

Estabilidade de unidades de gestão diferenciada ao longo das safras para diferentes culturas.

Palavras-Chave: Zona de manejo, Agricultura de precisão, Análise de agrupamento.

Autores:

MATEUS BORGES NACIBEN [UNICAMP]

Dr. HENRIQUE OLDONI (coorientador, pós-doutorando) [UNICAMP]

Prof. Dr. LUCAS RIOS DO AMARAL (orientador) [UNICAMP]

INTRODUÇÃO:

A agricultura de precisão (AP) permite analisar e gerenciar a variabilidade espacial das lavouras, visando o aumento da rentabilidade e a redução dos impactos ambientais (BANU, 2015). Um impasse enfrentado pela AP é a necessidade de uma densa base de dados, para se gerar um mapa que represente a realidade da área em análise (RODRIGUES JUNIOR et al., 2011). A partir de uma série de informações localizadas e ferramentas da AP são geradas as unidades de gestão diferenciadas (UGDs), também chamadas de zonas de manejo, as quais consistem na divisão da área em sub-regiões de acordo com combinações de fatores limitantes à produtividade (ALMEIDA et al., 2014).

As UGDs tratam a lavoura como grandes regiões com diferentes potenciais produtivos. Portanto, a estratégia mais eficiente para sua definição é a utilização de fatores que influenciem diretamente na produtividade da cultura (DOERGE, 2000), contendo informações acerca de diversas propriedades do solo e do terreno (SCHWALBERT et al., 2014). Destacam-se como camadas de informação para delimitação de UGDs os mapas de condutividade elétrica aparente e atributos físico-químicos do solo (ALVES et al., 2013), informações de relevo da área e os próprios mapas de produtividade (SCHWALBERT et al., 2014).

As características da cultura influenciam as delimitações das UGDs (DOERGE, 2000). Assim, podem ocorrer alterações de acordo com a mudança de cultura em uma área cultivada sob sistema de sucessão de culturas, já que os fatores limitantes à produtividade podem variar entre espécies de plantas ou materiais genéticos. Assim, a alteração das UGDs conforme a cultura e até mesmo ao longo das safras não é interessante, uma vez que ao ser realizado o manejo específico em cada UGD, este pode influenciar algum fator de produção que impactará na cultura seguinte.

Portanto o objetivo deste trabalho foi avaliar se a mesma delimitação de zonas de manejo pode ser utilizada para culturas diferentes e em diferentes anos. Para tanto, testamos duas formas de seleção de variáveis para o delineamento de UGDs em uma situação de sucessão de culturas soja-sorgo.

METODOLOGIA:

A área de estudo está localizada na Fazenda São José, município de Cosmópolis - SP. Possui 30 ha onde, a partir de 2019, iniciou-se o cultivo em sucessão entre soja e sorgo, com a cultura da soja cultivada no período da safra e o sorgo na entressafra (safrinha).

Em 2020, dados de solo foram coletados na área de estudo em uma malha amostral de 32 pontos georreferenciados na camada de 0 – 0,2 m de profundidade. Os pontos foram alocados seguindo distribuição otimizada com a função objetivo focando na manutenção da distância mínima entre pontos amostrados e locais de predição (WALVOORT, et al., 2010). Quatro subamostras por ponto foram coletadas no interior de um raio de 4 m do ponto georreferenciado para representar cada amostra composta. Atributos químicos e físicos do solo foram determinados; mas, como para a delimitação de UGDs é preconizado o uso de variáveis estáveis no tempo, utilizamos apenas a variáveis capacidade de troca catiônica (CTC) e teor de argila.

Além disso, foram coletados dados de condutividade elétrica aparente do solo (CEa) utilizando o sensor proximal EM38-MK2® (Geonics, Mississauga, Ontário, Canadá) na camada de 0 a 0,38 m de profundidade, com passadas a cada 30 m. Também utilizamos dados de elevação do terreno obtidos a partir de GNSS embarcado em colhedora, sendo que os atributos derivados do modelo digital de elevação (MDE) foram: declividade, curvatura geral, curvatura horizontal, curvatura vertical, aspecto e spi.

Em 2021 coletamos amostras indeformadas de solo nos mesmos pontos da amostragem de 2020, na profundidade central de 0,1 m por meio de anéis volumétricos para caracterização das propriedades físico-hídricas. Foram determinados os atributos: densidade do solo, resistência à penetração, porosidade total, macroporosidade, microporosidade e umidade na capacidade de campo.

Além desses dados, foram adquiridos os dados da produtividade do sorgo na safrinha de 2021 e da soja nas safras de 2020/21 e 2021/22, por meio de monitor de produtividade embarcado em colhedora combinada de grãos.

Os dados de CEa, de elevação e das produtividades foram submetidos ao procedimento de filtragem para remoção de outliers e inliers, seguindo o método apresentado por Maldaner et al. (2022).

Buffers de 16 m de foram gerados nos 32 pontos de amostragem do solo, dos quais no seu interior foram extraídos os valores registrados de produtividade, elevação e CEa, e determinada a média dessas variáveis em cada buffer. Além disso, nesses mesmos pontos foram extraídos os valores dos pixels dos atributos de terreno derivados do MDE. Deste modo, um conjunto de dados com 32 observações para cada atributo foi gerado.

Todos os atributos, exceto os extraídos do MDE, foram submetidos à análise geoestatística para interpolação dos mesmos com base nas recomendações de Oliver e Webster (2014).

Duas novas variáveis a partir dos dados de produtividade das três safras foram geradas: a média dos dados padronizados (média padronizada) e a primeira componente principal (PC1). Na primeira, cada variável de produtividade de 32 observações foi padronizada com média zero e desvio padrão um e, então, realizado a média dos três dados de produtividade para cada observação. Já na segunda abordagem os mesmos dados de produtividade padronizados das três safras foram submetidos à análise de componentes principais, sendo extraída os scores da primeira componente principal (PC1), já que apenas esta componente correspondeu a mais de 70% da variação total dos dados.

Uma matriz de correlação de Pearson dos 32 pontos foi gerada entre os dados de produtividade, média ponderada, PC1, atributos de solo e de terreno. Deste modo, foram selecionados dois grupos de variáveis para o delineamento das UGDs: as variáveis de solo e terreno correlacionadas à 1% de significância com a média padronizada; e as variáveis correlacionadas também à 1% de significância com a PC1.

Para a construção das UGDs, inicialmente os dados interpolados das variáveis selecionadas foram padronizados e submetidos à análise espacial multivariada baseada no índice de Moran e componentes principais (MULTISPATI-PCA) (DRAY et al., 2008). A partir disso, selecionamos as


componentes principais espaciais (sPC) que juntas somaram mais de 70% da variância total como variáveis de entrada para a análise de agrupamento fuzzy k-means (BEZDEK et al., 1984), seguindo recomendações de Córdoba et al. (2016). Testamos entre dois e cinco UGDs, dos quais foi escolhido o melhor número baseado em três funções: índice de desempenho fuzziness (FPI), entropia de partição modificada (MPE) e largura de silhueta (SW), em que quanto menor forem os valores de FPI e MPE e maior o valor de SW, maior será a qualidade dos agrupamentos gerados.

Por fim, foram avaliados e comparados os mapas de UGDs com base na Variância Reduzida (VR, %) (PING e DOBERMANN, 2003) dos dados de produtividade das três safras.

RESULTADOS E DISCUSSÃO:

Os atributos selecionados pelo método da sintetização das produtividades na PC1 para a delimitação das UGDs foram: elevação, CTC, densidade do solo e argila. Já para o método da média padronizada das produtividades foram: CTC e elevação (Tabela 1). Analisando as correlações individuais das produtividades (*dados não apresentados*), para a soja 2020/21 os atributos correlacionados foram CTC, argila, elevação e produtividade da soja 2021/22. Para a soja 2021/22 as variáveis obtidas foram: argila, elevação e produtividade da soja 2021/22, indicando boa estabilidade dos resultados para as duas safras de soja. Já no caso do sorgo 2021 não houve nenhum atributo correlacionado.

Para ambos os métodos de seleção de variáveis, o melhor número de UGDs foi duas, visto que duas das três funções adotadas indicaram a maior qualidade de agrupamentos quando dois grupos eram adotados (menor FPI e maior SW; FIGURA 1).



Matriz de correlação		
Variáveis	PC1	Méd. Pad
Elevação	-0,616**	0,451**
Declividade	0,190	-0,335
Curv. Geral	-0,093	0,155
Curv. Horizontal	-0,069	0,099
Curv. Vertical	-0,035	0,121
Aspecto	-0,389*	0,252
Spi	0,243	-0,340
CEa	-0,299	0,346
CTC	-0,517**	0,485*
Macroporosidade	-0,417*	0,309
Microporosidade	-0,340	0,248
RP	0,280	-0,158
Densidade	0,599**	-0,441*
Argila	-0,548**	0,384*
Sorgo 2021	-0,627	0,487
Soja 2020/21	-0,944	0,850
Soja 2021/22	-0,941	0,821

Tabela 1. Coeficiente de correlação para PCA e Média Padronizada.

* Significância de 0,05

** Significância de 0,01

Figura 1. Índice de desempenho fuzziness (FPI), entropia de partição modificada (MPE) e largura de silhueta (SW) para cada número de unidades de gestão diferenciada (UGDs) de acordo com o método de seleção utilizado.

Como o número de UGDs foi o mesmo e as variáveis selecionadas foram semelhantes, os mapas de UGDs foram similares para ambas as propostas de seleção (PC1 e média padronizada) (Figura 2).




Figura 2. Unidades de gestão diferenciada (UGDs) delimitadas.

Analisando a variância reduzida (VR) para ambos os mapas de UGDs (Tabela 2), é possível notar que o método de seleção pela média padronizada permitiu englobar melhor a variação da produtividade de soja (maiores valores de VR) quando em comparação ao método da PC1. Já para o sorgo os valores de VR foram bem baixos, mostrando que as duas UGDs criadas não representam seu comportamento. Porém, como nenhuma variável foi selecionada para representar o sorgo, esse resultado pode ser um simples artefato dos dados.

Variância Reduzida (VR)				
	Sorgo	Soja 2020/21	Soja 2021/22	Média
PC1	15,73	30,32	18,67	21,57
Méd. Pad.	10,06	31,13	22,09	21,09

Tabela 2. Variância reduzida.

Ao compararmos os mapas de produtividade das safras de soja 2020/21 e 2021/22 e da safrinha de sorgo de 2021 (Figura 3), observamos que os mapas de produtividade da soja foram parecidos, enquanto o mapa da produtividade do sorgo apresentou um comportamento espacial distinto. Ao comparar estes mapas (Figura 3) com os mapas de UGDs (Figura 2), verificamos que a UGD 1 coincidiu, em grande parte, com as regiões de baixa produtividade, enquanto a UGD 2 com áreas de maior produtividade. Isso ocorreu para os mapas de UGDs de ambos os métodos de seleção. Já no sorgo o comportamento não seguiu o padrão do delineamento das UGDs, portanto, a UGD delimitada para a soja pode não funcionar para o sorgo ao longo das safras.




Figura 3. Mapas de produtividade de soja e sorgo.

CONCLUSÕES:

Os métodos de seleção de variáveis utilizados nesta pesquisa não permitiram a criação de zonas de manejo que contemplassem a variação na produtividade para as culturas de soja e sorgo. Desse modo, o emprego de zonas de manejo em áreas com sucessão de culturas continua desafiador. Estudos futuros precisam contemplar outras formas de seleção de variáveis que busquem englobar o comportamento espacial de ambas as culturas.

BIBLIOGRAFIA

- ALMEIDA, A. C. S. et al. **Métodos para a definição de unidades de gestão diferenciada**. Congresso Brasileiro de Agricultura de Precisão. **Anais...**São Pedro, SP: set. 2014.
- ALVES, S. M. F. et al. Definição de zonas de manejo a partir de mapas de condutividade elétrica e matéria orgânica. **Bioscience Journal**, Uberlândia, v.29, n. 1, p. 104-114, 2013.
- BANU, S. Precision Agriculture: Tomorrow's Technology for Today's Farmer. **Journal of Food Processing & Technology**, v. 06, n. 08, 2015.
- BEZDEK, J.C., EHRLICH, R., FULL, W. FCM: the fuzzy c-means clustering algorithm. **Computers & Geosciences**, v. 10, p. 191–203, 1984
- CÓRDOBA, M. A. et al. Protocol for multivariate homogeneous zone delineation in precision agriculture. **Biosystems Engineering**, v.43, p. 95-107, fev. 2016
- DOERGE, T. A. **Management zone concepts. Site-Specific management guidelines**. 2000. Disponível em: <[https://www.ipni.net/publication/ssmg.nsf/0/C0D052F04A53E0BF852579E500761AE3/\\$FILE/SSMG-02.pdf](https://www.ipni.net/publication/ssmg.nsf/0/C0D052F04A53E0BF852579E500761AE3/$FILE/SSMG-02.pdf)>
- DRAY, S.; SAÏD, S.; DÉBIAS, F. Spatial ordination of vegetation data using a generalization of Wartenberg's multivariate spatial correlation. **Journal of Vegetation Science**, v. 19, n. 1, p. 45-56, 2008.
- MALDANER, L. F.; MOLIN, J. P.; SPEKKEN, M. Methodology to filter out outliers in high spatial density data to improve maps reliability. **Scientia Agricola**, v.79, n.1, p.1-7, 2022.
- OLIVER, M. A.; WEBSTER, R. A tutorial guide to geostatistics: Computing and modelling variograms and kriging. **Catena**, Grã-Bretanha, v. 113, p. 56–69, fev. 2014.
- 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.
- SCHWALBERT, R. A. et al. Zonas de manejo: atributos de solo e planta visando a sua delimitação e aplicações na agricultura de precisão. **Revista Plantio Direto**, p. 21–32, 2014.
- WALVOORT, D.J.J.; BRUS, D.J.; GRUIJTER, J.J.de. An R package for spatial coverage sampling and random sampling from compact geographical strata by k-means. **Computers & Geosciences**, v.36, n.10, p. 1261-1267, 2010.
- PING, J.L.; DOBERMANN, A. Creating spatially contiguous yield classes for site-specific management. **Agronomy Journal**, n.95, p. 1121-1131, 2003.