

Delineamento de potenciais zonas de manejo para intervenções espacialmente diferenciadas para as culturas de algodão, soja e milho

Delineation of potential management zones for spatially differentiated interventions for cotton, soybean, and corn crops

Eduardo Antonio Speranza¹, Ivani de Oliveira Negrão Lopes², Carlos Manoel Pedro Vaz³, Julio Cezar Franchini dos Santos⁴, Ricardo Yassushi Inamasu⁵, Ladislau Marcelino Rabello⁶, Lucio André de Castro Jorge⁷

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

²Pesquisadora, Embrapa Soja, Londrina (PR), Brasil, ivani.negrao@embrapa.br

³Pesquisador, Embrapa Instrumentação, São Carlos (SP), Brasil, carlos.vaz@embrapa.br

⁴Pesquisador, Embrapa Soja, Londrina (PR), Brasil, julio.franchini@embrapa.br

⁵Pesquisador, Embrapa Instrumentação, São Carlos (SP), Brasil, ricardo.inamasu@embrapa.br

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

⁷Pesquisador, Embrapa Instrumentação, São Carlos (SP), Brasil, ladislau.rabello@embrapa.br

RESUMO

Este trabalho descreve uma metodologia aplicada ao delineamento de potenciais zonas de manejo para implantação experimental de atividades de intervenção espacialmente diferenciadas em agricultura de precisão para as culturas de algodão, soja e milho. Abrange diferentes algoritmos de agrupamento de dados disponíveis na literatura e diferentes conjuntos de atributos que descrevem a física do solo e as características de fertilidade, condutividade elétrica do solo, índices de vegetação e mapas de produtividade. O valor dos agrupamentos obtidos, frente à tarefa de delimitar zonas de manejo é inferido com base na habilidade de cada combinação de parâmetros em gerar grupos que maximizam a homogeneidade de produtividade.

Palavras-chave: variabilidade espacial; agrupamento de dados; experimentação *on-farm*.

ABSTRACT

This work describes a methodology applied to the delineation of potential management zones for the experimental implementation of spatially differentiated intervention activities in precision agriculture for cotton, soybean and corn crops. It encompasses different data clustering algorithms available in the literature and different sets of attributes describing soil physics and fertility features, soil electrical conductivity, vegetation indices, and yield maps. The potential of each outcome to serve as management zones is inferred considering the ability of each configuration to produce groups able to maximize yield homogeneity.

Keywords: spatial variability; data clustering; on-farm experimentation.

<https://doi.org/10.4322/978-65-86819-38-0.1000054>

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

1 INTRODUÇÃO

O desenvolvimento de tecnologias de informação e comunicação (TICs) capazes de coletar, processar e compartilhar dados de relevo, solo, cultura e clima de uma área de produção, quando aplicadas para a identificação e tratamento da variabilidade espacial em agricultura de precisão (AP), caracterizam o conceito de agricultura digital. Um dos conceitos utilizados para realizar essa identificação e tratamento é a subdivisão das áreas de produção em zonas de manejo (ZM) (Doerge, 1999). Essa subdivisão deve se manter relativamente constante ao longo do tempo e, para tanto, deve ser determinada a partir de atributos não antropizados e relacionados principalmente ao solo e à cultura, além do conhecimento do próprio produtor.

A literatura apresenta diversas abordagens computacionais que podem ser utilizadas para o delineamento de ZM, a maioria delas considerando algoritmos de classificação não supervisionados (sem classificação prévia), conhecidos como algoritmos de agrupamento. Gavioli et al. (2019) realizaram um estudo comparando a eficiência e eficácia para delineamento de ZM de 20 algoritmos de agrupamentos distintos, onde foram obtidos desempenhos considerando diferentes situações. Neste trabalho, são descritos a metodologia utilizada e os resultados obtidos no delineamento de ZM para talhões experimentais de produção de algodão, soja e milho localizados no estado de Mato Grosso. O objetivo principal foi auxiliar na estratégia para construção de experimentação *on-farm* (Bullock et al. 2019; Shiratsuchi et al. 2019) para identificação de recomendações de aplicação de insumos e corretivos à taxa variada. Para este trabalho, foram utilizadas abordagens de agrupamento distintas para duas áreas experimentais distintas, considerando diferentes tipos de dados de entrada. Os algoritmos Flexible-beta (Lance; Willians, 1967) e Ward

(Ward Júnior, 1963) foram utilizados para delineamento de ZM para um talhão experimental que recebeu as culturas de soja, milho e algodão, em períodos intercalados de safra e safrinha, nos anos de 2019 e 2020. Adicionalmente, foram obtidos agrupamentos de consenso (*ensembles*) para os resultados obtidos com essas abordagens.

A abordagem SWMU Clustering (Speranza, 2017), baseada no algoritmo de Ward e que possui o viés de gerar mapas de ZM que mantenha estruturas espaciais contíguas, foi utilizada para o delineamento de ZM em um talhão experimental contendo exclusivamente a cultura do algodão.

2 MATERIAL E MÉTODOS

Este trabalho foi realizado considerando dois talhões experimentais. O primeiro deles (talhão A), com aproximadamente 100 ha, pertence ao grupo agrícola Sementes Petrovina e está localizado em Pedra Preta/MT, com coordenadas centrais (lon, lat) O 54°4'18.94", S 16°52'53.72" no *datum* WGS84 (Figura 1a). Para esse talhão, foram utilizados dados de 2019, onde ocorreu o cultivo da soja e do milho, e de 2020, onde a cultura do milho foi substituída pela cultura do algodão, além de dados de condutividade elétrica aparente (CEa) e textura do solo obtidos em 2017. Com relação ao sistema de cultivo desse talhão, foi utilizada a sequência soja-algodão (safra 2017-2018), soja-milho (2018-2019) e soja-algodão (2019-2020) nas últimas três safras, em sistema de plantio direto, mas sem a utilização de cultura de cobertura na entressafra entre a colheita do milho (ou algodão) e o plantio da soja. O segundo (talhão B), com aproximadamente 170 ha, pertence ao grupo agrícola Amaggi e está localizado em Sapezal/MT, com coordenadas centrais (lon, lat) O 58°52'59.28", S 13°35'4.07" no *da-*



Figura 1. Delimitação de área dos talhões experimentais utilizados: (a) talhão A, de 100 ha, pertencente ao grupo Sementes Petrovina; e (b) talhão B, de 170 ha, pertencente ao grupo Amaggi.

tum WGS84 (Figura 1b). Para esse talhão, foram utilizados dados de monitoramento da safra do algodão de 2020. O sistema de cultivo desse talhão nas últimas três safras foi de algodão de primeira safra em sistema de plantio direto e crotalaria na entressafra (algodão-crotalaria).

Para o talhão A, foram utilizadas diferentes combinações de atributos para o delineamento de ZM, a partir de dados coletados em campo. Em 2017, foram gerados mapas de CEa do solo em duas profundidades (30 cm e 90 cm). Em 2019, foram coletadas 70 amostras de solo em grade igualmente espaçada (100 m x 150 m) na profundidade 0-20 cm para análise do teor dos atributos pH, P, K, Ca, Mg, V, CTC, Cu, Fe, Mn e Zn e também para a identificação do teor de argila. Por ser uma área com histórico de incidência de nematoides, foram coletadas amostras utilizando essa mesma grade espacial para análise da presença dos nematoides das espécies *Pratylenchus brachyurus*, *Rotylenchulus reniformis* e *Heterodera glycines* tanto no solo quanto na raiz em 2019, com análise repetida para a primeira e segunda espécies em 2020. Os dados referentes à cultura correspondem aos mapas dos índices de vegetação NDVI e NDWI obtidos a partir de imagens do satélite Sentinel-2 nos meses de março, abril e maio de 2020; e mapas de produtividade da soja (2019), milho (2019) e algodão (2020). Para este estudo, os dados com alta densidade de pontos, como CEa do solo, mapas de produtividade e índices de vegetação, foram transformados em valores médios dentro de cada uma das células da grade de 70 m pré-definida para a análise de solo. Assim, todos os atributos coletados se referiam à mesma unidade de área, permitindo sua utilização nas análises de agrupamento realizadas. O conjunto de dados final possui 33 atributos e 70 amostras, o que não é usual no delineamento de ZM para AP, onde normalmente são utilizados altas densidades espaciais e conjuntos reduzidos de atributos. Adicionalmente, esse conjunto de dados foi pré-agrupado em 14 diferentes subconjuntos (categorias), cada um deles utilizado individualmente como entrada para os algoritmos de agrupamento (Tabela 1).

Considerando a Tabela 1, foram realizadas cinco diferentes análises de componentes principais, considerando todos os atributos (PCATodos), apenas atributos coletados em 2019 (PCA19), apenas atributos do solo coletados em 2019 (PCA19Sol), todos os atributos coletados em 2020 (PCA20) e todos os atributos de solo coletados em 2020 (PCA20Sol). O grupo Todos contém todos os atributos do conjunto de dados (incluindo os índices de vegetação NDVI e NDWI em 2020), e os grupos Atr19 e Atr20 contêm todos os

atributos obtidos em 2019 e 2020, respectivamente. O grupo Atr19Sol possui apenas os atributos de solo coletados em 2019 e o grupo Atr20Sol apenas os atributos de solo coletados em 2020. Nema19 e Nema20 compõem os atributos referentes à incidência de nematoides em 2019 e 2020. Finalmente, o grupo AnaliseS possui todos os atributos referentes à análise química de fertilidade do solo e o grupo FiSolo possui os atributos do grupo AnaliseS acrescido dos atributos referentes à física do solo.

Para a execução desse experimento, foram utilizados os algoritmos Flexible e Ward considerando os diferentes conjuntos de dados de entrada descritos na Tabela 2. Devido às diferenças visualizadas nos mapas de zonas de manejo obtidos com as diferentes combinações de atributos de entrada e a utilização dos dois algoritmos de maneira individual, foram gerados agrupamentos de consenso a partir da abordagem de *ensemble* de agrupamentos baseada em acúmulo de evidências desenvolvida por Fred e Jain (2005).

Para o talhão B, foram utilizados para o delineamento das ZM todos os atributos obtidos durante a safra do algodão de 2019: CEa do solo nas profundidades de 30 cm e 90 cm, mapas de índices de vegetação NDVI e NDRE nos meses de maio e junho e mapa de produtividade, obtido durante a colheita realizada no mês de agosto. Nesse caso, como todos os atributos possuíam alta densidade espacial, foi realizada uma reamostragem de todos eles para uma grade regular de 10 m x 10 m, considerando os valores médios obtidos dentro de cada célula (Figura 2).

A partir desses atributos, o delineamento de ZM foi realizado utilizando-se a abordagem de agrupamento SWMU Clustering, com os seguintes parâmetros: $k = 200$ para a tesselação inicial, indicando que o agrupamento hierárquico será iniciado com 200 grupos divididos espacialmente; $maxDMC = 5$, indicando que serão gerados mapas com no máximo 5 ZM; e $porcDMU = 5\%$, indicando que uma ZM deve ocupar no mínimo 5% da área total do talhão. A definição desses parâmetros é importante para reduzir o grau de estratificação dos mapas de ZM gerados.

Com a definição dos atributos de entrada e algoritmos e abordagens de agrupamento para cada uma das duas situações, os procedimentos de delineamento de ZM foram executados para as duas áreas, proporcionando resultados que são exibidos e discutidos a seguir.

3 RESULTADOS E DISCUSSÃO

Para o talhão A, foi gerado um total de 168 agrupamentos distintos para potenciais mapas de zonas de

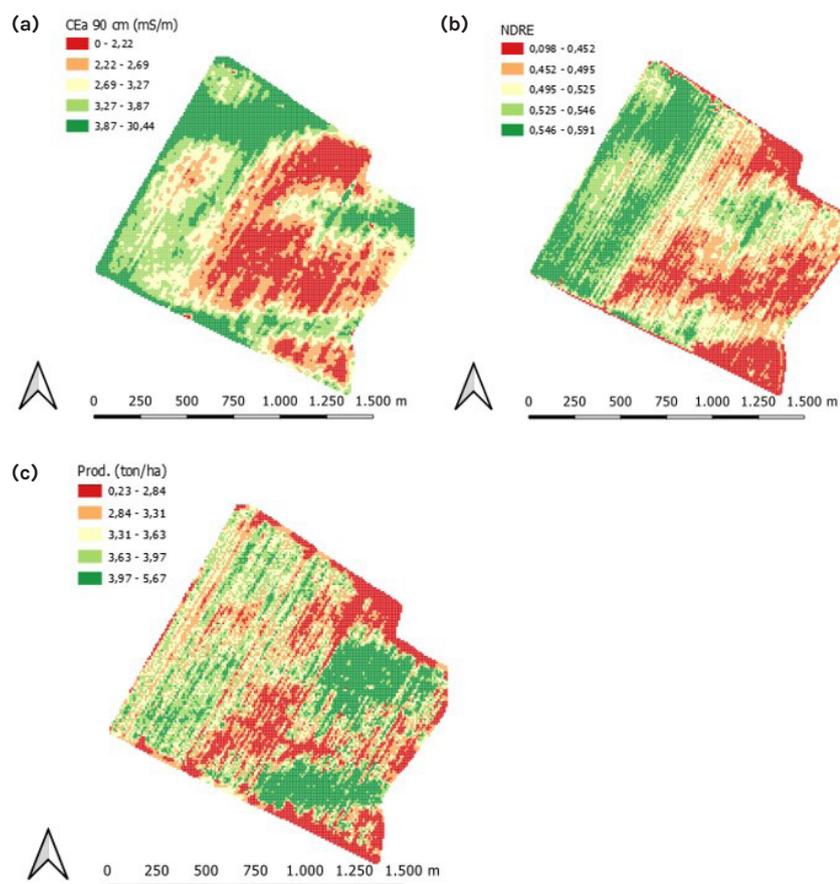


Figura 2. Exemplos de mapas utilizados no delineamento de ZM para o talhão B: (a) CEa do solo a 90 cm; (b) NDRE; e (c) produtividade.

Tabela 2. Estatística F para o fator grupo (F_g) obtido em cada um dos 168 agrupamentos gerados no experimento, considerando diferentes combinações de atributos, algoritmos e quantidades de grupos.

Atributos	Soja (2019)		Milho (2019)				Algodão (2020)					
	Flexível- β		Ward		Flexível- β		Ward		Flexível- β		Ward	
	k=3	k=4	k=3	k=4	k=3	k=4	k=3	k=4	k=3	k=4	k=3	k=4
PCATodos	27,0	17,8	24,1	15,8	1,0	13,4	2,2	15,4	21,3	14,0	15,8	10,4
PCA19	1,5	7,6	23,3	17,9	3,3	4,2	20,6	13,6	1,3	5,7	7,4	5,0
PCA19Sol	26,3	24,2	30,6	21,4	1,0	0,7	11,8	8,4	11,5	14,4	20,4	20,6
PCA20	8,3	10,8	10,0	14,9	0,1	0,2	0,4	0,3	8,1	15,4	8,7	17,2
PCA20Sol	12,9	16,0	13,9	14,5	1,4	1,0	2,0	1,3	16,9	14,8	8,6	10,1
Todos	37,7	25,3	20,0	15,9	2,7	1,8	1,9	1,7	34,4	26,9	15,2	21,4
Atr19	9,9	6,6	10,4	10,3	4,4	24,4	4,4	11,1	8,7	5,7	9,4	6,7
Atr19Sol	16,4	32,9	43,2	30,6	1,5	2,4	3,0	3,1	12,1	28,5	15,6	11,6
Atr20	10,8	12,7	10,5	7,4	0,2	0,2	0,6	0,5	15,2	22,2	24,3	16,6
Atr20Sol	27,8	18,5	28,0	19,7	1,2	1,1	0,0	0,7	38,3	28,3	42,7	29,5
Nema19	5,4	3,6	6,6	6,8	1,6	1,5	1,6	1,0	14,6	10,0	8,4	16,4
Nema20	10,0	7,3	19,1	12,6	2,6	1,7	3,0	2,1	19,4	12,8	19,2	16,3
AnaliseS	42,7	49,0	60,2	39,7	5,3	3,5	1,1	1,9	22,5	19,2	22,9	15,3
FiSolo	0,3	5,6	6,4	5,6	2,9	3,4	0,4	3,4	1,1	4,5	5,5	4,5

manejo, considerando: as 14 categorias distintas de atributos (Tabela 1); três diferentes safras (soja-2019, milho-2019 e algodão-2020); dois diferentes algoritmos (Ward e Flexible); e duas diferentes quantidades de grupos (ou ZM) para cada caso (três e quatro grupos). As quantidades de grupos foram definidas com base nas distâncias entre os grupos, visualizadas nos dendogramas. Para avaliar se os agrupamentos obtidos seriam bons delimitadores de zonas de produtividades mais homogêneas, foi utilizada a estatística F referente ao fator grupo (F_g), no modelo de análise de variância (anava): $P_{ij} = \mu + g_i + e_{ij}$. Nesse modelo, P_{ij} representou a produtividade de um pixel j dentro de um grupo i , μ a produtividade média do talhão, g_i o efeito do grupo i e e_{ij} a diferença entre a produtividade do pixel e a produtividade média do grupo. Como em todo modelo ANOVA com um único fator, F é a razão das variâncias entre e dentro de grupos. Assim, quanto maior o valor de F_g , mais forte a evidência de que as produtividades dos pixels dentro dos grupos obtidos (zonas candidatas) são mais homogêneas. A Tabela 2 exibe os valores de F obtidos para cada um dos 168 agrupamentos gerados.

Os resultados da Tabela 2 mostram que os melhores resultados foram obtidos com a utilização dos atributos relacionados à fertilidade do solo obtidos na safra de soja de 2019, mesmo com a variação de algoritmos e quantidade de grupos utilizada. A utilização de todos os atributos do solo para as safras de soja de 2019 e algodão de 2020, nesse caso considerando três grupos, também apresentou bons resultados. Um resultado importante também exibido na Tabela 2 pode ser verificado com o uso de PCA, que

não se mostrou eficiente no pré-processamento dos dados para análise de agrupamento. Considerando os melhores agrupamentos exibidos na Tabela 2, foram realizadas análises utilizando a metodologia de *ensembles* desenvolvida por Fred e Jain (2005), para as seguintes combinações: (I) conjunto de atributos Atr20Sol e os agrupamentos gerados utilizando o algoritmo Flexible (para três grupos) e o algoritmo de Ward (para três grupos); (II) conjunto de atributos AnaliseS e agrupamentos gerados utilizando o algoritmo Flexible (três e quatro grupos) e o algoritmo de Ward (três e quatro grupos); (III) conjuntos de atributos Todos, Atr20Sol e AnaliseS e o algoritmo Flexible (para três e quatro grupos); e (IV) conjuntos de atributos Atr19Sol, Atr20Sol e AnaliseS e o algoritmo Ward (para três e quatro grupos). O melhor resultado obtido, segundo os valores de F_g , foi para a combinação IV para três grupos, obtendo o valor 53. Apesar de apresentar um valor mais baixo que a melhor solução exibida na Tabela 2, onde a utilização do algoritmo de Ward para três grupos e a utilização do conjunto de dados de fertilidade do solo para a safra de soja de 2019 apresentou F_g igual a 60, essa solução pode ser utilizada como agrupamento de consenso quando se deseja observar não apenas os atributos de fertilidade, mas também todos os atributos relacionados ao solo, inclusive os obtidos em outras safras. A Figura 3 exibe os dois melhores mapas obtidos nessa análise.

A Figura 4 exibe os mapas de zonas de manejo obtidos para o talhão B, a partir da metodologia definida previamente. Apesar de o algoritmo SWMU Clustering ter sido executado para fornecer mapas contendo de duas a cinco ZMs, os mapas com quatro e cinco ZMs

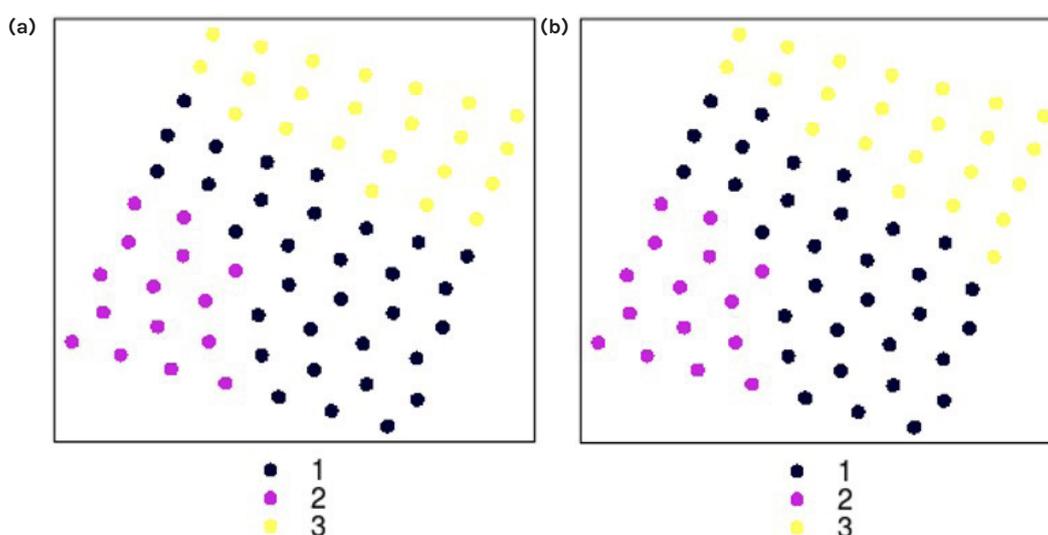


Figura 3. Melhores agrupamentos obtidos para o talhão A, considerando: (a) dados de fertilidade do solo, algoritmo de Ward para três grupos para a safra de soja de 2019; e (b) *ensemble* com três grupos considerando agrupamentos obtidos com o algoritmo de Ward (três e quatro grupos originalmente) e os diferentes conjuntos de atributos relacionados à fertilidade do solo e todos os atributos de solo (nas safras de 2019 e 2020), também gerados para a safra de soja de 2019.

não foram gerados, pois possuíam alto nível de estratificação, contendo partes disjuntas de ZMs com área menor do que 5% da área total.

Adicionalmente, a Tabela 3 apresenta os valores médios de cada uma das sete variáveis utilizadas para a obtenção das ZMs (NDVI e NDRE em duas datas, CEa do solo em duas profundidades e produtividade), separados por ZM para os mapas contendo duas e três ZMs.

A partir da Tabela 3, podemos analisar cada variável e concluir qual seria a separação mais adequada (2 ou 3 ZM), de forma a garantir que o mapa de ZM escolhido proporcione uma melhor redução da variabilidade espacial para a área de estudo.

Para os dados de CEa, nas duas profundidades, é possível verificar que a ZM 1, para o mapa de três ZMs, possui valores próximos à média geral, enquanto que as ZMs 2 e 3 possuem valores abaixo e acima da média, respectivamente. Nesse caso, se considerarmos

apenas duas ZMs, estaríamos deixando de destacar uma região com valores de CEa muito acima da média, como a ZM 3. Considerando os dados de índice de vegetação, embora os valores absolutos sejam bastante próximos, é possível verificar melhores respostas da ZM 1 e da ZM 3 com relação à ZM 2, da mesma forma que observado para os valores de CEa do solo. Finalmente, considerando a produtividade, podemos destacar, no mapa contendo três ZMs, valores menores para a ZM 2 em comparação com as ZMs 1 e 3. No entanto, a ZM 1 se mostrou uma área mais produtiva do que a ZM 3, ou seja, com um comportamento contrário se observarmos os dados da CEa do solo e índices de vegetação.

A partir dessas análises, considerando o mapa com três ZMs, é possível verificar que a ZM 2 é uma área com textura de solo mais arenosa, conforme indicado pelos dados de CEa e, conseqüentemente, com potencial produtivo menor, que pode ser observado nos

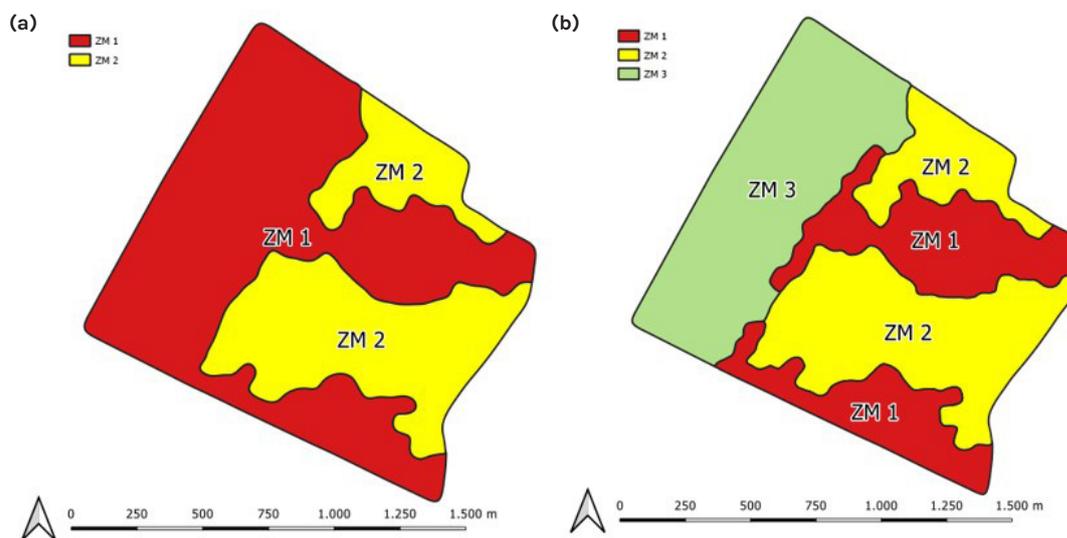


Figura 4. Mapas de ZM delineados para o talhão B, escolhidos a partir da análise de redução da variância de produtividade, contendo: (a) dois ZM e (b) três ZM.

Tabela 3. Valores médios para todas as variáveis, considerando as zonas de manejo e também a área total.

Atributo	Total		2 ZM		3 ZM		
	Média	DP	1	2	1	2	3
CEa-30 (mS/m)	3,14	1,14	3,53	2,39	3,14	2,39	3,84
CEa-90 (mS/m)	0,87	1,70	1,43	-0,12	0,73	-0,12	1,98
NDVI-1	0,87	0,06	0,89	0,86	0,89	0,87	0,90
NDRE-1	0,49	0,04	0,51	0,46	0,49	0,46	0,52
NDVI-2	0,86	0,08	0,88	0,83	0,87	0,83	0,89
NDRE-2	0,50	0,06	0,53	0,46	0,50	0,46	0,54
Produtividade(ton/ha)	3,40	0,76	3,63	3,07	3,74	3,06	3,55

dados de produtividade. Entretanto, a ZM 3, apesar de possuir um potencial produtivo maior que a ZM 1, de acordo com os dados de CEa e índices de vegetação, apresentou valores de produtividade mais baixos. Desse modo, é importante que a ZM 1 e a ZM 3 sejam investigadas separadamente, para que possam ser verificadas as causas de a produtividade maior ter sido obtida na ZM 1.

4 CONCLUSÕES

Este trabalho descreveu a metodologia utilizada e os resultados obtidos para o delineamento de zonas de manejo para talhões experimentais da produção de algodão, soja e milho, localizados no estado de Mato Grosso, com o objetivo de subsidiar a implementação de experimentação *on-farm*. Foram utilizados conjuntos distintos de dados de entrada para as duas situações: para o talhão A foram considerados vários atributos do solo e dois índices de vegetação (NDVI e NDWI), com uma densidade amostral baixa de aproximadamente uma amostra a cada 2 ha; para o talhão B, foram considerados apenas atributos coletados com alta densidade de pontos em campo, como os mapas de CEa do solo e produtividade e os índices de vegetação gerados a partir de imagens de drone, ajustados em grade espacial de 10 m de resolução (aproximadamente mil amostras por ha). Com relação à metodologia, para o talhão A foram utilizados os algoritmos Ward e Flexible individualmente e a abordagem de *ensemble* baseada em acúmulo de evidências para obtenção de agrupamentos de consenso. Nesse caso, a qualidade dos agrupamentos foi inferida pela estatística *F* para o fator grupo na análise de variância. Já para o talhão B, foi utilizado o algoritmo SWMU Clustering, que proporciona a obtenção de zonas de manejo com redução da estratificação espacial. Nesse caso, foram utilizados os valores médios de cada variável usada, obtidos em cada zona de manejo delimitada, como forma de definir qual seria a melhor alternativa dentre os mapas obtidos. De maneira geral, para ambos os casos, as metodologias utilizadas proporcionaram o delineamento de zonas de manejo capazes de reduzir a variabilidade espacial das áreas estudadas e que possam ser utilizadas para o delineamento de experimentos *on-farm*.

AGRADECIMENTOS

Aos grupos agrícolas Amaggi e Sementes Petrovina e ao Instituto Matogrossense do Algodão (IMAmt), pelo suporte às coletas de dados realizadas.

REFERÊNCIAS

- BULLOCK, D. S.; BOERNGEN, M.; TAO, H.; MAXWELL, B.; LUCK, J. D.; SHIRATSUCHI, L.; PUNTEL, L.; MARTIN, N. F. The data-intensive farm management project: changing agronomic research through on-farm precision experimentation. **Agronomy Journal**, v. 111, n. 6, p. 2736-2746, 2019. DOI: <http://doi.org/10.2134/agronj2019.03.0165>.
- DOERGE, T. Defining management zones for precision farming. **Crop Insights**, v. 8, n. 21, p. 1-5, 1999.
- FRED, A. L. N.; JAIN, A. K. Combining multiple clusterings using evidence accumulation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 27, n. 6, p. 835-850, 2005. DOI: <http://doi.org/10.1109/TPAMI.2005.113>.
- GAVIOLI, A.; SOUZA, E. G.; BAZZI, C. L.; SCHENATTO, K.; BETZEK, N. M. Identification of management zones in precision agriculture: an evaluation of alternative cluster analysis methods. **Biosystems Engineering**, v. 181, p. 86-102, 2019. DOI: <http://doi.org/10.1016/j.biosystemseng.2019.02.019>.
- LANCE, G. N.; WILLIAMS, W. T. A general theory of classificatory sorting strategies: 1. Hierarchical systems. **The Computer Journal**, v. 9, n. 4, p. 373-380, 1967. DOI: <http://doi.org/10.1093/comjnl/9.4.373>.
- SHIRATSUCHI, L. S.; BRIANTE, P.; BRANDAO, Z. N.; BULLOCK, D. S.; SILVA JUNIOR, C. A.; RAMOS JUNIOR, E. U. On-farm precision experimentation with cotton to generate algorithms for site-specific management of nitrogen fertilizers based on airborne imagery. In: ASA, CSSA AND SSSA INTERNATIONAL ANNUAL MEETINGS, 2019, ASA-CSSA-SSSA. **Anais [...]**. 2019.
- SPERANZA, E. A. **Mineração de dados espaciais aplicada no delineamento de unidades de gestão diferenciada em agricultura de precisão**. 2017. Tese (Doutorado em Ciência da Computação) – Universidade Federal de São Carlos, São Carlos, 2017.
- WARD JÚNIOR, J. H. Hierarchical grouping to optimize an objective function. **Journal of the American Statistical Association**, v. 58, n. 301, p. 236-244, 1963. DOI: <http://doi.org/10.1080/01621459.1963.10500845>.