

**UNIVERSIDADE FEDERAL DA GRANDE DOURADOS
FACULDADE DE CIÊNCIAS AGRÁRIAS**

**MÉTODOS DE DETERMINAÇÃO DE ZONAS DE MANEJO A
PARTIR DE DADOS DE PRODUTIVIDADE DE MILHO**

**ANDRÉ MIGUEL CAPUANO BRANDT
LEONARDO BONINI VILLETTI**

**DOURADOS
MATO GROSSO DO SUL
2024**

MÉTODOS DE DETERMINAÇÃO DE ZONAS DE MANEJO A PARTIR DE DADOS DE PRODUTIVIDADE DE MILHO

André Miguel Capuano Brandt

Leonardo Bonini Villetti

Orientador: Prof. Dr. Jorge Wilson Cortez

Trabalho de Conclusão de Curso apresentado à
Universidade Federal da Grande Dourados, como
parte dos requisitos para obtenção do título de
Engenheiro Agrônomo.

Dourados
Mato Grosso do Sul
2024

Dados Internacionais de Catalogação na Publicação (CIP).

B821m Brandt, André Miguel Capuano
Métodos de Determinação de Zonas de Manejo a Partir de dados de Produtividade do Milho
[recurso eletrônico] / André Miguel Capuano Brandt, Leonardo Bonini Villetti. -- 2024.
Arquivo em formato pdf.

Orientador: Jorge Wilson Cortez.
TCC (Graduação em Agronomia)-Universidade Federal da Grande Dourados, 2024.
Disponível no Repositório Institucional da UFGD em:
<https://portal.ufgd.edu.br/setor/biblioteca/repositorio>

1. Agricultura de Precisão. 2. Geoprocessamento. 3. Mapas de produtividade. I. Villetti,
Leonardo Bonini . II. Cortez, Jorge Wilson. III. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

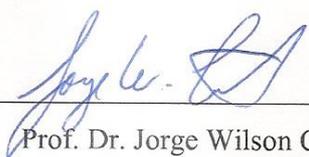
©Direitos reservados. Permitido a reprodução parcial desde que citada a fonte.

**MÉTODOS DE DETERMINAÇÃO DE ZONAS DE MANEJO A PARTIR
DE DADOS DE PRODUTIVIDADE DE MILHO**

André Miguel Capuano Brandt
Leonardo Bonini Villetti

Trabalho de conclusão de curso apresentado como parte dos requisitos exigidos para obtenção
do grau de Bacharel em ENGENHARIA AGRONÔMICA

Aprovado em 01/11/2024.



Prof. Dr. Jorge Wilson Cortez

Orientador – UFGD/FCA



Profa. Dra. Anamari Viegas de Araújo Motomiya

UFGD/FCA



Prof. Dr. Eber Augusto Ferreira do Prado

IFMS – Ponta Porã

AGRADECIMENTOS

Agradecemos primeiramente a Deus por sempre iluminar meus caminhos, me mantendo sempre no caminho do bem, da justiça e da verdade.

Agradecemos ao meu orientador, Jorge Wilson Cortez, pela orientação excepcional, pelo apoio constante e pelos ensinamentos valiosos que contribuíram significativamente para o meu crescimento acadêmico e profissional.

Agradecemos ao Eng. Agr. Gilberto Darci Bernardi pela disponibilidade dos dados para a realização desse trabalho.

Aos nossos familiares, expressamos nossa gratidão pela compreensão, amor incondicional e apoio irrestrito ao longo dessa trajetória. Sem vocês, nada disso seria possível.

Agradecemos aos amigos e colegas que estiveram ao nosso lado, compartilhando conhecimentos, trocando experiências e oferecendo suporte em momentos desafiadores. Suas contribuições foram fundamentais para o nosso desenvolvimento pessoal e acadêmico

À Universidade Federal da Grande Dourados (UFGD), agradecemos pela infraestrutura, pelo ambiente propício ao aprendizado e pela oportunidade de fazer parte de uma instituição que valoriza a educação e a pesquisa.

Esses agradecimentos representam apenas uma pequena parte do reconhecimento que tenho por todos que contribuíram de alguma forma para a minha jornada. A todos vocês, nossos sinceros e profundo agradecimento.

BRANDT, A. M. C.; VILLETTI, L. B. **Métodos de determinação de zonas de manejo a partir de dados de produtividade de milho**. 2024. 43f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Agrônômica) – Faculdade de Ciências Agrárias, Universidade Federal da Grande Dourados, Dourados, 2024.

RESUMO

A agricultura de precisão usa uma abordagem moderna para a gestão agrícola, visa otimizar o uso de insumos e maximizar a produtividade, respeitando as variações espaciais dentro de um campo agrícola. A identificação e a delimitação de zonas de manejo são etapas cruciais nesse processo, permitindo uma aplicação diferenciada de insumos com base nas necessidades específicas de cada zona. Assim, objetivou-se avaliar os dados do monitor de produtividade da colhedora de grãos e métodos de geração de zonas de manejo a partir de três safras de milho, referentes aos anos de 2019, 2020 e 2021. Para este trabalho foram utilizados dados de produtividade obtidos a partir de sensores presentes na colhedora em uma propriedade comercial. Os dados foram submetidos a um processo de filtragem, análise estatística e geoespacial para identificar padrões e variações dentro das áreas de cultivo. A metodologia utilizada na geração de zonas de manejo incluiu técnicas de ponderação e a aplicação de algoritmos de clusterização para segmentação das zonas. O uso do método de normalização da produtividade pela média pode ser utilizado para geração de zonas de manejo, desde que seja com faixas mais restritivas, como produtividade baixa menor que 95% e produtividade alta maior que 105%. O uso dos softwares MZA e o complemento *Smart-Map* do QGIS são uma opção de geração de zonas de manejo e apresentam resultados similares. A geração de zonas de manejo a partir dos dados de produtividade é estratégia valiosa para a agricultura de precisão, proporcionando um aumento na eficiência do uso de recursos e contribuindo para tomada de decisões mais eficientes.

Palavras-chave: Agricultura de precisão. Variabilidade espacial. Unidades de gestão diferenciadas.

BRANDT, A. M. C.; VILLETTI, L. B. **Methods for determining management zones from maize yield data**. 2024. 43f. Course Completion Work (Bachelor's Degree in Agronomic Engineering) – Faculty of Agrarian Sciences, Federal University of Grande Dourados, Dourados, 2024.

ABSTRACT

Precision agriculture, which uses a modern approach to farm management, aims to optimize the use of inputs and maximize productivity while respecting spatial variations within an agricultural field. The identification and delimitation of management zones are crucial steps in this process, allowing for a differentiated application of inputs based on the specific needs of each zone. Thus, the objective of this study was to evaluate the data from the grain harvester's productivity monitor and methods for generating management zones from three corn harvests, referring to the years 2019, 2020 and 2021. For this work, productivity data obtained from sensors present in the harvester on a commercial property were used. The data were subjected to a process of filtering, statistical and geospatial analysis to identify patterns and variations within the cultivation areas. The methodology used in the generation of management zones included weighting techniques and the application of clustering algorithms for zone segmentation. The use of the method of normalization of productivity by average can be used to generate management zones, as long as it is with more restrictive ranges, such as low productivity less than 95% and high productivity greater than 105%. The use of MZA software and the Smart-Map add-on of QGIS are an option for generating management zones and present similar results. The generation of management zones from productivity data is a valuable strategy for precision agriculture, providing an increase in the efficiency of resource use and contributing to more efficient decision-making.

Keywords: Precision agriculture. Spatial variability. Differentiated management units.

SUMÁRIO

1	INTRODUÇÃO	9
2	REVISÃO BIBLIOGRÁFICA	11
2.1	Aspectos econômicos da cultura do milho	11
2.2	Agricultura de precisão	12
2.3	Mapas de produtividade	12
2.4	Zonas de manejo	13
3	MATERIAL E MÉTODOS	16
3.1	Descrição do local	16
3.2	Insumos e colhedora	18
3.3	Dados de granulometria	18
3.4	Dados de produtividade	19
3.5	Geração de zonas de manejo	20
3.5.1	Normalização da média	20
3.5.2	Pelo software MZA	21
3.5.3	Pelo complemento Smart-Map	21
3.6	Análise dos dados	22
4	RESULTADOS E DISCUSSÃO	23
4.1	Granulometria	23
4.2	Análise dos dados de produtividade	23
4.3	Zonas de manejo	29
4.3.1	Zonas de manejo pela normalização da média	29
4.3.2	Zonas de manejo com o software MZA	32
4.3.3	Zonas de manejo com o complemento Smart-Map	34
4.3.4	Concordância dos mapas de zonas de manejo	35
4.3.5	Zonas de manejo do produtor e recomendação atual	36
5	CONCLUSÕES	39
6	REFERÊNCIAS BIBLIOGRÁFICAS	40

1 INTRODUÇÃO

Em tempos não muito distantes, a tecnologia presente na agricultura era muito restrita, a obtenção de dados de colheita era muito precária, fazendo com que certos parâmetros fossem medidos com imprecisão. Na década de 50, com o surgimento da agricultura 2.0 os primeiros passos foram implantados para facilitar as formas de manejo e contribuir para a produção em grande escala com o estabelecimento dos maquinários agrícolas.

Somente em 1980, os primeiros mapas de produtividade começavam a tomar forma na Europa com colhedoras equipadas com sensores de fluxo de grãos, e nesta mesma época, o uso mais frequente de satélites e de equipamentos possibilitavam já a aplicação de insumos a taxa variável nos Estados Unidos (MOLIN et al., 2015). Ainda citam os autores, que no Brasil os primeiros equipamentos capazes de efetuar essas atividades chegaram nos anos 2000, com a liberação dos sinais de Sistema de Navegação Global por Satélite (GNSS) de forma gratuita, popularizando mundo afora a ideia de Agricultura de Precisão.

Já a partir do ano de 1990 até 2010 iniciou-se uma grande revolução que contribuiu para chegar à tecnologia presente nos dias atuais, denominada como Agricultura 3.0, permitindo a integração de tecnologias avançadas, automação e sensoriamento remoto aos maquinários.

A agricultura 4.0 teve início de 2010 até os dias atuais e vem cada dia se expandindo devido a grandes investimentos de pesquisas na área; alguns exemplos de tecnologias que estamos vivenciando nessa fase são os drones que possibilitam uma visão mais ampla da área a ser estudada e permite realizar aplicações com maior facilidade. Outro grande ponto foi o avanço de estudos na área da biotecnologia na agricultura permitindo o melhoramento das mais variadas espécies de plantas.

Ocorreu também o aprimoramento da análise de dados em larga escala que é uma das tecnologias fundamentais na tecnologia 4.0, pois auxilia a tomada de decisões estratégicas e na otimização das operações agrícolas. Com o avanço da tecnologia, a quantidade de dados gerados no setor agrícola aumentou significativamente, incluindo informações sobre clima, solo, culturas, maquinário e taxa variável.

Com os resultados extraídos dos monitores, há muitas possibilidades de interpretações de dados; o uso de dados de fertilidade do solo juntamente com parâmetros obtidos pelos sensores de colheita permitiu análises mais precisas de locais específicos nas lavouras. Uma das possibilidades é a criação de zonas de manejo dividindo a área agrícola em áreas homogêneas com base nas características identificadas. Por exemplo, pode-se delimitar zonas de alta produtividade, zonas de média produtividade e zonas de baixa produtividade.

Objetivou-se avaliar os dados de produtividade do monitor da colhedora de grãos e métodos de geração de zonas de manejo a partir de três safras de milho, referente aos anos de 2019, 2020 e 2021 em área comercial de produção de milho.

2 REVISÃO BIBLIOGRÁFICA

2.1 Aspectos econômicos da cultura do milho

O milho (*Zea mays*) desempenha um papel fundamental na economia e na sociedade, pois seus grãos são utilizados na produção de rações para animais e como alimento essencial na dieta de grande parte da população (SIMIONI et al., 2017). O milho é uma das plantações mais relevantes economicamente e amplamente pesquisada, devido ao seu alto valor nutricional dos grãos, sendo essencial na dieta humana e animal (SOUZA et al., 2012). Segundo dados da CONAB (2024), a expectativa da principal cultura da 2ª safra, o milho, tem uma estimativa de produção de 88,12 milhões de toneladas.

De acordo com os dados da SEMADESC, a área de milho na 2ª safra 2022/2023 em Mato Grosso do Sul alcançou 2.355.016,62 hectares e a produtividade média ponderada foi de 100,64 sacas por ha. As médias ponderadas de produtividade por regiões foram de: 128,60 sacas por ha para região norte que representa aproximadamente 11,1% da área acompanhada pelo projeto; 100,13 sacas por ha para a região centro que representa cerca de 20,9% áreas acompanhada pelo SIGA-MS e 96,25 sacas por ha para região sul, que representa aproximadamente 68,0% da área de cultivo acompanhada pelo projeto. Gerando a produção total de milho em Mato Grosso do Sul a quantidade de 14.220.532,37 toneladas na 2ª safra 2022/2023 (SEMADESC, 2023).

Os municípios que registraram valores acima da produtividade média estadual foram: Alcinópolis, com 156,2 sacas por ha; Chapadão do Sul e Costa Rica, com 143,9 sacas por ha; Figueirão, com 135 sacas por ha e Santa Rita do Pardo, com 132,2 sacas por ha. Além desses, os municípios de Paranaíba, São Gabriel do Oeste, Coxim, Ribas do Rio Pardo, Rio Negro, Paraíso das Águas, Cassilândia, Aral Moreira, Aparecida do Taboado, Douradina, Sonora, Rio Brilhante, Maracaju, Corumbá, Dourados, Laguna Carapã, Bandeirantes, Camapuã e Anastácio também tiveram a produtividade acima da média estadual (SEMADESC, 2023).

Conforme os levantamentos do projeto para a safra de inverno 2022/2023, a área de milho atingiu 2,355 milhões de hectares, a produção 14,22 milhões de toneladas e produtividade 100,64 sc/ha. Entre a safra 2012/2013 e a safra 2022/2023 a produção aumentou em 81,3%, a área semeada aumentou 49,8% e a produtividade aumentou em 21,0% (SEMADESC, 2024)

2.2 Agricultura de precisão

A agricultura de Precisão (AP) se origina na gestão da variabilidade espacial das lavouras. No entanto, entende-se que tem várias formas de abordagem e pode ser praticada em diferentes níveis de complexidade. De acordo com Vettorazzi & Ferraz (2000), a agricultura de precisão (AP) utiliza informações geoespaciais para realizar intervenções específicas no cultivo, garantindo a precisão necessária.

A agricultura de precisão (AP) tem como objetivo melhorar procedimentos, elevar a produção agrícola e diminuir despesas, que pode ser desde o momento da semeadura até a fase da colheita, em que as máquinas produzem mapas de produtividade em tempo real (SIMAS et al., 2023). Dessa forma, é possível caracterizar esse sistema como uma forma de administrar a agricultura levando em consideração a diversidade de áreas e períodos, visando a lucratividade, a preservação ambiental, entre outros objetivos (COMPARIN e CORTEZ, 2023).

No Brasil, a prática predominante é a gestão da adubação das lavouras com base na amostragem georreferenciada de solo e aplicação de corretivos e fertilizantes de forma localizada e em doses variáveis, o que tem tido grande apelo comercial porque, num primeiro momento, oferece chances de economia de insumos (MOLIN et al., 2015). A melhoria da agricultura na região central do Brasil foi impulsionada pela adoção da agricultura de precisão, que se mostrou fundamental para lidar com solos ácidos e de baixa fertilidade (SCALON et al. 2022).

Mesmo com as vantagens das tecnologias de Agricultura de Precisão, sua aplicação ainda é limitada em certas áreas do Brasil, devido principalmente à falta de adoção da amostragem de solo em grade, da adubação a taxa variada a lanço (PEREIRA et al., 2022) e ao uso correto dos mapas de produtividade.

Assim, a agricultura de precisão permite identificar áreas específicas no campo e criar mapas detalhados que orientam onde e como aplicar insumos agrícolas, considerando as variações nos fatores de produção (ANTUNIASSI, 2000).

2.3 Mapas de produtividade

A geração de mapas de produtividade é essencial para a agricultura, auxiliando na tomada de decisões, na gestão precisa dos recursos e maximizando a produção, sendo a melhor forma para se visualizar a variabilidade da lavoura e distinguir áreas homogêneas (MOLIN,

2002). De acordo com Balastreire (1998), a etapa mais simples de ser realizada no ciclo da AP é a elaboração de mapas de produtividade.

Para a obtenção dos mapas de produtividade, utiliza-se de equipamentos que geram pontos por hectare, sendo que cada ponto representa uma porção da lavoura, sendo posteriormente transformados em camada raster em softwares que tratam de dados espaciais (MOLIN, 2000). Ainda citam os autores que é desafiador a criação e interpretação precisa dos dados que mostram as variações nas plantações, mas os mapas de colheita, são fundamentais para demonstrar aos agricultores e demais envolvidos a produtividade (MOLIN, 2000).

Os mapas de produtividade são uma ferramenta importante da AP, pois permitem avaliar os dados de produtividade das lavouras em diferentes pontos da área georreferenciada por meio do monitor de colheita, que possuem como equipamentos os sensores de massa, velocidade, umidade, posição da plataforma, rotação do elevador de grãos dentre outros, que juntos nos permite medir a quantidade de grãos em cada área durante a colheita (INACIO e CORTEZ, 2023). Os autores ainda verificaram que ao efetuar a correlação da granulometria com a produtividade, os coeficientes encontrados indicam que as correlações são muito fracas e positiva para areia *versus* produtividade e silte *versus* produtividade.

Os mapas de produtividade não são apenas ferramentas de análise espacial, mas também podem ser usados para análises temporais. A comparação de mapas de diferentes safras permite que os agricultores identifiquem tendências na produtividade ao longo do tempo, possibilitando ajustes em práticas de manejo (CAMPOS et al., 2021).

Estudo em que se analisou a acurácia dos mapas de produtividade gerados em áreas onde algumas colhedoras não possuíam monitor de colheita, em comparação com aquelas equipadas utilizando os métodos de interpolação o "inverso da distância ao quadrado" e "krigagem", verificaram que a eliminação de passadas impacta negativamente na precisão dos mapas em ambos os métodos, e que a quantidade mínima de monitores necessária varia de acordo com a precisão desejada, sendo recomendado distribuir as colhedoras de forma a garantir amostras uniformes na área colhida (BAZZI et al., 2008).

2.4 Zonas de manejo

São várias as abordagens para delimitar áreas de manejo (DOERGE, 1999), sendo que esses métodos envolvem a criação de categorias de manejo usando informações isoladas de produtividade, análise de solo, topografia e sensores remotos ou proximais. Conforme Doerge (2000), certos atributos locais permanecem estáveis ao longo do tempo (morfológicos,

condutividade elétrica, propriedades físicas do solo) e, se correlacionados com a produtividade das culturas, podem ser considerados confiáveis para delimitar as áreas de manejo.

Segundo Schwambach et al. (2021) uma das maneiras mais simples para fazer as zonas de manejo é pela espacialização da argila. Os autores ainda afirmam que em talhões em que se observa variações acentuadas no teor de argila (variação espacial) e que se verifica o efeito dessa variação textural nos mapas de produtividade ao longo das safras (variação temporal), o uso da argila como delimitador de zonas de manejo se torna eficiente.

Outra forma de delimitar zonas de manejo é a partir da utilização de sensores remotos ou proximais, tal método tem se demonstrado eficiente na coleta de dados de áreas extensas e com alta resolução. Esses permitem a medição de atributos como a temperatura do solo, umidade e variações de nutrientes, ajudando a delimitar zonas de manejo com maior precisão. Além disso, tecnologias como drones e satélites têm sido amplamente utilizadas para monitorar a variabilidade espacial dentro de campos agrícolas (ZHANG et al., 2018).

As tecnologias de sensoriamento remoto e algoritmos de aprendizado de máquina estão se tornando componentes-chave na agricultura de precisão, permitindo a coleta e análise de dados detalhados sobre variabilidade do solo, clima e condições das culturas. O sensoriamento hiperespectral é amplamente utilizado, especialmente para a identificação de padrões espaciais em diferentes tipos de solos e safras, enquanto drones equipados com sensores oferecem uma solução de baixo custo e alta eficiência para monitoramento em tempo real (WANG et al., 2024). A combinação dessas tecnologias pode melhorar significativamente a definição e ajuste das zonas de manejo.

Segundo Rodrigues Junior et al. (2011) todos os métodos usados para definir zonas de manejo são relativamente simples de aplicar, mas é crucial reunir o máximo de dados possível. Ainda citam que os tratamentos podem ser aplicados através de sistemas mecanizados comumente utilizados na agricultura convencional.

Devido aos projetos em agricultura de precisão gerarem uma quantidade significativa de informações sobre solo e plantas, é essencial empregar métodos que possam integrar esses dados para delimitar adequadamente as áreas de manejo diferenciado (zonas de manejo) e analisar sua resposta às diferentes condições de manejo e clima (SANTOS et al., 2003). Modelos que usam a lógica "Fuzzy" têm sido utilizados para sistemas de controle e gestão de zonas de manejo. Os autores também destacam que a produtividade é o resultado final de todos os fatores que a influenciam em um ambiente, e em sua pesquisa a subdivisão do terreno em áreas de gestão (zonas de manejo) variou entre as duas colheitas de milho estudadas, com 2 e 3 áreas para o primeiro e segundo anos.

A técnica da geoestatística possibilita a identificação de regiões com baixa produtividade e a análise dos elementos que a afetam, podendo facilitar a compreensão e a distribuição espacial o que possibilita a aplicação de diferentes taxas de tratamento em áreas específicas do campo, sendo essas áreas específicas conhecidas como zonas de manejo (BARBOSA et al., 2019). Para a geração de zonas de manejo, os autores citam que se utilizaram os mapas obtidos pela *fuzzy k-means* e nos índices de desempenho de imprecisão (FPI) e entropia de classificação normalizada (NCE) e que com base nos menores valores de FPI e MPE, e a significância do índice *kappa*, recomenda-se a utilização de duas classes na geração de zonas de manejo sem a necessidade de correção de anisotropia geométrica, para o referido estudo.

3 MATERIAL E MÉTODOS

3.1 Descrição do local

A área do estudo utilizada foi um talhão com pivô central de aproximadamente 73,77 ha de uma Fazenda Comercial (Figura 1) no município de Dourados - MS, com coordenadas em graus decimais: longitude de -54,3102897 e latitude de -22,0204642 (WGS84). A área tem sido conduzida no sistema plantio direto e sucessão anual das culturas soja e milho. A altitude média do terreno, conforme dados do Copernicus Global DSM 30 m, é de 289,04 m com valores mínimos de 284,76 m e máximos de 292,94 m. A declividade média de 0,77% da área variando de 0,02 a 7,01%.

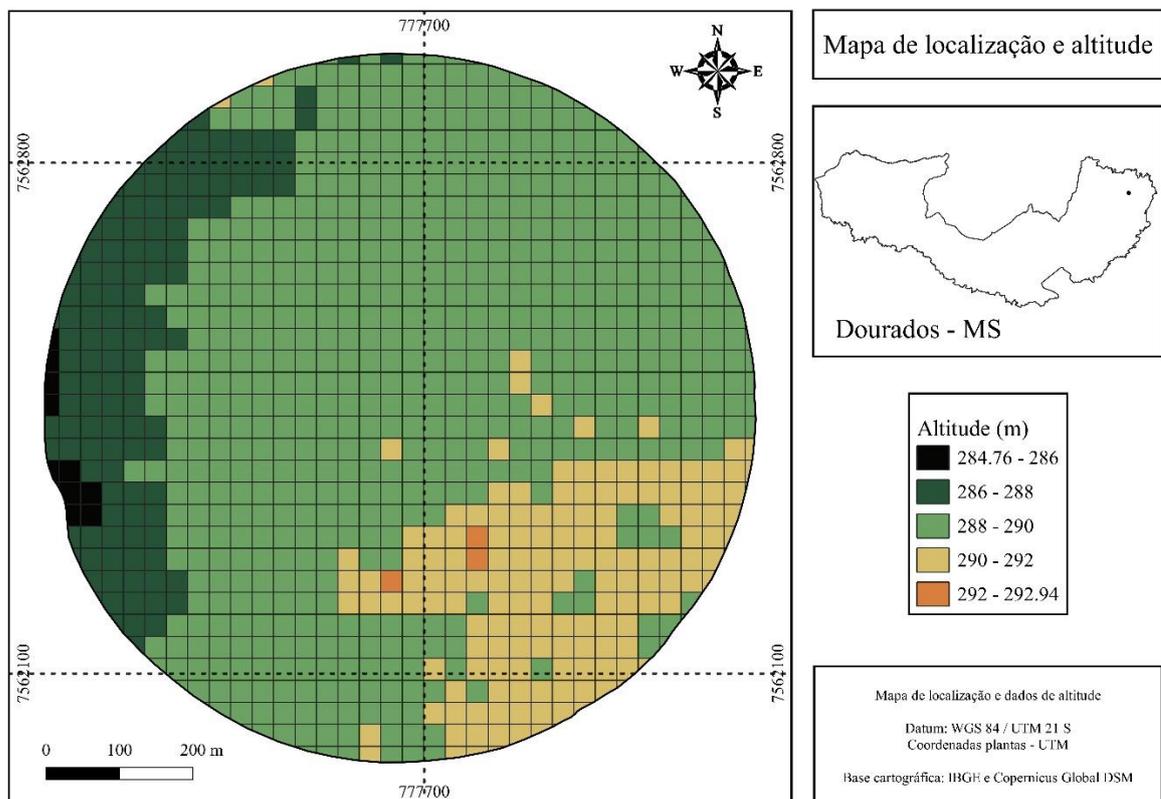


FIGURA 1. Mapa de localização e altimetria do terreno

A área do estudo possui solo com teor médio de areia de 652 g kg⁻¹, argila de 268 g kg⁻¹ e silte de 80 g kg⁻¹, classificado como solo tipo 2 que segundo o MAPA IN 2/2008 (MAPA, 2008), caracteriza solo de textura média. Segundo o mapa de solos do Estado de Mato Grosso do Sul (IBGE, 2001) essa área está dentro de região de solos classificados como Argissolo Vermelho.

Os dados de temperatura média e precipitação do período de acompanhamento do talhão foram obtidos por meio de estação meteorológica de Dourados – UFGD (GUIA CLIMA, 2023) (Figura 2).

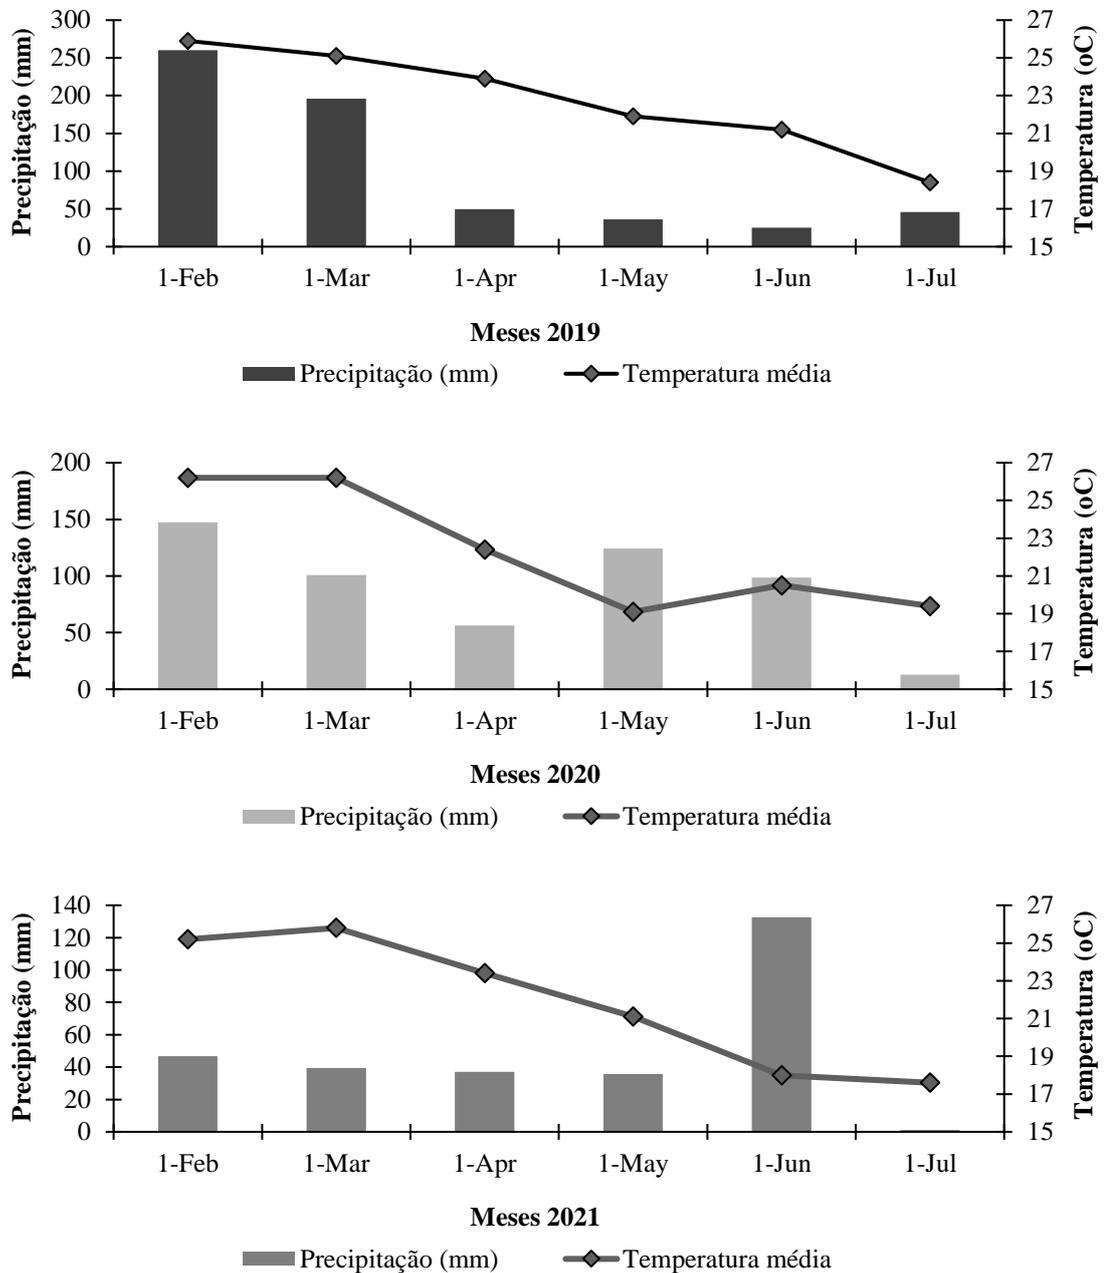


FIGURA 2. Gráfico de precipitação acumulada e temperatura média para meses de 2019/2020/2021. Fonte: Guia Clima (2024).

Durante o ciclo da cultura do milho nos anos de 2019, 2020 e 2021, a irrigação com pivô foi operado de maneira estratégica para otimizar a produtividade da lavoura. O pivô foi acionado todas as noites entre as chuvas, aplicando uma lâmina de 9 mm. A irrigação ocorreu das 21h30 às 05h30, durante a qual o pivô percorreu meio pivô por noite. Esse manejo foi

adaptado às condições climáticas, uma vez que o sistema não era acionado em dias de chuva. Além disso, para evitar a sobreposição de água, o pivô só era religado um dia após a precipitação, garantindo que a umidade do solo fosse mantida em níveis ideais para o desenvolvimento do milho.

3.2 Insumos e colhedora

Foi selecionado um talhão de estudo (pivô) em que se obteve os dados da semeadura do milho nas safras de 2019, 2020 e 2021. Os insumos utilizados estão descritos no Quadro 1. O uso de herbicida, inseticida e fungicida foram utilizados conforme recomendação agrônômica e níveis de infestação.

QUADRO 1 - Descrição dos insumos agrícolas utilizados na semeadura da soja e milho para as safras 2019, 2020 e 2021.

	2019	2020	2021
		<i>Milho (Zea mays)</i>	
Híbrido	DEFENDER VIP 3	DEFENDER VIP 3	KWS 9606 VIP3
Semeadura	03/02/2019 à 05/02/2019	25/02/2020 à 27/02/2020	30/01/2021 à 01/02/2021
Densidade	58.000 sementes ha ⁻¹	58.000 sementes ha ⁻¹	60.000 sementes ha ⁻¹
Adubo (N-P-K)	17-45-00 + 45-00-00 +00-00-60	17-45-00 + 45-00-00 +00-00-60	17-45-00 + 45-00-00 +00-00-60
Dose (kg ha ⁻¹)	100 + 100 + 100	100 + 100 + 100	100 + 100 + 100
Colheita - data	01/07/2019 à 03/07/2019	25/07/2020 à 27/07/2020	28/06/2021 à 30/06/2021

A colhedora utilizada foi da marca John Deere, modelo S660 com plataforma de colheita de 7,65 m.

3.3 Dados de granulometria

As amostras para caracterização do solo foram retiradas em 2021, utilizando zonas que o produtor definiu em sua área. A área do pivô foi dividida em quatro zonas sendo que cada zona teve o caminhamento na área com 10 subamostras que geraram uma amostra composta

para cada zona (Figura 3). Os dados de argila e areia foram espacializados na área de modo categorizado utilizando o valor do atributo em cada zona, no QGIS (QGIS, 2022).

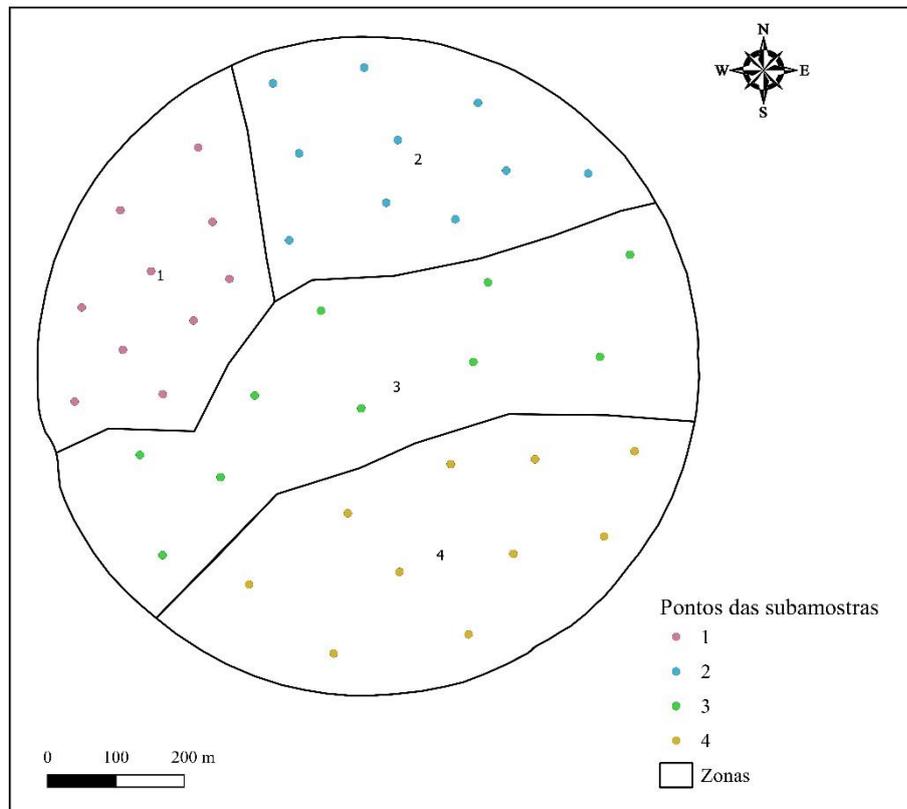


FIGURA 3. Pontos utilizados para coleta das subamostra de solo em cada zona.

3.4 Dados de produtividade

Os dados de produtividade foram coletados no período de 3 anos por colhedora equipada com sensor de massa, monitor e receptor GNSS com capacidade de coleta de dados a cada 1 segundo. Os dados foram extraídos utilizando o software do fabricante e posteriormente tratados pelo software de plataforma livre o QGIS (QGIS, 2022).

Além dos dados de produtividade (Mg ha^{-1}) em massa seca, foi obtido do monitor dos dados de umidade (%), largura da plataforma (m) e velocidade (km h^{-1}).

O processo de filtragem foi realizado conforme Schwambach (2020). Resumidamente foi filtrado:

- dados contendo erro de posicionamento e/ou coordenadas geográficas nulas,
- dados com produtividade nulos,
- dados de produtividade acima de 15 Mg ha^{-1} ,

- dados com umidade da massa <0,99%,
- dados coletados com largura mínima de trabalho da plataforma menor que 75% (<5,73 m), e
- dados de velocidade <0,99 km h⁻¹.

Após essa pré-filtragem, os dados produtividade foram submetidos ao cálculo do desvio padrão, o valor de produtividade média ± 3 desvios padrões foi definido como limite, em que os valores acima desse limite, para mais ou para menos, foram eliminados.

3.5 Geração de zonas de manejo

3.5.1 Normalização da média

Após a filtragem, os dados de produtividade de cada pixel (P) de 10 x 10 m, foi normalizado (N) pela média ($N = [P / \text{média}] * 100$) de cada ano (MOLIN et al., 2015). Posteriormente os pixels foram classificados como: menor que 80% como potencial baixo, o que estiver entre 80 a 120% como médio e o que estiver acima de 120% como alto.

Posteriormente, realizou-se a interpolação dos dados normalizados de cada ano, por meio do inverso da distância, comando “Interpolação IDW”, em pixel de 10 m.

O cálculo das zonas de manejo nas três classes estabelecidas foi realizado utilizando a “calculadora raster” do QGIS, em que se fez média da normalização dos três anos (2019, 2020 e 2021). As zonas de manejo estabelecidas como padrão foram: zona 1, baixa produtividade, menor que 80%; zona 2, média produtividade, entre 80 e 120%; e zona 3, alta produtividade, maior que 120%.

Além das zonas estabelecidas nos critérios acima, foi possível também estabelecer três classes mais restritivas, seguindo a mesma premissa, baixa, média e alta produtividade, que foram:

- zona 1: <85%, <90% e <95%;
- zona 2 de: 85 a 115%; 90 a 110% e 95 a 105%, e
- zona 3: >115%, >110% e >105% (BERNARDI et al., 2018)

Assim, foram testados quatro propostas de classificações da normalização da média para geração de zonas de manejo.

3.5.2 Pelo software MZA

Para gerar as zonas de manejo por meio do software *Management Zone Analyst* – MZA (FRIDGEN et al., 2004) do Departamento de Agricultura dos Estados Unidos deve-se fazer o *download* em sua página da internet (MZA, 2022). Para fazer as zonas de manejo no MZA precisa-se que todos os dados estejam em uma única camada de pontos e devem ser exportados em TXT para inserção no software. Antes de exportar os dados em TXT, realizou-se a interpolação dos dados por meio do inverso da distância, comando “Interpolação IDW”, em pixel de 10 m. Posteriormente os dados das safras de 2019, 2020 e 2021 foram agrupados em única matriz de polígonos de 10 x10 m, e por fim, criados os centroides de cada polígono, para assim ter os dados dos três anos no mesmo local. Essa camada centroide foi exportada em TXT para inserção no MZA.

O processamento no MZA (FRIDGEN et al., 2004) envolveu o uso de estatística multivariada, e no método de similaridade foi usado a distância Euclidiana, em “*Fuzzy c-means*” foi utilizado máximo de iterações = 300, critério de convergência = 0,0001, coeficiente Fuzzy de 1,30 e o número de zonas a ser criado foi definido de 2 a 3. Foram obtidos os índices índice de desempenho de imprecisão (FPI) e entropia de classificação normalizada (NCE), sendo que ao minimizar o valor de NCE e FPI, o número ideal de zonas pode ser obtido (RODRIGUES e CORÁ, 2015).

Após o processamento no MZA, como resultado final, é gerado um arquivo TXT para ser inserido novamente no QGIS. Assim, para cada ponto o MZA definiu a qual zona o mesmo deve pertencer. Os polígonos das zonas foram feitos de forma manual no QGIS a partir da geração de uma nova camada seguindo a classificação proposta pelo MZA.

3.5.3 Pelo complemento *Smart-Map*

O complemento *Smart-Map* (PEREIRA et al., 2022) para o QGIS, é distribuído gratuitamente para instalação. Os dados de produtividade foram interpolados por meio da geoestatística, validação cruzada e o interpolador Krigagem, sendo posteriormente analisados na aba “*Management Zones*”.

Na aba “*Management Zones*” o complemento também se utiliza de estatística multivariada para análise dos dados. Foi utilizado no processo 100 interações, coeficiente Fuzzy de 1,25, para duas e três zonas.

3.6 Análise dos dados

Os dados produtividade foram submetidos à análise descritiva para obtenção de medidas de tendência central e dispersão de toda a área, antes e após a filtragem dos dados.

Após o processo de limpeza dos dados de produtividade do milho de cada ano foi realizada a interpolação dos dados utilizando a geoestatística, validação cruzada e o interpolador Krigagem com o complemento do QGIS o *Smart-Map*, versão 2.0 (PEREIRA et al., 2022). O complemento *Smart-Map* (PEREIRA et al., 2022) fez uma reamostragem dos dados de produtividade para 5000 pontos. A partir desse arquivo reamostrado, realizou-se a análise geoestatística e a Krigagem. Os pressupostos da hipótese intrínseca da geoestatística foram considerados para a modelagem e ajuste do semivariograma experimental de acordo com Vieira (2002), obtendo os seguintes parâmetros: C_0 (efeito pepita), $C_0 + C_1$ (patamar) e a (alcance, m). Os modelos foram postos a prova pelo método de validação cruzada. A razão entre o efeito pepita e patamar $C_0 / (C_0 + C_1) \times 100$ é o índice de dependência espacial (IDE) expresso em percentagem, sendo classificado como forte se o valor da razão for $< 25\%$, moderada quando estiver entre 25 e 75 % e fraca se a razão for $> 75\%$ (CAMBARDELLA et al., 1994). Após a validação dos modelos foi realizada a Krigagem utilizando o alcance e o número de vizinhos na estimativa igual a 16. A produtividade média das três safras foi obtida pela álgebra de mapas na “Calculadora raster” do QGIS. O cálculo de área de cada classe da legenda foi feita utilizando o comando “Reclassificação por tabela” e o “*r.report*” no QGIS.

Os dados de produtividade foram analisados para cada zona delimitada, em função de cada método, obtendo medidas de tendência central e dispersão.

Para comparar a relação entre os mapas de zonas de manejo foi utilizado o coeficiente do índice *Kappa* (JENSEN, 1996). No QGIS os mapas das zonas de manejo foram “Reclassificados por tabela” em função das suas zonas e aplicado o comando “*r.kappa*” para comparar os mapas que possuíam a mesma quantidade de zonas.

4 RESULTADOS E DISCUSSÃO

4.1 Granulometria

Dados de granulometria (Figura 4) indicam solo com valores elevados de areia na zona 3 (666 g kg⁻¹) e maior argila nas zonas 2 e 4, de 274 e 280 g kg⁻¹, respectivamente. Conforme o guia para agrupamento de classe de textura (EMBRAPA, 1988) verifica-se que toda a área é de classe média, mesmo tendo as variações de valores para cada zona. Embora tenham ocorrido variações de areia e argila na área, essas mudanças de valores nas zonas foram de apenas 3,45% e 9,71%, respectivamente.

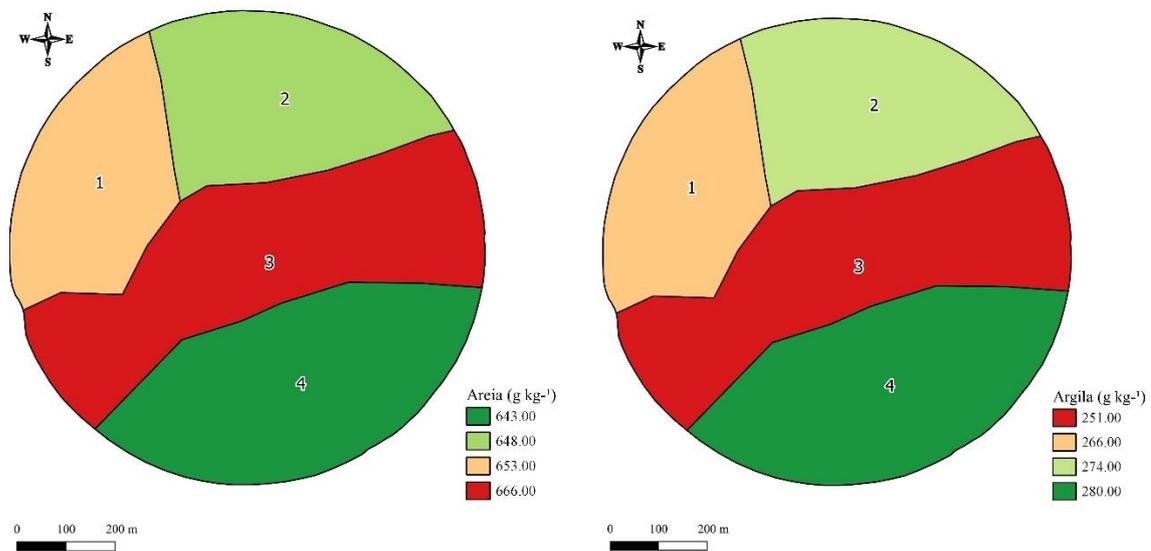


FIGURA 4. Espacialização da areia e argila (g kg⁻¹) na área de estudo.

Os valores de silte na área foi de 81, 78, 83 e 77 g kg⁻¹ nas zonas definidas pelo produtor 1, 2, 3 e 4, respectivamente. Os dados de silte mostram uma variação muito pequena de 7,22%, ou seja, variando de 77 a 83 g kg⁻¹.

4.2 Análise dos dados de produtividade

Os dados descritivos da produtividade do milho nos anos de 2019, 2020 e 2021 indicam que a média ficou com valores próximos antes e após a filtragem (Quadro 2). O desvio padrão e o valores de máximo foram mais elevados antes da filtragem. Dados de valores máximos indicam valores de produtividades extremamente altos caracterizados como erros de leitura pelo sensor de massa da colhedora.

QUADRO 2 - Estatística dos dados de produtividade (Mg ha⁻¹) antes e após a filtragem.

Parâmetros	2019		2020		2021	
	Antes	Depois	Antes	Depois	Antes	Depois
Média	8,24	8,21	9,51	9,45	6,43	6,38
DP	2,78	0,95	2,87	1,20	2,69	1,51
Mínimo	0,32	4,96	0,32	5,22	0,32	1,56
Máximo	105,4	11,38	112,08	13,56	106,27	11,14
CV (%)	33,71	11,63	30,21	12,70	41,82	23,70
Pontos	63281	59653	81084	76633	62450	59698
Dispersão						
Assimetria	22,17	-0,24	15,38	-0,33	14,69	-0,10
Kurtose	686,73	0,42	432,11	0,96	423,17	0,33
Normalidade						
RJ	0,54	0,99	0,67	0,99	0,72	0,99
P	<0,010	<0,010	<0,010	<0,01	<0,010	<0,010

DP: desvio padrão; CV (%): coeficiente de variação. RJ: Teste de normalidade de Ryan Joiner. P: probabilidade. *: distribuição normal pelo teste de Ryan-Joiner ($P > 0,05$). **: distribuição não normal pelo teste de Ryan-Joiner ($P < 0,05$).

O processo de filtragem promoveu a redução do coeficiente de variação (CV) (Quadro 2). Para a interpretação do CV, foi observado o proposto por Warrick e Nielsen (1980) que o classificou como CV baixo se menor que 12%, médio entre 12 e 60% e alto acima de 60%. Assim, dados de produtividade antes da filtragem ficaram com CV médio e dados de produtividade após a filtragem ficaram com CV médio (2020 e 2021) e baixo em 2019.

Com o processo de filtragem dos dados, ocorreu redução do número de pontos original do conjunto, reduzindo em 5,73% em 2019, 5,49% em 2020 e de 4,41% em 2021 (Quadro 2). No processo de filtragem inicial dos dados de produtividade de 2019, obteve-se média foi de 8,17 Mg ha⁻¹ e o desvio padrão de 1,07 Mg ha⁻¹. Com esse valor calculou-se três vezes o desvio padrão e obteve-se o valor de corte de 3,21 Mg ha⁻¹, ficando o intervalo de 4,96 a 11,38 Mg ha⁻¹. Assim, todos os valores de produtividade, fora desse limite, foram retirados. Esse corte retirou 760 pontos do conjunto em 2019. O mesmo foi feito para 2020 e 2021.

Em 2020, após filtragem inicial, obteve-se média foi de 9,39 Mg ha⁻¹ e o desvio padrão de 1,39 Mg ha⁻¹ (Quadro 2). Tendo o valor de três vezes o desvio padrão de 4,17 Mg ha⁻¹, e intervalo de corte de 5,22 a 13,56 Mg ha⁻¹, todos os valores de produtividade fora desse limite foram retirados. Esse corte retirou 1357 pontos do conjunto. Em 2021, alguns pontos fora do perímetro da área foram excluídos do conjunto de dados. A média após a filtragem inicial foi de 6,36 Mg ha⁻¹ e o desvio padrão de 1,60 Mg ha⁻¹. Tendo calculado três vezes o desvio padrão que resultou no valor de 4,8 Mg ha⁻¹, e intervalo de corte de 1,56 a 11,16 Mg ha⁻¹, todos os valores de produtividade fora desse limite foram retirados, reduzindo o conjunto em mais 579 pontos.

A análise da assimetria e curtose podem ser feitas baseado no valor de cada coeficiente sendo o de assimetria deve ser próximo de zero e o coeficiente de curtose próximo ao valor de 3, o que indicam uma distribuição com tendência a normalidade dos dados (NJEBAN, 2018). Mas para ter a certeza da normalidade somente com o teste de normalidade. Assim, a dispersão dos dados de produtividade com relação a assimetria (A_s) indica dados com assimetria positiva a direita (Quadro 2 e Figura 5). Neste caso, foi devido aos altos valores de produtividade registrado pelo sensor, que são um erro. Os dados de assimetria foram classificados como simétrico ou assimetria fraca quando, $A_s \leq 0,15$, assimetria moderada, quando $0,15 < A_s < 1,0$ e assimetria forte positiva, quando, $A_s \geq +1,0$ (FERREIRA, 2005). Portanto, somente os dados filtrados ficaram próximo a zero.

Os dados de produtividade apresentaram dispersão com relação ao coeficiente de curtose (k), sendo como platicúrtica ou achatada quando $k > 2,63$ (FERREIRA, 2005) para dados sem filtragem (Quadro 2), e foram leptocúrtica ou alongada quando apresentaram $k < 2,63$, após a filtragem (Quadro 2). Dados filtrados de produtividade ficaram abaixo de 3, indicando tendência de normalidade (NJEBAN, 2018).

No teste de normalidade de Ryan Joiner (RJ), os dados de produtividade ficaram próximos a 1,0 quando foram filtrados. Mas os dados do valor de probabilidade (P) foi $P < 0,01$ indicando que os dados não seguem uma distribuição normal. Para a normalidade dos dados o valor de P deveria ser $> 0,050$, em que aceita H_0 , e assim os dados seriam de distribuição normal. Mesmo com a filtragem e a retirada dos dados maiores que três vezes o desvio padrão não foi possível eliminar os valores que afetam a normalidade.

A pressuposição de normalidade dos dados para a geoestatística não é uma necessidade, como afirma Cressie (1991), enfatiza que o atributo em estudo não deve apresentar distribuição alongada, que poderia comprometer as análises. Apesar do teste de RJ não ter dado normalidade (simetria), os demais coeficientes (assimetria, curtose) tendem e indicam uma proximidade da normalidade, como pode ser visto pelos dados pós filtragem (Figura 5), próximos a curva normal.

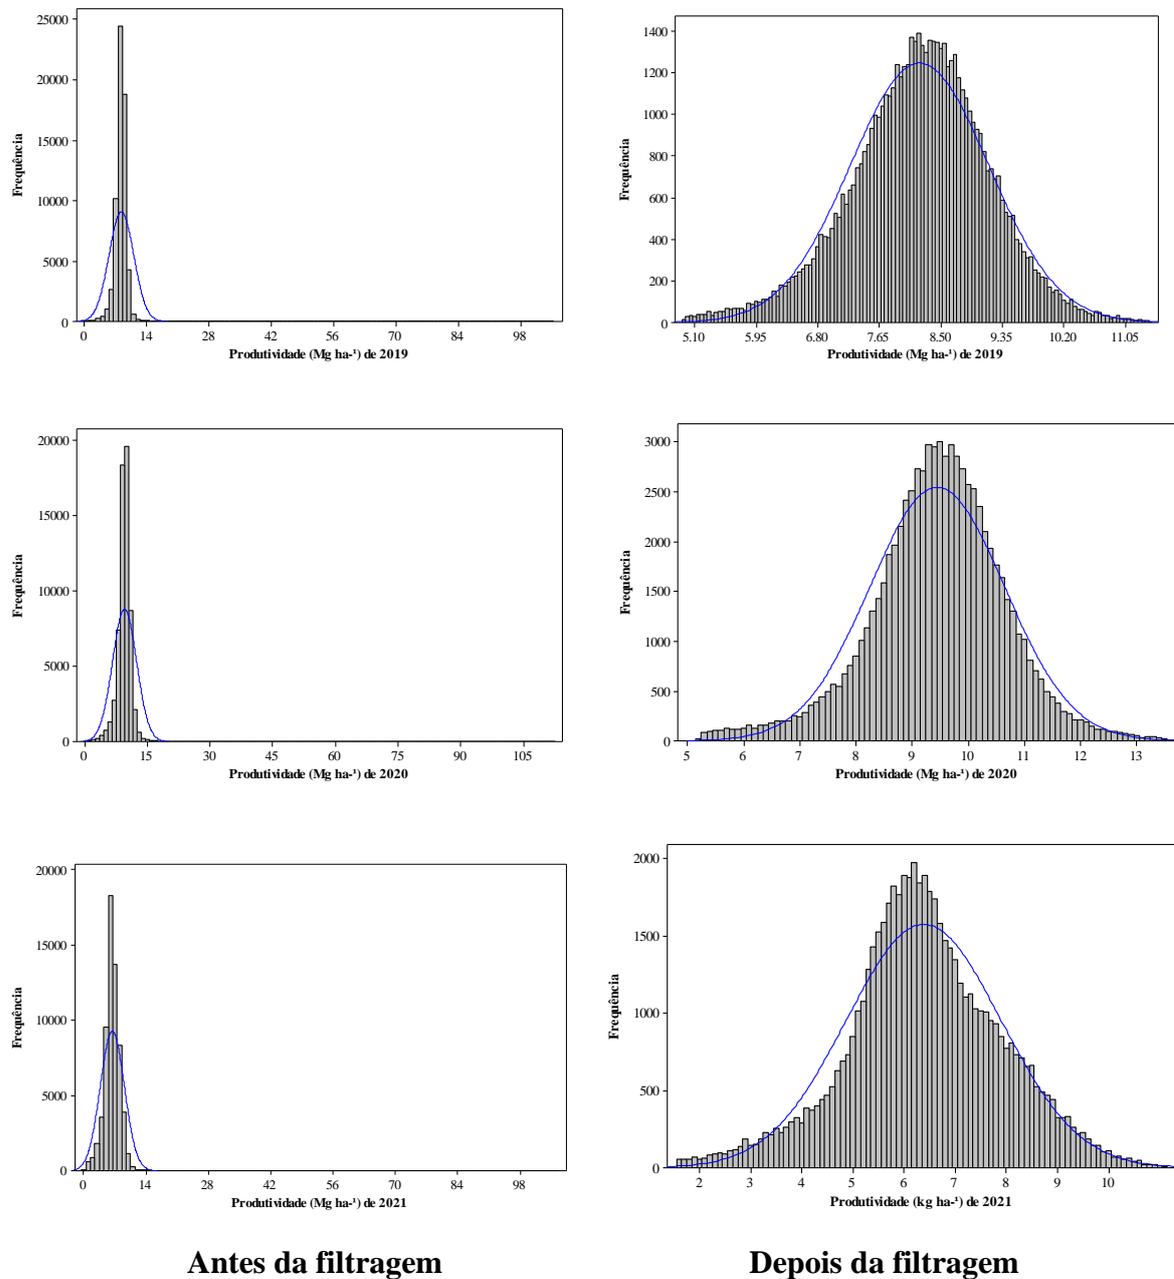


FIGURA 5. Histograma com curva normal da produtividade em 2019, 2020 e 2021 antes e após o processo de filtragem.

Os dados de produtividade filtrados foram submetidos a análise geoestatística, validação cruzada e feita a interpolação por Krigagem (Quadro 3). O modelo do semivariograma ajustado foi o esférico para 2019 e 2021 e exponencial para 2020. Normalmente, o modelo esférico é o mais encontrado, mas em situações que ocorre perda de semelhança com o aumento da distância, ocorre o modelo exponencial (GREGO et al., 2014). O valor do R^2 foi alto para todos os modelos, indicando bom ajuste.

O índice de dependência espacial (IDE), calculados a partir do efeito pepita (Co) e do patamar ($Co+C$), foi classificado como moderada (Quadro 3) por estar entre 25 e 75 %, para 2019 e 2020 (CAMBARDELLA et al., 1994). O IDE em 2021 teve o menor valor, tendo dependência espacial forte ($<25\%$). O ano de 2021 foi o que teve a menor produtividade e maior variação do coeficiente de variação, mas de certo modo melhorou a dependência espacial entre os pontos.

QUADRO 3. Dados ajustados do semivariograma para a produtividade do milho.

	Modelo	Parâmetros Semivariograma				Validação cruzada			
		Co	$Co+C$	IDE	A	R^2	CA	R^2	Equação
2019	Esférico	0,228	0,433	52,65	521,63	0,99	1,051	0,47	$y=1,051x-0,426$
2020	Exponencial	0,353	0,684	51,60	599,02	0,94	1,136	0,47	$y=1,136x-1,292$
2021	Esférico	0,073	1,413	5,17	396,31	0,99	1,005	0,90	$Y=1,005x-0,030$

Co : efeito pepita; $Co+C$: patamar; A: alcance (m); IDE: índice de dependência espacial; CA: Coeficiente angular.

O alcance representa o ponto de estabilidade em torno da variância dos dados. Esse crescimento do alcance até a estabilização, define o comportamento da variável estudada, e nos anos de 2019 e 2020 verifica-se maiores valores do alcance (Quadro 3), e menor no ano de 2021.

Mesmo verificado o bom ajuste do alcance, R^2 e do IDE do semivariograma, este foi posto à prova pela validação cruzada para verificação dos erros de estimativas. Assim, verificou-se que o coeficiente angular (CA), que indica o posicionamento entre a reta original e estimada, representando quanto o modelo do semivariograma é capaz de estimar o fenômeno. Dados dos três anos (2019, 2020 e 2021) ficaram próximos a 1,0 (Quadro 3). Com R^2 da validação menor em 2019 e 2020 e maior em 2021. Para estudo da geoestatística, o R^2 foi menor em 2019 e 2020 e maior em 2021. A equação (Quadro 3) da validação cruzada indica os parâmetros ajustados no processo.

A interpretação da validação cruzada pode ser feita como reta aberta ($<0,4$), reta medianamente aberta (0,4 a 0,8) e reta fechada ($>0,8$) (COELHO et al., 2012). Quanto mais próxima de 1,0, temos a reta fechada ou sobreposta que garante um excelente modelo de semivariograma. Assim, todos os modelos de semivariograma (Quadro 3) podem ser utilizados na Krigagem por terem retas fechadas.

Os dados de produtividade do milho foram submetidos a Krigagem e os resultados indicaram variação dos valores ao longo dos anos, sendo menor no ano de 2021 (Figura 6), com maior parte da área abaixo de 7 Mg ha⁻¹. O ano de 2019 apresentou a maior parte da área na classe de 8-9 Mg ha⁻¹, enquanto em 2020 foi na classe > 9 Mg ha⁻¹. Detalhe que na safra 2019

e 2020 tiveram o mesmo híbrido e ficaram com produtividades próximas, já na safra 2021 utilizou um híbrido diferente dos outros anos.

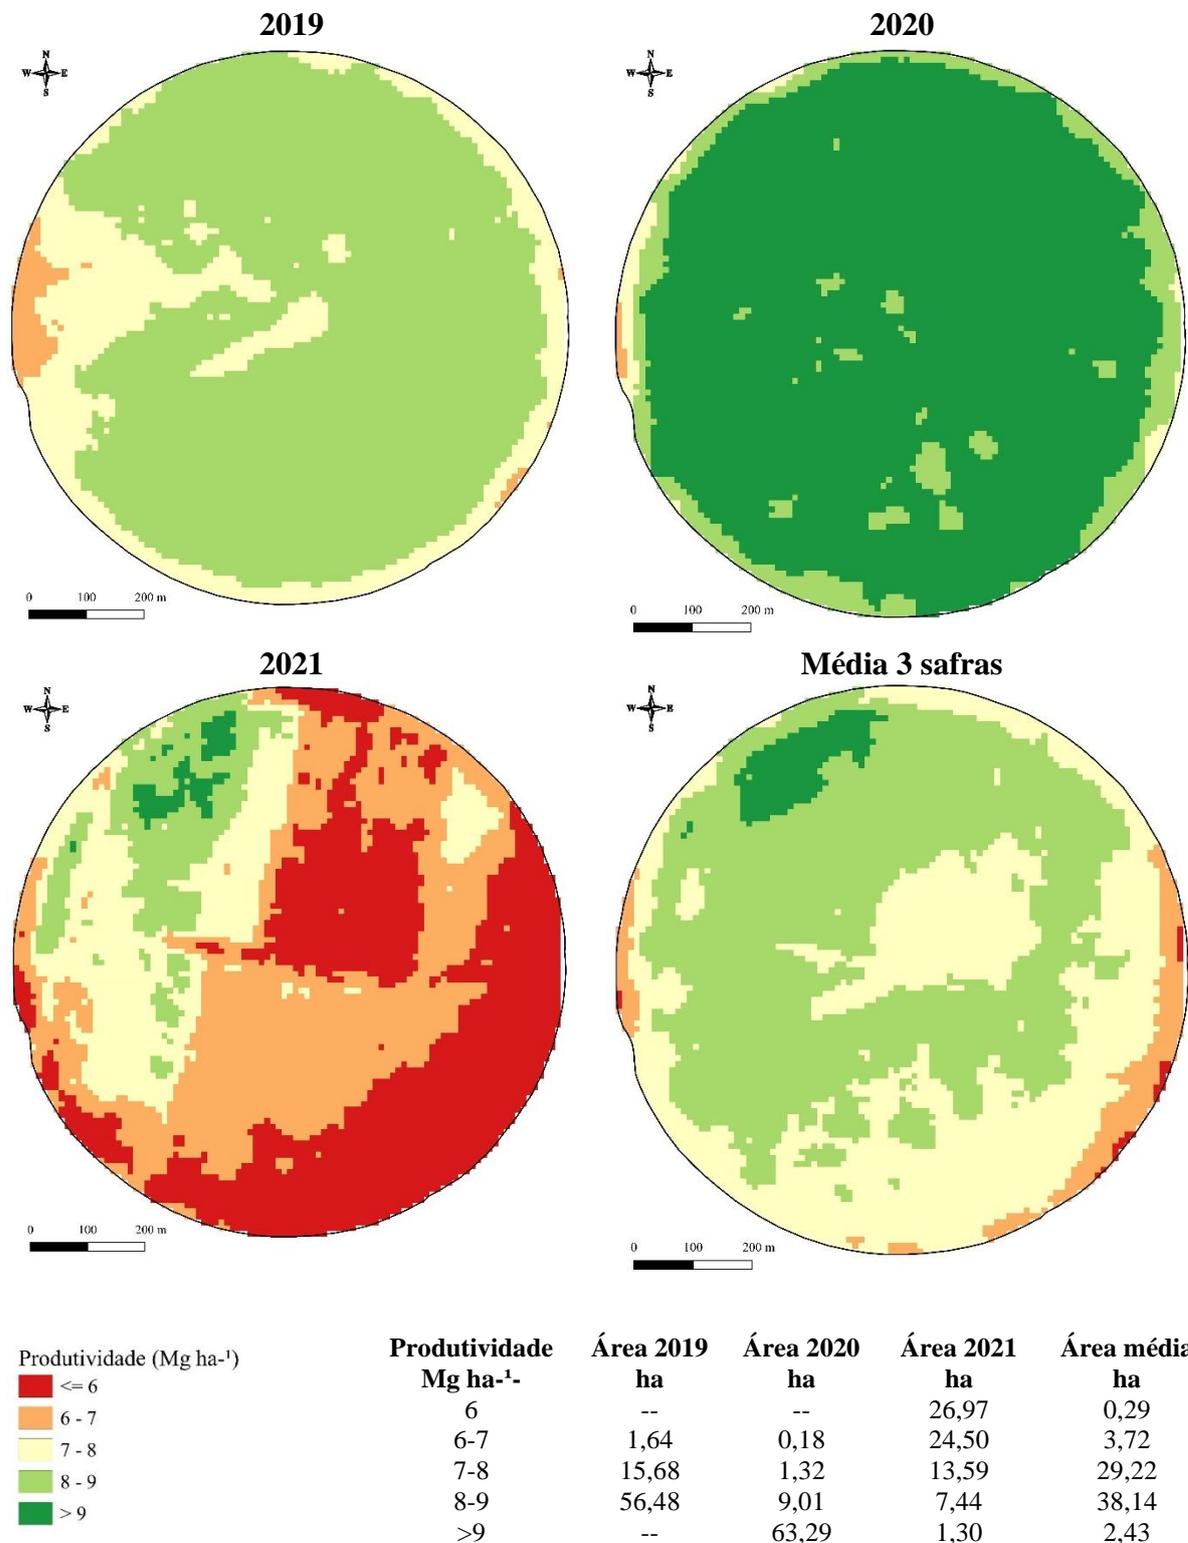


FIGURA 6. Espacialização da produtividade e área de cada classe em 2019, 2020, 2021 e a média das três safras.

Em 2021 (Figura 6), devido a variação de produtividade, ficou mais evidente a diferença entre as áreas, que foi também identificada na espacialização média das três safras. A menor produtividade foi na região sudeste da área, caracterizada por ter a maior altitude (Figura 1) e maior concentração de areia (Figura 4).

Pela espacialização média das três safras a região mais ao norte com maior produtividade é uma área mais baixa, menor altitude (Figura 1).

4.3 Zonas de manejo

4.3.1 Zonas de manejo pela normalização da média

Os dados de produtividade normalizados pela média indicam que a normalização menos restritiva (MOLIN et al., 2015) não se verificou diferença na área (Figura 7). Mas ao se fazer a normalização dos dados de produtividade de modo mais restritivo (BERNARDI et al., 2018), foi possível perceber a definição de áreas distintas, com maior e menor produtividade da soja. Assim, os mapas de produtividade e a análise de sua variabilidade espacial e temporal permitem a definição de zonas de manejo (BERNARDI, et al., 2018).

A utilização de normalização dos dados de produtividade pela média com classificações intermediárias (85% a 115% e 90% a 110%), não demonstraram grandes variações da produtividade (Figura 7).

Portanto, pela observação das espacializações na Figura 7, verifica-se que para a geração de zonas de manejo, neste caso, é com a classe mais restritiva (95% a 105%), conforme utilizado por Bernardi et al. (2018).

Foi analisado os dados médios de produtividade dentro de cada ano e em cada zona (Quadro 4). Em todas as chaves de classificações a zona 3 foi a que apresentou a menor produtividade, grande parte associada a produtividade do ano de 2021 que foi a menor entre os três anos.

Os dados do coeficiente de variação foram baixos conforme proposto por Warrick e Nielsen (1980), que o classificou como CV baixo se menor que 12%, médio entre 12 e 60% e alto acima de 60%.

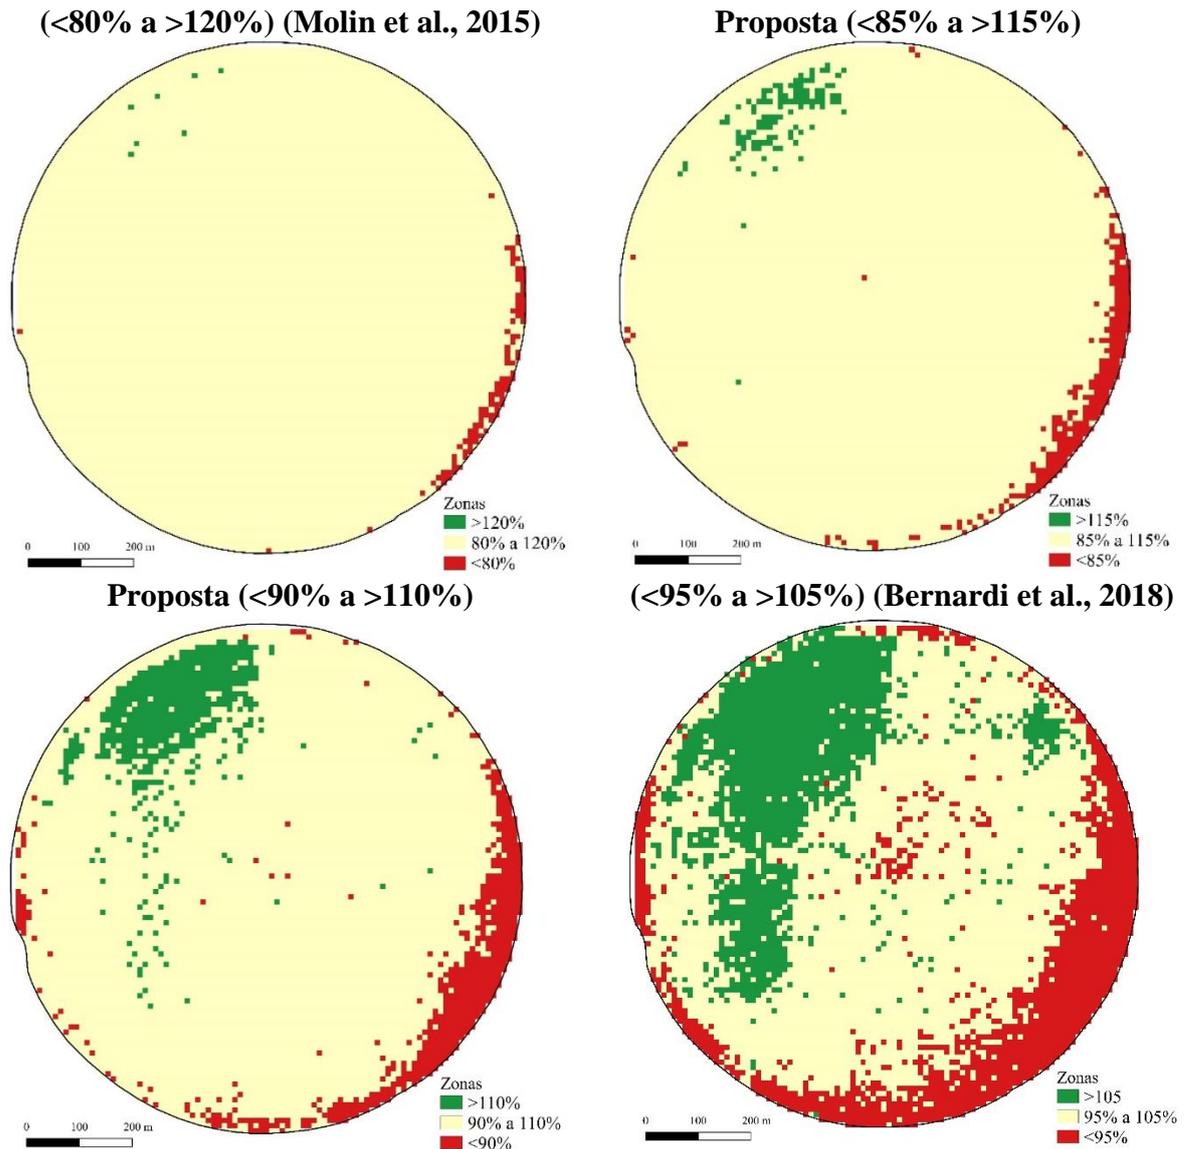


FIGURA 7. Espacialização da produtividade normalizada.

Os dados médios de produtividade dentro de cada zona e a proposta de classificação (Figura 8) indicam que ocorre diferença significativa entre as zonas, ao observar as barras de desvio padrão. Essa diferença ocorreu em todas as propostas de classificação, mostrando que todas a normalização dos dados de produtividade pela média e as classificações, podem ser utilizadas. No entanto, para este trabalho a mais adequada, sugere-se apenas a mais restritiva (95% a 105%).

QUADRO 4 - Dados de produtividade (Mg ha⁻¹) em cada zona gerada pelo MZA.

(<80% a >120%) (Molin et al., 2015)									
Parâmetros	Zona 1			Zona 2			Zona 3		
	2019	2020	2021	2019	2020	2021	2019	2020	2021
Média	10,25	11,94	8,53	8,24	9,51	6,31	6,03	6,73	4,09
DP	0,35	0,52	0,69	0,74	0,85	0,67	0,42	0,65	0,86
CV (%)	3,41	4,36	8,09	8,98	8,94	6,97	6,97	9,66	6,97
(<85% a >115%)									
Parâmetros	Zona 1			Zona 2			Zona 3		
	2019	2020	2021	2019	2020	2021	2019	2020	2021
Média	9,88	11,49	8,31	8,24	9,49	6,32	6,39	7,16	4,42
DP	0,40	0,57	0,75	0,61	0,70	0,52	0,49	0,74	0,90
CV (%)	4,05	4,96	9,03	7,40	7,38	6,97	7,67	10,34	6,97
(<90% a >110%)									
Parâmetros	Zona 1			Zona 2			Zona 3		
	2019	2020	2021	2019	2020	2021	2019	2020	2021
Média	9,53	11,06	8,08	8,23	9,47	6,34	6,76	7,64	4,74
DP	0,44	0,60	0,81	0,44	0,51	0,36	0,54	0,79	0,93
CV (%)	4,62	5,42	10,02	5,35	5,39	6,97	7,99	10,34	6,97
(<95% a >105%) (Bernardi et al., 2018)									
Parâmetros	Zona 1			Zona 2			Zona 3		
	2019	2020	2021	2019	2020	2021	2019	2020	2021
Média	9,20	10,67	7,84	8,22	9,46	6,37	7,12	8,10	5,01
DP	0,49	0,65	0,88	0,23	0,27	0,18	0,59	0,82	0,95
CV (%)	5,33	6,09	11,22	2,80	2,85	6,97	8,29	10,12	6,97

DP: desvio padrão; CV (%): coeficiente de variação.

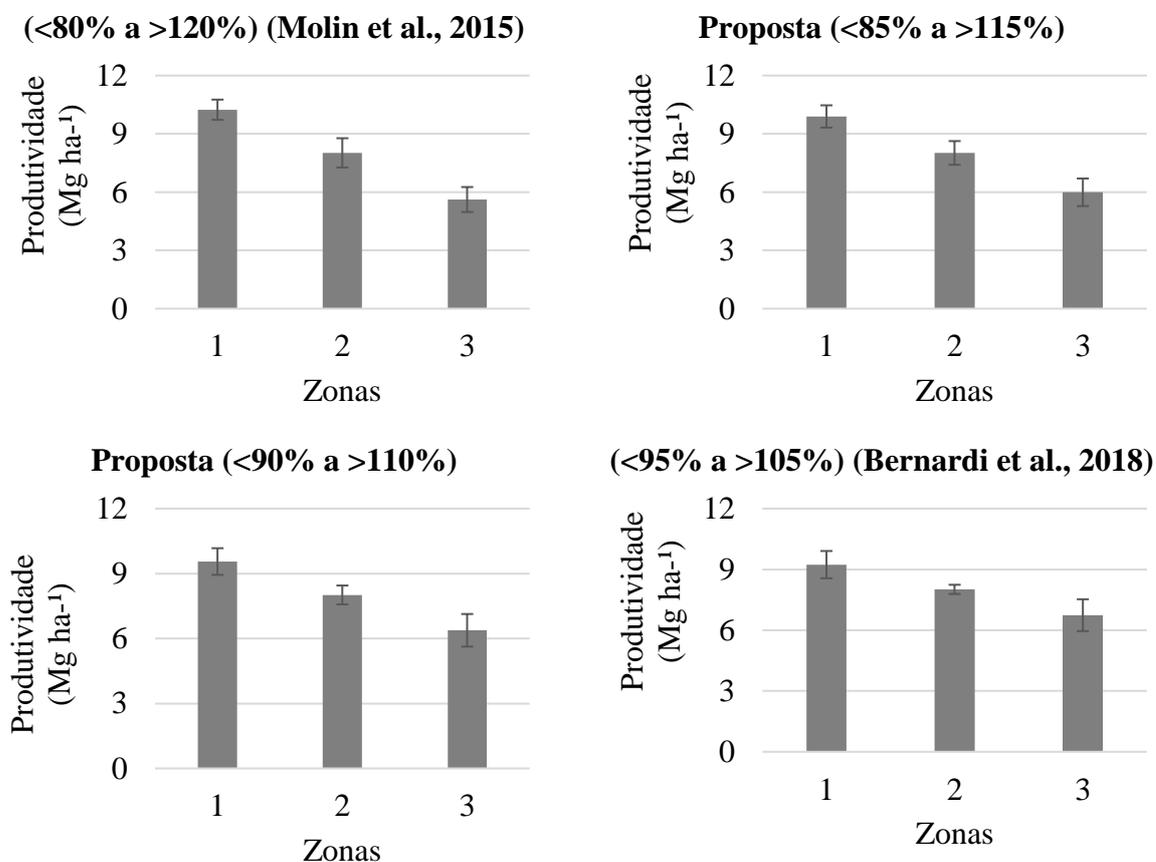


FIGURA 8. Dados médios de produtividade dentro de cada zonas de manejo classificadas pela normalização da média com barras de desvio padrão da média.

4.3.2 Zonas de manejo com o software MZA

O Índice de desempenho de imprecisão (FPI) e entropia de classificação normalizada (NCE) calculados pelo MZA (FRIDGEN et al., 2004) foi de 0,0535 e de 0,0195 para duas zonas, respectivamente e de 0,0518 e 0,0253 para três zonas, respectivamente. O FPI é uma medida do grau de imprecisão e os valores são restritos entre 0 e 1 (ODEH et al., 1992). A NCE é mais usada para decidir quantos clusters são mais apropriados (BEZDEK, 1981). O menor valor de NCE foi para duas zonas, enquanto que o menor de FPI foi para três zonas.

Com os valores de FPI e NCE fez-se a espacialização das zonas geradas pelo software MZA (FRIDGEN et al., 2004) em duas e três zonas (Figura 9). Pode-se verificar a distinção de regiões bem distribuídas na área, seja para duas ou três zonas.

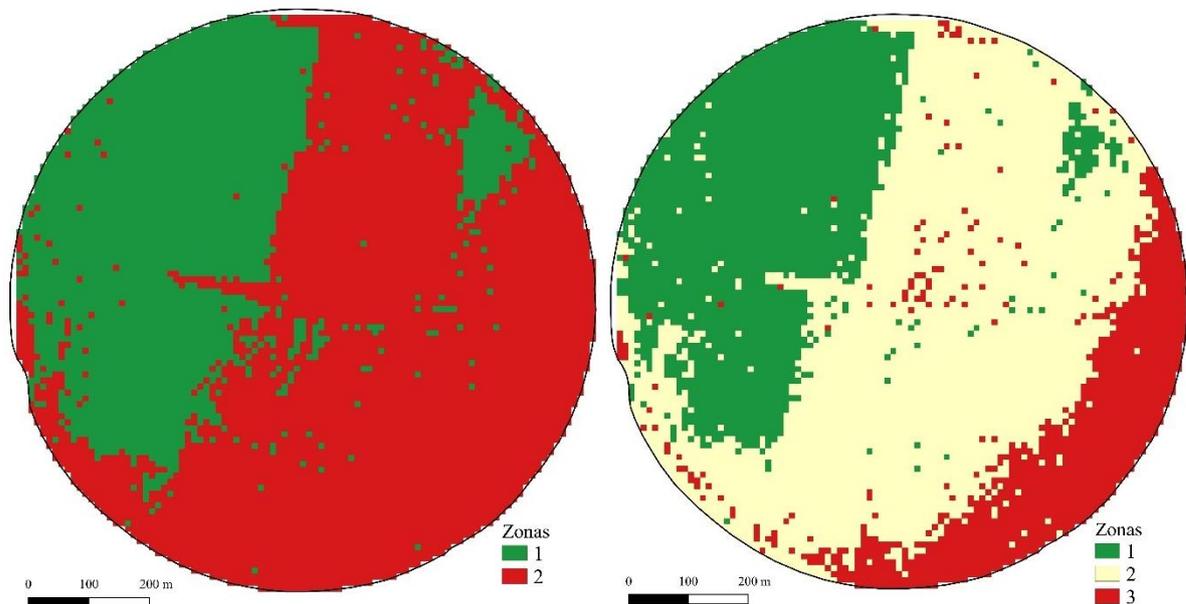


FIGURA 9. Zonas de manejo classificadas em duas e três classes pelo MZA.

Para entender o que cada zona gerada pelo MZA (FRIDGEN et al., 2004) representa, foi analisada a produtividade dentro de cada zona nos três anos (Quadro 5). Para duas zonas pode-se verificar que a zona 1 é a de maior produtividade (Quadro 5 e Figura 10), que corresponde à área de altitude mais baixa (Figura 1) e com valor mais elevado de argila (Figura 4). Apesar da zona 1 ter maior produtividade, essa não apresentou diferença da zona 2, pela observação das barras de desvio padrão (Figura 10).

QUADRO 5 - Dados de produtividade (Mg ha⁻¹) em cada zona gerada pelo MZA.

Classificação em duas zonas						
Parâmetros	Zona 1			Zona 2		
	2019	2020	2021	2019	2020	2021
Média	8,11	9,49	7,57	8,26	9,39	5,71
DP	0,48	0,56	0,61	0,45	0,55	0,78
CV (%)	5,92	5,92	8,06	5,92	5,86	13,66

Classificação em três zonas									
Parâmetros	Zona 1			Zona 2			Zona 3		
	2019	2020	2021	2019	2020	2021	2019	2020	2021
Média	8,10	9,50	7,74	8,31	9,47	6,17	8,06	9,17	4,58
DP	0,50	0,56	0,54	0,40	0,51	0,38	0,52	0,60	0,65
CV (%)	6,17	5,89	6,98	4,81	5,39	6,16	6,45	6,54	14,19

DP: desvio padrão; CV (%): coeficiente de variação.

Com três zonas (Quadro 5), a zona 1 foi a de maior produtividade, que corresponde a mesma região no mapa de duas zonas (Figura 9). A zona 3 tem a menor produtividade e a zona 2 ficou sendo uma zona intermediária. A zona 3 caracteriza-se por ser a região com maior altitude (Figura 1) e menores valores de areia (Figura 4). As diferenças entre as três zonas ocorreram apenas entre as zonas 1 e 3, como pode ser observado pelas barras de desvio padrão (Figura 10).

A maioria dos valores do coeficiente de variação para a produtividade dentro das zonas foi baixo (Quadro 5), a exceção da produtividade de 2021 na zona 2 e 3, que foi médio, como proposto por Warrick e Nielsen (1980).

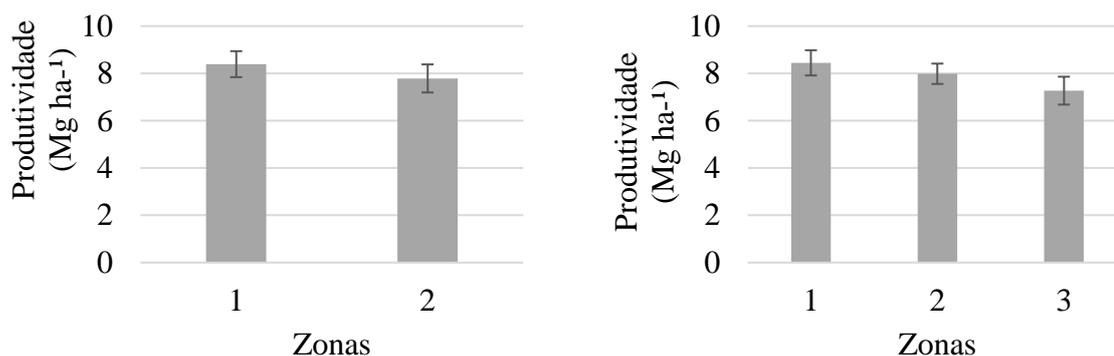


FIGURA 10. Dados médios de produtividade dentro de cada zonas de manejo classificadas pelo MZA.

4.3.3 Zonas de manejo com o complemento *Smart-Map*

O Índice de desempenho de imprecisão (FPI) e entropia de classificação normalizada (NCE) calculados pelo *Smart-Map* (PEREIRA et al., 2022) foi de 0,095 e de 0,118 para duas zonas, respectivamente e de 0,137 e 0,149 para três zonas, respectivamente.

As zonas geradas (Figura 11) pelo *Smart-Map* (PEREIRA et al., 2022) foram semelhantes as geradas pelo software MZA (FRIDGEN et al., 2004). Fato este devido utilizarem da mesma lógica de programação e parâmetros (*Fuzzy c-means*). Fica evidente que existe uma área de maior produtividade ao noroeste e de menor produtividade a sudeste da área.

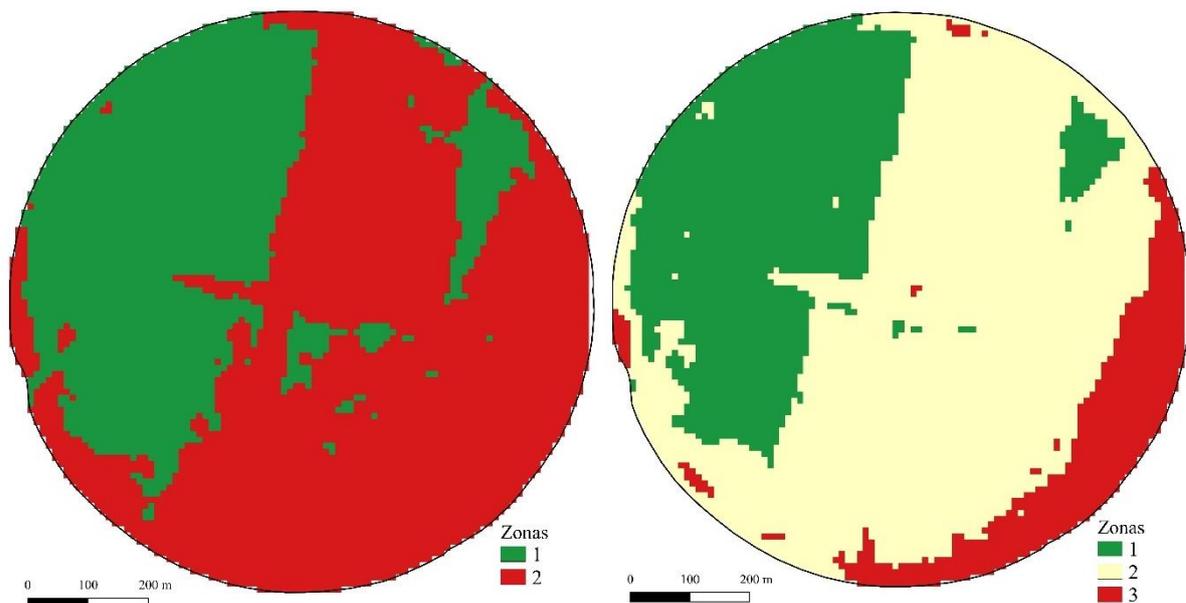


FIGURA 11. Zonas de manejo classificadas em duas e três classes pelo *Smart-Map*.

Os dados médios de produtividade de cada em cada zona assemelham-se aos gerados anteriormente pelo MZA (FRIDGEN et al., 2004). Em que a zona 1 é a de maior produtividade e a zona 2 ou 3, dependendo da classificação, à de menor produtividade. A diferença significativa, ao analisar as barras de desvio padrão (Figura 12), só ocorre quando se faz a geração de três zonas de manejo. Tendo diferença entre a zona 1 e a zona 3. Portanto, recomenda-se a geração de três zonas de manejo para a área.

O coeficiente de variação (CV) dos dados de produtividade dentro das zonas foi baixo (Quadro 6), a exceção da produtividade de 2021 na zona 2 e 3, que foi médio (WARRICK E NIELSEN, 1980).

QUADRO 6 - Dados de produtividade (Mg ha⁻¹) em cada zona gerada pelo Smart-Map.

Classificação em duas zonas						
Parâmetros	Zona 1			Zona 2		
	2019	2020	2021	2019	2020	2021
Média	8,12	9,49	7,68	8,25	9,37	5,59
DP	0,45	0,48	0,70	0,41	0,53	0,92
CV (%)	5,54	5,54	9,11	5,54	5,66	16,46

Classificação em três zonas									
Parâmetros	Zona 1			Zona 2			Zona 3		
	2019	2020	2021	2019	2020	2021	2019	2020	2021
Média	8,11	9,51	7,89	8,31	9,45	6,05	7,94	9,01	3,99
DP	0,46	0,47	0,60	0,36	0,48	0,48	0,50	0,61	0,76
CV (%)	5,67	4,94	7,60	4,33	5,08	7,93	6,30	6,77	19,05

DP: desvio padrão; CV (%): coeficiente de variação.

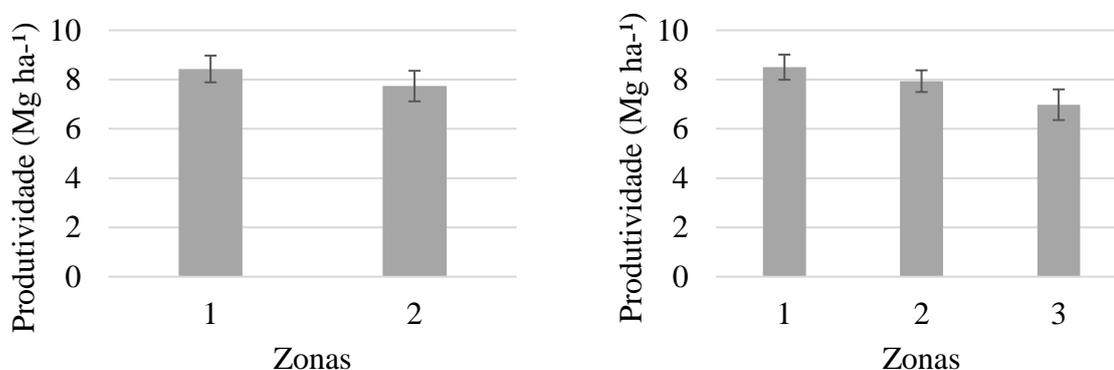


FIGURA 12. Dados médios de produtividade dentro de cada zonas de manejo classificadas pelo Smart-Map.

4.3.4 Concordância dos mapas de zonas de manejo

O coeficiente de concordância *Kappa* foi utilizado para verificar a precisão entre mapas, medindo a concordância de pares entre o pixel (KITCHEN et al., 2005). Pode-se avaliar a precisão dos mapas gerados neste trabalho (Quadro 7) com duas e três zonas de acordo com o proposto por Landis e Koch (1977) em que valores negativos indicam nenhuma concordância, de 0 a 0,2 concordância fraca, de 0,2 a 0,4 concordância razoável, de 0,4 a 0,5 concordância moderada, de 0,5 a 0,8 concordância boa e de 0,8 a 1 indicam concordância quase perfeita.

A análise de concordância das zonas, seja com duas ou três, é quase perfeita, pois os valores de *Kappa* estão acima de 0,8 (LANDIS e KOCH, 1977) para a relação entre o MZA (FRIDGEN et al., 2004) e o *Smart-Map* (PEREIRA et al., 2022). Chedid et al. (2024) trabalhando com índices de vegetação também concluíram que com o *Kappa* de 90% (0,9) é possível afirmar que os mapas testados são eficientes no monitoramento.

QUADRO 7 – Índice Kappa para análise da concordância dos mapas de zonas de manejo.

Para mapas com 2 zonas		
	Kappa	Acertos (%)
Smart-Map versus MZA	0,88	94,32
Para mapas com 3 zonas		
Smart-Map versus MZA	0,84	90,86
Smart versus N (<80% a >120%)	0,04	58,82
Smart versus N (<85% a >115%)	0,15	62,21
Smart versus N (<90% a >110%)	0,39	70,88
Smart versus N (<95% a >115%)	0,63	78,86
MZA versus N (<80% a >120%)	0,04	55,02
MZA versus N (<85% a >115%)	0,14	58,55
MZA versus N (<90% a >110%)	0,37	67,85
MZA versus N (<95% a >115%)	0,69	81,95

N: dados de produtividade normalizados. Smart-Map (PEREIRA et al., 2022). MZA (FRIDGEN et al., 2004)

O índice *Kappa* para a relação *Smart-Map* (PEREIRA et al., 2022) e MZA (FRIDGEN et al., 2004) com dados da produtividade normalizados, teve concordância boa (0,5 a 0,8) conforme Landis e Koch (1977), somente quando esteve na faixa de 95% a 115%, conforme Bernardi et al. (2018).

Portanto, os mapas de zonas de manejo gerados com o *Smart-Map* (PEREIRA et al., 2022) e MZA (FRIDGEN et al., 2004) podem ser utilizados na área, seja com duas ou três zonas. As zonas propostas com dados de produtividade normalizados na faixa de 95% a 115%, conforme Bernardi et al. (2018) também podem ser utilizados na área. Reforçando, que como citado anteriormente, as diferenças de produtividades entre as zonas só ocorreram quando se utilizou três zonas na área.

4.3.5 Zonas de manejo do produtor e recomendação atual

As zonas de manejo utilizadas pelo produtor (Figura 4) são quatro (04), e ao analisar os dados de produtividade dos três anos e a média dentro dessas zonas (Figura 13) não se observa diferença pelas barras de desvio padrão, seja na média, ou de maneira individualizada a cada ano. Desse modo, para esses dados de produtividade analisados, as zonas que estão sendo utilizadas na área, para fins de coleta de solo e outros manejos não apresentam diferença significativa entre si.

O coeficiente de variação (CV) dos dados de produtividade dentro das zonas do produtor foi baixo (Quadro 8), a exceção da produtividade de 2021 na zona 2, 3 e 4, que foi médio (WARRICK e NIELSEN, 1980).

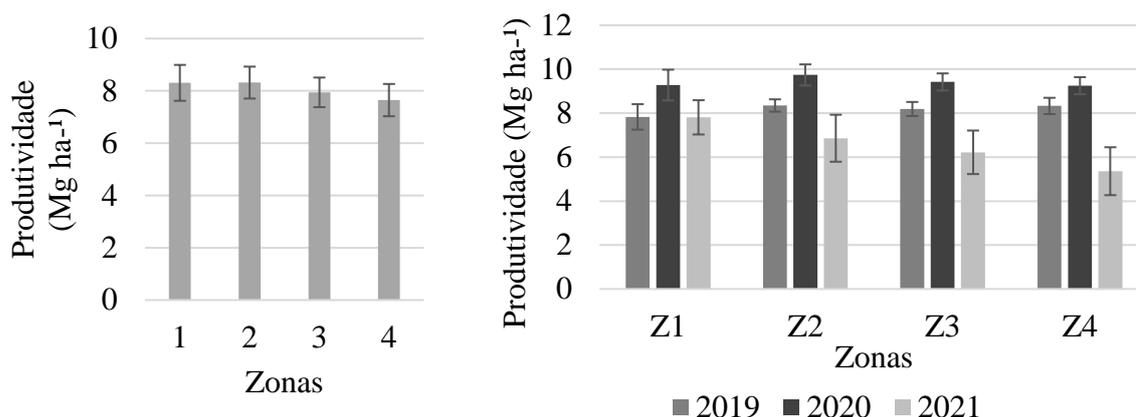


FIGURA 13. Dados médios e individuais dos valores de produtividade das três safras em cada zona de manejo do produtor.

QUADRO 8 – Coeficiente de variação baseados nas zonas de manejo do produtor.

Parâmetros	Zona 1			Zona 2		
Ano	2019	2020	2021	2019	2020	2021
CV (%)	7,41	7,54	9,99	3,35	4,93	15,60
Parâmetros	Zona 3			Zona 4		
Ano	2019	2020	2021	2019	2020	2021
CV (%)	3,91	4,14	15,92	4,44	4,22	20,34

Com base no estudo deste trabalho, é evidente que as zonas atuais (produtor) não apresentam a variação da produtividade na área, e entendendo que a planta “é o melhor sensor”, pode-se inferir que as zonas geradas com a normalização dos dados de produtividade na faixa de 95% a 105% (BERNARDI et al., 2018), as zonas geradas pelo e MZA (FRIDGEN et al., 2004) e *Smart-Map* (PEREIRA et al., 2022) são uma melhor opção para realização de manejos na área (Figura 14).

Com base nos dados de produtividade analisados anteriormente dentro de cada zona, ficou comprovado que com três zonas tem-se diferença de produtividade entre a Zona 1 e Zona 3, sendo essa a recomendação para o talhão (Figura 14). Apesar que com duas zonas não deixa de ser uma opção (Figura 14).

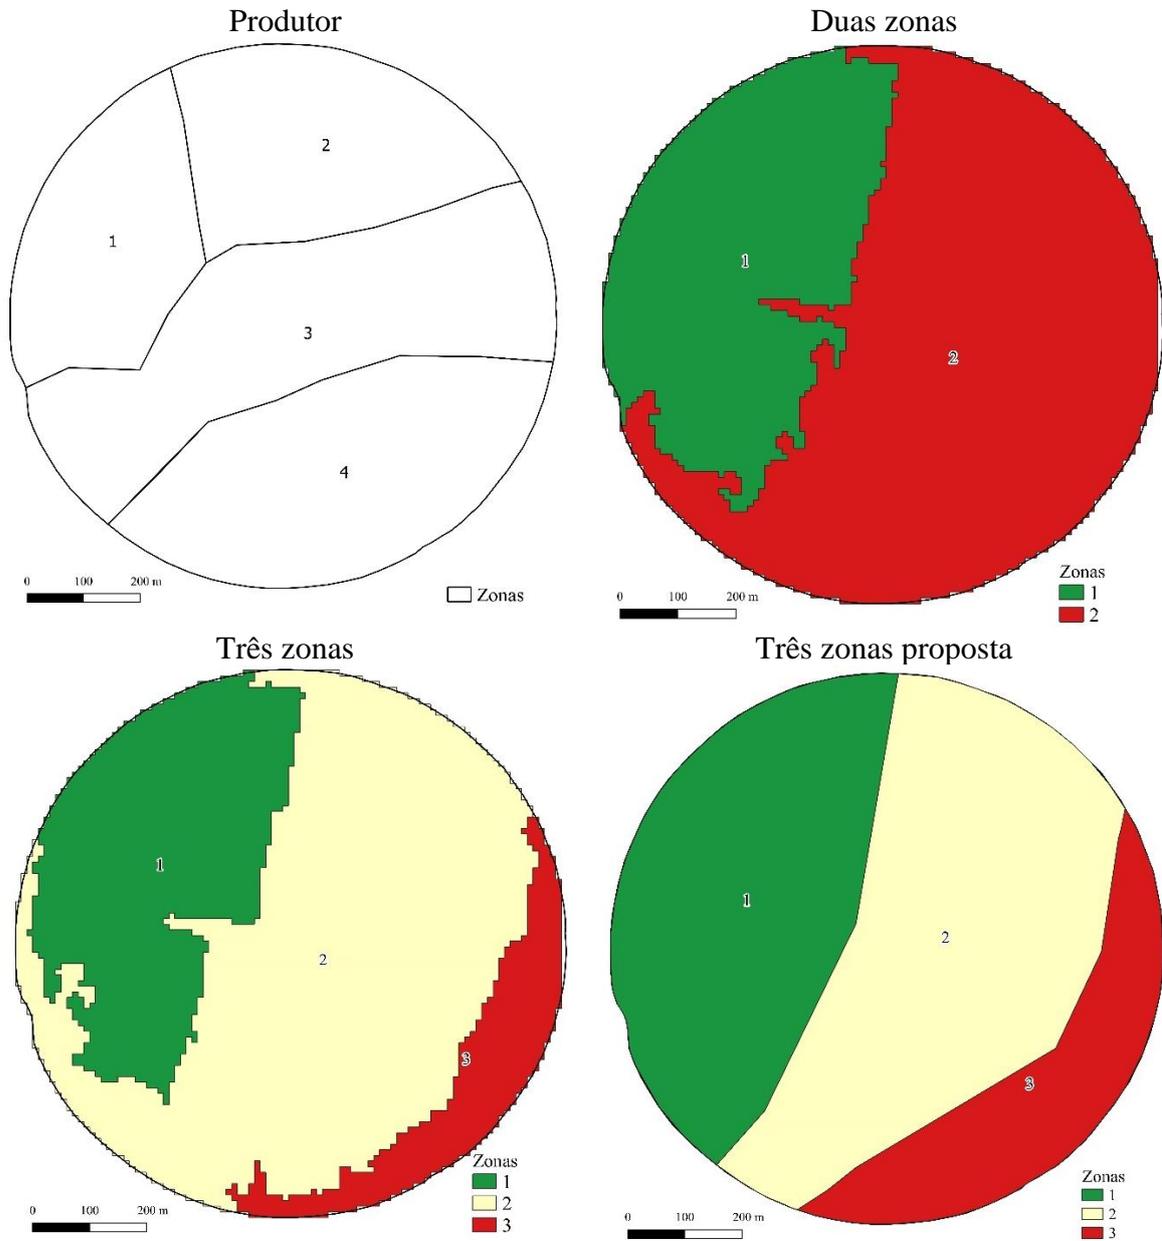


FIGURA 14. Zonas de manejo do produtor e zonas de manejo recomendada baseados nos dados de produtividade analisados neste trabalho.

5 CONCLUSÕES

Os dados de produtividade apresentaram variabilidade espacial e temporal.

O uso do método de normalização da produtividade pela média pode ser utilizado para geração de zonas de manejo, desde que seja com faixas mais restritivas, como produtividade baixa menor que 95% e produtividade alta maior que 105%.

O uso dos softwares MZA e o complemento *Smart-Map* do QGIS são uma opção de geração de zonas de manejo e apresentam resultados similares.

O uso de três zonas de manejo na área, se mostrou a melhor opção, em virtude das diferenças de produtividade entre as zonas.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ANTUNIASSI, U. R. Agricultura de precisão: aplicação localizada de herbicidas. In: CONGRESSO BRASILEIRO DA CIÊNCIA DAS PLANTAS DANINHAS, 22., 2000, Foz do Iguaçu, PR, Anais... Londrina, SBCPD, 2000. P.25-43.

BALASTREIRE, L.A. Estudo de caso, uma pesquisa brasileira em agricultura de precisão, In: SILVA, FM.; BORGES, P.H. de M. Mecanização e agricultura de precisão Lavras: UFLA/SBEA, 1998. p.203-32.

BARBOSA, D. P., BOTTEGA, E. L., VALENTE, D. S. M., SANTOS, N. T., GUIMARÃES, W. D., & FERREIRA, M. DE P. Influence geometric anisotropy in management zones delineation. *Revista Ciência Agronômica*, v.50, n.4, p.543–551, 2019.

BAZZI, C. L., SOUZA, E. G., OPAZO, M. A. U., NÓBREGA, L. H. P., & PINHEIRO NETO, R. Influência da distância entre passadas de colhedora equipada com monitor de colheita na precisão dos mapas de produtividade na cultura do milho. *Engenharia Agrícola*, v.28, n.2, p.355–363, 2008.

BERNARDI, A.C.C.; BETTIOL, G.M.; FERREIRA, R.P.; SANTOS, K.; RABELLO, L.M.; INAMASU, R.Y. Spatial variability of soil properties and yield of a grazed alfalfa pasture in Brazil. *Precision Agriculture*, v.17, p.737-752, 2016.

BEZDEK, J.C. Reconhecimento de Padrões com Algoritmos de Função Objetivo Fuzzy. Kluwer Academic Publishers, Norwell: 1981. p. 256.

CAMBARDELLA, C.A.; MOORMAN, T.B.; NOVAK, J.M.; PARKIN, T.B.; KARLEN, D.L.; TURCO, R.F. & KONOPKA, A.E. Field-scale variability of soil properties in central Iowa soils. *Soil Sci. Soc. Am. J.*, v.58; p.1501-1511, 1994.

CAMPOS, F. et al. "Impacto da Irrigação na Produtividade do Milho." *Revista Brasileira de Agricultura Irrigada*, 2020.

CHEDID, V., CORTEZ, J. W., ARCOVERDE, S. N. S. Monitoring the vegetative state of coffee using vegetation indices. *Engenharia Agrícola*, v.44, e20220212, 2024.

COELHO, D. S.; CORTEZ, J. W.; OLSZEWSKI, N.; Variabilidade espacial da resistência mecânica a penetração em Vertissolo cultivado com manga no perímetro irrigado de Mandacaru, Juazeiro, Bahia, Brasil. *Revista Brasileira de Ciências do Solo*, Viçosa, v.36 n.3, p.755-763, 2012.

COMPARIN, P.J.S.; CORTEZ, J.W. Soil sample densities combined with additional points in the variability of soil chemical attributes. *Rev. Gest. Soc. Ambient.*, Miami, v.17., n.8, p.1-17, e03218, 2023.

CONAB. Nova estimativa para a produção de grãos na safra 2023/2024 está em 297,54 milhões de toneladas. Acesso em 20 de agosto de 2024. Disponível em: <https://www.conab.gov.br/ultimas-noticias/5579-nova-estimativa-para-a-producao-de-graos-na-safra-2023-2024-esta-em-297-54-milhoes-de-toneladas> .

CRESSIE, N. Fitting variogram models by weighted least squares. *Mathematical Geology*, New York, v. 17, n.4, p. 563-586, 1985.

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

DOERGE, T.A. *Management zones concepts. Site-specific management guidelines*. Norcross: Potash & Phosphate Institute, 2000, 135 p.

EMBRAPA. Serviço Nacional de Levantamento e Conservação de Solos. Critérios para distinção de classes de solos e de fases de unidades de mapeamento: normas em uso pelo SNLSC. Rio de Janeiro, 1988. 67 p. (Embrapa-SNLCS. Documentos, 11).

FERREIRA, DF *Estatística básica* 1. ed. Lavras:UFLA, 2005.

FRIDGEN, J.J.; KITCHEN, N.R.; SUDDUTH, K.A.; DRUMMOND, S.T.; WIEBOLD, W.J.; FRAISSE, C.W. Management Zone Analyst (MZA). *Agronomy Journal*, v.96, p.100-108, 2004.

GIACOMINI, L. T.; Implantação da agricultura de precisão em cultivo de soja na Fazenda Giacomini localizada em Xanxerê-SC – Universidade Tecnológica Federal do Paraná, Pato Branco, 2021. Disponível

em: <https://repositorio.utfpr.edu.br/jspui/bitstream/1/27218/1/agriculturaprecisaosojaxanxere.pdf>

GREGO, C. R.; OLIVERIA, R.P.; VIEIRA, S.R. Geoestatística aplicada a Agricultura de Precisão. In: BERNARDI, A.C.C.; NAIME, J.M.; RESENDE, A.V.; BASSOI, L.H.; INAMASU, R.Y. (Ed.). Agricultura de precisão: resultados de um novo olhar. Brasília, DF: Embrapa, 2014

IBGE - EMBRAPA - Mapa de Solos do Brasil. Rio de Janeiro: IBGE, 2001 - Escala 1:5.000.000.

INACIO, K. A. M.; CORTEZ, J. W. variabilidade espacial da produtividade da soja e sua correlação com atributos químicos e textura do solo. Rev. Gest. Soc. Ambient., v.17, n.2, p.1-18, e03226, 2023.

JENSEN, J.R. Introductory digital image processing: a remote sensing perspective. Upper Saddle River: Prentice-Hall, p. 250–251, 1996.

KITCHEN, N.; SUDDUTH, K.; MYERS, D.; DRUMMOND, S.; HONG, S. Delineating productivity zones on claypan soil fields using apparent soil electrical conductivity. Computers and Electronics in Agriculture, Amsterdam, v. 46, n. 1, p. 285-308, 2005.

KOPPEN, W. P. Climatologia, com un estudio de los climas de la tierra. México: Fondo de Cultura Económica, 1948. 478p.

LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. Biometrics, New York, v.33, 159–174, 1977.

MAPA - MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. Instrução Normativa Nº 2, de 9 de outubro de 2008. Diário Oficial da União, Brasília, n. 197, seção 1, p. 71, 2008,

MOLIN, J. P. Geração interpretação de mapas de produtividade para agricultura de precisão. In: BORÉM, A.; GIÚDICE, M. P. del; QUEIROZ, D. M. de; MANTOVANI, E. C.; FERREIRA, L. R.; VALLE, F. X. R. do; GOMIDE, R. L. (Ed.). Agricultura de precisão. Viçosa, MG: Universidade Federal de Viçosa, 2000. p. 237-258.

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

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. Agricultura de Precisão. 1 ed. São Paulo: Oficina de textos, 2015. 235p.

MZA. Management Zone Analyst. Disponível em: <https://www.ars.usda.gov/research/software/download/?softwareid=24&modecode=50-70-10-00> . Acesso em 01 de fevereiro de 2022.

NJEBAN, H. Comparison and Evaluation of GIS-Based Spatial Interpolation Methods for Estimation Groundwater Level in AL-Salman District—Southwest Iraq. Journal of Geographic Information System, v.10, p.362-380, 2018.

ODEH, IOA; CHITTLEBOROUGH, DJ; MCBRATNEY, AB Reconhecimento de padrões de solo com fuzzy-c-means: Aplicação à classificação e inter-relações solo-relevo. Soil Science Society of America Journal, v. 2, p. 505-516, 1992.

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, 12, 1350, 2022. <https://doi.org/10.3390/agronomy12061350>

PEREIRA, K.M.; CORTEZ, J.W.; CERVI, R.F.; ARCOVERDE, S.N.S. Variabilidade espacial de micronutrientes catiônicos do solo. In: ZUFFO, A. M.; AGUILERA, J.G. Pesquisas agrárias e ambientais: Volume X. Nova Xavantina-MT: Pantanal, 2022.p.108-117.

QGIS.org. QGIS Geographic Information System. QGIS Association. 2022. Disponível em: <http://www.qgis.org> Acesso em: 03 de fevereiro de 2022.

RODRIGUES JUNIOR, F.A.; VIEIRA, L.B.; QUEIROZ, D.M.; SANTOS, N.T. Geração de zonas de manejo para cafeicultura empregando-se sensor SPAD e análise foliar. Campina Grande. Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande, v.15, n.8, p.778-787, 2011.

RODRIGUES, M. S.; CORÁ, J. E. Management zones using fuzzy clustering based on spatial-temporal variability of soil and corn yield. Engenharia Agrícola, v. 35, n. 3, p. 470–483, 2015.

SANTOS, A. O., PALLONE FILHO, W. J., UNGARO, M. R. G., LINO, A. C. L., RADIN, B. Prospecção de zonas potenciais para manejo diferenciado em agricultura de precisão utilizando-se padrões de solo-planta-clima. Revista Brasileira de Engenharia Agrícola e Ambiental, v.7, n.3, p.463–468, 2003.

SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A.; ARAÚJO, J. C.; OLIVEIRA, J. B.; CUNHA, T. J. F. Sistema Brasileiro de Classificação de Solos. Brasília: Embrapa, 2018.

SCALON, L.Q.; CORTEZ, J.W.; SCHWANBACH, D.A. Variabilidade espacial da fertilidade do solo e mapas de recomendação. In: ZUFFO, A. M.; AGUILERA, J.G. Pesquisas agrárias e ambientais: Volume X. Nova Xavantina-MT: Pantanal, 2022.p.118-126.

SCHWAMBACH, D. A., CORTEZ, J. W., FLORA, D. P. D., HENRIQUES, H. J. R., DONAIRE, L. D. O. Variability of soybean and corn yield and soil texture in the generation of management zones. Energia Na Agricultura, v.36, n.3, p.335–347, 2021.

SEMADESC. Boletim Casa Rural: agricultura. Ed. Nº 538. Campo Grande: SEMADESC, 2023. 40p.

SEMADESC. MS tem a melhor safrinha de milho dos últimos 10 anos, superando 14 milhões de toneladas. Disponível em: <https://www.semadesc.ms.gov.br/ms-tem-a-melhor-safrinha-de-milho-dos-ultimos-10-anos-superando-14-milhoes-de-toneladas/> Acesso em: 16 de junho de 2024.

SIMAS, G.H.N.; FIEDLER, S.; CORTEZ, J.W. Uso de imagens aéreas com drones para identificação de falhas no estabelecimento da soja. In: ZUFFO, A. M.; AGUILERA, J.G. Inovações em pesquisas agrárias e ambientais - Volume I. Nova Xavantina-MT: Pantanal, 2023.p.6-15.

SIMIONI, F. J., BARTZ, M. L. C., WILDNER, L. DO P., SPAGNOLLO, E., VEIGA, M. DA, & BARETTA, D. Indicadores de eficiência técnica e econômica do milho cultivado em sistema plantio direto no Estado de Santa Catarina, Brasil. *Revista Ceres*, v.64, n3, p.232–241, 2017.

SILVA, A. et al. "A Eficácia da Irrigação na Agricultura: O Caso do Milho." *Caderno de Ciência e Tecnologia*, 2021.

SOUZA, J. A. DE., BUZETTI, S., TARSITANO, M. A. A., VALDERRAMA, M. (2012). Lucratividade do milho em razão das fontes, doses e épocas de aplicação de nitrogênio. *Revista Ceres*, v. 59, n. 3, p. 321–329, 2012.

VETTORAZZI, C.A.; FERRAZ, S.F.B. Silvicultura de precisão: uma nova perspectiva para o gerenciamento de atividades florestais. In: BORÉM, A.; GIUDICE, M.P.; QUEIRÓZ, D.M. de. (Ed.). *Agricultura de precisão Viçosa*, 2000. p.65-75.

VIEIRA, S. R.; MILLETE, J.; TOPP, G. C. & REYNOLDS, W. D.; Handbook for geostatistical analysis of variability in soil and climate data. In: ALVAREZ, V. V. H.; SCHAEFER, C. E. G. R.; BARROS, N. F.; MELLO, J. W. V.; COSTA, J. M. *tópicos em ciência do solo*. Viçosa, MG: Sociedade Brasileira De Ciência do Solo, v.2, p.1-45, 2002.

WANG, J.; WANG, Y.; LI, G.; QI, Z. Integration of Remote Sensing and Machine Learning for Precision Agriculture: A Comprehensive Perspective on Applications." *Agronomy*, v.14, n.9, 1975, 2024.

WARRICK, A. W.; NIELSEN, D. R.; Spatial variability of soil physical properties in the field. In: Environmental soil physics. New York: Academic, p. 665-675,1980.

ZHANG, C.; SOKALSKI, R.; JOHNSON, D. M.; LARKIN, S. Remote sensing for precision agriculture: Use of imagery to improve farm management. Agronomy Journal, v. 110, n. 4, p. 1305-1316, 2018.