

Estudo de Caso 1 - Técnicas de Agricultura de Precisão para Criação de Zonas de Manejo Usando Sensores Proximais e Software R na Fazenda Pamplona, Cristalina, GO

Ronaldo Pereira de Oliveira
Ziany Neiva Brandão
Hugo Machado Rodrigues

Introdução

As características do solo devem ser conhecidas antes da semeadura. São informações essenciais para a tomada de decisão na aplicação de corretivos, fertilizantes e fornecimento de água, visando ao alcance da produtividade desejada. As características físicas do solo, quando combinadas aos elementos químicos, ou seja, macronutrientes, micronutrientes, pH, matéria orgânica e teores de alumínio, são responsáveis pelo comportamento das interações dentro do solo, que, em última instância, são determinantes à produtividade das culturas (Raij, 2011; Brandão et al., 2015; Meneghetti, 2018).

Na Agricultura de Precisão (AP), a tomada de decisão vem sendo facilitada por meio do mapeamento de subáreas que possuem características similares dentro de um talhão agrícola, conhecidas como Zonas de Manejo (ZMs). Essas ZMs possuem menor variabilidade espacial de alguns atributos do solo e podem receber um tratamento uniforme. Um talhão assim subdividido facilita a gerência de insumos que podem ser aplicados por meio de mapas de prescrição produzidos após avaliação dos principais fatores que afetam a produtividade naquela área. Após criados, esses mapas são então instalados em tratores e pulverizadores adequados para aplicação em taxa variada (ATV) de insumos. As tarefas de identificação e separação dessas áreas heterogêneas na fazenda podem ser feitas por meio do uso de sensores orbitais e proximais. Esses permitem a identificação da variabilidade espacial tanto do solo como da cultura e seus usos vêm se tornando cada vez mais comuns entre os produtores, pela facilidade de geração de mapas de aplicação de insumos que estejam bem correlacionados às variáveis que foram obtidas pelos sensores.

Na AP, dentre as diferentes técnicas de amostragem, destacam-se os dispositivos que podem mensurar a condutividade elétrica aparente do solo (CEa), pela rapidez e capacidade de obtenção de elevado número de amostras em campo, além de fornecer medições com correlações altas com teores de argila (Williams; Hoey, 1987; Matias et al., 2015), disponibilidade de água no solo (Kachanoski et al., 1990), capacidade de troca catiônica e teores de cálcio e magnésio trocáveis (McBride et al., 1990), teor de matéria orgânica (Jaynes, 1996; Kravchenko; Bullock, 1999), teor de sais da solução do solo, pH, cálcio e CTC (Brandão et al., 2011; Söderström et al., 2016) dentre outros atributos (Minasny; Hartemink, 2011; Piikki et al., 2016; Söderström et al., 2016; Babaeian et al., 2019).

A condutividade elétrica aparente do solo (CEa) é expressa em milisiemens/m ($mS m^{-1}$) e informa a capacidade do solo em conduzir corrente elétrica, sendo esse um parâmetro facilmente obtido em laboratório para amostras de solo. A CEa está intrinsecamente relacionada à salinidade e a umidade do solo, tendo sido relacionada ao pH, matéria orgânica e capacidade de troca catiônica em muitos estudos (Piikki et al., 2016; Söderström et al., 2016).

Outro atributo eletromagnético mensurado por sensores geofísicos que também tem recebido destaque na AP é a suscetibilidade magnética aparente (SMA), que também é medida pelo mesmo equipamento usado na medição da condutividade elétrica aparente do solo (CEa), o EM38®.

Esse atributo mensura a presença de materiais metálicos e reflete, em geral, valores medidos por unidade de volume de solo (Heil; Schmidhalter, 2019). Entretanto, os valores da SMA medidos com o EM38® são dados definidos como a razão entre os campos magnéticos dos circuitos primário e secundário, sendo, assim, uma medida adimensional. De acordo com Heil e Schmidhalter (2019), a susceptibilidade magnética é influenciada por alguns óxidos e hidróxidos, por matéria orgânica no solo, que elevam a temperatura do mesmo, bem como pelo intemperismo que gera decomposição de rochas e aumento de metais no solo. A SMA é mais sensível à camada superficial do solo devido ao manejo do mesmo, e, por isso, áreas cultivadas tendem a apresentar valores mais elevados dessa variável quando comparados às áreas sem a presença da ação humana (Matias et al., 2015; Heil; Schmidhalter, 2019).

Na agricultura, a SMA tem apresentado boas correlações e potencial para identificação de diferentes tipos de solos (Söderström et al., 2016), na delimitação de compartimentos da paisagem (Santos et al., 2011; Matias et al., 2015), na identificação da correlação com atributos químicos para fertilização (Becegado; Ferreira, 2005; Zawadzki et al., 2012) e também para predição de atributos como textura, umidade gravimétrica e CTC (Heil; Schmidhalter, 2019; Vasques et al., 2020). Assim, os atributos CEa e SMA podem ser facilmente determinados com equipamento não-invasivo como o EM38® (Geonics), que permite obter medidas de até 80 hectares em um dia, dependendo das condições de medição (Söderström et al., 2016; Heil; Schmidhalter, 2017).

Para auxiliar o mapeamento de ZMs é possível lançar mão de dados que reflitam a topografia da área em avaliação. Esses dados estão disponíveis, gratuitamente, na resolução de 12,5 metros, para todo o globo terrestre, por meio da iniciativa da empresa americana Alaska Satellite Facility (2022). Esses dados são uma representação do relevo e são descritos como modelos digitais de elevação (MDE). Um MDE também pode ser criado a partir do uso de aeronaves não tripuladas (drones) ou por levantamento de cotas altimétricas por meio de uma equipe especializada. No entanto, essas duas últimas abordagens necessitarão de terceirização de serviços, que por vezes é demorada ou cara. Em contrapartida, o resultado, quando utilizados os dados oriundos de campanhas de campo para levantamento topográfico, refletem em um MDE com melhor resolução espacial. No presente trabalho, foram usados dados do MDE obtidos no site da ALOS PALSAR (Alaska Satellite Facility, 2022), que dimensiona as alterações de relevo na área de estudo, em conjunto com os dados mensurados por sensores proximais para identificação das propriedades do solo em duas profundidades distintas.

Assim, o objetivo geral deste trabalho foi avaliar três técnicas de delineamento de ZMs, tendo como foco a melhoria da produtividade do algodoeiro em um sistema de produção comercial. As três técnicas de obtenção das ZMs aqui utilizadas foram: 1) a partir da combinação de dados de EM38® e MDE; 2) a partir do primeiro componente da análise de componentes principais (PCA), utilizando os dados de EM38® e MDE; e 3) usando mapas espacializados de alguns atributos do solo, coletados em campo após a medição com o sensor EM38. Foram mapeados, para este trabalho, os teores de areia e argila, bem como nutrientes como: N, P, K, Ca, e Mg, obtidos de amostras compostas e medidas em laboratório. O mapa de produtividade do algodoeiro, obtido durante a colheita, foi utilizado como referência para avaliação das três metodologias.

Apresenta-se, a seguir, um aprimoramento na estratégia de criação de ZM realizada em condições de campo dentro de um talhão na Fazenda Pamplona, localizada em Cristalina, GO, para a safra do algodão 2019.

Material e Métodos

Localização e cultura

O trabalho foi conduzido na Fazenda Pamplona, localizada no município de Cristalina, GO, em área experimental de 27,2 ha, cujas coordenadas centrais são 16°15' 23"S, 47°38'13"W. Os solos da região são, predominantemente, Latossolos vermelho-amarelos, argilosos, com altitude média na área experimental de 970 m. O período chuvoso vai de outubro a março e, durante o ciclo da cultura, que foi de dezembro de 2018 até junho de 2019, foram registrados 670,5 mm de chuva, que foi cerca de metade da pluviometria média anual para a área, embora em novembro de 2018, quando da medição com os sensores em campo, a pluviometria registrada foi de 254,4 mm no mês. Antes do preparo do solo para instalação do experimento, foram escolhidos 16 pontos para coleta de solo e análise laboratorial. Esses pontos consideraram a variação da produtividade observada nos mapas de anos anteriores, para a soja e algodão na área escolhida, conforme apresentados na Figura 1. Os pontos centrais foram previamente marcados e georreferenciados utilizando o GPS 76CSx da Garmin.



Figura 1. Imagem aérea do cultivo com soja em 2018 (A) e mapa de produtividade do algodão na safra 2017 (B), no Talhão G, Fazenda Pamplona, Cristalina, GO.

Fonte: Arquivo SLC Agrícola (B).

Coleta de dados de solo para mapeamento e análises de laboratório

Foram coletadas oito subamostras de solo na profundidade de 0-20 cm, em torno de cada ponto central georreferenciado, e o material foi levado ao Instituto Brasileiro de Análise (IBRA) para realização das análises dos atributos químicos e físicos do solo. As metodologias de quantificação dos teores desses atributos do solo foram as mesmas utilizadas por Tedesco et al., (1995) e Claessen (1997).

Os 16 pontos georreferenciados de N, P, K, Ca, Mg, CTC, pH, areia e argila foram avaliados quanto à distribuição de frequência dos valores para caracterização espacial. Em seguida, foram ajustados semivariogramas para cada um desses, com exceção do Ca e P que não apresentaram dependência espacial adequada e foram mapeados por meio do espacializador IDW (do inglês *Inverse Distance Weighted*) (Isaaks; Srivastava, 1989). Todos os outros atributos foram mapeados com

resolução final de 5 m por meio de *krigagem* (método utilizado em geoestatística para interpolar dados) ordinária utilizando a função *krige* presente no pacote *gstat* (Gräler et al., 2016) disponível para o software *R* (R Foundation..., 2021). Esses mapas foram avaliados quanto à acurácia utilizando-se o método de validação cruzada *leave-one-out*, que é útil quando não existem muitos pontos disponíveis para confecção do mapa.

Coleta de dados com sensores proximais

A Condutividade Elétrica (CEa) e a Suscetibilidade Magnética do Solo (SMa) foram quantificadas por meio do sensor de indução eletromagnética EM38-MK2® (Figura 2), da Geonics®, que registra a CEa (mS m^{-1}) em duas profundidades simultaneamente, utilizando um conjunto de três bobinas, bem como os valores proporcionais para a suscetibilidade magnética aparente (SMa).



Figura 2. Sensor de indução eletromagnética EM38®. Fazenda Pamplona, Cristalina, GO.

A configuração das bobinas, para esse experimento, usou distanciamento de 1 m e 0,5 m. A configuração de 1 m de distância entre as bobinas representa um valor de volume do solo de, aproximadamente, 0,75 m a 1 m, enquanto a distância 0,5 m representa leituras de um volume de solo mais raso (0,05 m a 0,75 m). Por isso, os atributos de condutividade elétrica e de suscetibilidade magnética medidos pelo sensor são descritos como sendo aparentes, denominados aqui como CEa e SMa, respectivamente, pois representam valor referente a um volume de solo (Heil; Schmidhalter, 2017; Geonics, 2021).

O equipamento foi adaptado a uma caminhonete e as medidas foram coletadas e armazenadas, tendo sido georreferenciadas por um GPS Trimble®. Os dados obtidos foram de latitude, longitude e elevação (m), além dos valores da SMa e CEa do solo (milisemens por metro, mS m^{-1}) nas duas profundidades, ou seja, 0,5 m e 1 m, coletados a intervalos de um segundo, sendo registrado também o número de observações de cada medida. As medidas de CEa e SMa foram realizadas em toda a área de estudo, sobrepondo inclusive os pontos de coleta das amostras do solo descritas na seção anterior.

Mapeamento dos dados de sensores proximais

Para o mapeamento dos dados medidos pelo sensor EM38®, os dados de CEa e SMA foram avaliados quanto à distribuição dos valores para teste de normalidade utilizando visualização dos histogramas. Em seguida, foram ajustados semivariogramas (representação gráfica da variação de um conjunto de dados em relação à distância indicando ou não a existência de variabilidade espacial, segundo Grego et al., 2014) experimentais e empíricos para caracterização da dependência espacial das variáveis quantificadas pelo sensor, utilizando-se as funções presentes no pacote *gstat* do software R®. Depois dos semivariogramas ajustados, utilizou-se o método de interpolação de *krigagem* ordinária utilizando a função *krige* presente no pacote supracitado, com a resolução do mapa de saída em 5 m. (Guastaferrero et al., 2010). Para avaliação dos mapas produzidos, foram selecionados, aleatoriamente, 500 pontos de CEa e SMA e reservados para validação externa dos mapas de sensores proximais produzidos.

Colheita e mapa de produtividade

A produtividade do algodão foi avaliada com colheita mecanizada, utilizando a colhedora de algodão modelo John Deere® CP690 (John Deere, 2021), que possui sistema GreenStar® HarvestDoc® integrado. Esse sistema é composto de sensor de rendimento do tipo fluxo ultrassônico, monitor de dados (Monitor GreenStar™ 2), cartão de armazenamento de dados (Keycard) e antena receptora de Sistema de Posicionamento Global (GPS) com sinal diferencial e receptor StarFire™. Os dados de produtividade, latitude, longitude e altitude (m) foram gravados em intervalos de 3 segundos. A avaliação inicial dos dados foi feita usando o software APEX® (John Deere, 2021) e exportados em formato *shapefile* para tratamento, limpeza e filtragem.

A partir dos dados da colhedora, foi possível confeccionar o mapa de produtividade do algodão. Para isso foram utilizados 100 pontos de amostragem na safra de 2019, distribuídos em toda a área de estudo. Da seleção de pontos de medição da produtividade foram escolhidos, aleatoriamente, 70 para definição e ajuste da estrutura espacial usando geoestatística. A partir desses 70 pontos, foram criados semivariogramas e realizada a espacialização dos dados por meio de *krigagem* ordinária (função *krige*) com resolução final de 5 m. Por fim, os 30 pontos de produtividade restantes foram usados para avaliação da acurácia do mapa gerado por *krigagem* ordinária.

Modelo Digital de Elevação (MDE)

Para representação da geomorfologia da área de estudo, foi selecionado o modelo digital de elevação (MDE) gratuitamente disponível no site da agência americana *Alaska Satellite Facility* com resolução final de 12,5 m (Alaska Satellite Facility, 2022).

Criação das Zonas de Manejo

Considerando as medidas obtidas nas duas profundidades do sensor proximal, para o trabalho foram usadas mais nove variáveis, além dos quatro mapas derivados do sensor EM38®, que foram confeccionados a partir do método de *krigagem* ordinária. Foram utilizados os mapas do MDE, N, P, K, Ca, Mg, CTC, argila e areia, bem como o mapa da produtividade do algodoeiro, totalizando 13 covariáveis para definição de ZMs a partir das diferentes abordagens descritas no objetivo deste trabalho. Apesar do pH ter sido mapeado, esse não foi utilizado para definição de ZM.

A partir dessas 13 covariáveis, foi utilizado o algoritmo de agrupamento por meio da função *k-means* presente nativamente no software R. O número ótimo de zonas de manejo pode ser avaliado segundo metodologias estatísticas diversas, tal como o método da “silhueta” (*silhouette*). Compararam-se os números de clusters sugeridos pelo método *silhouette* a partir da avaliação do índice de Calinski-Harabasz (Calinski, Harabasz, 1974). Esse último método mensura a variação de todos os centróides de cada agrupamento, a partir do centróide do conjunto de dados completo. O índice Calinski-Harabasz considera que o número de agrupamentos ideal é aquele que apresenta o maior valor de proporção. De acordo com este método, o número ótimo de zonas de manejo foi determinado entre quatro e cinco. Assim, para efeitos práticos de implantação na área pelos agricultores, definiu-se como sendo quatro um número plausível para operação; portanto, esse número de ZM pode ser interpretado como relativo ou subjetivo, uma vez que varia considerando a extensão da área de estudo e a viabilidade na sua implantação.

O mapa de produtividade via *krigagem* ordinária foi utilizado como referência para avaliação dos métodos de definição de ZM, que foram: a) ZM somente usando os quatro mapas do EM38®, mapa de elevação digital (MDE) e o mapa de produtividade via *kmeans*; b) ZM utilizando o primeiro componente da análise de componentes principais (*PCA*, *Principal Componente Analysis*) usando os quatro mapas do EM38®, o MDE e o mapa de produtividade; e c) ZM a partir dos oito mapas de dados de atributos do solo analisados em laboratório.

Para verificação da razoabilidade e da eficiência das zonas de manejo definidas a partir das informações obtidas pelos mapas de covariáveis, foram utilizados os 100 pontos de produtividade de algodão distribuídos pela área de estudo, obtidos da safra de 2019. Cada ponto de produtividade recebeu uma classe de ZM referente às zonas distintas pelos métodos descritos acima. A variância da média da produtividade de cada classe foi comparada pelo método de análise de variância via função AOV nativamente presente no software R.

Resultados e Discussão

Estatísticas e espacialização

Os dados das amostras de solo apresentaram distribuição próxima à normalidade e seus histogramas são apresentados na Figura 3.

Os dados de sensores apresentaram distribuição próxima à normalidade, embora a distribuição da frequência tenha indicado maior ocorrência dos valores à esquerda do gráfico (Figura 4A) para os dados obtidos pelo EM38-MK2. Segundo Yamamoto e Landim (2013), não há necessidade de conversão dos dados caso esse comportamento ocorra. Os semivariogramas ajustados para cada uma das propriedades medidas pelo sensor proximal podem ser observados na Figura 4B. Os semivariogramas experimentais ajustados para cada um dos atributos avaliados podem ser observados na Figura 5.

Os parâmetros de ajustes dos atributos de solo e dados dos sensores são observados na Tabela 1. Foi possível observar que os dados das amostras de solo apresentaram valores de alcance, ou seja, a distância máxima de dependência espacial, em torno de 120 m. Por sua vez, nos dados do EM38®, os valores de alcance, que representam a distância na qual os atributos não apresentaram dependência, estiveram entre 400 m e 500 m, com exceção do atributo CEa 1 m, que apresentou dependência de 150 m, aproximando-se aos valores dos obtidos para os dados das amostras de solo, indicando possível concordância entre dados do sensor e aqueles das amostras laboratoriais.

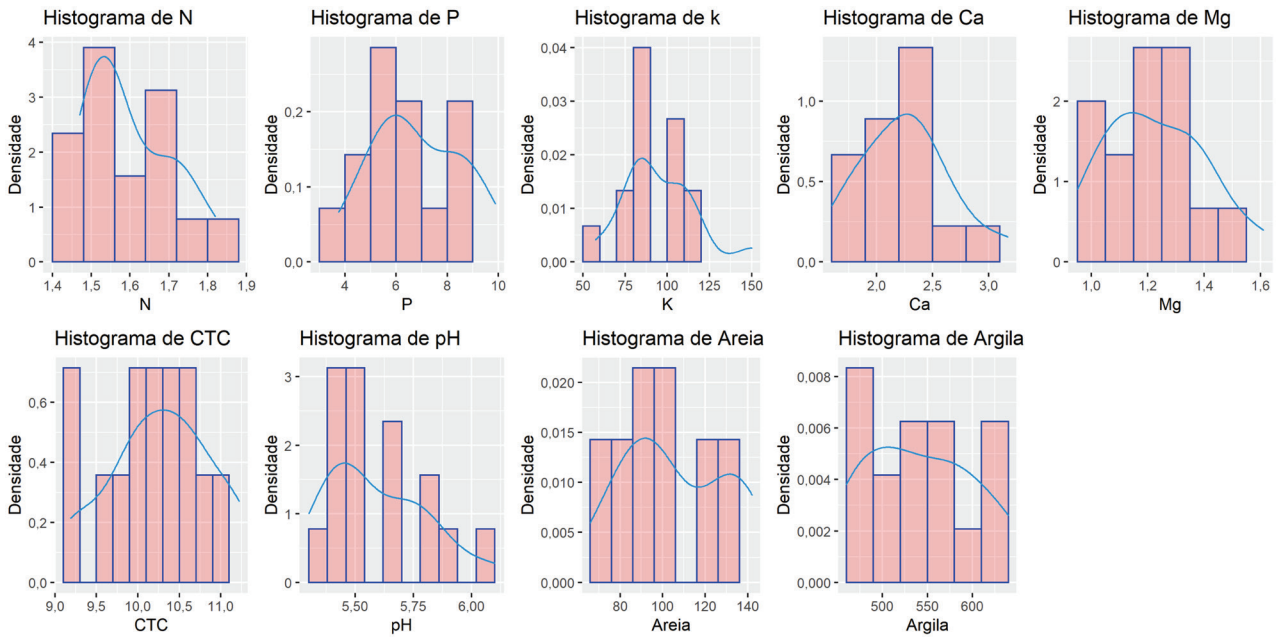


Figura 3. Histograma de distribuição de frequência para os atributos químicos e físicos do solo obtidos no campo, talhão G, Fazenda Pamplona, Cristalina, GO. N: nitrogênio; P: fósforo; K: potássio; Ca: cálcio; Mg: magnésio; CTC: capacidade de troca de cátions.

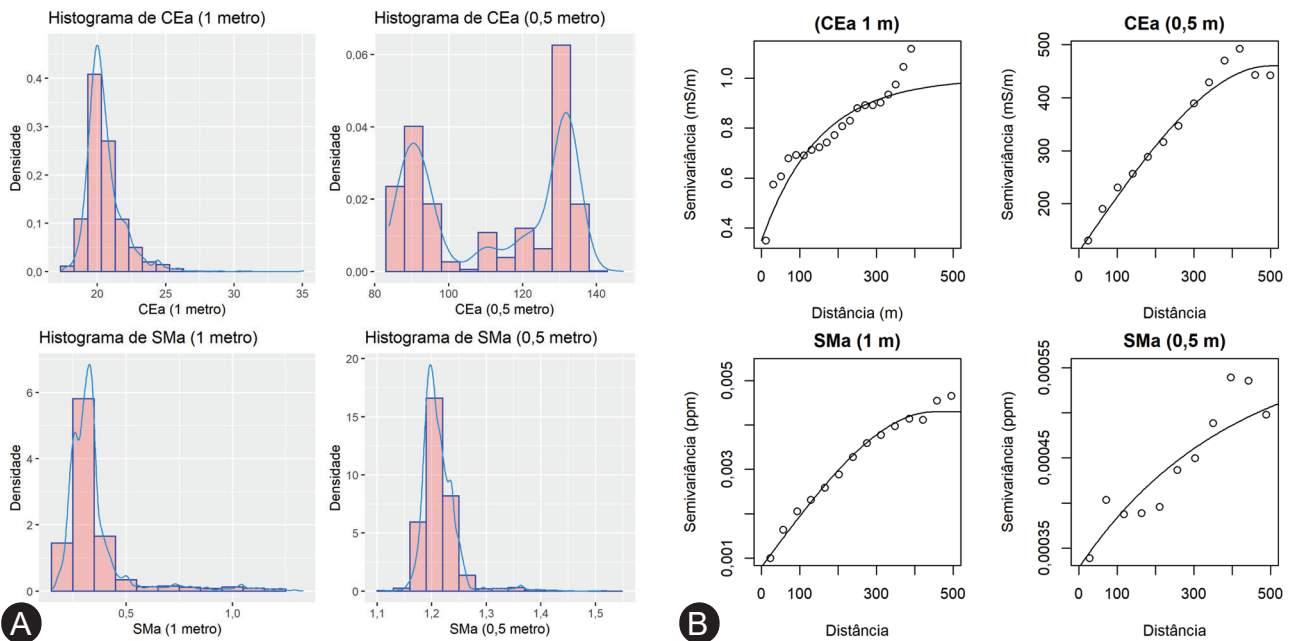


Figura 4. Condutividade elétrica aparente (CEa), e Susceptibilidade magnética aparente (SMa), com distância entre as bobinas de 1,0 m e 0,5 m obtidas pelo sensor EM38[®]-MK2 no Talhão G da Fazenda Pamplona, Cristalina, GO. A) Distribuição dos dados do sensor; B) Semivariogramas em função das distâncias entre bobinas.

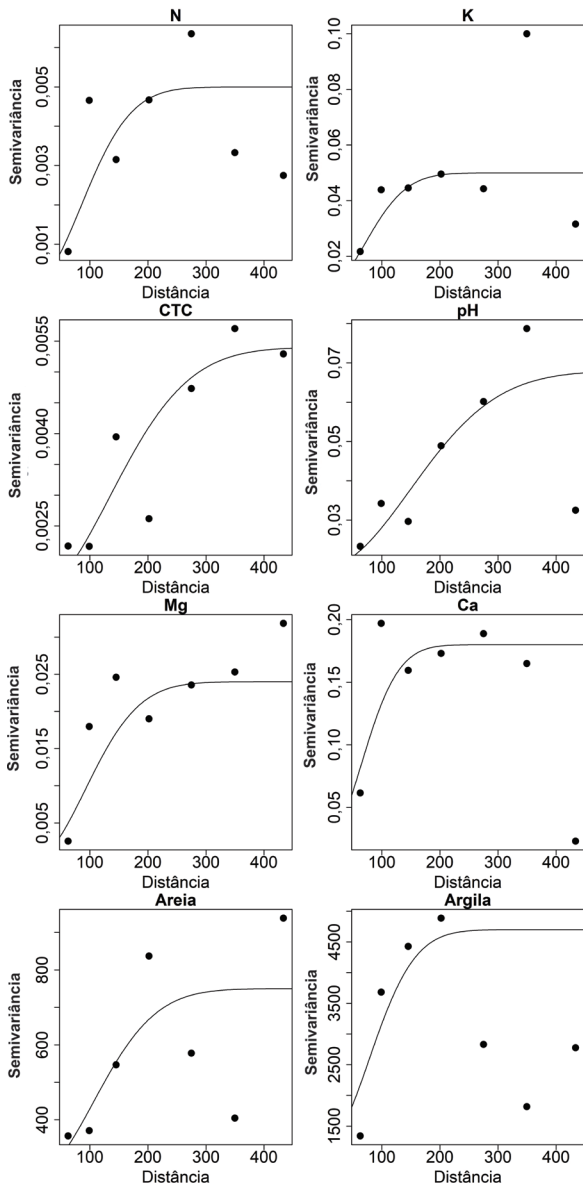


Figura 5. Semivariogramas dos atributos pH, N, K, Ca, Mg, CTC, teores de areia e argila coletados no talhão G, Fazenda Pamplona, Cristalina, GO, e medidos em laboratório. N: nitrogênio; K: potássio; Ca: cálcio; Mg: magnésio; CTC: capacidade de troca de cátions.

Tabela 1. Parâmetros de ajustes dos semivariogramas dos atributos de solo avaliados no talhão G, Fazenda Pamplona, Cristalina, GO.

Sensor EM38®									
	CEa 1 m		CEa 0.5 m		SMa 1 m		SMa 0.5 m		
Efeito pepita	0,35		110		0,0008		0,0003		
Patamar	1		460		0,0035		0,0006		
Alcance (m)	150		500		450		397,93		
Modelo	Matern		Esférico		Esférico		Matern		
Atributo do solo									
	pH	N	K	Ca	Mg	CTC	areia	argila	
Efeito pepita	0,01	0,00	100	0,00	0,00	0,05	20	1200	
Patamar	0,07	0,015	600	0,23	0,05	0,45	700	4700	
Alcance (m)	210	120	150	90	130	120	110	110	
Modelo	Gaussiano	Gaussiano	Matern	Gaussiano	Gaussiano	Gaussiano	Gaussiano	Matern	

CEa: condutividade elétrica aparente; SMa: suscetibilidade magnética aparente; N: nitrogênio; K: potássio; Ca: cálcio; Mg: magnésio; CTC: capacidade de troca de cátions; Efeito pepita ou "nugget effect": descontinuidade na origem do variograma, correspondendo à diferença entre as amostras de maior proximidade e gerada por microrregionalizações, erros de amostragens ou erros de medidas (Grego; Oliveira, 2015); Patamar ou "sill": representa o nível de variabilidade onde o variograma se estabiliza, correspondendo à diferença entre o ponto de maior correlação ou a origem do variograma e o ponto que teoricamente representa a variância populacional e a variabilidade se estabiliza (Grego; Oliveira, 2015); Alcance ou "range": distância na qual a máxima variabilidade é atingida e que corresponde ao aumento da distância entre as amostras (Grego; Oliveira et al., 2015); Modelo: modelos teóricos para ajuste do variograma.

Durante a etapa de variografia, para a propriedade de CEa 1m foram obtidas duas posições de patamares, indicando anisotropia geométrica (Yamamoto; Landim, 2013), que pode ocorrer com acúmulo de material argiloso e, conseqüentemente, maior ocorrência de umidade e óxidos que influenciam nos valores de leitura de CEa (Heil; Schmidhalter, 2019). Assim, para preparação do modelo de ajuste, foram consideradas as menores distâncias, a fim de representar essas feições no mapa de espacialização da CEa 1 m.

O mapa de sensor proximal para o atributo CEa 0,5 m apresentou os maiores valores de condutividade elétrica na área central, como pode ser visto na Figura 6, enquanto que os menores valores apresentaram-se nas bordaduras da área de estudo. Esse efeito pode ser devido à presença de metais ou mesmo de areia nas regiões de bordaduras a norte e a sul, pois são delimitadas pelas estradas de acesso e de manobra de máquinas agrícolas. Nas bordaduras a leste e a oeste, localizadas em meio à cultura, foram observados, nas análises de solo, os maiores valores para Fe, Zn e Cu, tanto nas bordaduras a leste da área de estudo quanto no canto inferior, a oeste. Nessas mesmas áreas foram encontrados os maiores valores de areia, em comparação à região central da área.

Estudando a influência de atributos do solo na condutividade elétrica para estimativa de produtividade de leguminosas, Akanji et al. (2018) observaram a influência de metais como Fe, Zn e Cu, na CEa obtida na profundidade de 0-15 cm, tendo encontrado correlações variando de 86% a 79% ($P < 0,05$), embora não tenha encontrado para areia. É interessante notar a diferença dos valores de CEa encontrada utilizando a bobina de 1 m e 0,5 m, refletindo as respostas eletromagnéticas possivelmente influenciadas pelos nutrientes disponíveis àquela profundidade. Essas correlações necessitam de outros estudos em diferentes profundidades, o que não foi possível de ser realizado neste trabalho.

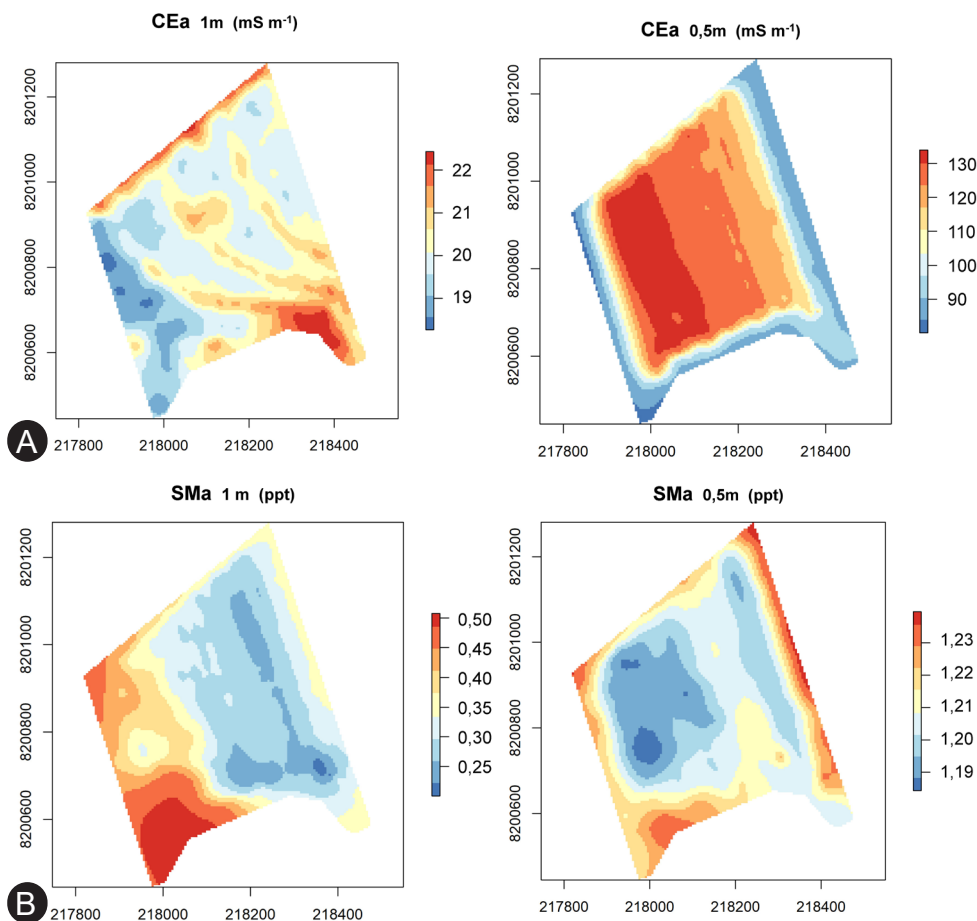


Figura 6. Mapas interpolados dos dados obtidos pelo sensor EM38[®]-MK2 nas profundidades de 0,5 m e 1 m, coletados no Talhão G, Fazenda Pamplona, Cristalina, GO, safra 2019. A) CEa - condutividade elétrica aparente; B) SMA - suscetibilidade magnética aparente.

Foi possível observar, pela amplitude dos valores obtidos pela CEa na Figura 6, que as diferenças podem estar relacionadas ao manejo na área de cultivo, onde, na profundidade de 0,5 m, os valores são elevados, possivelmente devido à aplicação de insumos. Já a bobina de 1 m refletiu, em maior parte, o comportamento em subsuperfície, inclusive apresentando valor máximo com menor intensidade quando comparado ao mapa de CEa de 0,5 m.

Ainda na Figura 6, também foi possível observar que o mapa de SMA utilizando a bobina de 1 metro apresentou valores maiores na região sudoeste, enquanto as bordas dos mapas apresentaram padrões distintos daqueles da propriedade de CEa 0,5 m, possivelmente devido à coleta dos dados de sensores proximais ter excedido à área de cultivo e o centro do mapa de CEa 0,5 m estar refletindo alguma característica do manejo, enquanto o mapa de SMA 1 m pode estar refletindo, em maior parte, as características minerais do solo. É possível observar que a SMA de 1 m representou bem os baixos valores centrais do conteúdo de areia no solo (Figura 7), tendo sido observada correlação de 49,6% ($P < 0,05$) entre essas variáveis, conforme apresentado na Tabela 2. Matias et al. (2015) avaliaram que a SMA apresentou melhor potencial na caracterização do solo quando utilizados os atributos físicos areia, argila e silte, com influência de fatores de formação mineralogia e erosão do solo. O mapa de SMA 0,5 m realiza leituras mais rasas e foi menos sensível à granulometria. O mapa de SMA 0,5 m apresentou os menores valores também no centro da área de estudo, sendo inversamente similar ao mapa de CEa 0,5 m, o que pode ser confirmado pela correlação inversa superior a 43,5% ($P < 0,05$), conforme visto na Tabela 2. Todos os mapas de atributos químicos e físicos do solo, obtidos das amostras coletadas no campo, são apresentados na Figura 7.

A análise de componentes principais (PCA) foi realizada para auxiliar na interpretação das interações entre a variável produtividade de algodão, os atributos químicos e físicos do solo, além dos dados de sensores proximais, sendo apresentado na Figura 8 o gráfico da PCA onde foram plotadas as dimensões 1 versus a 2. É possível perceber, no gráfico, que a variável produtividade está acompanhando os valores de areia, CTC, SMA 1 m e CEa 0,5 m, enquanto é inversamente proporcional às variáveis MDE, argila, SMA 0,5 m, CEa 1 m e P.

O mapa de produtividade do algodoeiro da safra 2019, gerado exclusivamente com dados da colhedora (Figura 9), foi criado para servir como referência na avaliação dos mapas gerados pelas metodologias de ZM sugeridas anteriormente. É possível observar que as regiões de tonalidade vermelha representam os maiores valores de produtividade de algodão (kg ha^{-1}) enquanto que as regiões em azul estão atreladas aos menores valores. Os valores intermediários estão distribuídos entre as tonalidades laranja e amarela. A acurácia do mapa de produtividade, utilizando os 30 pontos de validação externa, foi considerada boa e apresentou valor de erro médio de 6,88%.

Os valores das correlações de Pearson entre todas as variáveis podem ser observados na Tabela 2. Os dados da CEa de 1 m correlacionaram bem com Mg, apresentando correlações superiores a 38%, com elevado grau de significância ($P < 0,05$). Já a SMA de 0,5 m correlacionou bem com CTC e N. Embora o Ca não tenha apresentado correlações com os dados do sensor, este elemento apresentou elevada correlação inversa com o conteúdo de argila ($r = -0,537$) e direta com o pH do solo ($r = 0,702$), o que, nesse caso, auxilia na avaliação nutricional da área e na determinação das condições adequadas à produção. As correlações da areia e argila com a SMA podem se dar devido ao manejo do solo, uma vez que tanto a colheita quanto os processos de aplicação de adubos geram o revolvimento do solo e promovem o deslocamento de partículas mais leves, como é o caso da argila, e a deposição de partículas de areia (Sanchez et al., 2012; Matias et al., 2015).

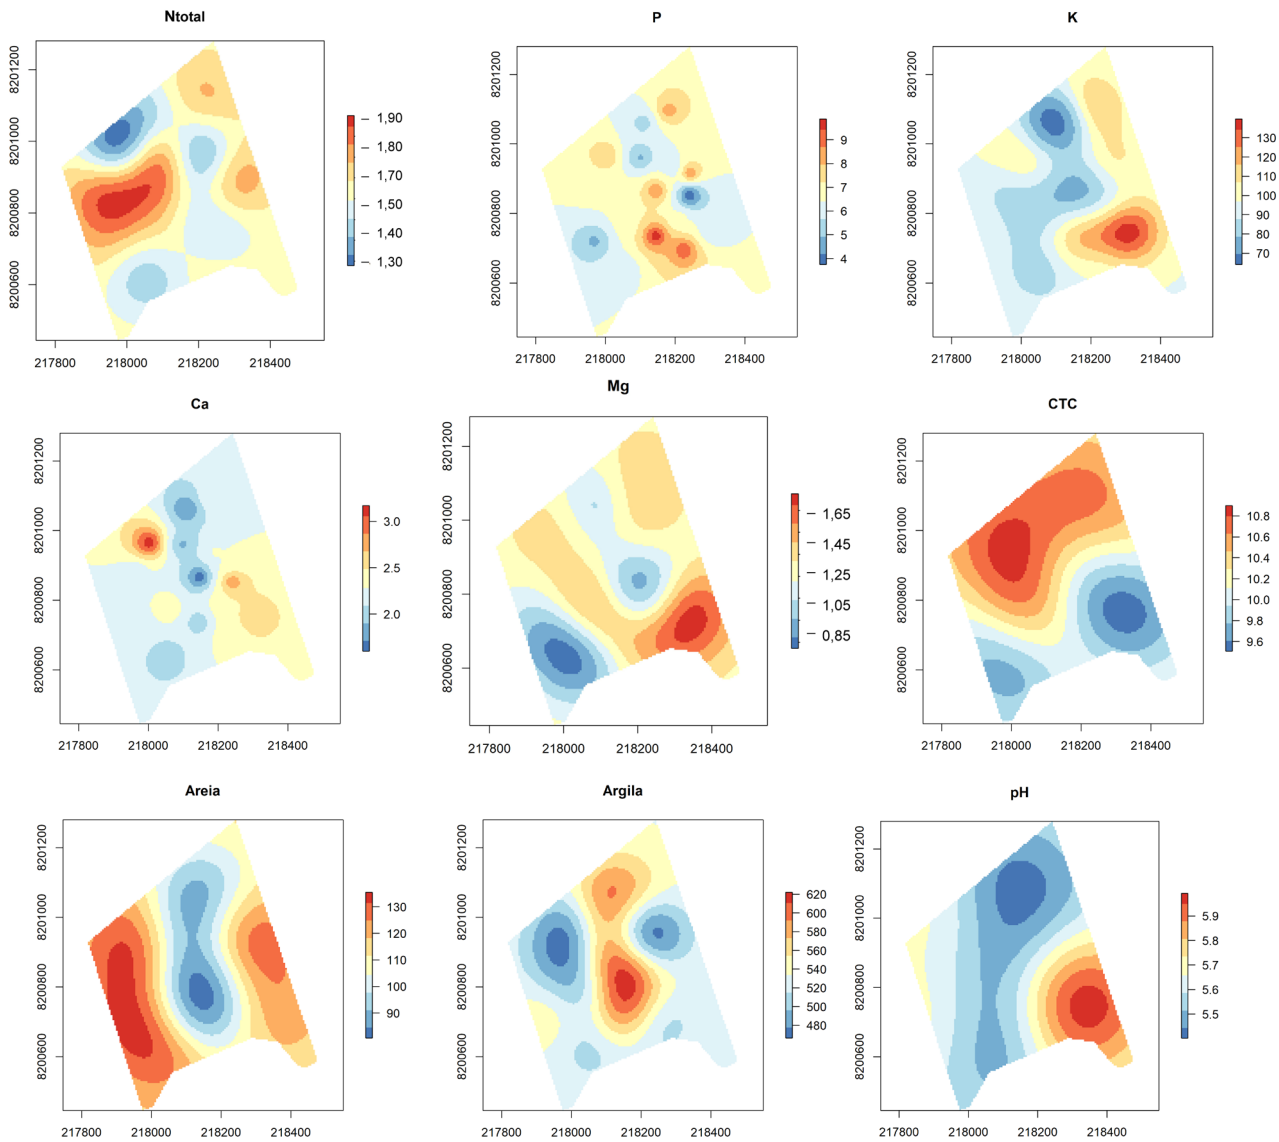


Figura 7. Mapas interpolados dos atributos químicos e físicos do solo, obtidos das amostras coletadas no Talhão G, Fazenda Pamplona, Cristalina, GO, safra 2019. N: nitrogênio; P: fósforo; K: potássio; Ca: cálcio; Mg: magnésio; CTC: capacidade de troca de cátions.




Figura 8. Análise dos componentes principais para os atributos de produtividade do algodoeiro e covariáveis obtidos no Talhão G, Fazenda Pamplona, Cristalina, GO, safra 2019. CEa: condutividade elétrica aparente; SMA: suscetibilidade magnética aparente; N: nitrogênio; P: fósforo; K: potássio; Ca: cálcio; Mg: magnésio; CTC: capacidade de troca de cátions.

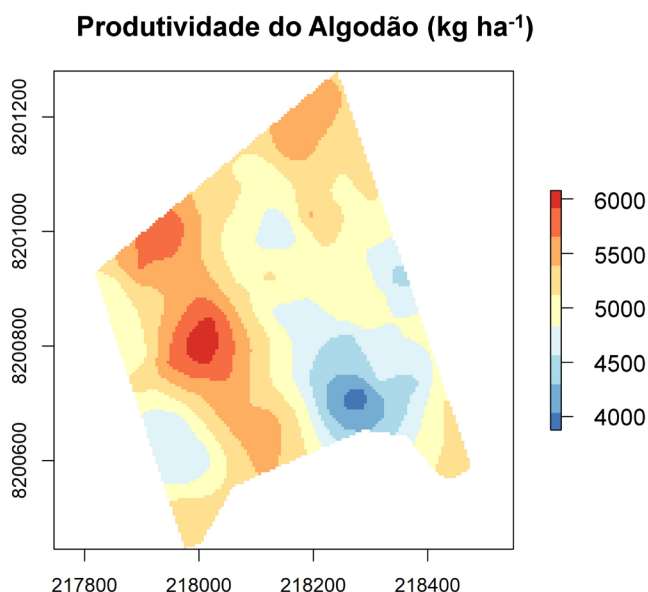


Figura 9. Mapa interpolado da produtividade do algodoeiro (kg ha⁻¹), obtido com dados de campo para o Talhão G, Fazenda Pamplona, Cristalina, GO, safra 2019.

Tabela 2. Correlação de Pearson entre as covariáveis obtidas para a safra 2019 no Talhão G da Fazenda Pamplona, Cristalina, GO.

	Prod.	CEa-1m	CEa-0,5 m	SM-1.0m	SM-0.5m	pH	P	K	Ca	Mg	CTC	N total	Areia	Argila
Prod.	1													
CEa-1m	-0,477*	1												
CEa-0,5m	0,279	0,092	1											
SM-1m	0,441*	-0,349*	0,279	1										
SM-0,5m	-0,434*	0,136	-0,435*	0,392	1									
pH	-0,181	0,304*	-0,378	-0,318	0,335	1								
P	-0,193	0,479*	0,069	-0,292	-0,094	-0,169	1							
K	-0,072	0,469*	-0,372*	-0,283	0,479*	0,692	0,335	1						
Ca	0,230	0,228	-0,119	-0,138	0,041	0,702	-0,077	0,516	1					
Mg	0,009	0,560*	-0,117	-0,389	-0,003	0,315	0,419	0,651	0,321	1				
CTC	0,327*	-0,128	0,376*	0,115	-0,551*	-0,499	0,128	-0,340	0,109	0,225	1			
N total	0,212	-0,360	0,315	0,271	-0,668*	-0,319	-0,113	-0,254	-0,299	0,117	0,360	1		
Areia	0,442*	-0,467*	0,169	0,496*	-0,243	0,297	-0,241	0,122	0,346	-0,112	-0,223	-0,032	1	
Argila	-0,369	0,135	-0,217	-0,368	0,198	-0,269	0,089	-0,152	-0,537	-0,187	-0,156	0,101	-0,780	1
MDE	-0,012	0,202	-0,610*	-0,622*	0,007	-0,080	-0,102	-0,189	0,111	0,081	0,300	-0,018	-0,296	0,162

*Significância (P < 0,05). Prod.: produtividade; CEa: condutividade elétrica aparente; SM: suscetibilidade magnética aparente; N: nitrogênio; P: fósforo; K: potássio; Ca: cálcio; Mg: magnésio; CTC: capacidade de troca de cátions; MDE: modelo digital de elevação.

Resultados por método de delineamento das Zonas de Manejo (ZM)

A) ZM a partir de dados do EM38®-MK2, MDE e produtividade

Nesse método, a zona de manejo foi criada a partir dos mapas dos atributos do sensor proximal, do MDE e do mapa de produtividade de algodão utilizando o algoritmo de clusterização *k-means* (Figura 10A). O cluster na cor verde representou a borda capturada pelos mapas de sensores, sendo associado aos mais baixos valores da produtividade, sendo importante observar que os dados dos limites superiores e inferiores foram mensurados para além dos limites da cultura do algodão, delimitadas a noroeste e a sudeste por estradas de acesso ao talhão. O cluster preto foi eficiente na representação do decaimento da produtividade a oeste do mapa de produtividade, mas ainda representando uma produtividade alta, relacionada aqui a 5.200 kg ha⁻¹ - 5.000 kg ha⁻¹, uma vez que, no mapa da Figura 9, a produtividade total variou de 3.900 kg ha⁻¹ a 6.300 kg ha⁻¹. Em síntese,

pode-se inferir que a cor azul (Figura 10A), que está associada aos mais altos valores, representou bem a produtividade, quando comparados aos dados no mapa de produtividade (Figura 9), enquanto o cluster laranja mesclou os valores de média e baixa produtividade (canto inferior a nordeste da Figura 10A), não sendo adequado, portanto, aos valores baixos na escala da produção.

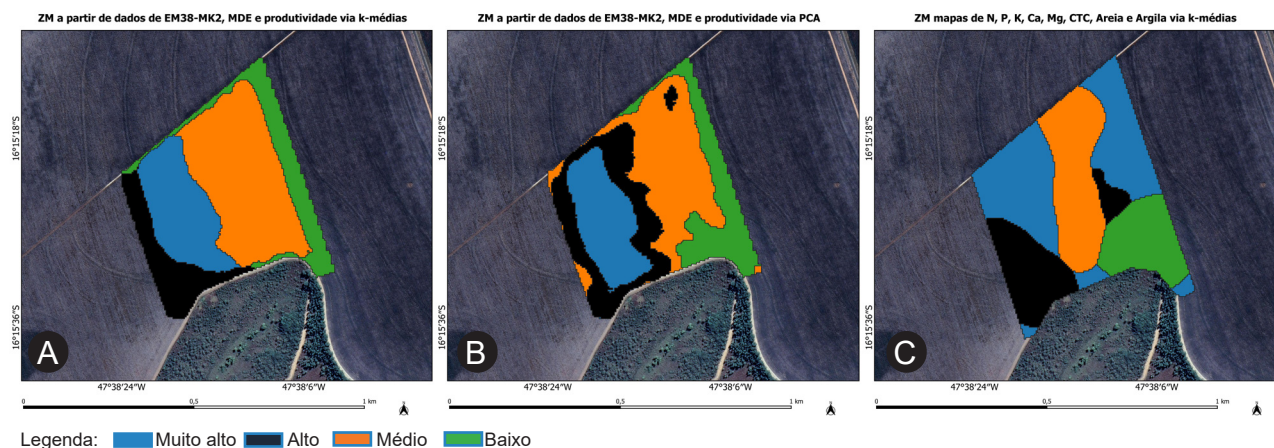


Figura 10. Mapas para quatro Zonas de Manejo (ZM), produzidos por diferentes métodos de delineamento, para dados obtidos na safra 2019, Talhão G, Fazenda Pamplona, Cristalina, GO. A) ZM a partir de dados do EM38®, modelos digitais de elevação (MDE) e produtividade do algodoeiro por *k-means*; B) ZM a partir de mapas de sensor proximal, MDE e produtividade do algodoeiro via análise de componentes principais (PCA); C) ZM a partir de mapas de atributos químicos e físicos do solo via *k-means*.

Fonte: Google Earth (2021).

B) ZM via PCA usando dados do EM38®-MK2, MDE e produtividade

A ZM proposta pela metodologia B foi gerada a partir dos mapas dos dados de sensores proximais, do MDE e do mapa de produtividade do algodoeiro. Diferentemente do método anterior (A), os dados foram submetidos à análise de PCA. Apesar da correlação da SMA de 1 m com a produtividade e o MDE, seu mapa após o PCA foi desconsiderado do algoritmo por ter apresentado pouca contribuição na primeira dimensão, tendo sido usados os outros atributos de sensor.

Esta metodologia representou e distinguiu bem as regiões de maior e menor ocorrência dos valores de produtividade, quando comparados os mapas da ZM Baixo e da produtividade. Mais uma vez foi observado que a cor azul delimitou bem as mais altas produtividades (Figura 10B). Ainda é importante observar nessa figura que o cluster preto, associado aos valores de alta produtividade, apresentou comportamento circundante ao cluster azul, representando o decréscimo da produtividade, mas ainda indicando que a produtividade está alta na área. Esse comportamento também pode ser visto na pequena área (em preto) a nordeste, que está circundada por médias produtividades (cor laranja). A classe verde agrupou a borda leste com comportamento similar ao inverso da distribuição do K e Mg na Figura 7, contemplando os dados da mancha de menor valor a sudeste do mapa de referência para a produtividade, apresentado anteriormente na Figura 9.

C) ZM a partir dos mapas dos atributos químicos e físicos do solo.

Essa metodologia considerou todos os mapas de atributos químicos e físicos, que foram escalonados e submetidos ao algoritmo de k-médias (Figura 10C). Apesar do mapa de produtividade do algodoeiro não ter sido incorporado ao algoritmo, a identificação das médias e baixas produtividades foi muito clara, onde o cluster verde apresentou os menores valores de produtividade, com o canto inferior ao sul mais influenciado pela CTC. Os clusters das cores azul e preto representaram bem a distribuição da areia, como visto na Figura 7.

Análise da variância das Zonas de Manejo

Para avaliar a capacidade de distinção das classes propostas pelos três métodos estudados (A, B e C), foram utilizados os 100 pontos do mapa de colheita do algodão. Os valores das médias de produtividade por zonas foram comparados utilizando a análise de variância e os resultados, a 95% de confiança, são apresentados na Tabela 3.

Tabela 3. Análise de variância para os dados de produtividade do algodoeiro em função das quatro classes de zonas de manejo (ZM) para cada um dos métodos propostos. Fazenda Pamplona, Cristalina, GO.

	Graus de liberdade	Soma de quadrados	Quadrados médios	Valor F	Probabilidade (>F)
ZM método A					
Zonas	3	6545290	2181763	7,996	8,12E-05***
Residuals	97	26466688	272852		
ZM método B					
Zonas	3	10058471	3352824	14,17	9,91E-08***
Residuals	97	22953508	236634		
ZM método C					
Zonas	3	6940636	2313545	8,608	4,02E-05***
Residuals	97	26071343	268777		

Graus de significância: 0 (****) 0,001 (***) 0,01 (**) 0,05 (*) 0,1 (.) 1. ZM: zona de manejo.

As ZMs propostas pelos três métodos foram capazes de distinguir as regiões de produtividade. Constatou-se que a ZM, obtida via PCA, utilizando os dados de EM38[®]-MK2, MDE e produtividade, apresentou o melhor desempenho, tendo em vista o valor F.

Considerações Finais

A criação de ZMs por meio da incorporação de dados de sensores proximais e remotos permite realizar um zoneamento tanto via *k-means* quanto PCA com eficiência para distinção de classes de produtividade do algodoeiro. A melhor eficácia é obtida quando usados os dados, via PCA, do sensor, MDE e produtividade do algodoeiro (segundo método).

O uso das ZMs obtidas por dados de CEa e SMa pode estimar com precisão adequada a produtividade do algodoeiro.

Referências

- AKANJI, M. A.; OSHUNSANYA, S. O.; ALOMRAN, A. Electrical conductivity method for predicting yields of two yam (*Dioscorea alata*) cultivars in a coarse textured soil. **International Soil and Water Conservation Research**, v. 6, p. 230-236, 2018. Disponível em: <https://doi.org/10.1016/j.iswcr.2018.03.006> Acesso em: 19 jul. 2022.
- ALASKA SATELLITE FACILITY. **ALOS PALSAR**. Fairbanks, 2022. Disponível em: <https://asf.alaska.edu/data-sets/sar-data-sets/alos-palsar/>. Acesso em 10 jan. 2022.
- BABAEIAN, E.; SADEGHI, M.; JONES, S. B.; MONTZKA, C.; VEREECKEN, H.; TULLER, M. Ground, proximal, and satellite remote sensing of soil moisture. **Reviews of Geophysics**, v. 57, n. 2, p. 530-616, June 2019. DOI: [org/10.1029/2018RG000618](https://doi.org/10.1029/2018RG000618).
- BECEGATO, V. A.; FERREIRA, F. J. F. Gamaespectrometria, resistividade elétrica e susceptibilidade magnética de solos agrícolas no noroeste do estado do Paraná. **Revista Brasileira de Geofísica**, v. 23, n. 4, p. 371-405, 2005. DOI: [10.1590/S0102-261X2005000400004](https://doi.org/10.1590/S0102-261X2005000400004).

BRANDÃO, Z. N.; OLIVEIRA, R. P.; SANA, R. S.; SOFIATTI, V.; ZONTA, J. H.; MEDEIROS, J. C. Spectral reflectance for growth assessment and yield estimate of irrigated cotton. **Australian Journal of Crop Science**, v. 9, n. 1, p. 75-84, 2015. Disponível em: http://www.cropj.com/brandao_9_1_2015_75_84.pdf. Acesso em: 19 jul. 2022.

BRANDÃO, Z. N.; ZONTA, J. H.; MEDEIROS, J. C.; SANA, R. S.; FERREIRA, G. B. Condutividade elétrica aparente e sua correlação com o pH em solos no cerrado de Goiás. In: INAMASU, R. Y.; NAIME, J. de M.; RESENDE, Á. V. de; BASSOI, L. H.; BERNARDI, A. C. de C. (ed.). **Agricultura de precisão: um novo olhar**. São Carlos, SP: Embrapa Instrumentação, 2011. p. 162-167.

CALINSKI, T.; HARABASZ, J. A Dendrite method for cluster analysis. **Communications in Statistics**, v. 3, n. 1, p. 1-27, 1974. Disponível em: <http://dx.doi.org/10.1080/03610927408827101>. Acesso em: 20 jul. 2022.

CLAESSEN, M. E. C. (org.). **Manual de métodos de análise de solo**. 2. ed. rev. e atual. Rio de Janeiro: EMBRAPA-CNPS, 1997. 212 p. (EMBRAPA-CNPS. Documentos, 1).

GEONICS. **EM38-MK2**. Disponível em: <http://www.geonics.com/html/em38.html>. Acesso em 16 out. 2021.

GRÄLER, B.; PEBESMA, E.; HEUVELINK, G. Spatio-Temporal interpolation using gstat. **The R Journal**, v. 8, n. 1, p. 204-218, 2016. Disponível em: <https://journal.r-project.org/archive/2016/RJ-2016-014/RJ-2016-014.pdf>. Acesso em: 11 out. 2022.

GREGO, C. R.; OLIVEIRA, R. P. de. Conceitos básicos da geoestatística. In: OLIVEIRA, R. P. de; GREGO, C. R.; BRANDÃO, Z. N. (ed.). **Geoestatística aplicada na agricultura de precisão utilizando o Vesper**. Brasília, DF: Embrapa, 2015. p. 41-62. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1051869/1/GeoVespercap3.pdf>. Acesso em: 10 ago. 2022.

GREGO, C. R.; RODRIGUES, C. A. G.; VICENTE, L. E.; BOLFE, E. L.; VICTORIA, D. de C. Agricultura. In: TÔSTO, S. G.; RODRIGUES, C. A. G.; BOLFE, E. L.; BATISTELLA, M. (ed.). **Geotecnologias e geoinformação: o produtor pergunta, a Embrapa responde**. Brasília, DF: Embrapa, 2014. p. 135-148. (Coleção 500 perguntas, 500 respostas). Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/103408/1/Cap.-9.pdf>. Acesso em: 20 abr. 2022.

GUASTAFERRO, F.; CASTRIGNANÒ, A.; DE BENEDETTO, D.; SOLLITO, D.; TROCCOLI, A.; CAFARELLI, B. A. Comparison of different algorithms for the delineation of management zones. **Precision Agriculture**, v. 11, p. 600-620, 2010. Disponível em: <https://doi.org/10.1007/s11119-010-9183-4> Acesso em: 19 jul. 2022.

HEIL, K.; SCHMIDHALTER, U. The Application of EM38: Determination of soil parameters, selection of soil sampling points and use in agriculture and archaeology. **Sensors**, v. 17, n. 11, 2540, 2017. DOI: 10.3390/s17112540.

HEIL, K.; SCHMIDHALTER, U. Theory and guidelines for the application of the geophysical sensor EM38. **Sensors**, v. 19, 4293, 2019. DOI: 10.3390/s19194293.

ISAAKS, E. H.; SRIVASTAVA, R. M. **An introduction to applied geostatistics**. Ames: Oxford University Press, 1989. 561 p.

JAYNES, D. B. Improved soil mapping using electromagnetic induction surveys. In: INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE, 3., 1996, Minneapolis. **Proceedings...** Madison: ASA, 1996. p. 169-179.

JOHN DEERE. **Colhedora de algodão modelo CP690**. Disponível em: <https://www.deere.com.br/pt/colheitadeiras/colhedora-de-algodao-cp690/>. Acesso em: 1º nov. 2021.

KACHANOSKI, R. G.; WESENBEECK, I. V.; JONG, E. D. Field scale patterns of soil water storage from non-contacting measurements of bulk electrical conductivity. **Canadian Journal of Soil Science**, v. 70, n. 3, p. 537-542, 1990. Disponível em: <https://doi.org/10.4141/cjss90-056>. Acesso em: 20 jul. 2022.

KRAVCHENKO, A. N.; BULLOCK, D. G. A Comparative study of interpolation methods for mapping soil properties. **Agronomy Journal**, v. 91, p. 393-400. 1999. Disponível em: <https://doi.org/10.2134/agronj1999.00021962009100030007x>. Acesso em: 20 jul. 2022.

MATIAS, S. S. R.; MARQUES JÚNIOR, J.; PEREIRA, G. T.; SIQUEIRA, D. S. Ferramentas matemáticas, suscetibilidade magnética e modelos de paisagem aplicados na delimitação de áreas de manejo específico. **Revista Brasileira de Ciência do Solo**, v. 39, p. 968-980, 2015. DOI: 10.1590/01000683rbcbs20140638.

MCBRIDE, R. A.; GORDON, A. M.; SHRIVE, S. C. Estimating forest soil quality from terrain measurements of apparent electrical conductivity. **Soil Science Society of America Journal**, v. 54, n. 1, p. 290-293, 1990. Disponível em: <https://doi.org/10.2136/sssaj1990.03615995005400010047x>. Acesso em: 20 jul. 2022.

MENEGHETTI, A. M. **Manual de procedimentos de amostragem e análise química de plantas, solo e fertilizantes**. Curitiba: EDUTFPR, 2018. 252 p. Disponível em: <http://repositorio.utfpr.edu.br/jspui/>. Acesso: 10 ago. 2022.

- MINASNY, B.; HARTEMINK, A. E. Predicting soil properties in the tropics. **Earth-Science Reviews**, v. 106, n. 1-2, p. 52-62, 2011. Disponível em: <https://doi.org/10.1016/j.earscirev.2011.01.005>. Acesso em: 20 jul. 2022.
- PIIKKI, K.; SÖDERSTRÖM, M.; ERIKSSON, J.; JOHN, J. M.; MUTHEE, P. I.; WETTERLIND, J.; LUND, E. Performance evaluation of proximal sensors for soil assessment in smallholder farms in Embu County, Kenya. **Sensors**, v. 16, n. 11, 2016. Disponível em: <https://doi.org/10.3390/s16111950>. Acesso em: 20 jul. 2022.
- R FOUNDATION FOR STATISTICAL COMPUTING. **R: a language and environment for statistical computing**. Vienna, Austria, 2021. Disponível em: <http://www.R-project.org/>. Acesso em: 12 fev. 2021.
- RAIJ, B. V. **Fertilidade do solo e manejo de nutrientes**. Piracicaba: International Plant Nutrition Institute, 2011. 420 p.
- SANCHEZ, R. B.; MARQUES JUNIOR, J.; PEREIRA, G. T.; BARACAT NETO, J.; SIQUEIRA, D. S.; SOUZA, Z. M. Mapeamento das formas do relevo para estimativa de custos de fertilização em cana-de-açúcar. **Engenharia Agrícola**, v. 32, p. 280-292, 2012. Disponível em: <https://www.scielo.br/j/eagri/a/QXB5rztvTR4QxCKchjR9f8Nm/?format=pdf&lang=pt>. Acesso: 10 ago. 2022.
- SANTOS, H. L.; MARQUES JÚNIOR, J.; MATIAS, S. S. R.; SIQUEIRA, D. S.; PEREIRA, G. T. Suscetibilidade magnética na identificação de compartimentos da paisagem em uma vertente. **Revista Brasileira de Ciências Agrárias**, v. 6, n. 4, p. 710-716, 2011. Disponível em: <http://hdl.handle.net/11449/72716>. Acesso em: 20 jul. 2022.
- SÖDERSTRÖM, M.; ERIKSSON, J.; ISENDAHL, C.; SCHAAN, D. P.; STENBORG, P.; REBELLATO, L.; PIIKKI, K. Sensor mapping of Amazonian Dark Earths in deforested croplands. **Geoderma**, v. 281, p. 58-68, 2016. Disponível em: <https://doi.org/10.1016/j.geoderma.2016.06.024>. Acesso em: 20 jul. 2022.
- TEDESCO, J. M.; GIANELLO, C.; BISSANI, C. A.; BOHNEM, H.; VOLKWEISS, S. J. **Análise de solo, plantas e outros materiais**. 2. ed. Porto Alegre: UFRGS, 1995. 174 p. (Boletim técnico de solos, 5).
- VASQUES, G. M.; RODRIGUES, H. M.; COELHO, M. R.; BACA, J. F. M.; DART, R. O.; OLIVEIRA, R. P.; TEIXEIRA, W. G.; CEDDIA, M. B. Field proximal soil sensor fusion for improving high-resolution soil property maps. **Soil Systems**, v. 4, n. 3, p. 52, 2020. Disponível em: <https://doi.org/10.3390/soilsystems4030052>. Acesso em: 20 jul. 2022.
- WILLIAMS, B. G.; HOEY, D. The use of electromagnetic induction to detect the spatial variability of the salt and clay content of soils. **Australian Journal of Soil Research**, v. 25, n. 1, p. 21-27, 1987. Disponível em: <https://doi.org/10.1071/SR9870021>. Acesso em: 20 jul. 2022.
- YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística: conceitos e aplicações**. São Paulo: Senac, 2013. 215 p.
- ZAWADZKI, J.; MAGIERA, T.; FABIJAŃCZYK, P.; KUSZA, G. Geostatistical 3-dimensional integration of measurements of soil magnetic susceptibility. **Environmental Monitoring and Assessment**, v. 184, p. 3267-3278, 2012. DOI 10.1007/s10661-011-2187-3.