2373	3.87b	6.99	2.77	4.65
	Dados Não Filtrados - MM	1	1640	4.03b	7.86	2.56	5.15
		2	2246	4.05a	7.5	2.65	5.06
Dados Filtrados - MM	1	1523	3.91a	5.79	2.91	4.45	
	2	2363	3.89b	5.9	2.86	4.72	
3	Dados Não Filtrados - IDQ	1	1427	3.97b	8.44	2.44	5.41
		2	1480	3.87c	8.39	2.45	5.12
		3	979	4.3a	7.22	3.3	5.38
	Dados Filtrados - IDQ	1	1247	3.7c	6.8	2.77	4.41
		2	1411	4.02a	5.41	3.36	4.78
		3	1228	3.94b	6.09	3.14	4.66
	Dados Não Filtrados - MM	1	1218	4b	7.55	2.56	5.15
		2	1437	3.87c	6.32	2.65	4.64
		3	1231	4.29a	4.9	3.62	5.06
	Dados Filtrados - MM	1	1198	3.72c	5.56	2.86	4.22
		2	1425	4.02a	2.26	3.52	4.72
		3	1263	3.93b	5.18	3.16	4.44

Nota: NC: Número da classe avaliada.

Fonte: Autores.

Na Área B, para a classe de manejo 2, as produtividades médias observadas variaram entre 3,91 e 4,22 t/ha quando o método de interpolação IDQ foi utilizado, e entre 3,89 e 4,05 t/ha para o método MM. Nota-se que os dados não filtrados apresentaram maior amplitude de variação, com mínimos de até 2,56 e máximos superiores a 5,40, enquanto o uso de dados filtrados reduziu ligeiramente essa dispersão. O coeficiente de variação (CV) foi relativamente elevado, situando-se entre 5,79% e 7,86%, indicando heterogeneidade produtiva dentro da classe.

Na classe 3, as produtividades médias oscilaram entre 3,93 e 4,20 t/ha tanto para IDQ quanto para MM. Os dados filtrados resultaram em menor variação intraclasse, como evidenciado pelos valores de CV, que ficaram entre 5,18% e 6,20%, inferiores aos observados com dados não filtrados (até 8,22%). Essa redução sugere que o pré-processamento dos dados contribuiu para maior consistência estatística.

A análise do teste de comparação de médias indicou a formação de classes de manejo estatisticamente distintas na Área B, quando foi realizada a divisão em duas ou três classes observou-se que todas as zonas de manejo geradas apresentaram médias de produtividade distintas entre as classes, independente do método de interpolação utilizado e da utilização de dados filtrados ou não. O que pode-se considerar que independente do método de interpolação utilizado e da filtragem de dados ou não, foi possível gerar zonas de manejo com médias estatisticamente significativas também nessa área.



4 CONCLUSÕES

Os resultados deste trabalho indicam que a aplicação da filtragem dos dados, associada à interpolação pelo método da Média Móvel, proporcionou maior precisão na definição das zonas de manejo. Essa melhoria sugere que a filtragem contribui de forma significativa para a consistência e a confiabilidade das informações, resultando em uma organização mais adequada das zonas para a aplicação localizada de insumos. Entretanto, observou-se que, independentemente do método de interpolação utilizado ou da aplicação da filtragem, todas as zonas de manejo geradas mantiveram classes de produtividade estatisticamente distintas, reforçando a robustez do processo de zoneamento.



REFERÊNCIAS

BAZZI, C. L.; MARTINS, M. R.; CORDEIRO, B. E.; GEBLER, L.; SOUZA, E. G.; SCHENATTO, K.; PAULA FILHO, P.L. Yield map generation of perennial crops for fresh consumption. *Precision Agriculture*, v. 1, p.1-14, 2021.

Beck, A.; Searcy, S.; Roades, J. Yield data filtering techniques for improved map accuracy. *Engineering a Sustainable Future*. v. 17, p. 423-431, 2001. doi: 10.13031/2013.6456

BETZEK, N. M.; SOUZA, E. G.; BAZZI, C. L.; SCHENATTO, K.; GAVIOLI, A.; MAGALHAES, P. S. G. Computational routines for the automatic selection of the best parameters used by interpolation methods to create thematic maps. *Computers and Electronics in Agriculture*, v.157, p. 49-62, 2019. <https://doi.org/10.1016/j.compag.2018.12.004>

BEZDEK, J. C. Pattern recognition with fuzzy objective function algorithms. New York, NY: Springer US, 1981. 253 p.

BURROUGH, P. A. Fuzzy mathematical methods for soil survey and land evaluation. *European Journal of Soil Science*, online, v. 40, n. 3, p. 477-492, 1989.

Byabazaire, J.; O'Hare, G.; Collier, R.; Kulatunga, C.; Delaney, D., "A Comprehensive Approach to Assessing Yield Map Quality in Smart Agriculture: Void Detection and Spatial Error Mapping", *Agronomy*, v. 13, p. 1-15, 2023. DOI: 10.3390/agronomy13071943.

BLACKMORE, S. The interpretation of trends from multiple yield maps. v.26, p.37-51, 2000. [https://doi.org/10.1016/S0168-1699\(99\)00075-7](https://doi.org/10.1016/S0168-1699(99)00075-7)

DOERGE, T. A. Yield Map Interpretation. *Journal of Production Agriculture*, v.12 p. 54-61, 2013. <https://doi.org/10.2134/jpa1999.0054>

GAVIOLI, A.; SOUZA, E. G.; BAZZI, C. L.; SCHENATTO, K.; BETZEK, N. M. Identification of management zones in precision agriculture: An evaluation of alternative cluster analysis methods. v.181, p.86-102, 2019. <https://doi.org/10.1016/j.biosystemseng.2019.02.019>

GETAHUN, S.; KEFALE, H.; GELAYE, Y. Application of Precision Agriculture Technologies for Sustainable Crop Production and Environmental Sustainability: A Systematic Review. *The Scientific World Journal*. v.1 p.1-12. 2024. DOI: <https://doi.org/10.1155/2024/2126734>

KHAN, H.; FAROOQUE, A.; ACHARYA, B.; ABBAS, F.; ESAU, T.; ZAMAN, Q. U. Delineation of Management Zones for Site-Specific Information about Soil Fertility Characteristics through Proximal Sensing of Potato Fields. *Agronomy*, v.12, 2020. <https://doi.org/10.3390/agronomy10121854>

LI, Y.; SHI, Z.; WU, H.; LI, F.; LI, H. Definition of management zones for enhancing cultivated land conservation using combined spatial data. *Environmental Management*, online, v. 52, n. 4, p. 792-806, 2013.

MORAL, F. J.; TERRÓN, J. M.; SILVA, J. R. M. Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques. *Soil & Tillage Research*, online, v. 106, n. 2, p. 335-343, 2010.



PACCIORETTI, Pablo Ariel; CÓRDOBA, Mariano; BALZARINI, Mónica Graciela. FastMapping: Software to create field maps and identify management zones in precision agriculture. *Computers and Electronics in Agriculture*, v. 175, art. 105556, 2020. DOI: 10.1016/j.compag.2020.105556.

SCHENATTO, K.; SOUZA, E. G.; BAZZI, C. L.; BIER, V. A.; BETZEK, N. M.; GAVIOLI, A. Data interpolation in the definition of management zones. *Acta Scientiarum*, v.38, p.31-40, 2016. 10.4025/actascitechnol.v38i1.27745

SCHENATTO, K.; SOUZA, E. G.; BAZZI, C. L.; GAVIOLI, A. BETZEK, N. M.; BENEDUZZI, H. M. Normalization of data for delineating management zones. *Computers and Electronics in Agriculture*, v.43, p. 238-248, 2017 <https://doi.org/10.1016/j.compag.2017.10.017>

SOBJAK, R., SOUZA, E. G. DE, BAZZI, C. L., & HACHISUCA, A. M. M. AgDataBox-Map – Uma aplicação web para criação de mapas temáticos e zonas de manejo: avaliação dos usuários. *Revista Caderno Pedagógico*, 21(12), p. 1–24, 2024. <https://doi.org/10.54033/cadpedv21n12-068>.

ODEH, I. O. A.; MCBRATNEY, A. B.; CHITTLEBOROUGH, D. J. Soil pattern recognition with fuzzy c-means: application to classification and soil-landform interrelationship. *Soil Science Society America Journal*, online, v. 56, n. 2, p. 505-516, 1992.

ZERAATPISHEH, Mojtaba; BAKHSHANDEH, Esmail; EMADI, Mostafa; LI, Tengfei; XU, Ming. Integration of PCA and Fuzzy Clustering for Delineation of Soil Management Zones and Cost-Efficiency Analysis in a Citrus Plantation. *Sustainability*, Basel, v. 12, n. 14, art. 5809, 19 jul. 2020. DOI: 10.3390/su12145809.

ZHANG, Z.; LÜ, X.; LV, N.; CHEN, J.; FENG, B.; LI, X. W.; MA, L. Defining agricultural management zones using Gis techniques: Case study of Drip-irrigated cotton fields. *Information Technology Journal*, online, v. 12, n. 21, p. 6241-6246, 2013.

