

DELINEAMENTO DE ZONAS DE MANEJO PARA O PLANEJAMENTO DE EXPERIMENTAÇÃO ON-FARM NA CULTURA DO ALGODÃO

Eduardo Antonio Speranza¹; Geovana Estevam de Sousa Olim²; Ricardo Yassushi Inamasu³; Carlos Manoel Pedro Vaz⁴; Lúcio André de Castro Jorge⁵

¹Cientista da Computação, Analista - Embrapa Informática Agropecuária, Campinas, SP. eduardo.speranza@embrapa.br / (19) 9 8138-1676; ²Engenheira Agrícola e Ambiental, Assistente de Campo - Grupo Amaggi, Sapezal, MT; ³Engenheiro Mecânico, Pesquisador - Embrapa Instrumentação, São Carlos, SP; ⁴Físico, Pesquisador - Embrapa Instrumentação, São Carlos, SP; ⁵Engenheiro Elétrico, Pesquisador - Embrapa Instrumentação, São Carlos, SP

Apresentado no
Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022
Campinas, SP, 09 a 11 de agosto de 2022

RESUMO: O Brasil é atualmente um dos maiores produtores e exportadores mundiais de algodão. O principal desafio dos produtores é a busca contínua do aumento da produtividade, aliado à qualidade do produto final, com foco no aumento da lucratividade e redução de impactos ao meio ambiente, tornando a produção de algodão no país cada vez mais sustentável. Desse modo, se torna cada vez mais necessária a adoção de técnicas de manejo que envolvam a coleta, análise e intervenção com base em dados, como a agricultura de precisão (AP). A subdivisão das áreas de produção em zonas de manejo (ZM) é uma das formas de se iniciar a adoção da AP em uma área de cultivo agrícola. Este trabalho teve como objetivo principal realizar o delineamento de ZM para uma área de produção de algodão de safra localizada em Sapezal-MT, utilizando técnicas computacionais de agrupamento de dados. A função principal desse delineamento foi auxiliar na estratégia para construção de experimentação *on-farm* para o estabelecimento de recomendações de adubação de cobertura nas diferentes ZM delimitadas para a área de estudo.

PALAVRAS-CHAVE: Análise de Agrupamento; Imageamento Aéreo; Produtividade

DELINEATION OF MANAGEMENT ZONES FOR ON-FARM EXPERIMENTATION IN COTTON PRODUCTION FIELDS

ABSTRACT: Brazil is currently one of the largest cotton producers and exporters in the world. The main challenge for farmers is seek for continuous productivity growth, associated with the quality of final product, focusing on increasing profitability and reducing environmental impacts, making cotton production in the country increasingly sustainable. Therefore, it has becoming increasingly necessary to adopt management tools driven by data collection, analysis and intervention, such as precision agriculture (PA). The subdivision of production fields in management zones (MZ) is one effective way to start the PA adoption in an agricultural cultivation area. The main goal of the present study is to perform the delineation of MZ for a cotton production area located in Sapezal-MT, using computing data clustering tools. The main purpose of this delineation is to assist in the strategy of on-farm experimentation for the establishment of nitrogen fertilizer topdressing recommendations in the different MZ delimited for the study cotton field.

KEYWORDS: Clustering analysis; Aerial Imaging; Yield

INTRODUÇÃO: Ao longo dos últimos anos, o Brasil tem se estabelecido entre os maiores produtores e exportadores mundiais de algodão (ABRAPA, 2020). Na safra 2018/2019, foram produzidos 2,779 milhões de toneladas de algodão em pluma no país, sendo o Estado de Mato Grosso responsável por 67% dessa produção, em uma área plantada aproximada de 1,09 milhões de hectares, o que proporcionou ao Estado uma produtividade média de 1,66 toneladas de pluma de algodão por hectare (CONAB, 2020). A alta produtividade do algodão no Mato Grosso também está relacionada com a qualidade da pluma, que proporciona um alto valor agregado dessa *commodity* no mercado internacional. Com clima e relevo amplamente favoráveis à produção do algodão, o desafio atual dos produtores do Estado é manter o alto patamar de produtividade, sem que seja necessário incrementar os investimentos em insumos e abertura de áreas novas na mesma proporção (FUNDAÇÃO MT, 2020). Desse modo, a adoção de técnicas de manejo com foco na gestão da produção,

como a agricultura de precisão (AP), tem grande potencial em auxiliar de maneira efetiva nesse desafio (BERNARDI et al., 2014). Adicionalmente, 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 que, quando aplicadas na AP, caracterizam o conceito de agricultura digital, potencializa a tomada de decisão pelo produtor com objetivo de reduzir perdas e aumentar a produção com base na gestão da variabilidade espacial. Um dos conceitos que podem ser utilizados para auxiliar o início desse processo é a subdivisão das áreas de produção em unidades de gestão diferenciada (UGD), popularmente conhecidas como zonas de manejo (ZM) (DOERGE, 1999). Essa subdivisão deve se manter relativamente constante ao longo do tempo e, para tanto, deve ser executada considerando a variabilidade natural da área. Desse modo, atributos não antropizados e relacionados principalmente ao solo e a cultura, além do conhecimento do próprio produtor, devem ser utilizados para que sejam obtidos mapas de ZM mais confiáveis. Dentre esses atributos, podem ser destacados: a condutividade elétrica aparente do solo (CEa), que pode ser correlacionada com diversas características do solo; índices de vegetação obtidos a partir de sensoriamento remoto, suborbital ou proximal; e a própria produtividade histórica da área (MOLIN et al., 2015). Este trabalho descreve a metodologia utilizada e os resultados obtidos no delineamento de ZM para um talhão experimental de produção de algodão localizado em Sapezal-MT. Esse delineamento teve como objetivo principal auxiliar na estratégia para construção de experimentação *on-farm* (BULLOCK et al. 2019; SHIRATSUCHI et al. 2019), onde foram estabelecidas, em cada ZM definida, diferentes parcelas virtuais para aplicação de diferentes taxas com quatro repetições[CV1] de adubação nitrogenada [CV2] durante o ciclo produtivo da safra de 2020.

MATERIAIS E MÉTODOS: A área de estudo utilizada neste trabalho compreende um recorte (125 ha) de um talhão experimental de expansão de algodão de safra com área total de aproximadamente 170 ha, localizado na Fazenda Tucunaré, em Sapezal-MT, com coordenadas geográficas centrais O 58°52'55'' e S 13°35'06'', pertencente ao grupo Amaggi (FIGURA 1).



FIGURA 1. Recorte do talhão experimental (delimitado em amarelo) que compreende a área de estudo utilizada. Imagem: Google Maps.

Para este experimento, foram coletados, em janeiro de 2019, dados de CEa do solo nas profundidades 0-30 e 0-90 cm, utilizando o sensor de campo Veris 3100® (Veris Technologies, Salina, KS, EUA) (FIGURA 2). Logo após a coleta desses dados, foi realizado o plantio do cultivar de algodão transgênico *WideStrike* (WS) na totalidade da área. Durante o crescimento da cultura, foram coletadas imagens em diversos períodos, utilizando uma aeronave remotamente pilotada (ARP) modelo Matrice 200® (DJI, Shenzhen, China) com câmera RGB de alta resolução espacial e câmera multiespectral modelo RedEdge-M® (Micasense, Seattle, WA, EUA). Nesse experimento, foram utilizados os mapas de índices de vegetação NDVI (*Normalized Difference Vegetation Index*) (ROUSE et al., 1973) e NDRE (*Normalized Difference Red Edge Index*) (BARNES, et al., 2000) gerados a partir das imagens multiespectrais coletadas durante o período de pico vegetativo da cultura, nos meses de maio (FIGURA 3) e junho (FIGURA 4) de 2019. Apesar da maior popularidade do NDVI, que pode ser obtido também a partir de imagens com 10 m de resolução espacial, como as que são fornecidas gratuitamente pelo satélite Sentinel-2® (European Space Agency, Paris, França), o NDRE, por utilizar uma banda espectral que representa reflectâncias entre as bandas do vermelho e infravermelho próximo, tende a expressar melhor as regiões de transição entre plantas saudáveis e não saudáveis em uma área de produção agrícola.




FIGURA 2. Mapas de condutividade elétrica aparente (CEa) do solo nas camadas (a) 0-30 cm e (b) 0-90 cm de profundidade, com valores em mS/m (Milisimens por metro).

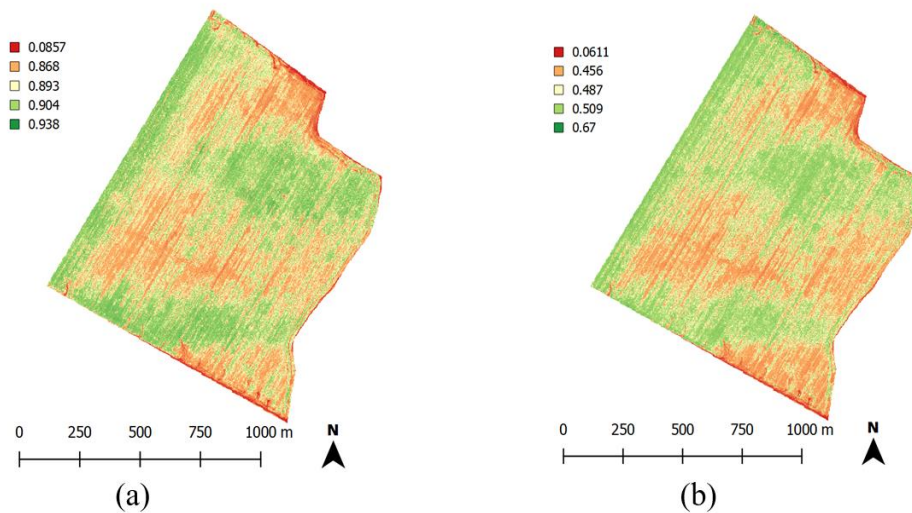


FIGURA 3. Mapas de índices vegetativos: (a) NDVI e (b) NDRE, obtidos a partir de imagens multiespectrais coletadas por câmera a bordo de ARP, em maio de 2019.

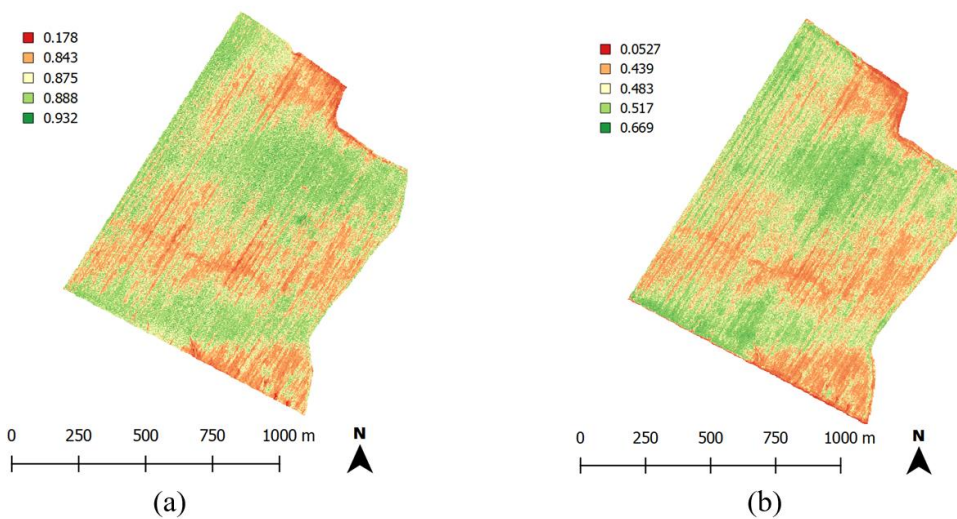


FIGURA 4. Mapas de índices vegetativos: (a) NDVI e (b) NDRE, obtidos a partir de imagens multiespectrais coletadas por câmera a bordo de ARP, em junho de 2019.

A partir da análise visual de “manchas” presentes nos mapas das figuras 2 e 3(a) e do conhecimento de campo, a equipe técnica da propriedade responsável pela execução das atividades na área delineou, manualmente e com a ajuda de sistemas de informações geográficas (SIG), um mapa contendo cinco potenciais ZM para planejamento e execução de coletas de amostras de folhas, para análise nutricional; e identificação da presença de diferentes espécies de nematoides, sendo coletada uma amostra composta por ZM (FIGURA 5).




FIGURA 5. Mapa de ZM delineado manualmente a partir da observação de mapas de NDVI, CEa do solo e conhecimento de campo.

A colheita do algodão para esse talhão foi realizada em duas datas distintas, no início de agosto de 2019, por meio de colhedoras auto enfardadeiras modelo CP690® (John Deere, Moline, IL, EUA), todas elas dotadas de monitor de colheita, permitindo assim a geração de um mapa único de produtividade (FIGURA 6). Esse mapa consiste da fusão dos dados obtidos pelas diferentes colhedoras, normalizados pela média de produtividade geral do talhão. Comparando-se os mapas das figuras 5 e 6, é possível verificar, de maneira visual, que as ZM delimitadas manualmente retrataram bem as diferenças de produtividade da área, principalmente nos locais onde foram obtidos níveis mais altos (ZM1 e ZM2).




FIGURA 6. Mapa de produtividade do algodão da safra de 2019, com valores em toneladas por hectare.

De posse de todos os mapas exibidos nas figuras de 2 a 6, foi realizado um processo semiautomático de mineração dos dados, com o intuito de gerar mapas de potenciais ZM utilizando algoritmos de agrupamento, considerando como insumos as informações coletadas em campo e fornecidas pela equipe técnica da propriedade. A utilização desse tipo de algoritmo permite definir mapas de ZM mais precisos, considerando tanto a variabilidade espacial presente nos próprios dados, quanto informações relevantes e restritivas definidas pela equipe técnica. Para que os dados das figuras 2, 3, 4 e 6 pudessem ser utilizados como atributos de entrada para esses algoritmos, os mesmos tiveram que ser normalizados em uma grade espacial única. A grade utilizada possui resolução espacial de 10 m, e foi obtida a partir de imagens de sensoriamento remoto do satélite Sentinel-2. Como todos os mapas possuem alta densidade de pixels, o ajuste de grade se deu a partir de algoritmos de interpolação espacial determinísticos, reamostragem ou cálculo de médias de pontos internos a

cada pixel. Esse ajuste permitiu a obtenção de sete atributos distintos para análise por parte de algoritmos de agrupamento e posterior delineamento de potenciais ZM: CEa do solo nas profundidades de 0-30 e 0-90 cm; NDVI e NDRE nos meses de maio e junho de 2019; e produtividade da safra de 2019. Apesar de o delineamento de ZM realizado manualmente ser válido, o mesmo foi executado com base em apenas 3 atributos (CEa nas duas profundidades e NDVI no mês de maio de 2019). Conforme a quantidade de atributos aumenta, fica cada vez mais difícil o delineamento manual ser realizado e, portanto, cada vez mais necessário o uso de algoritmos de agrupamento para que o resultado tenha um menor erro e forneça mapas com ZM coesas e bem separadas entre si.

Boa parte dos trabalhos presentes na literatura que envolvem o delineamento de ZM a partir de análise de agrupamento utilizam algoritmos particionais para execução dessa tarefa, especialmente o *fuzzy c-means* (FCM) (BEZDEK et al., 1984; KITCHEN et al., 2005; LI et al., 2007; MORARI et al., 2009; CÓRDOBA et al., 2013; GAVIOLI et al., 2016). Apesar de considerar parte das incertezas que ocorrem no campo e possuir um custo computacional linear, esse algoritmo apresenta algumas desvantagens: necessidade de se determinar previamente a quantidade desejada de grupos (ou ZM, nesse contexto); inicialização aleatória, o que pode proporcionar o ajuste da sua função objetivo para um mínimo local (e não global); e o não-determinismo, muitas vezes provocado pela própria inicialização aleatória, que faz com que possam ser obtidos grupos distintos em diferentes execuções considerando o mesmo conjunto de dados e parâmetros de entrada. Para este trabalho, a análise de agrupamento foi realizada utilizando o algoritmo de agrupamento hierárquico aglomerativo de Ward (WARD JR, 1963), com a inclusão de restrições para possibilitar a implantação prática das ZM definidas. Apesar de possuir custo computacional quadrático, esse algoritmo é determinístico e fornece ao usuário uma árvore contendo uma série de possíveis agrupamentos, com diferentes quantidades de grupos, conhecida como dendrograma. A heurística de construção do dendrograma consiste na fusão dos dois grupos mais similares em cada nível. A medida de similaridade utilizada pelo algoritmo de Ward é baseada no aumento do erro quadrático médio, ou seja, em cada passo de construção do dendrograma, os grupos mais similares e, portanto, que deverão ser fundidos, são aqueles cuja fusão proporciona o menor aumento do erro quadrático médio (ou da variabilidade) do agrupamento como um todo. O dendrograma resultante proporciona ao usuário escolher a quantidade de grupos ou ZM que seja mais adequada para a sua aplicação, realizando cortes. A abordagem utilizada neste trabalho inclui restrições espaciais ao algoritmo de Ward, considerando a disposição das amostras no mapa, para reduzir a possibilidade do surgimento de ZMs muito pequenas e ineficazes na prática.

O processo de delineamento de ZM para este trabalho foi realizado com o objetivo de definir regiões distintas para a execução de experimentação *on-farm* para a safra do algodão de 2020. Esse tipo de experimentação consiste em definir, dentro da área total do talhão, ou, quando possível, dentro de cada ZM, parcelas virtuais de mesma área e que permitam a utilização de diferentes doses com repetições para aplicações com diferentes taxas de, por exemplo, população (taxa de sementes no plantio), adubação nitrogenada de cobertura e regulador de crescimento. Todos esses procedimentos devem ser realizados conforme o planejamento da própria propriedade, e com os equipamentos disponíveis. As variações de taxas e doses a serem aplicadas são previamente definidas, considerando como testemunha a dose padrão que já é utilizada na propriedade. Ao final da experimentação, é esperado o estabelecimento de recomendações (curvas de resposta) de dose de população e aplicação de insumos para a área de estudo, considerando a resposta fornecida pela cultura por meio da produtividade obtida.

RESULTADOS E DISCUSSÃO: Com os dados referentes aos sete atributos distribuídos na mesma grade, foi obtido um total de 10.701 amostras com resolução espacial de 10 m. Dados estatísticos referentes a esses atributos (TABELA 1) mostram que o coeficiente de variação do NDRE é em geral maior do que do NDVI tendo, portanto, maior potencial de explicar a resposta da cultura, como pode ser verificado pelos maiores coeficientes de determinação R^2 obtidos, dentre os atributos correlacionados com a produtividade (coluna R^2 -Prod).

TABELA 1. Dados estatísticos referentes aos atributos utilizados para o delineamento de ZM por agrupamento de dados. Valores referentes aos dados ajustados em grade com 10 m de resolução espacial. A coluna R^2 -Prod representa o coeficiente de determinação do atributo em questão com relação à produtividade.

Atributo	Data	Estatística				
		Média	Variância	Desvio Padrão	Coef. Variação	R ² -Prod
CEa – 30 cm (mS/m)	Jan/2019	2,72	0,43	0,65	24,03	0,02
CEa – 90 cm (mS/m)	Jan/2019	0,55	0,35	0,59	106,56	0,18
NDVI-1	Mai/2019	0,87	0,006	0,08	8,87	0,20
NDRE-1	Mai/2019	0,47	0,002	0,05	10,12	0,35
NDVI-2	Jun/2019	0,85	0,005	0,07	8,64	0,11
NDRE-2	Jun/2019	0,37	0,005	0,07	19,90	0,26
Produtividade (ton/ha)	Ago/2019	3,40	0,40	0,63	18,68	-

Visando reduzir a possibilidade do surgimento de ZMs com área muito pequena e de difícil operacionalização na prática para a experimentação *on-farm*, foi utilizada uma metodologia de inicialização dos agrupamentos hierárquicos, conhecida como tesselação inicial (RUB e KRUSE, 2011). Esse procedimento leva em conta o princípio básico da geoestatística em considerar que amostras espacialmente próximas tendem a possuir características de solo e planta semelhantes. Sendo assim, o conjunto de 10.701 amostras foi dividido inicialmente em 200 grupos, a partir de algoritmo de agrupamento particional com inicialização não-aleatória (LLOYD, 1982) e utilizando como dados de entrada as coordenadas de latitude e longitude de cada amostra. Em seguida, utilizando como ponto de partida esse primeiro agrupamento gerado, a abordagem de agrupamento descrita na sessão anterior foi executada. Como resultado, foi gerado um dendrograma contendo outros 198 agrupamentos, onde a quantidade de grupos variou de 199 até 2. Para o contexto de delineamento de ZM, e considerando o mapa gerado de forma manual (FIGURA 5), decidiu-se pela realização de cortes no dendrograma resultante para os níveis de 2 a 5 grupos, gerando quatro mapas de ZM distintos. Em seguida, foi realizada uma análise utilizando o critério de validação interna da largura de silhueta (ROUSSEEUW, 1987), como uma tentativa de identificar qual desses mapas e, conseqüentemente, qual a quantidade de ZMs seria a mais indicada, considerando a coesão e a separação dos grupos gerados (FIGURA 7).




FIGURA 7. Critério da largura de silhueta aplicado nos 4 agrupamentos distintos gerados (de 2 a 5 ZMs).

Da maneira como os resultados estão exibidos na FIGURA 7, o critério da largura de silhueta permite uma análise relativa entre as quantidades de ZM pretendidas. No caso desse critério, os maiores índices indicam uma possibilidade maior de grupos mais coesos e bem separados e, portanto, se levarmos em consideração apenas esse resultado, o mapa contendo 2 ZM seria o mais indicado. Complementarmente, o valor da largura de silhueta para o mapa com 5 ZM delineado manualmente foi de -0,04 e, portanto, muito próximo ao valor (também negativo) obtido pelo mapa de 5 ZM delineado pela abordagem de agrupamento. Valores negativos para esse critério indicam que pode existir uma grande sobreposição de grupos, e que amostras alocadas em um determinado grupo poderiam proporcionar melhores resultados se tivessem sido alocadas em grupos

vizinhos. Adicionalmente, e até como forma de comprovar o resultado fornecido por esse critério, foram obtidos os valores médios de cada atributo em cada ZM, considerando os quatro mapas gerados pela abordagem de agrupamento e o mapa contendo 5 ZM, gerado manualmente (TABELA 2).

TABELA 2. Valores médios de cada atributo para cada ZM nos quatro mapas gerados por abordagem computacional de agrupamento de dados e no mapa gerado manualmente.

Atributo	Agrupamentos (valores médios)																			
	2 ZM		3 ZM			4 ZM				5 ZM				5 ZM - Manual						
	1	2	1	2	3	1	2	3	4	1	2	3	4	5	1	2	3	4	5	
CEa-30	2,39	3,03	2,39	3,11	2,92	2,39	3,11	2,91	2,36	2,38	3,11	2,92	2,40	2,36	3,14	3,28	2,51	2,35	2,61	
CEa-90	0,36	0,72	0,36	0,71	0,73	0,35	0,72	0,73	0,55	0,35	0,72	0,72	0,33	0,56	0,81	0,74	0,33	0,27	0,67	
NDVI-1	0,84	0,89	0,85	0,89	0,89	0,85	0,89	0,89	0,80	0,84	0,89	0,89	0,87	0,80	0,89	0,89	0,81	0,86	0,86	
NDRE-1	0,45	0,50	0,45	0,50	0,49	0,46	0,50	0,49	0,44	0,45	0,50	0,49	0,47	0,44	0,50	0,50	0,43	0,46	0,47	
NDVI-2	0,82	0,88	0,82	0,88	0,87	0,82	0,88	0,87	0,77	0,82	0,88	0,87	0,84	0,77	0,88	0,88	0,79	0,84	0,84	
NDRE-2	0,33	0,40	0,33	0,40	0,40	0,33	0,40	0,40	0,28	0,33	0,40	0,40	0,34	0,28	0,41	0,41	0,28	0,34	0,37	
Prod.	2,98	3,78	2,98	4,02	3,47	3,02	4,02	3,47	2,40	2,98	4,02	3,47	3,15	2,40	3,89	3,92	3,03	3,21	3,06	

Na TABELA 2, é possível observar que o mapa com 2 ZM mostra valores médios bem distintos entre as duas ZM considerando todos os atributos e, principalmente, para os valores de produtividade. Já para o mapa com 3 ZM, é possível observar que as médias obtidas para as ZMs 2 e 3 são relativamente próximas, não sendo de interesse prático essa separação. Por conta disso, essas 2 ZM foram fundidas pela abordagem computacional durante a formação do mapa contendo 2 ZM. Para os mapas contendo 4 e 5 ZM, algumas ZMs mostraram valores médios de produtividade também muito próximos e, considerando os outros atributos, até valores coincidentes em alguns casos. Essa proximidade de valores médios dificulta a separação dos grupos por parte da abordagem de agrupamento, gerando índices mais baixos para o critério da largura de silhueta, conforme a quantidade de ZMs aumenta. [CV1] Essa dificuldade também pode ser observada para o mapa de ZM delineado manualmente, principalmente entre as ZMs 1 e 2 e ZMs 4 e 5. A partir dessa análise complementar, entende-se que o mapa contendo 2 ZM é a melhor alternativa, dentre as que foram apresentadas, para a implementação da experimentação *on-farm* para essa área. A análise visual dos mapas de ZM obtidos (FIGURA 8) também é importante nesse contexto, para que seja avaliada a potencialidade de cada um em estabelecer ZMs capazes de atender aos requisitos da experimentação *on-farm*.




FIGURA 8. Mapas de ZM para o planejamento de experimentação *on-farm* contendo (a) 2 ZM e (b) 3 ZM,

geradas a partir da abordagem de agrupamento e os sete atributos da TABELA 1; e (c) 5 ZM, geradas manualmente pelo usuário, considerando os atributos CEa-30, CEa-90 e NDVI-1 da TABELA 1.

O mapa contendo 3 ZM (FIGURA 8b) mostra que a ZM 3 foi particionada em 5 regiões espacialmente disjuntas. A menor dessas regiões possui cerca de 1,5 ha de área, o que inviabilizaria a experimentação *on-farm* pretendida. Na prática, em uma experimentação desse tipo é importante distribuir, em cada ZM, parcelas virtuais com pelo menos três diferentes taxas de aplicação de insumos com repetições. Desse modo, ZMs ou partições de ZMs muito pequenas devem ser evitadas. Ainda com relação a esse mesmo mapa, deve ser considerada também a proximidade de valores médios para os atributos entre as ZMs 2 e 3, conforme já exemplificado na TABELA 2, o que proporcionou a fusão dessas duas ZM por parte da abordagem de agrupamento utilizada, resultando no mapa da FIGURA 8a. É possível verificar também semelhanças entre os mapas das figuras 8a e 8c. Considerando os dados de produtividade da TABELA 2, as ZMs 3, 4 e 5 e as ZMs 1 e 2 do mapa da FIGURA 8c poderiam ser fundidas em apenas duas ZMs, renomeadas, respectivamente, como ZM1 e ZM2. Nesse caso, a área da nova ZM1 (composta pelas ZMs 3,4 e 5 da Figura 8c) representaria cerca de 92% da área total da ZM1 do mapa da Figura 8(a); e a área da nova ZM2 (composta pelas ZMs 1 e 2 do mapa da Figura 8c) representaria cerca de 60% da área da ZM2 do mapa da FIGURA 8a. Essas diferenças se devem principalmente aos ajustes automáticos realizados pela abordagem de agrupamento e a utilização de outros cinco atributos adicionais em relação aos que foram utilizados para o delineamento manual. Considerando o mapa de 2 ZM exibido na FIGURA 8a, a experimentação *on-farm* para duas intervenções com aplicação de insumos de cobertura foram então planejadas para a safra do algodão de 2020 (FIGURA 9).

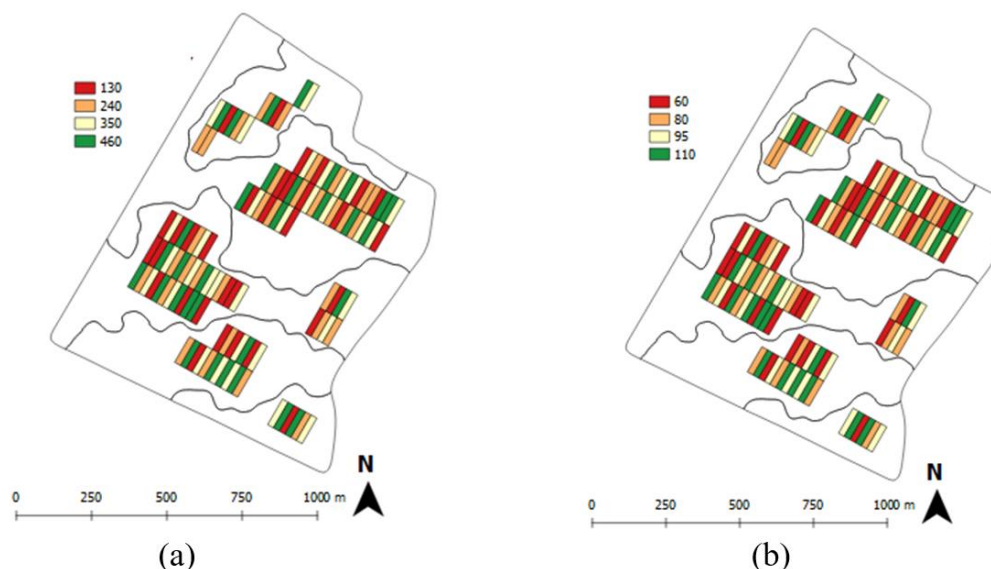


FIGURA 9. Planejamento de experimentação *on-farm* considerando ZMs e a aplicação de adubação de cobertura de (a) : (a) composto NPK (nitrogênio, fósforo e potássio) (a); e (b) ureia (b). Valores em kg/ha.

Para ambas as intervenções, foram definidos quatro níveis de taxas de aplicação, com quatro repetições distribuídas em cada ZM, totalizando 128 parcelas de aproximadamente 0,22 ha cada. O objetivo principal dessas intervenções é de identificar, para cada ZM, a resposta da cultura com relação aos diferentes níveis de insumo aplicados e, conseqüentemente, gerar recomendações de adubação por ZM, inicialmente para a área em específico, mas que, posteriormente, possa servir para outras áreas com características semelhantes. Em resumo, este trabalho mostrou que é possível delinear bons mapas de ZM manualmente, principalmente quando se tem uma área onde a variabilidade espacial tanto do solo quanto da cultura é bastante evidente. Entretanto, quando a quantidade de atributos aumenta, mesmo com essas evidências de localização, a tarefa se torna complexa e praticamente impossível de ser realizada sem o auxílio de algoritmos computacionais. No caso dessa área, a utilização de mais atributos adicionais e da abordagem de agrupamento computacional possibilitaram a obtenção de ZMs mais coesas e bem separadas, eliminando questões subjetivas que são naturais de uma análise manual.

CONCLUSÃO: Este trabalho descreveu o processo de delineamento de ZM realizado em um talhão experimental de produção de algodão localizado em Sapezal-MT. Esse delineamento teve como objetivo

auxiliar na estratégia de planejamento de uma experimentação *on-farm* para aplicação de adubação nitrogenada de cobertura em diferentes datas. Como trabalho futuro, será realizado o acompanhamento do crescimento da cultura e os efeitos causados pelas diferentes doses de aplicação de NPK e ureia, realizados de maneira equivalente nas 2 ZM identificadas. Para esse acompanhamento, serão avaliados, dentre outros atributos, imagens multiespectrais de sensoriamento remoto e suborbital; características físicas e de pedologia do solo; regiões com infestações de nematoides; e a produtividade da safra de 2020. O principal objetivo dessa análise é que, ao final, sejam obtidas doses recomendadas de NPK e ureia para as 2 ZM utilizadas, visando o manejo sítio-específico desse talhão nas safras futuras utilizando as ferramentas e os conhecimentos gerados pela AP.

AGRADECIMENTOS:

Agradecemos às equipes técnicas e de gestão do Instituto Matogrossense do Algodão (IMAmt), em nome dos engenheiros agrônomos Amandio Pires Junior e Márcio de Souza; do grupo Amaggi, em nome do administrador Sergio das Chagas e da engenheira agrícola e ambiental Karinna Pinheiro de Oliveira; e da Embrapa Instrumentação, em nome do engenheiro elétrico e pesquisador Ladislau Marcelino Rabello, pelo suporte operacional e disponibilização dos dados coletados. Agradecemos também ao prof. Ricardo Ciferri, do DC/UFSCar, pelo apoio técnico-científico.

REFERÊNCIAS

ABRAPA. **Associação Brasileira dos Produtores de Algodão**. Disponível em: <<https://www.abrapa.com.br>>. Acesso em: 06 de abril de 2020.

BARNES, E. M. et al. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In: **Proceedings of the Fifth International Conference on Precision Agriculture, Bloomington, MN, USA**. 2000.

BERNARDI, A. C. de C. et al. (Ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. 596 p.

BEZDEK, J. C.; EHRLICH, R.; FULL, W. FCM: The fuzzy c-means clustering algorithm. **Computers & Geosciences**, v. 10, n. 2-3, p. 191-203, 1984.

BULLOCK, D.S. et al. The data-intensive farm management project: Changing agronomic research through On-farm precision experimentation. **Agronomy Journal**, v. 111, n. 6, p. 2736-2746, 2019.

CONAB. **Companhia Nacional de Abastecimento**. Boletim da Safra de Grãos. Disponível em: <<https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>>. Acesso em: 03 de abril de 2020.

CÓRDOBA, M. al. Subfield management class delineation using cluster analysis from spatial principal components of soil variables. **Computers and electronics in agriculture**, v. 97, p. 6-14, 2013.

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

FUNDAÇÃO MT. **Produtores de algodão enfrentam cenário desafiador com preços baixos e custo de produção elevado**. Disponível em <<https://www.fundacaomt.com.br>>. Acesso em: 03 de abril de 2020.

GAVIOLI, A. et al. Optimization of management zone delineation by using spatial principal components. **Computers and Electronics in Agriculture**, v. 127, p. 302-310, 2016.

KITCHEN, N. R. et al. Delineating productivity zones on claypan soil fields using apparent soil electrical conductivity. **Computers and Electronics in Agriculture**, v. 46, n. 1-3, p. 285-308, 2005.

LI, Yan et al. Delineation of site-specific management zones using fuzzy clustering analysis in a coastal saline land. **Computers and Electronics in Agriculture**, v. 56, n. 2, p. 174-186, 2007.

LLOYD, S. Least squares quantization in PCM. **IEEE transactions on information theory**, v. 28, n. 2, p. 129-137, 1982.

MOLIN, J. P.; AMARAL, L.R.; COLAÇO, A. **Agricultura de precisão**. Oficina de Textos, 2015.

MORARI, F.; CASTRIGNANÒ, A.; PAGLIARIN, C. Application of multivariate geostatistics in delineating management zones within a gravelly vineyard using geo-electrical sensors. **Computers and Electronics in Agriculture**, v. 68, n. 1, p. 97-107, 2009.

ROUSE, J.W. et al. Monitoring vegetation systems in the Great Plains with ERTS. **NASA special publication**, v. 351, p. 309, 1974.

ROUSSEEUW, Peter J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. **Journal of computational and applied mathematics**, v. 20, p. 53-65, 1987.

RUB, G.; KRUSE, R. Exploratory hierarchical clustering for management zone delineation in precision agriculture. In: **Industrial Conference on Data Mining**. Springer, Berlin, Heidelberg, 2011. p. 161-173.

SHIRATSUCHI, L.S. et al. 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, and SSSA, 2019.

WARD JR, J. H. Hierarchical grouping to optimize an objective function. **Journal of the American statistical association**, v. 58, n. 301, p. 236-244, 1963.