REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

AVALIAÇÃO DA QUALIDADE DE ZONAS DE MANEJO DELINEADAS POR FUZZY C-MEANS A PARTIR DE DADOS DE PRODUTIVIDADE AGRÍCOLA

EVALUATION OF THE QUALITY OF MANAGEMENT ZONES DELINEATED USING FUZZY C-MEANS BASED ON CROP YIELD DATA

EVALUACIÓN DE LA CALIDAD DE ZONAS DE MANEJO DELINEADAS MEDIANTE FUZZY C-MEANS A PARTIR DE DATOS DE RENDIMIENTO AGRÍCOLA

Thaliny De Oliveira Peloi
Mestranda em Tecnologias Computacionais para o Agronegócio, Universidade Tecnológica Federal do Paraná, Brasil
E-mail: thalinypeloi@gmail.com

Kelyn Schenatto
Doutora em Engenharia Agrícola, Universidade Tecnológica Federal do Paraná, Brasil
E-mail: kschenatto@utfpr.edu.br

Deborah Catharine De Assis Leite
Doutora em Ciências, Universidade Tecnológica Federal do Paraná, Brasil
E-mail: deborahleite@utfpr.edu.br

Claudio Leones Bazzi
Doutor em Engenharia Agrícola, Universidade Tecnológica Federal do Paraná, Brasil
E-mail: bazzi@utfpr.edu.br

Ricardo Sobjak
Doutor em Engenharia Agrícola, Universidade Tecnológica Federal do Paraná, Brasil
E-mail: ricardosobjak@utfpr.edu.br

André Sandmann
Doutor em Engenharia Agrícola, Universidade Tecnológica Federal do Paraná, Brasil
E-mail: sandmann@utfpr.edu.br

Resumo

A Agricultura de Precisão possibilita a utilização de dados espacialmente referenciados para caracterizar a variabilidade existente nas áreas agrícolas e apoiar estratégias de manejo localizado. Nesse contexto, os mapas de produtividade constituem importante fonte de informação para identificar padrões espaciais e temporais de produção, especialmente mediante séries históricas. Este estudo teve como objetivo gerar e avaliar mapas de produtividade de diferentes safras e utilizá-los na delimitação de Zonas de Manejo em cinco áreas agrícolas localizadas em Céu Azul, Paraná. Foram

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

utilizados dados de produtividade provenientes de 11 safras, submetidos à filtragem para remoção de registros inconsistentes. Posteriormente, os dados foram interpolados pelos métodos Inverso da Distância, Inverso da Distância ao Quadrado e Média Móvel, considerando os oito vizinhos mais próximos. As Zonas de Manejo foram delimitadas pelo algoritmo Fuzzy C-Means e avaliadas pelos índices FPI, MPE, Redução da Variância, Índice de Suavidade e Índice Composto de Validação Integrada, além de ANOVA e teste de Tukey a 5%. Os resultados evidenciaram variabilidade espacial e temporal da produtividade e diferenças na configuração das zonas conforme o método de interpolação e o número de classes. A integração das etapas mostrou-se adequada para identificar padrões produtivos e delimitar Zonas de Manejo.

Palavras-chave: Agricultura de Precisão; Mapas de Produtividade; Zonas de Manejo.

Abstract

Precision Agriculture enables the use of spatially referenced data to characterize the variability present in agricultural fields and support site-specific management strategies. In this context, yield maps constitute an important source of information for identifying spatial and temporal production patterns, particularly through historical time series. This study aimed to generate and evaluate yield maps from different growing seasons and use them to delineate Management Zones in five agricultural fields located in Céu Azul, Paraná, Brazil. Yield data from 11 growing seasons were used and subjected to filtering to remove inconsistent records. Subsequently, the data were interpolated using the Inverse Distance, Inverse Distance Squared, and Moving Average methods, considering the eight nearest neighbors. Management Zones were delineated using the Fuzzy C-Means algorithm and evaluated using the FPI, MPE, Variance Reduction, Smoothing Index, and Integrated Validation Composite Index, in addition to ANOVA and Tukey's test at the 5% significance level. The results revealed spatial and temporal variability in yield, as well as differences in zone configuration according to the interpolation method and the number of classes. The integration of these procedures proved suitable for identifying production patterns and delineating Management Zones.

Keywords: Precision Agriculture; Yield Maps; Management Zones.

Resumen

La Agricultura de Precisión permite utilizar datos espacialmente referenciados para caracterizar la variabilidad existente en las áreas agrícolas y apoyar estrategias de manejo localizado. En este contexto, los mapas de rendimiento constituyen una importante fuente de información para identificar patrones espaciales y temporales de producción, especialmente mediante series históricas. Este estudio tuvo como objetivo generar y evaluar mapas de rendimiento de diferentes campañas agrícolas y utilizarlos para la delimitación de Zonas de Manejo en cinco áreas agrícolas ubicadas en Céu Azul, Paraná, Brasil. Se utilizaron datos de rendimiento provenientes de 11 campañas agrícolas, sometidos a un proceso de filtrado para eliminar registros inconsistentes. Posteriormente, los datos fueron interpolados mediante los métodos de Inverso de la Distancia, Inverso de la Distancia al Cuadrado y Media Móvil, considerando los ocho vecinos más próximos. Las Zonas de Manejo fueron delimitadas mediante el algoritmo Fuzzy C-Means y evaluadas utilizando los índices FPI, MPE, Reducción de la Varianza, Índice de Suavidad e Índice Compuesto de Validación Integrada, además de ANOVA y la prueba de Tukey al 5 %. Los resultados evidenciaron variabilidad espacial y temporal del rendimiento, así como diferencias en la configuración de las zonas según el método de interpolación y el número de clases. La integración de las etapas demostró ser adecuada para identificar patrones productivos y delimitar Zonas de Manejo.

Palabras clave: Agricultura de Precisión; Mapas de Rendimiento; Zonas de Manejo.

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

1. Introdução

A crescente demanda global por alimentos, aliada à necessidade de tornar os sistemas agrícolas mais eficientes e minimizar os impactos ambientais, está impulsionando o desenvolvimento de tecnologias que visam aprimorar a tomada de decisão no setor agrícola. Nesse sentido, a Agricultura de Precisão (AP) emerge como uma estratégia que se fundamenta na coleta, processamento e análise de dados espaciais, possibilitando levar em conta a variabilidade nas áreas agrícolas e implementar manejos mais focados. O desenvolvimento de sensores, sistemas de posicionamento e ferramentas computacionais tem aumentado a capacidade de monitoramento das lavouras e possibilitado o uso de dados espaciais na produção (SAHA et al., 2025).

A crescente adoção da agricultura digital tem levado ao uso de tecnologias fundamentadas em dados para o monitoramento e gestão das lavouras. A combinação de diversas fontes de informação permite analisar as características espaciais da lavoura e auxilia na tomada de decisões para um uso mais eficiente dos recursos. Logo, a agricultura digital amplia as oportunidades de processamento e análise dos dados coletados no campo, favorecendo estratégias de manejo informadas por dados que possuem uma referência espacial (KULATUNGA; DHELIM; KECHADI, 2024).

A implementação de tecnologias de Agricultura de Precisão gera uma enorme quantidade de dados georreferenciados, como dados de produtividade, atributos do solo e topografia. A interpretação desses dados possibilita reconhecer padrões de variabilidade nas zonas agrícolas e como os diferentes atributos se organizam no espaço. Contudo, para que essas informações sejam utilizadas, é necessário um conjunto de procedimentos de organização, tratamento e análise que permita converter os dados coletados em informações valiosas para a tomada de decisão (PACCIORRETTI; CÓRDOBA; BALZARINI, 2020).

Os mapas de produtividade, entre as informações coletadas pela Agricultura de Precisão, são uma das principais fontes para entender a variabilidade espacial na produção agrícola. Não apenas representa a distribuição da produtividade em uma

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

área, mas também possibilita, ao se comparar mapas de diferentes safras, a investigação da estabilidade espacial e temporal do comportamento produtivo. Conjuntos históricos de mapas de produtividade, portanto, podem ser valiosos na identificação de áreas que, ao longo do tempo, mantiveram padrões semelhantes de produtividade. No entanto, para que esses dados sejam úteis, é crucial que sejam submetidos a um tratamento e validação adequados, visto que inconsistências nos mapas podem comprometer análises posteriores (CLARKE et al., 2024).

A variabilidade espacial presente nos mapas de produtividade pode ajudar a identificar áreas com distintos potenciais produtivos dentro de uma mesma propriedade agrícola. Nesse sentido, a definição de Zonas de Manejo (ZM) é uma forma de agrupar áreas com semelhanças, permitindo o planejamento de diferentes abordagens de manejo. Idealmente, as zonas devem apresentar relativa homogeneidade quanto a características relacionadas à vitalidade das plantas, ao potencial produtivo e/ou à qualidade do solo. Para isso, diferentes tipos de dados espaciais podem ser empregados, como, por exemplo, mapas de produtividade, características do solo, leituras de condutividade elétrica e imagens obtidas por sensoriamento remoto (VALLENTIN et al., 2020).

A delimitação de Zonas de Manejo pode ser realizada por diferentes métodos de análise e agrupamento, e a escolha da abordagem pode influenciar a configuração espacial das zonas obtidas. Métodos de agrupamento, como K-Means e Fuzzy C-Means, têm sido empregados para identificar regiões com características semelhantes em áreas agrícolas. A comparação entre diferentes técnicas de agrupamento demonstra que os métodos podem apresentar comportamentos distintos diante de um mesmo conjunto de dados, evidenciando a importância da seleção adequada da abordagem utilizada na definição das zonas (GAVIOLI et al., 2019).

Entre essas abordagens, o Fuzzy C-Means apresenta uma característica particularmente relevante para a análise de dados agrícolas, pois permite representar o grau de pertencimento de cada observação aos grupos formados. Essa característica pode ser útil em situações nas quais a transição entre regiões com diferentes características ocorre de forma gradual, em vez de apresentar limites

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

espacialmente abruptos. Estudos recentes têm utilizado o Fuzzy C-Means associado a dados de produtividade e atributos do solo para a delimitação de Zonas de Manejo, demonstrando seu potencial para representar diferentes padrões de variabilidade espacial (SILVA JÚNIOR et al., 2025).

Apesar dos avanços na utilização de diferentes fontes de dados e métodos para a delimitação de Zonas de Manejo, permanece a necessidade de compreender como a informação proveniente de diferentes safras pode contribuir para representar de forma mais consistente a variabilidade produtiva das áreas agrícolas. A utilização de uma única safra pode refletir condições específicas ocorridas naquele ciclo produtivo, enquanto a análise de múltiplas safras permite investigar a persistência de padrões espaciais ao longo do tempo. Assim, a utilização conjunta de mapas de produtividade provenientes de diferentes safras pode contribuir para uma caracterização mais robusta da variabilidade espacial e para a definição de zonas de manejo representativas do comportamento produtivo das áreas agrícolas (CLARKE et al., 2024).

Diante dessa questão, torna-se relevante investigar se a utilização de mapas de produtividade provenientes de diferentes safras permite identificar padrões espaciais consistentes e estabelecer Zonas de Manejo capazes de representar a variabilidade produtiva das áreas agrícolas. A resposta a essa questão pode contribuir para o aprimoramento do uso de dados históricos de produtividade na Agricultura de Precisão, especialmente em situações nas quais se busca estabelecer zonas de manejo com maior representatividade espacial e temporal. Nesse contexto, este estudo teve como objetivo gerar e analisar mapas de produtividade de diferentes safras e utilizá-los na delimitação de Zonas de Manejo, avaliando a variabilidade espacial e temporal da produtividade e a capacidade das zonas obtidas de representar padrões produtivos semelhantes entre as safras.

2. Revisão da Literatura

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

2.1 AGRICULTURA DE PRECISÃO E VARIABILIDADE ESPACIAL DA PRODUTIVIDADE

A Agricultura de Precisão constitui uma abordagem de manejo baseada no reconhecimento da variabilidade espacial e temporal das áreas agrícolas. Entre as principais fontes de informação estão os dados obtidos por monitores de produtividade, que registram o rendimento das culturas associado às coordenadas geográficas, permitindo representar espacialmente o comportamento produtivo dos talhões (LONGCHAMPS et al., 2022).

A produtividade das culturas pode apresentar diferenças expressivas dentro de uma mesma área, decorrentes da interação entre características do ambiente, condições de cultivo e fatores relacionados ao desenvolvimento das plantas. A identificação dessas diferenças possibilita reconhecer regiões com comportamentos produtivos distintos e compreender melhor a distribuição espacial do rendimento das culturas (CÓRDOBA; BALZARINI, 2021).

A utilização de informações provenientes de diferentes safras amplia a compreensão da variabilidade produtiva, pois permite verificar se determinados padrões espaciais permanecem ao longo do tempo. As séries históricas podem contribuir para diferenciar regiões que apresentam comportamento produtivo mais estável daquelas cujas produtividades apresenta maior variação entre os ciclos agrícolas (SANTOS et al., 2023).

A identificação de regiões com características produtivas semelhantes está diretamente relacionada à definição de zonas de manejo. Essas zonas correspondem a subdivisões da área agrícola estabelecidas a partir da similaridade das características consideradas relevantes para o manejo, permitindo representar a variabilidade existente de maneira organizada e facilitar a interpretação dos padrões espaciais observados (KESHAVARZI et al., 2025).

2.2 MAPAS DE PRODUTIVIDADE E QUALIDADE DOS DADOS

Os mapas de produtividade constituem uma importante forma de

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

representação espacial do rendimento das culturas, permitindo visualizar sua distribuição dentro do talhão e identificar regiões com diferentes níveis de produtividade (CÓRDOBA; BALZARINI, 2021).

Entretanto, os registros provenientes dos monitores de produtividade podem apresentar erros decorrentes de diferentes fatores relacionados à aquisição dos dados. Problemas de posicionamento, falhas nos sensores, variações no fluxo de produto e registros realizados durante momentos de transição da operação podem gerar valores que não representam adequadamente a produtividade observada na área (ROBINSON, 2023).

Diante dessas limitações, o processamento dos dados constitui uma etapa importante para melhorar a confiabilidade das informações utilizadas na geração dos mapas. A identificação e remoção de registros inconsistentes contribuem para reduzir a influência de observações que possam distorcer a representação espacial da produtividade (MATCHAM et al., 2022).

A necessidade de processamento torna-se ainda mais relevante quando são utilizadas grandes quantidades de dados provenientes de diferentes operações de colheita. Nesse contexto, procedimentos automatizados podem auxiliar na identificação de registros discrepantes e tornar o tratamento dos dados mais eficiente (UDDIN; SAMIAPPAN; DREWRY, 2026).

A padronização do processamento também é importante para a utilização de séries históricas de produtividade, pois procedimentos consistentes entre diferentes safras favorecem a comparação dos mapas e reduzem a possibilidade de que diferenças decorrentes do processamento sejam interpretadas como mudanças reais no comportamento produtivo da área (DAMIANO; NIEMI, 2022).

2.3 INTERPOLAÇÃO ESPACIAL DE DADOS DE PRODUTIVIDADE

Os dados obtidos pelos monitores de produtividade são registrados de forma pontual ao longo das trajetórias percorridas pelas máquinas durante a colheita. Para representar a distribuição da produtividade em toda a área, a interpolação espacial permite estimar valores em locais sem observações e gerar uma superfície contínua

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

a partir dos dados disponíveis. Entre os métodos utilizados na agricultura estão técnicas determinísticas e geoestatísticas, como o Inverso da Distância Ponderada e a Krigagem, que apresentam diferentes formas de estimar os valores e podem produzir representações distintas da variabilidade espacial. Dessa forma, a escolha do interpolador deve considerar as características e a distribuição dos dados, uma vez que seu desempenho pode influenciar a representação dos padrões produtivos da área (CÓRDOBA; BALZARINI, 2021).

Os mapas interpolados podem, posteriormente, ser utilizados como base para procedimentos de agrupamento espacial, permitindo identificar regiões com comportamentos produtivos semelhantes e subsidiar a delimitação de zonas de manejo (SANTOS et al., 2023).

2.4 ZONAS DE MANEJO E FUZZY C-MEANS

As zonas de manejo correspondem a regiões de uma área agrícola que apresentam características semelhantes em relação às variáveis utilizadas em sua delimitação. Sua definição permite organizar a variabilidade espacial em grupos identificáveis, facilitando a interpretação dos diferentes padrões produtivos e o planejamento de estratégias de manejo localizado. Nesse contexto, técnicas de agrupamento fuzzy podem ser utilizadas quando os limites entre regiões com diferentes características produtivas ocorrem de forma gradual (KESHAVARZI et al., 2025).

O Fuzzy C-Means é um método de agrupamento que permite atribuir diferentes graus de pertencimento das observações aos grupos formados. Essa característica possibilita representar situações em que uma mesma observação apresenta diferentes níveis de associação com as classes, sendo particularmente útil para dados agrícolas nos quais as transições entre regiões produtivas podem ocorrer de maneira gradual, sem limites espaciais claramente definidos (BEZDEK, 1981).

A definição do número de grupos influencia diretamente a configuração das zonas de manejo. Um número reduzido de classes pode representar a variabilidade de forma mais generalizada, enquanto um número elevado pode resultar em maior

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

fragmentação espacial. Dessa forma, a quantidade de zonas deve possibilitar a diferenciação dos padrões produtivos sem gerar subdivisões excessivas. A utilização de dados de produtividade provenientes de diferentes safras também pode contribuir para identificar regiões com comportamentos semelhantes e verificar a permanência desses padrões ao longo do tempo (SANTOS et al., 2023).

2.5 AVALIAÇÃO E VALIDAÇÃO DAS ZONAS DE MANEJO

A avaliação das zonas de manejo deve verificar se os grupos formados apresentam diferenças efetivas na produtividade e se possuem adequada homogeneidade interna. Nesse sentido, procedimentos estatísticos complementam a interpretação dos mapas e permitem verificar se as zonas representam regiões com comportamentos produtivos distintos (SANTOS et al., 2023).

A homogeneidade interna é um aspecto importante na avaliação das zonas, uma vez que delimitações adequadas tendem a apresentar menor variabilidade dentro dos grupos e maior diferenciação entre as classes. A estabilidade dos padrões espaciais também pode ser considerada, especialmente quando são utilizadas séries históricas de produtividade, permitindo verificar a permanência de comportamentos semelhantes entre diferentes safras (KESHAVARZI et al., 2025).

A análise de variância (ANOVA) é utilizada para verificar a existência de diferenças significativas entre as médias dos grupos. Quando são identificadas diferenças significativas, testes de comparação múltipla, como o teste de Tukey, podem ser empregados para determinar quais classes apresentam diferenças entre si, contribuindo para uma avaliação mais detalhada das zonas de manejo (MONTGOMERY, 2019; TUKEY, 1949).

3. Metodologia

O estudo foi realizado em cinco áreas agrícolas localizadas no município de Céu Azul, Paraná, com altitude média de aproximadamente 750 m. As áreas são destinadas à produção comercial e manejadas em sistema de rotação de culturas, incluindo milho, soja, aveia e trigo, com áreas de 15,60 ha (A), 71,62 ha (B), 27,48

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

ha (C), 23,49 ha (D) e 28,89 ha (E). As etapas metodológicas do estudo são apresentadas na Figura 1.

Figura 1 - Representação das áreas amostrais: áreas agrupadas.



Os dados de produtividade foram obtidos por meio do monitor de colheita de uma colhedora CASE e convertidos pelo software AFS CASE. Posteriormente, os dados foram processados no AgDataBox-Map, onde foram delimitados os contornos das áreas experimentais e realizados os recortes, considerando apenas os pontos pertencentes às respectivas áreas. A filtragem foi realizada no módulo ADB-Cleaning, com remoção de valores menores ou iguais a zero, registros duplicados, outliers e inliers.

Após a filtragem, foram obtidas, no AgDataBox-Map, estatísticas descritivas dos dados de produtividade, incluindo média, mediana, valores mínimo e máximo, variância, desvio-padrão e coeficiente de variação. Os dados foram avaliados considerando as 11 safras disponíveis, visando caracterizar a variabilidade espacial e temporal da produtividade.

Para cada safra e área, a interpolação dos dados de produtividade foi realizada no AgDataBox-Map, utilizando os métodos Inverso da Distância (ID), com potência (p=1), Inverso da Distância ao Quadrado (IDQ), com (p=2), e Média Móvel. Foram considerados os oito vizinhos mais próximos para a estimativa dos valores.

As Zonas de Manejo (ZM) foram delineadas no AgDataBox-Map por meio do algoritmo Fuzzy C-Means (FCM). O método permite representar a variabilidade espacial por meio de diferentes graus de pertinência dos pontos aos agrupamentos.

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

Foram avaliadas diferentes configurações quanto ao número de zonas, buscando identificar o agrupamento mais adequado para representar a variabilidade dos mapas de produtividade.

A qualidade das zonas de manejo foi avaliada pelos índices de Partição Fuzzy (FPI), Entropia de Partição Modificada (MPE), Redução da Variância (RV) e Índice de Suavidade (SI). Esses indicadores foram utilizados para avaliar a separação e organização dos agrupamentos, a homogeneidade interna e a continuidade espacial das zonas. A avaliação por múltiplos indicadores permite comparar diferentes configurações de agrupamento e selecionar a alternativa mais adequada para o zoneamento.

O Índice Composto de Validação Integrada (ICVI) foi calculado a partir dos índices FPI, MPE e RV sendo utilizado como critério complementar para a seleção do número de zonas de manejo. Menores valores de ICVI indicam melhor desempenho conjunto dos indicadores.

A homogeneidade interna das zonas foi avaliada pela Redução da Variância (RV), que relaciona a variância interna das zonas à variância total da área. Valores mais elevados indicam maior redução da variabilidade interna e maior homogeneidade das classes de manejo. A redução da variância também tem sido utilizada na avaliação da eficiência de diferentes configurações de zonas de manejo obtidas por Fuzzy C-Means,

O FPI foi utilizado para avaliar o grau de separação entre os agrupamentos fuzzy, o MPE para avaliar a organização das classes e o SI para quantificar a continuidade espacial das zonas. A avaliação conjunta desses indicadores permitiu comparar as diferentes configurações de zoneamento e subsidiar a seleção das zonas de manejo mais adequadas.

Por fim, as zonas de manejo foram avaliadas por meio da ANOVA, a fim de verificar a existência de diferenças significativas entre as médias de produtividade das classes. Quando identificadas diferenças significativas, foi aplicado o teste de Tukey, a 5% de probabilidade, para comparação das médias entre as zonas.

4. Resultados e Discussão

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

A análise dos dados de produtividade das cinco áreas estudadas evidenciou variabilidade espacial e temporal entre as safras avaliadas. As estatísticas descritivas obtidas após a filtragem dos dados demonstraram diferenças nos valores de produtividade, variância e coeficiente de variação entre as áreas e safras, indicando que a produtividade apresentou distribuição heterogênea ao longo do espaço e do tempo. Essa variabilidade reforça a necessidade de métodos capazes de representar espacialmente os diferentes padrões produtivos observados nas áreas agrícolas.

A partir dos dados filtrados, foram gerados mapas de produtividade para cada safra utilizando os métodos Inverso da Distância (ID), Inverso da Distância ao Quadrado (IDQ) e Média Móvel (MM), considerando os oito vizinhos mais próximos. Os diferentes interpoladores permitiram representar a distribuição espacial da produtividade e evidenciar regiões com diferentes níveis produtivos. Embora os métodos tenham apresentado capacidade de representar os padrões espaciais observados, foram identificadas diferenças na configuração e no grau de suavização das superfícies geradas, refletindo-se posteriormente na delimitação das zonas de manejo.

A utilização da produtividade média das safras possibilitou sintetizar a variabilidade temporal e gerar uma representação integrada do comportamento produtivo das áreas. A aplicação do algoritmo Fuzzy C-Means no AgDataBox-Map permitiu o agrupamento dos dados em diferentes números de zonas de manejo, sendo avaliadas configurações com duas e três classes. Os resultados demonstraram que tanto o método de interpolação quanto o número de zonas influenciaram a distribuição espacial das classes. De modo geral, a utilização de três zonas proporcionou maior diferenciação entre regiões de menor, intermediário e maior potencial produtivo, permitindo representar de forma mais detalhada a variabilidade existente.

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

Figura 2 - Zonas de Manejo geradas com a produtividade média de todas as safras na área A, por meio dos métodos de interpolação de dados ID, IDQ e MM, com 2 e 3 classes.

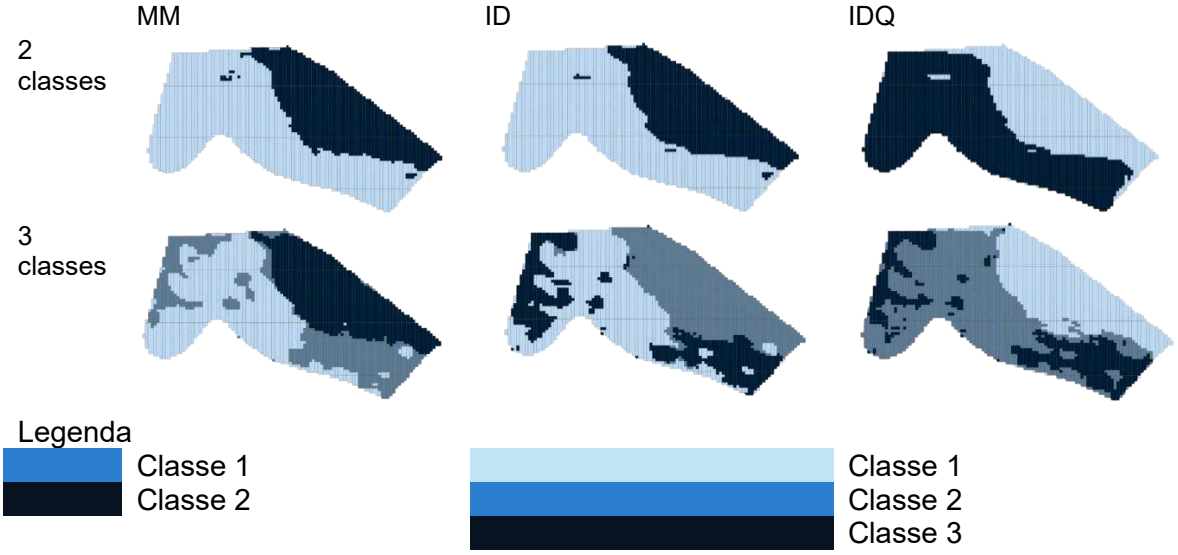

Fonte: Autoria própria (2026).

Figura 3 - Zonas de Manejo geradas com a produtividade média de todas as safras na área B, por meio dos métodos de interpolação de dados ID, IDQ e MM, com 2 e 3 classes.

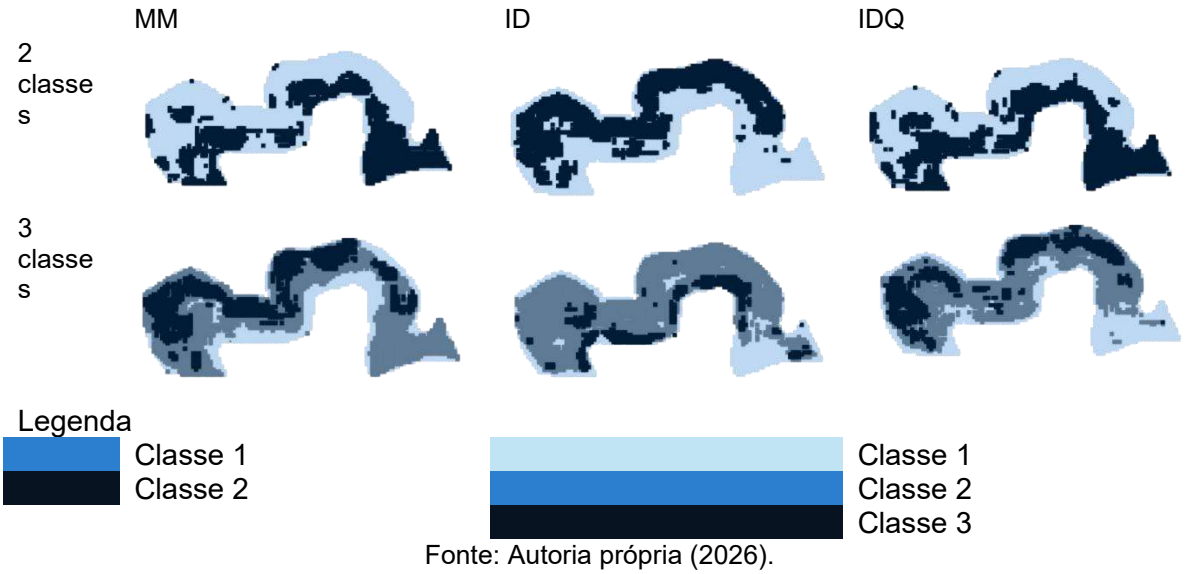

Fonte: Autoria própria (2026).

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

Figura 4 - Zonas de Manejo geradas com a produtividade média de todas as safras na área C, por meio dos métodos de interpolação de dados ID, IDQ e MM, com 2 e 3 classes.

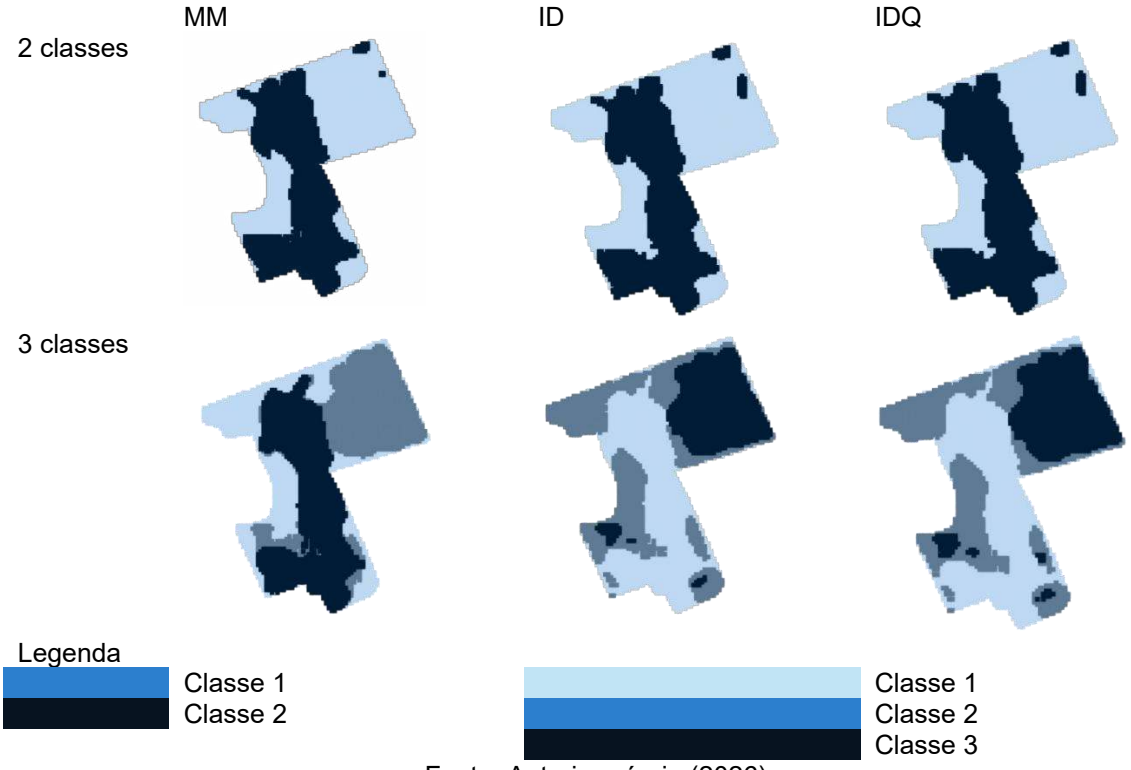

Fonte: Autoria própria (2026).

Figura 5 - Zonas de Manejo geradas com a produtividade média de todas as safras na área D, por meio dos métodos de interpolação de dados ID, IDQ e MM, com 2 e 3 classes.

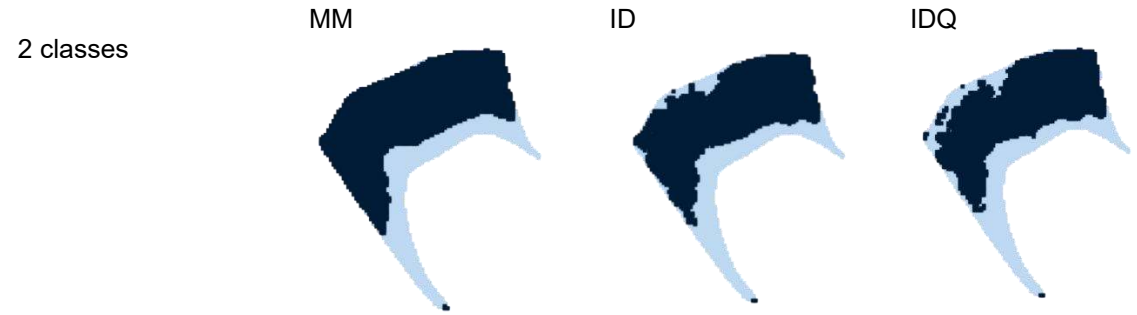

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

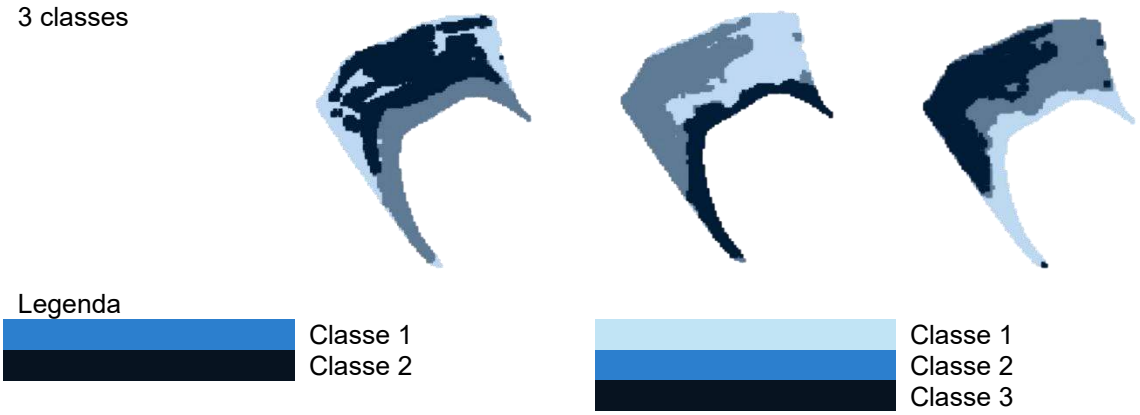

Fonte: Autoria própria (2026).

Figura 6 - Zonas de Manejo geradas com a produtividade média de todas as safras na área D, por meio dos métodos de interpolação de dados ID, IDQ e MM, com 2 e 3 classes.

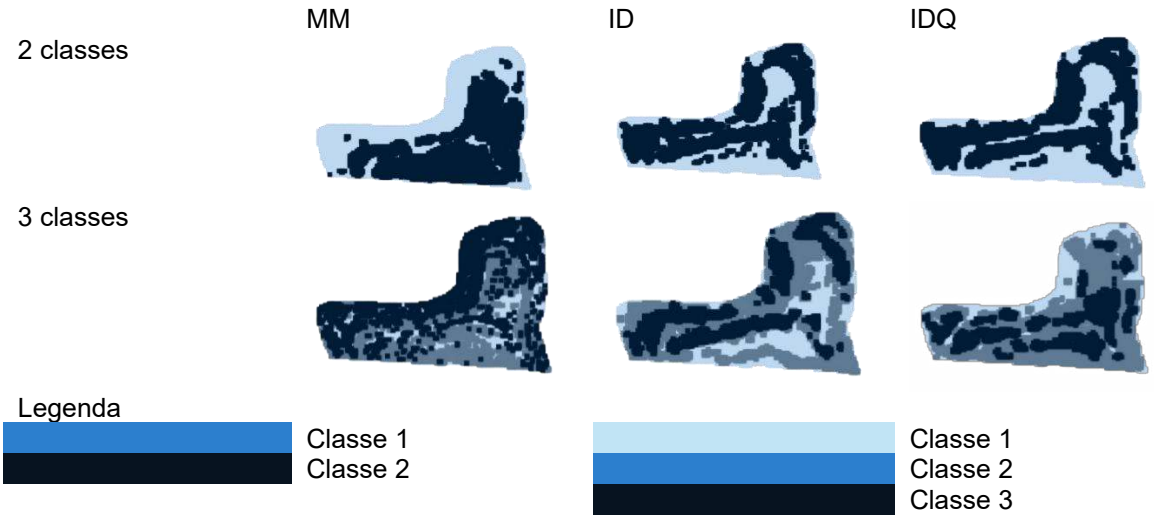

Fonte: Autoria própria (2026).

A avaliação das zonas de manejo foi realizada por meio dos índices FPI, MPE, RV, SI e ICVI, considerando diferentes métodos de interpolação e números de classes. Esses indicadores permitiram avaliar aspectos relacionados à separação dos agrupamentos, à homogeneidade interna e à continuidade espacial das zonas, possibilitando a comparação entre as diferentes configurações obtidas pelo Fuzzy C-Means. A análise conjunta dos índices permitiu identificar as configurações que apresentaram melhor desempenho para representar a variabilidade produtiva das áreas estudadas.

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

Na Área A, os resultados indicaram diferenças entre os métodos de interpolação e o número de classes. A configuração com três classes apresentou maior redução da variância, destacando-se o método ID (31,87) e a Média Móvel (28,70), enquanto o método MM com duas classes apresentou o menor FPI (0,39) e melhor desempenho quanto à continuidade espacial. O menor ICVI foi obtido pelo método ID com três classes (0,68). De modo geral, os resultados indicam que a escolha da configuração mais adequada depende da avaliação conjunta dos indicadores, com destaque para o método MM em diferentes critérios.

Tabela 1 - Estatísticas de produtividade por método e número de classes – Área A.

Mét	ZM	Nº	MD	DP	CV (%)	Min	Med	Max	SI	FPI	MPE	VR	ICVI
IDQ	2	2372	3,87b	0,27	6,99	2,77	3,89	4,65	88,10	0,46	0,53	0,65	0,99
		1514	3,92a	0,27	6,94	2,92	3,95	4,78					
	3	1228	3,94b	0,24	6,09	3,14	3,96	4,66	69,30	0,64	0,65	24,80	0,75
		1410	4,02a	0,22	5,41	3,36	4,02	4,78					
		1248	3,70c	0,25	6,80	2,77	3,72	4,41					
ID	2	2374	3,13b	0,21	6,77	2,20	3,14	3,81	89,70	0,43	0,51	0,64	0,99
		1512	3,16a	0,23	7,25	2,29	3,20	3,69					
	3	1388	3,26a	0,15	4,49	2,73	3,26	3,81	72,00	0,61	0,62	31,90	0,68
		1219	3,18b	0,20	6,36	2,30	3,21	3,69					
		1279	2,97c	0,19	6,51	2,20	3,00	3,43					
MM	2	2363	3,89b	0,23	5,90	2,86	3,89	4,72	91,30	0,39	0,46	0,32	1,00
		1523	3,91a	0,23	5,79	2,91	3,95	4,45					
	3	1428	4,02a	0,17	4,24	3,52	4,02	4,72	77,70	0,59	0,60	28,70	0,71
		1198	3,72c	0,21	5,54	2,86	3,75	4,22					
		1260	3,93b	0,20	5,18	3,16	3,96	4,44					

Mét = método de interpolação; ZM = número de zonas de manejo; Nº = identificação da zona de manejo; MD = média de produtividade (t ha⁻¹); Var = variância; CV = coeficiente de variação (%); Min = valor mínimo; Med = mediana; Max = valor máximo; SI = índice de suavidade; FPI = Fuzzy Performance Index; MPE = Modified Partition Entropy; VR = redução da variância; ICVI = Índice Composto de Validação Integrada. Letras distintas sobrescritas nas médias indicam diferença estatística significativa entre zonas de manejo.

Na Área B, os métodos de interpolação apresentaram médias de produtividade semelhantes, variando de 4,89 a 5,49 t ha⁻¹, com baixa variabilidade interna das zonas, destacando-se o método MM pelos menores coeficientes de variação. A configuração com três classes proporcionou maior discriminação dos níveis produtivos e maiores valores de redução da variância, especialmente para os

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

métodos IDQ (42,60%) e ID (42,68%), além de apresentar diferenças estatísticas entre as classes. O ICVI apresentou menores valores para IDQ (0,66) e MM (0,67), indicando melhor desempenho dessas configurações. De forma geral, a divisão em três classes apresentou maior capacidade de diferenciar os níveis de produtividade, com destaque para o método MM pelo conjunto dos indicadores avaliados.

Tabela 2 - Estatísticas de produtividade por método e número de classes – Área B.

Mét	ZM	N	Nº	Méd	DP	Var	CV (%)	Min	Med	Max	SI	FPI	MPE	VR	ICVI
IDQ	2	1	1458	5,01b	0,32	0,10	5,90	4,37	5,47	6,74	59,30	0,58	0,64	32,97	0,70
		2	1567	5,49a	0,35	0,13	7,08	3,23	5,02	6,18					
	3	1	1129	4,93b	0,35	0,12	7,10	3,23	4,94	6,18	45,00	0,60	0,63	42,60	0,66
		2	843	5,42a	0,34	0,12	6,27	4,44	5,39	6,74					
		3	1053	5,44a	0,32	0,10	5,87	4,37	5,41	6,40					
ID	2	1	1518	5,01b	0,32	0,10	6,41	3,45	5,03	6,02	59,90	0,58	0,64	37,18	0,73
		2	1507	5,48a	0,29	0,08	5,21	4,59	5,47	6,61					
	3	1	1000	4,89c	0,30	0,09	6,05	3,45	4,93	5,73	45,04	0,60	0,63	42,68	0,72
		2	1031	5,46a	0,29	0,09	5,38	4,59	5,44	6,58					
		3	994	5,38b	0,28	0,08	5,22	4,66	5,36	6,61					
MM	2	1	1577	5,46a	0,25	0,06	4,54	4,54	5,44	6,39	61,20	0,57	0,63	38,30	0,68
		2	1448	5,04b	0,29	0,08	5,67	3,60	5,06	5,92					
	3	1	986	5,37b	0,26	0,07	4,83	4,30	5,35	6,39	48,10	0,58	0,61	38,20	0,67
		2	929	4,94c	0,28	0,08	5,68	3,60	4,96	5,69					
		3	1110	5,42a	0,26	0,07	4,82	4,73	5,41	6,30					

Mét = método de interpolação; ZM = número de zonas de manejo; Nº = identificação da zona de manejo; MD = média de produtividade (t ha^{-1}); Var = variância; CV = coeficiente de variação (%); Min = valor mínimo; Med = mediana; Max = valor máximo; SI = índice de suavidade; FPI = Fuzzy Performance Index; MPE = Modified Partition Entropy; VR = redução da variância; ICVI = Índice Composto de Validação Integrada.Letr as distintas sobrescritas nas médias indicam diferença estatística significativa entre zonas de manejo.

Na Área C, os métodos de interpolação apresentaram médias de produtividade entre 3,72 e 4,39 t ha^{-1}, com baixos coeficientes de variação, indicando boa homogeneidade interna das zonas. A configuração com três classes proporcionou maior discriminação dos níveis produtivos e maiores valores de redução da variância, entre 50,39% e 52,19%. O método MM com três classes destacou-se por apresentar o menor ICVI (0,56) e coeficientes de variação reduzidos, indicando maior homogeneidade interna e melhor organização espacial

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

das zonas. Dessa forma, a configuração com três classes pelo método MM apresentou o melhor desempenho conjunto entre as alternativas avaliadas.

Tabela 3 - Estatísticas de produtividade por método e número de classes – Área C.

Mét	ZM	N	Nº	Méd	DP	Var	CV (%)	Min	Medi	Máx	SI	FPI	MPE	VR	ICVI
IDQ	2	1	1922	4,31a	0,35	0,13	8,51	2,82	4,34	5,32	83,87	0,43	0,49	19,47	0,78
		2	2217	3,95b	0,37	0,13	8,95	2,69	3,96	5,09					
	3	1	1592	4,39a	0,31	0,09	6,99	3,53	4,39	5,32	73,54	0,48	0,51	50,39	0,81
		2	1312	3,72c	0,28	0,08	7,41	2,69	3,74	4,57					
		3	1235	4,20b	0,26	0,07	6,10	3,24	4,18	5,09					
ID	2	1	1923	4,30a	0,34	0,12	8,60	2,72	3,75	4,99	85,04	0,43	0,50	19,36	0,76
		2	2216	3,96b	0,35	0,12	8,10	2,83	4,06	5,26					
	3	1	1596	4,38a	0,29	0,08	6,54	3,59	4,38	5,26	74,86	0,46	0,50	51,89	0,79
		2	1322	3,73c	0,26	0,07	7,07	2,72	3,76	4,55					
		3	1221	4,19b	0,24	0,06	5,69	3,47	4,18	4,99					
MM	2	1	2184	3,98b	0,32	0,10	7,95	2,80	3,99	4,91	87,16	0,40	0,47	18,40	0,80
		2	1955	4,28a	0,32	0,10	7,53	2,93	4,31	5,11					
	3	1	1300	3,76c	0,25	0,06	6,56	2,80	3,79	4,51	79,70	0,42	0,45	52,19	0,56
		2	1229	4,18b	0,22	0,05	5,22	3,27	4,18	4,91					
		3	1610	4,36a	0,26	0,07	5,96	3,65	4,37	5,11					

Mét = método de interpolação; ZM = número de zonas de manejo; Nº = identificação da zona de manejo; MD = média de produtividade (t ha⁻¹); Var = variância; CV = coeficiente de variação (%); Min = valor mínimo; Med = mediana; Max = valor máximo; SI = índice de suavidade; FPI = Fuzzy Performance Index; MPE = Modified Partition Entropy; VR = redução da variância; ICVI = Índice Composto de Validação Integrada. Letras distintas sobrescritas nas médias indicam diferença estatística significativa entre zonas de manejo.

Na Área D, os métodos de interpolação apresentaram médias de produtividade entre 4,12 e 4,67 t ha⁻¹, com baixos coeficientes de variação, indicando boa homogeneidade interna das zonas. A configuração com três classes proporcionou maior discriminação dos níveis produtivos e aumento da redução da variância, destacando-se o método MM com 44,26%. O método MM com três classes também apresentou o menor ICVI (0,56) e baixos valores de CV, além de maior diferenciação entre as classes de produtividade. Dessa forma, a configuração com três classes pelo método MM apresentou o melhor desempenho conjunto entre as alternativas avaliadas.

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

Tabela 4 - Estatísticas de produtividade por método e número de classes – Área D.

Mét	ZM	N	Nº	Méd	DP	Var	CV (%)	Min	Med	Max	SI	FPI	MPE	VR	ICVI
IDQ	2	1	1325	4,60a	0,32	0,10	6,90	3,40	4,60	5,59	78,75	0,50	0,56	22,31	0,78
		2	2211	4,26b	0,31	0,10	7,28	2,93	4,25	5,35					
	3	1	810	4,67a	0,31	0,09	6,56	3,51	4,67	5,59	70,12	0,50	0,52	18,77	0,81
		2	1382	4,30b	0,31	0,10	7,18	2,93	4,29	5,35					
		3	1344	4,30b	0,34	0,11	7,87	2,96	4,30	5,44					
ID	2	1	1238	4,61a	0,29	0,08	6,27	3,55	4,61	5,53	82,57	0,52	0,59	24,40	0,76
		2	2298	4,27b	0,29	0,08	6,73	3,03	4,27	5,24					
	3	1	1375	4,32b	0,28	0,08	6,49	3,20	4,32	5,24	72,60	0,54	0,57	20,87	0,79
		2	1375	4,29c	0,31	0,10	7,27	3,03	4,29	4,50					
		3	786	4,67a	0,29	0,08	6,16	3,55	4,47	4,86					
MM	2	1	1024	4,60a	0,27	0,07	5,94	3,68	4,59	5,43	92,72	0,30	0,36	19,95	0,80
		2	2512	4,31b	0,26	0,07	6,09	3,17	4,32	5,19					
	3	1	1132	4,12c	0,22	0,05	5,22	3,17	4,14	4,71	72,50	0,42	0,44	44,26	0,56
		2	892	4,63a	0,26	0,07	5,65	4,01	4,62	5,43					
		3	1512	4,45b	0,20	0,04	4,48	3,91	4,44	5,19					

Mét = método de interpolação; ZM = número de zonas de manejo; Nº = identificação da zona de manejo; MD = média de produtividade (t ha^{-1}); Var = variância; CV = coeficiente de variação (%); Min = valor mínimo; Med = mediana; Max = valor máximo; SI = índice de suavidade; FPI = Fuzzy Performance Index; MPE = Modified Partition Entropy; VR = redução da variância; ICVI = Índice Composto de Validação Integrada. Letras distintas sobrescritas nas médias indicam diferença estatística significativa entre zonas de manejo.

Na Área E, os métodos de interpolação apresentaram médias de produtividade entre 3,40 e 3,86 t ha^{-1}, com baixos coeficientes de variação, indicando boa homogeneidade interna das zonas. A configuração com três classes proporcionou maior discriminação dos níveis produtivos e aumento da redução da variância, destacando-se os métodos ID (45,70%) e MM (42,97%). O método ID com três classes apresentou o menor ICVI (0,54) e maior VR, indicando melhor organização interna e maior capacidade de representar a variabilidade espacial da produtividade. Dessa forma, a configuração com três classes pelo método ID apresentou o melhor desempenho conjunto entre as alternativas avaliadas.

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

Tabela 5 - Estatísticas de produtividade por método e número de classes – Área E.

Mét	ZM	N	Nº	Méd	DP	Var	CV (%)	Min	Med	Max	SI	FPI	MPE	VR	ICVI
IDQ	2	1	2820	3,53b	0,27	0,05	5,99	2,91	2,81	4,34	68,17	0,60	0,66	25,14	0,75
		2	2693	3,82a	0,23	0,07	7,60	1,98	3,55	4,64					
	3	1	1962	3,75b	0,23	0,05	6,17	2,91	3,75	4,54	55,07	0,59	0,62	35,77	0,64
		2	1919	3,44c	0,25	0,06	7,25	1,98	3,47	4,10					
		3	1962	3,83a	0,21	0,05	5,55	3,04	3,81	4,64					
ID	2	1	2735	3,55b	0,26	0,07	7,29	2,04	3,56	4,27	69,68	0,53	0,60	22,03	0,78
		2	2778	3,80a	0,21	0,05	5,64	3,00	3,94	4,59					
	3	1	1961	3,82a	0,19	0,05	4,92	3,37	3,79	4,59	54,83	0,51	0,54	45,70	0,54
		2	1665	3,40c	0,21	0,04	6,30	2,04	3,44	3,98					
		3	1887	3,77b	0,19	0,04	5,13	3,00	3,76	4,51					
MM	2	1	2605	3,68a	0,25	0,06	6,71	2,39	3,70	4,46	75,63	0,57	0,64	0,01 negativo	1,00
		2	2908	3,68a	0,23	0,05	6,32	2,18	3,69	4,39					
	3	1	2061	3,86a	0,15	0,02	3,83	3,42	3,85	3,85	64,23	0,56	0,59	42,97	0,57
		2	1750	3,48c	0,20	0,04	5,87	2,18	3,52	3,52					
		3	1702	3,67b	0,19	0,04	5,21	2,88	3,68	3,68					

Mét = método de interpolação; ZM = número de zonas de manejo; Nº = identificação da zona de manejo; MD = média de produtividade (t ha^{-1}); Var = variância; CV = coeficiente de variação (%); Min = valor mínimo; Med = mediana; Max = valor máximo; SI = índice de suavidade; FPI = Fuzzy Performance Index; MPE = Modified Partition Entropy; VR = redução da variância; ICVI = Índice Composto de Validação Integrada.Letras distintas sobrescritas nas médias indicam diferença estatística significativa entre zonas de manejo.

A análise de variância e o teste de Tukey permitiram verificar diferenças estatisticamente significativas entre as zonas de manejo, confirmando a capacidade do Fuzzy C-Means em diferenciar regiões com distintos níveis de produtividade. De forma geral, a integração dos dados históricos, filtragem, interpolação e agrupamento possibilitou identificar padrões espaciais e temporais e delimitar zonas com diferentes potenciais produtivos. A avaliação conjunta dos índices de validação e dos testes estatísticos permitiu selecionar configurações com maior homogeneidade interna e diferenciação entre as classes, evidenciando o potencial das séries históricas de produtividade para o delineamento de zonas de manejo.

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

5. Conclusão

A utilização de séries históricas de produtividade, associada às etapas de filtragem, interpolação e agrupamento Fuzzy C-Means, mostrou-se adequada para a delimitação e avaliação de zonas de manejo nas cinco áreas estudadas. O processamento dos dados contribuiu para a redução de inconsistências e para a obtenção de mapas capazes de representar a variabilidade espacial e temporal da produtividade.

Os resultados evidenciaram diferenças de produtividade entre as áreas e safras, confirmando a presença de variabilidade espacial e temporal. A utilização de três classes proporcionou, de modo geral, maior diferenciação dos níveis produtivos e maior redução da variabilidade interna das zonas, embora o desempenho tenha variado conforme a área e o método de interpolação.

O Fuzzy C-Means apresentou capacidade de identificar regiões com diferentes níveis de produtividade. A avaliação conjunta dos índices FPI, MPE, RV, SI e ICVI, associada à ANOVA e ao teste de Tukey, possibilitou comparar as configurações e identificar aquelas com maior homogeneidade interna e diferenciação entre as classes. Entre as áreas avaliadas, os melhores resultados foram obtidos com diferentes métodos de interpolação, evidenciando que não houve uma única configuração superior para todas as áreas.

Dessa forma, as séries históricas de produtividade mostraram potencial para subsidiar o delineamento de zonas de manejo mais representativas da variabilidade das áreas agrícolas. Como perspectiva, recomenda-se avaliar a estabilidade temporal das zonas em diferentes safras e condições de cultivo, bem como investigar outras técnicas de agrupamento e métodos de validação que possam aprimorar o delineamento das zonas de manejo.

Referências

BHAGWAN, P. V. et al. Delineation and evaluation of management zones for site-specific nutrient management using a geostatistical and fuzzy C mean cluster approach. **Scientific Reports**, v. 15, art. 20991, 2025. DOI: https://doi.org/10.1038/s41598-025-07283-0.

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

BEZDEK, J. C. **Pattern recognition with fuzzy objective function algorithms**. New York: Plenum Press, 1981. DOI: https://doi.org/10.1007/978-1-4757-0450-1.

CLARKE, D. E. et al. Whole-farm yield map datasets – Data validation for exploring spatiotemporal yield and economic stability. **Agricultural Systems**, v. 218, 103972, 2024. DOI: https://doi.org/10.1016/j.agsy.2024.103972.

CÓRDOBA, M.; BALZARINI, M. A random forest-based algorithm for data-intensive spatial interpolation in crop yield mapping. **Computers and Electronics in Agriculture**, v. 184, 106094, 2021. DOI: https://doi.org/10.1016/j.compag.2021.106094.

GAVIOLI, A. et al. Optimization of management zone delineation by using spatial principal components. **Computers and Electronics in Agriculture**, v. 127, p. 302–310, 2016. DOI: https://doi.org/10.1016/j.compag.2016.06.029.

GAVIOLI, A. et al. Identification of management zones in precision agriculture: an evaluation of alternative cluster analysis methods. **Biosystems Engineering**, v. 181, p. 86–102, 2019. DOI: https://doi.org/10.1016/j.biosystemseng.2019.02.019.

KULATUNGA, C.; DHELIM, S.; KECHADI, T. Machine Learning for Dynamic Management Zone in Smart Farming. **arXiv**, 2024. DOI: https://doi.org/10.48550/arXiv.2408.00789.

LONGCHAMPS, L. et al. Yield sensing technologies for perennial and annual horticultural crops: a review. **Precision Agriculture**, v. 23, p. 2407–2448, 2022. DOI: https://doi.org/10.1007/s11119-022-09906-2.

MATCHAM, E. G. et al. Filtering, editing, and cropping yield maps in a R environment with the package cleanRfield. **Agronomy Journal**, 2022. DOI: https://doi.org/10.1002/agj2.21055.

PACCIORRETTI, P. A.; CÓRDOBA, M.; BALZARINI, M. G. FastMapping: software to create field maps and identify management zones in precision agriculture. **Computers and Electronics in Agriculture**, v. 175, 105556, 2020. DOI: https://doi.org/10.1016/j.compag.2020.105556.

ROBINSON, S. V. J. et al. Precision agricultural data and ecosystem services: can we put the pieces together? **Ecological Solutions and Evidence**, v. 4, n. 4, e12271, 2023. DOI: https://doi.org/10.1002/2688-8319.12271.

SAHA, G. et al. Smart IoT-driven precision agriculture: land mapping, crop prediction, and irrigation system. **PLOS ONE**, v. 20, n. 3, e0319268, 2025. DOI: https://doi.org/10.1371/journal.pone.0319268.

SANTOS, L. M. G. et al. Methodology for estimating productive potential zones from productivity data. **Semina: Ciências Agrárias**, v. 44, n. 3, p. 1001–1016, 2023. DOI: https://doi.org/10.5433/1679-0359.2023v44n3p1001.

CC BY

REMUNOM
ISSN 2178-6925

Received: 13/10/2026 - **Accepted:** 08/11/2026
Vol: 13.23
DOI: 10.66104/mfsmg402
Pages: 1-23

SILVA JÚNIOR, J. F. et al. Delineation of potential management zones for cowpea by factorial kriging and spatial Fuzzy C-Means of yield and soil chemical and texture properties. **Revista Brasileira de Ciência do Solo**, v. 49, e0230158, 2025. DOI: https://doi.org/10.36783/18069657rbcs20230158.

STERLE, L. G. G.; MOLIN, J. P. Management zones for irrigated and rainfed grain crops based on data layer integration. **Agronomy**, v. 15, n. 8, 1864, 2025. DOI: https://doi.org/10.3390/agronomy15081864.

TUKEY, J. W. Comparing individual means in the analysis of variance. **Biometrics**, v. 5, n. 2, p. 99–114, 1949.

UDDIN, M.; SAMIAPPAN, S.; DREWRY, J. L. Automated yield monitor data post-processing pipeline via explainable model benchmarking and stacked ensemble. **Computers and Electronics in Agriculture**, v. 241, 111278, 2026. DOI: https://doi.org/10.1016/j.compag.2025.111278.

VALLENTIN, C. et al. Delineation of management zones with spatial data fusion and belief theory. **Precision Agriculture**, v. 21, p. 802–830, 2020.

CC BY