

# Metodologia para sugestão de grades amostrais mínimas para monitoramento da variabilidade espacial de videiras



*Empresa Brasileira de Pesquisa Agropecuária  
Embrapa Agricultura Digital  
Ministério da Agricultura, Pecuária e Abastecimento*

**BOLETIM DE PESQUISA  
E DESENVOLVIMENTO  
50**

**Metodologia para sugestão de grades  
amostrais mínimas para monitoramento  
da variabilidade espacial de videiras**

*Eduardo Antonio Speranza  
Célia Regina Grego  
Luciano Gebler*

**Embrapa Agricultura Digital**  
Av. André Tosello, nº 209 Campus da Unicamp,  
Barão Geraldo - Campinas - SP  
CEP: 13083-886  
Fone: (19) 3211-5700

www.embrapa.br  
www.embrapa.br/fale-conosco/sac

Presidente  
*Stanley Robson de Medeiros Oliveira*

Secretária-Executiva  
*Maria Fernanda Moura*

Membros  
*Adriana Farah Gonzalez, membro nato, Alexandre de Castro, membro indicado, Carla Cristiane Osawa, membro nato, Debora Pignatari Drucker, membro eleito, Ivan Mazoni, membro eleito, João Camargo Neto, membro indicado, João Francisco Goncalves Antunes, membro eleito, Magda Cruciol, membro nato.*

Revisão de texto  
*Adriana Farah Gonzalez*

Normalização bibliográfica  
*Carla Cristiane Osawa*

Projeto gráfico da coleção  
*Carlos Eduardo Felice Barbeiro*

Editoração eletrônica e arte da capa  
*Magda Cruciol e Mariana Pilatti*

Foto da capa  
*Neide Furukawa adaptado por Magda Cruciol*

**1ª edição**

**Todos os direitos reservados.**

A reprodução não autorizada desta publicação, no todo ou em parte, constitui violação dos direitos autorais (Lei nº 9.610).

**Dados Internacionais de Catalogação na Publicação (CIP)**

Embrapa Agricultura Digital

---

Speranza, Eduardo Antonio.

Metodologia para sugestão de grades amostrais mínimas para monitoramento da variabilidade espacial de videiras / Eduardo Antonio Speranza, Célia Regina Grego, Luciano Gebler. - Campinas : Embrapa Agricultura Digital, 2021.

PDF (33 p.) : il. color. - (Boletim de pesquisa e desenvolvimento / Embrapa Agricultura Digital, 2764-2633 ; 50).

1. Agricultura de precisão. 2. Geoestatística. 3. Análise de agrupamento. 4. Vitivinicultura. I. Grego, Célia Regina. II. Gleber, Luciano. III. Título. IV. Embrapa Agricultura Digital. V. Série

CDD (21. ed.) 630.2195

## Sumário

---

Resumo e Abstract .....	4
Introdução .....	5
Material e Métodos .....	8
Resultados e Discussão .....	11
Conclusões .....	30
Referências.....	31

# Metodologia para sugestão de grades amostrais mínimas para monitoramento da variabilidade espacial de videiras

Eduardo Antonio Speranza<sup>1</sup>

Célia Regina Grego<sup>2</sup>

Luciano Gebler<sup>3</sup>

**Resumo** – Na fruticultura, onde as áreas de produção são muito pequenas quando comparadas com as culturas de grãos, a representatividade de uma grade de amostras ideal para a aplicação da geoestatística é muito densa com relação ao que é utilizado na agricultura de precisão (AP) tradicional, o que torna a amostragem uma atividade extremamente cara ao produtor. Assim, metodologias que pretendem propor um número mínimo de amostras necessárias para o estabelecimento de atividades voltadas a AP, considerando a representação satisfatória da variabilidade espacial da área e o custo da coleta de dados e análise são importantes para tomadas de decisão com relação ao manejo. Este trabalho teve como objetivo principal estabelecer uma metodologia, baseada em análise de dados, que permita sugerir grades amostrais mínimas necessárias para identificar a variabilidade espacial do solo e da cultura em parreirais de videiras. Os resultados mostram que, mesmo com grades com quantidades reduzidas de quatro amostras por hectares, essa variabilidade espacial já pode ser identificada.

**Termos para indexação:** vitivinicultura, agricultura de precisão, geoestatística, análise de agrupamento.

## Methodology for suggesting minimal sampling grids for monitoring the spatial variability of vineyards

**Abstract** – In orcharding, where fields are very small compared to grain crops, the representativeness of an ideal sample grid for the application of geostatistics is very

---

<sup>1</sup> Bacharel em Ciência da Computação, doutor em Ciência da Computação, analista da Embrapa Agricultura Digital, Campinas, SP.

<sup>2</sup> Engenheira Agrônoma, doutora em Agronomia, pesquisadora da Embrapa Agricultura Digital, Campinas, SP.

<sup>3</sup> Agrônomo, doutor em Recursos Hídricos e Saneamento Ambiental, pesquisador da Embrapa Uva e Vinho, Bento Gonçalves, RS.

dense compared to that used in traditional precision agriculture (PA), which makes sampling an extremely expensive activity for the farmer. Therefore, methodologies that intend to propose a minimum number of samples necessary for the establishment of activities aimed at PA, considering the satisfactory representation of the spatial variability of the area and the cost of data collection and analysis, are important for decision-making regarding management. The main goal of this work was to establish a methodology, based on data analysis, which allows the suggestion of minimum sampling grids necessary to identify the spatial variability of soil and crop in vineyards. The results show that, even with grids with reduced amounts of four samples per hectare, this spatial variability can already be identified.

**Index terms:** viticulture, precision agriculture, geostatistics, cluster analysis.

## Introdução

---

O estabelecimento de pontos amostrais é considerado um dos primeiros passos para o estabelecimento de um programa de agricultura de precisão em qualquer cultura. Dado o custo existente nesta etapa, sempre há a preocupação em estabelecer o balanceamento de representatividade técnica e economicidade ao produtor. Além disso, é necessário estabelecer um número mínimo de pontos para a aplicação das técnicas de geoestatística para a análise geoespacial, tornando o problema da representatividade adequada um ponto de preocupação de técnicos e produtores.

Para as culturas extensivas, como grãos, fibras e energia, a principal estratégia para a obtenção de representatividade é o estabelecimento de grades amostrais com muitos pontos esparsos, adotando sub amostras ao redor de um ponto central, criando uma célula, para maior cobertura de área a ser representada. Entretanto, essas células obedecem ao conceito de amostra pela média, resumida em cada ponto central da grade. Dada a área entre o ponto central de cada uma das células, a grade ainda reproduz boa representatividade da variabilidade espacial para áreas extensas.

Já na fruticultura, de maneira geral, que conta com áreas muito pequenas em relação às demais culturas, e onde uma planta isolada pode ser considerada uma célula produtiva isolada, com alta variabilidade no meio, a representatividade de uma grade que apresente um número grande de pontos, ideal para a aplicação da geoestatística, acaba por ser muito mais densa do que em relação ao utilizado na agricultura de precisão (AP) tradicional, tornando a geração da grade e sua análise extremamente cara ao produtor. Da mesma maneira, devido à reduzida área de análise, é desnecessário o uso de subamostras, dada a grande variabilidade que se quer capturar no ambiente, permitindo o uso de pontos centrais simples, mais afeitos aos conceitos originais da geoestatística. Assim, é necessário encontrar o balanço entre o número mínimo de pontos necessário para o estabelecimento de boas

análises geoestatísticas, que permitam uma boa representatividade da variabilidade espacial da área e o custo do estabelecimento da grade para análise.

Considerando esse contexto, metodologias relacionadas à análise de dados podem ser utilizadas para sugerir grades otimizadas que permitam iniciar a implementação do manejo baseado em AP. O processo de descoberta de conhecimento em bancos de dados (KDD)<sup>4</sup> é conceitualmente definido na literatura por várias etapas que envolvem, de uma maneira geral, atividades relacionadas ao pré-processamento, mineração e pós-processamento dos dados (Fayyad et al., 1996; Rezende, 2003). Considerando o contexto da agricultura de precisão (AP), as atividades e etapas que envolvem o delineamento de zonas de manejo (ZM) permitem que esse processo seja considerado, do ponto de vista computacional, como um processo de KDD (Santos; Saraiva, 2015).

Nesse sentido, a análise geoestatística surge como uma ferramenta que considera a variabilidade espacial entre pontos vizinhos de amostragem para melhor precisão no mapeamento. Trata-se de uma ferramenta bastante difundida na literatura para análise de dados de solo e planta amostrados em pontos georreferenciados (Goovaerts, 1997; Vieira, 2000; Soares, 2006; Oliveira et al., 2015) e auxilia no pré-processamento para outras análises como na mineração de dados. Com a geoestatística pode-se estimar o valor de uma dada propriedade para um local onde não foi medida, utilizando uma função de correlação espacial entre os dados sem viés e com variância mínima (Vieira, 2000).

A aplicação da geoestatística em áreas de videiras foi realizada por Valladares et al. (2009) com objetivo de determinar os teores de cobre e zinco disponíveis no solo quanto à variabilidade espacial em áreas de vinhedos comerciais e experimentais. Foram verificados altos teores nos vinhedos, possivelmente em virtude da aplicação de agroquímicos, sendo que foram maiores nos vinhedos comerciais em comparação com os experimentais.

A etapa central do processo de delineamento de ZM envolve atividades de mineração de dados que permitem a identificação e validação de padrões de comportamento com base em atributos do solo e da cultura. Esses padrões deverão permitir a geração de mapas contendo ZMs com variabilidade espacial reduzida, considerando todos os atributos analisados; e com contiguidade espacial suficiente para que sejam factíveis de serem utilizadas na prática. Como o delineamento de ZM envolve a extração de padrões diretamente a partir de dados sem rotulação prévia, algoritmos de aprendizado de máquina não-supervisionados, também conhecidos como algoritmos de agrupamento, são amplamente utilizados na literatura para esse fim.

Apesar de se tratar de uma classe específica de algoritmos, com abordagens tradicionais bem estabelecidas, variações dessas abordagens, com o intuito de

---

<sup>4</sup> KDD: Do inglês *Knowledge Discovery in Databases*

melhorar a sua eficiência e eficácia para determinados domínios de aplicação, têm surgido com frequência na literatura. Gavioli et al. (2019) realizaram uma avaliação considerando 20 metodologias distintas de agrupamento disponíveis para o contexto de delineamento de ZM em AP. Foram utilizados dados de atributos do solo e da cultura de 3 áreas comerciais com culturas de soja e milho. Dos 20 algoritmos experimentados, 17 conseguiram gerar mapas de ZM satisfatórios, com destaque para os métodos McQuitty (McQuitty, 1966) e Fanny (Kaufman; Rousseeuw, 2009). Apesar de os resultados serem satisfatórios com relação à geração de agrupamentos não aleatórios e concordantes com o conjunto de dados de entrada, esses métodos não estão preparados para lidar com restrições espaciais e, por muitas vezes, proporcionam a obtenção de mapas estratificados e de difícil interpretação e uso. Estudos mais recentes apontam para a inclusão de restrições espaciais obrigatórias ou opcionais durante a execução do algoritmo de agrupamento (Ruß; Kruse, 2011; Speranza, 2017); ou a execução de retificações em atividades de pós-processamento (Betzek et al., 2018) como metodologias alternativas para ajuste dos mapas de ZM por conta dessa questão.

Independentemente da acurácia dos resultados obtidos, é certo que a utilização de algoritmos de agrupamento distintos e diferentes quantidades de ZM como parâmetro de entrada para esses algoritmos, mesmo considerando o mesmo conjunto de dados, podem proporcionar a obtenção de mapas de ZM muito distintos e de difícil escolha sobre qual seria utilizado por parte do usuário final. A alternativa mais geral, independentemente do contexto, é a utilização de ferramentas estatísticas que medem a qualidade dos agrupamentos com relação aos dados de entrada, a partir de medidas de coesão intragrupos e separação intergrupos (Vendramin et al., 2010). No contexto da AP, estudos indicam que grande parte da variabilidade espacial da lavoura é indicada pelo comportamento histórico da sua resposta com relação ao manejo e às próprias condições de solo e de clima obtidas por meio de mapas de produtividade (Molin et al., 2015). Sendo assim, a redução da variância da produtividade relativa à área total de estudo após a sua divisão em ZMs é uma medida válida a ser adotada nesse contexto, podendo auxiliar na escolha do melhor mapa de ZM a ser utilizado (Sobjak et al., 2016).

Considerando toda a contextualização aqui apresentada e o ferramental estatístico e computacional disponível, o objetivo principal deste trabalho de pesquisa foi o desenvolvimento de uma metodologia para sugestão de grades amostrais para monitoramento de variáveis relacionadas ao solo e à cultura em parreirais de videira de uva, a partir de análises geoestatísticas e de agrupamento de dados. Para tanto, foram consideradas diferentes grandes amostrais de coleta de dados, que passaram por um processo de KDD envolvendo três etapas: 1) pré-processamento e transformação dos dados, a partir de análises geoestatísticas; 2) mineração de dados e descoberta de padrões, a partir de análises de agrupamento; e 3) avaliação dos



resultados, a partir da verificação da redução da variância da produtividade proporcionada pelos mapas de ZM obtidos.

## Material e Métodos

---

### Definição da área experimental e coleta de dados

A área de estudo escolhida para este trabalho compreende um parreiral de videira com cerca de 3,69 ha de área, pertencente ao produtor Ermano Varaschin, com coordenadas centrais (Long,Lat)  $0\ 51^{\circ}\ 15'\ 7.248''$  e  $S\ 28^{\circ}\ 23'\ 15.185''$ , considerando o datum WGS 84 (Figura 1). Nessa área, são cultivadas as variedades Pinot Noir, Chardonnay e Merlot. Entretanto, considerando os objetivos deste trabalho, a informação sobre as variedades não foi utilizada, pois o manejo realizado é similar em todas elas.

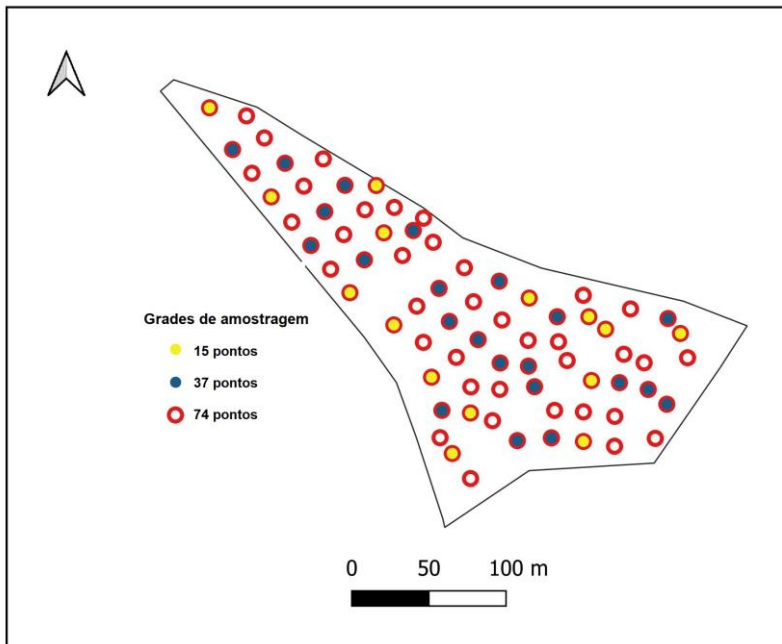


**Figura 1.** Área de estudo

Foram coletados dados referentes à safra de 2019/2020, considerando uma grande quantidade de variáveis relacionadas ao solo e à cultura (88 no total), agrupadas em atributos relacionados à produtividade, tecido vegetal, física, química e textura do solo e índices de vegetação. A grade espacial de amostras dos dados

contém originalmente 74 pontos, o que proporcionou a obtenção de dados referentes a todos os atributos a uma resolução de aproximadamente 20 amostras por hectare.

No intuito de verificar o número adequado de pontos para otimizar a coleta no campo e custos das análises em laboratório sem prejuízo para os resultados de análise de variabilidade espacial para todas as variáveis, foram utilizadas 3 diferentes quantidades de pontos de amostragem, partindo da grade de 74 pontos originais, reduzindo para metade (37 pontos) e ainda numa grade mínima de 15 pontos. Optou-se por reduzir o número de pontos de acordo com a eliminação de pontos mais próximos conforme a Figura 2.



**Figura 2.** Distribuição das 3 grades de amostragem com 74, 37 e 15 pontos na área de estudo.

### Análise Geoestatística

Foi realizada a análise geoestatística para todas as variáveis nas três grades pré-determinadas. A análise foi composta pelo semivariograma experimental e ajustado para cada um dos atributos selecionados conforme indicado por Vieira (2000). Os semivariogramas ajustados a um dos modelos mais frequente (Esférico, Exponencial e Gaussiano) forneceram os parâmetros de ajuste utilizados pelo

método de interpolação espacial por krigagem ordinária (Oliver; Webster, 1990), para que possam ser gerados os mapas com melhor precisão possível considerando a existência de dependência espacial. O semivariograma trata-se de um gráfico da semivariância  $\gamma(h)$  versus a distância  $h$ . Com o interpolador krigagem ordinária é possível estimar valores para qualquer local onde a variável não foi medida, garantindo interpolação sem tendência e com variância mínima. Construiu-se mapas de contornos em função das coordenadas geográficas em SIG (QGIS 3.10), e os programas utilizados para análise geoestatística foram os desenvolvidos por Vieira (2000).

## Análise de Agrupamento

As análises de agrupamento e, conseqüentemente, os mapas de ZM, foram gerados utilizando apenas os atributos que apresentaram dependência espacial para as três grades de amostragem propostas e que, conseqüentemente, tiveram mapas finais gerados a partir de interpolação espacial. Para esses atributos, foram gerados mapas com resolução espacial final de 1m, totalizando 37.855 pontos, independentemente da quantidade de amostras da grade original.

O atributo relacionado à produtividade serviu como referência para as análises realizadas neste trabalho e, desse modo, as amostras desse atributo também foram interpoladas na grade espacial de 1 m. No entanto, apenas a grade de 74 amostras mostrou dependência espacial para esse atributo e, conseqüentemente, um único mapa de produtividade foi gerado, a partir dessa grade.

Para o processo de agrupamento dos dados interpolados, foi utilizada a abordagem de agrupamento hierárquico SWMU Clustering (Speranza, 2017). Essa abordagem permite que sejam obtidos agrupamentos com reduzida estratificação espacial quando estes são exibidos em forma de mapa. Neste trabalho, foram consideradas as restrições de tesselação inicial  $k=200$ , para inicialização do algoritmo; número máximo de grupos  $maxDMC=5$ , proporcionando retificações espaciais nos mapas de saída a partir de 5 grupos; e  $porcDMU=5$ , que limita o tamanho mínimo espacial (área) de um grupo em pelo menos 5% da área total de estudo. Além disso, foi definido um intervalo válido de 2 a 5 grupos para cada configuração utilizada, intervalo este que é frequentemente utilizado para o delineamento de ZM em AP.

Os mapas de ZM obtidos a partir de análise de agrupamento foram avaliados com relação à sua capacidade em reduzir a variância da produtividade da área, por meio do índice de redução de variância (VR, Equação (1)) (Dobermann et al., 2003; Xiang et al., 2007).

$$VR = \left( 1 - \frac{\sum_{i=1}^c W_i * V_{mzi}}{V_{field}} \right) * 100 \quad (1)$$

De acordo com a Equação (1), a *VR* deve ser calculada em função da soma das variâncias de produtividade dentro de cada grupo gerado (*V<sub>mzi</sub>*), ponderada pela sua área (*W<sub>i</sub>*) com relação a variância da área total (*V<sub>field</sub>*). A partir desse cálculo, é possível verificar qual a porcentagem de redução da variância da produtividade obtida para cada agrupamento gerado.

Outra avaliação realizada com os mapas de ZM obtidos foi a verificação da concordância desses mapas com relação a mapas de ZM obtidos considerando apenas a variável de produtividade, por meio do coeficiente de Kappa (Cohen, 1960). Esse coeficiente é um índice estatístico capaz de verificar a concordância entre dois mapas considerando uma tabela de contingência cruzada (*kappa*, Equação (2)).

$$kappa = \frac{Pr(a) - Pr(e)}{(1 - Pr(e))} \quad (2)$$

Na Equação (2), *Pr(a)* é a concordância relativa observada e *Pr(e)* é a probabilidade hipotética de concordância entre os mapas avaliados, calculados a partir da tabela de contingência. O valor de *kappa* varia de 1 (completa concordância) até 0 (sem concordância). De acordo com Kitchen et al. (2005), valores altos do índice *kappa* (próximos de 1) ocorrem quando a concordância espacial entre dois mapas de ZM é máxima.

Neste trabalho, os potenciais mapas de ZM obtidos utilizando diferentes grupos de atributos e diferentes resoluções de grades amostrais de origem que proporcionam maiores reduções de variância da produtividade e maiores concordâncias com relação a mapas de ZM que consideram a produtividade, podem ser indicativos para a necessidade de grades amostrais mais ou menos precisas. Desse modo, a discussão dos resultados está baseada nessa premissa.

## Resultados e Discussão

---

Os dados foram submetidos à análise estatística descritiva e geoestatística para todas as variáveis nas grades pré-determinadas. De forma geral (Tabelas 2, 3 e 4) não foram observadas grandes diferenças em torno da média e do coeficiente de variação dos dados quando foram reduzidos os pontos de amostragem de 75 para 37 e 15 pontos. Contudo, houve grande redução da variabilidade espacial quando se reduziu o número de amostras, principalmente na grade de 15 pontos, comparando com 74 e 37 pontos. Na Tabela 1, para os dados de produção e tecido vegetal (16

variáveis) foram contabilizadas 15 variáveis com dependência espacial (ajustes dos semivariogramas) na grade de 74 pontos, 14 variáveis com dependência espacial na grade de 37 pontos e apenas 4 variáveis apresentaram dependência espacial na grade de 15 pontos de amostragem.

**Tabela 1.** Média e coeficiente de variação (CV), modelos de ajuste do semivariograma (esférico, exponencial e gaussiano) das variáveis relacionadas a produção e tecido vegetal.

Variáveis	Média			CV* (%)			Modelo de ajuste		
	Grades de pontos								
	74	37	15	74	37	15	74	37	15
<b>Produção</b>									
<b>BRIX</b>	18,59	18,07	18,4	5,375	17,66	5,9	Esf	-	-
<b>Acidez_total</b>	119,9	119,5	119,7	17,7	26,4	20,9	Esf	Esf	-
<b>Quantidade cachos/ 3 plantas</b>	65,77	65,54	72,7	27,69	30,86	25,8	Gau	Gau	-
<b>Peso 3 cachos /gramas</b>	245,2	238	238,2	42,35	44,21	40,0	Esf	Esf	-
<b>Produtividade g/ponto</b>	1845	1841	2001	54,76	58,3	56,0	Exp	-	-
<b>Tecido Vegetal</b>									
<b>Nitrogênio (TKN) % m/m</b>	3,097	3,10	3,0	11,55	11,58	13,3	Esf	Esf	-
<b>Fósforo total % m/m</b>	0,2908	0,295	0,3	15,57	15,77	14,0	Esf	-	Esf
<b>Potássio total % m/m</b>	1,711	1,816	1,9	29,25	27,91	29,6	Esf	Esf	-
<b>Cálcio total % m/m</b>	1,878	1,922	2,0	29,7	30,59	28,6	Exp	Esf	-
<b>Magnésio total % m/m</b>	0,6141	0,631	0,7	23,04	23,79	24,6	Esf	Esf	-
<b>Enxofre total % m/m</b>	0,2942	0,289	0,3	23,57	17,08	17,8	Esf	Esf	-
<b>Cobre total mg/kg</b>	11,5	11,84	11,3	23,97	24,43	23,5	Esf	Esf	Gau
<b>Zinco total mg/kg</b>	53,95	55,84	55,2	19,03	19,31	13,8	-	-	Gau
<b>Ferro total mg/kg</b>	315,7	325	358	51,11	52,53	54,1	Exp	Esf	-
<b>Manganês total mg/kg</b>	315,8	325,9	333	28,6	26,89	28,8	Gau	Gau	-
<b>Boro total mg/kg</b>	34,65	34,46	34,5	17,29	16,83	14,7	Esf	Gau	Esf

\*CV (%): Coeficiente de Variação; Modelo de ajuste Esférico (Esf), Exponencial (Exp) e Gaussiano (Gau) e Ausência de ajuste devido a não ocorrência de dependência espacial (-).

Na Tabela 2 estão as análises para os dados de física e química do solo de 0-20 e de 0-40cm de profundidade. Houve redução de 80% das variáveis com dependência espacial quando se reduziu de 75 para 15 pontos, no entanto, com 37 pontos praticamente o número de ajustes foi o mesmo do que para 74 pontos, sem prejuízo para a representatividade da dependência espacial para essas variáveis.

**Tabela 2.** Média e coeficiente de variação (CV), modelos de ajuste do semivariograma (esférico, exponencial e gaussiano) das variáveis relacionadas a física e química do solo de 0-20 e de 20-40 cm de profundidade.

Variáveis	Média		CV* (%)			Modelo de ajuste			
	Grades de amostragem						74	37	15
	74	37	15	74	37	15			
<b>Física de solo</b>									
<b>(0-20 e 20-40 cm)</b>									
Umidade (g/g) 20 cm	0,326	0,32	0,32	10,68	10,58	12,29	-	-	-
Areia(%) 20 cm	6,979	6,85	6,95	14,51	13,80	15,18	Esf	Esf	-
Silte(%) 20 cm	24,2	23,87	24,15	7,997	6,90	7,77	Exp	Esf	Gau
Argila(%) 20 cm	68,82	69,27	68,91	3,72	3,28	3,71	Exp	Esf	Gau
Umidade (g/g) 40 cm	0,326	0,32	0,32	10,68	10,58	12,29	-	-	-
Areia(%) 40 cm	6,979	6,85	6,95	14,51	13,80	15,18	Esf	Esf	-
Silte(%) 40 cm	24,2	23,87	24,15	7,997	6,90	7,77	Exp	Esf	Gau
Argila(%) 40 cm	68,82	69,27	68,91	3,721	3,28	3,71	Exp	Esf	Gau
<b>Química de solo</b>									
<b>(0-20cm)</b>									
ph_AGUA	6,21	6,20	6,17	12,91	12,46	13,58	Esf	Gau	-
FOSFORO_mg/ dm3	5,686	5,25	4,83	101,6	82,51	62,13	Esf	-	-
POTASSIO_mg /dm3	197,9	205	198,4 0	46,85	43,24	42,34	Esf	Esf	-
POTASSIO_cm ol/dm3	0,506	0,52	0,51	46,85	43,23	42,34	Esf	Esf	-
MATERIA ORGANICA %	4,00	4,03	4,05	16,29	15,06	13,50	-	-	-
ALUMINIO_cm olc/dm3	0,172	0,14	0,23	302,8	349,7	307,7	-	-	-
CALCIO_cmolc /dm3	6,916	7,00	7,09	37,49	35,89	40,82	Gau	-	-
Mg_cmolc_dm	4,797	4,82	4,79	29,57	27,33	33,02	Gau	Gau	-

<b>3</b>									
<b>ctc_efetiv</b>	12,39	12,48	12,61	28,47	27,00	30,47	Gau	Gau	-
<b>ctc_ph7</b>	15,68	15,76	15,95	14,39	13,43	15,92	-	Gau	-
<b>ZINCO_mg_dm</b>	3,079	3,24	3,20	55,96	56,69	55,49	-	Gau	-
<b>3</b>									
<b>COBRE_mg_d</b>	6,715	6,77	7,09	37,62	33,41	31,27	-	Esf	-
<b>m3</b>									
<b>ENXOFRE_mg_</b>	12,89	12,56	12,63	22,13	16,68	18,14	-	Esf	-
<b>dm3</b>									
<b>BORO_mg_dm</b>	0,171	0,17	0,17	49,67	51,54	53,98	Esf	-	-
<b>3</b>									
<b>Condutividade</b>								Esf	-
<b>Elétrica</b>									
	0,306	0,29	0,26	42,1	36,09	0,09	Esf		
<b>Química de solo</b>									
<b>(20-40cm)</b>									
<b>ph_AGUA</b>	5,496	5,40	5,50	14,18	12,87	13,64	-	Esf	-
<b>FOSFORO_mg/</b>	4,427	4,69	5,38	112	104,6	118,7	Esf	Esf	-
<b>dm3</b>									
<b>POTASSIO_mg</b>	88,86	91,03	97,87	45,90	43,25	47,31	-	Esf	-
<b>/dm3</b>									
<b>POTASSIO_cm</b>	0,223	0,23	0,25	45,88	43,22	47,28	-	Esf	-
<b>ol/dm3</b>									
<b>MATERIA</b>	3,504	3,46	3,68	15,35	14,17	14,75	-	-	Gau
<b>ORGANICA %</b>									
<b>ALUMINIO_cm</b>	1,138	1,20	0,97	105,1	100,7	125,5	-	-	-
<b>olc/dm3</b>									
<b>CALCIO_cmolc</b>	3,934	3,76	4,26	68,92	71,04	64,37	Gau	-	-
<b>/dm3</b>									
<b>Mg_cmolc_dm</b>	3,252	3,10	3,42	55,57	55,92	54,52	Gau	Esf	-
<b>3</b>									
<b>ctc_efetiv</b>	8,549	8,29	8,88	41,18	41,22	40,14	Gau	-	-
<b>ctc_ph7</b>	14,58	14,50	14,91	15,65	17,09	15,29	Esf	Esf	-
<b>ZINCO_mg_dm</b>	1,285	1,26	1,50	58,98	59,82	61,02	Esf	-	-
<b>3</b>									
<b>COBRE_mg_d</b>	6,666	6,75	6,85	32,43	32,10	32,40	Esf	Esf	-
<b>m3</b>									
<b>ENXOFRE_mg_</b>	15,22	15,29	14,90	18,38	18,22	18,36	Esf	-	-
<b>dm3</b>									
<b>BORO_mg_dm</b>	0,175	0,18	0,15	55,59	60,75	69,14	Esf	Esf	-
<b>3</b>									
<b>Condutividade</b>								Gau	-
<b>Elétrica</b>									
	1,292	1,22	0,21	44,23	36,16	0,43	Esf		

\*CV (%): Coeficiente de Variação; Modelo de ajuste Esférico (Esf) Exponencial (Exp) e Gaussiano (Gau) e Ausência de ajuste devido a não ocorrência de dependência espacial (-)

Para as variáveis relacionadas aos índices de vegetação, houve redução de 40% das variáveis com dependência espacial quando foi reduzido o número de pontos de 74 para 37 pontos e aproximadamente 90% a menos de variáveis com dependência espacial quando se adotou a grade de 15 pontos (Tabela 3).

**Tabela 3.** Média e coeficiente de variação (CV), modelos de ajuste do semivariograma (esférico, exponencial e gaussiano) das variáveis relacionadas a Índices de vegetação com Proble<sup>5</sup> e sem Proble<sup>6</sup>.

Variáveis	Média			CV (%)			Modelo de ajuste		
	74	37	15	74	37	15	74	37	15
<b>Índices de Vegetação com Proble</b>									
SR	16,19	16,39	16,62	11,91	9,58	1,52	Esf	-	-
NDVI	0,881	0,88	0,89	2,325	1,65	2,41	Esf	-	-
mNDVI	0,615	0,62	0,62	5,060	4,54	-1,05	Esf	Esf	-
SGR	8,711	8,56	8,37	13,10	12,36	-0,81	-	Esf	-
RGR	1,967	1,96	1,95	20,95	20,02	-0,61	Esf	Esf	-
NPCI	0,091	0,09	0,10	31,89	27,81	1,80	Esf	-	-
SRPI	0,836	0,831	0,83	6,02	5,27	5,55	Esf	-	Gau
NPQI	-0,014	-0,017	-0,02	-	-228	-	Exp	-	-
				275,4		252,2			
SIPI	1,01	1,011	1,01	0,325	0,269	0,33	Esf	Esf	-
PI1	1,818	1,816	1,81	13,21	12,56	11,41	Exp	Esf	-
PI2	0,09	0,098	0,10	13,86	10,85	7,97	Esf	Esf	-
PI3	0,745	0,740	0,74	7,143	5,99	5,90	Esf	Esf	Esf
EVI	-	-0,001	0,00	-	-11,9	-7,88	Esf	-	Gau
	0,0007			15,29					
<b>Índices de Vegetação sem Proble</b>									
SR	18,52	18,08	17,50	21,32	23,77	27,37	-	-	-
NDVI	0,892	0,890	0,89	3,343	2,924	3,32	Esf	Esf	-
mNDVI	0,616	0,614	0,62	8,196	7,475	6,50	Esf	Esf	-
SGR	8,711	8,561	8,37	13,1	12,36	9,29	-	Esf	-
RGR	0,942	0,947	0,94	16,86	16,51	17,16	Esf	-	-
NPCI	0,149	0,156	0,17	51,25	49,28	45,78	Esf	Esf	-
SRPI	0,747	0,737	0,71	14,48	14,85	15,94	Esf	Esf	-
NPQI	-0,05	-0,052	-0,05	-	-24,4	-	Esf	-	-
				29,34		18,05			
SIPI	1,013	1,014	1,02	1,426	1,106	1,23	Esf	-	-

<sup>5</sup> Alvo considerado para leitura do sensor é a folha da planta.

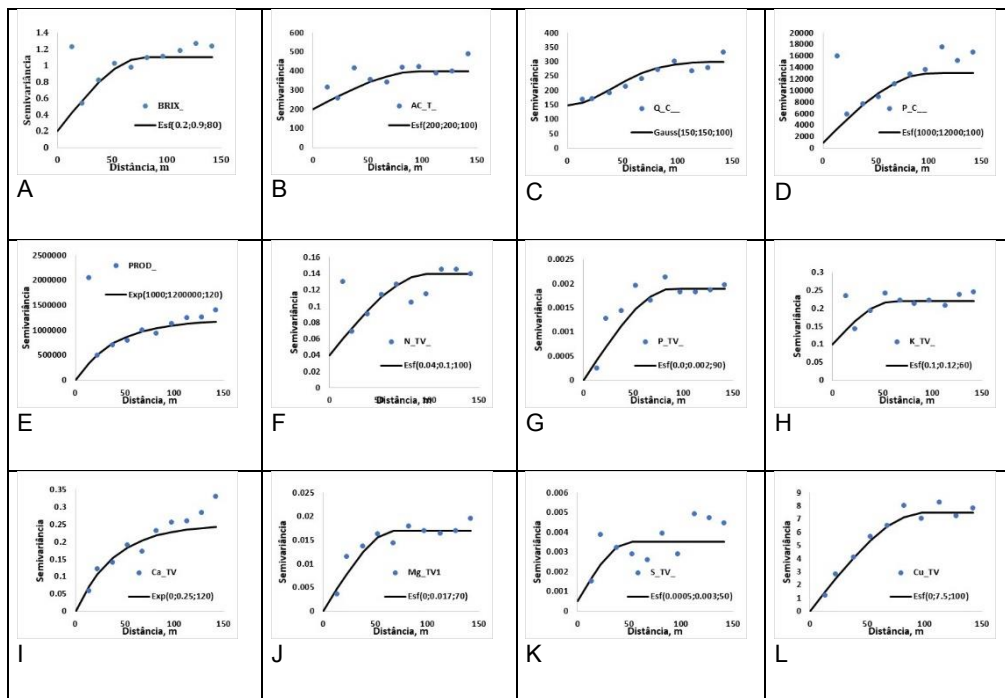
<sup>6</sup> Alvo considerado para leitura do sensor é o dossel da planta.




<b>PI1</b>	2,537	2,53	2,516	17,37	12,14	7,90	Esf	-	-
<b>PI2</b>	0,1024	0,10	0,104	26,84	19,81	18,42	Esf	Esf	-
<b>PI3</b>	0,6249	0,62	0,606	13,18	12,23	11,89	Esf	-	-
<b>SAVI</b>	-	-0,75	-0,751	-	-16,0	-	Gau	Esf	-
	0,7432			15,92		20,71			
<b>EVI</b>	-	-	-0,001	-	-52,8	-	Gau	Esf	-
	0,0004	0,0005		56,73		67,38			

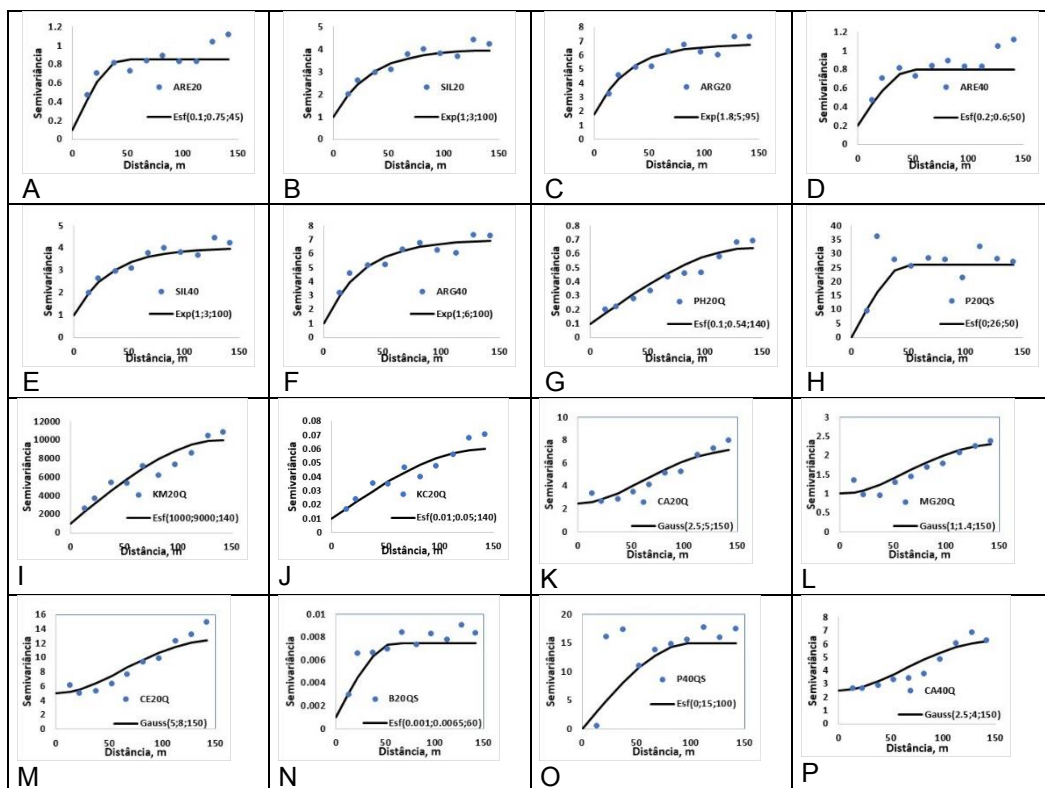
\*CV (%): Coeficiente de Variação; Modelo de ajuste Esférico (Esf), Exponencial (Exp) e Gaussiano (Gau) e Ausência de ajuste devido a não ocorrência de dependência espacial (-).

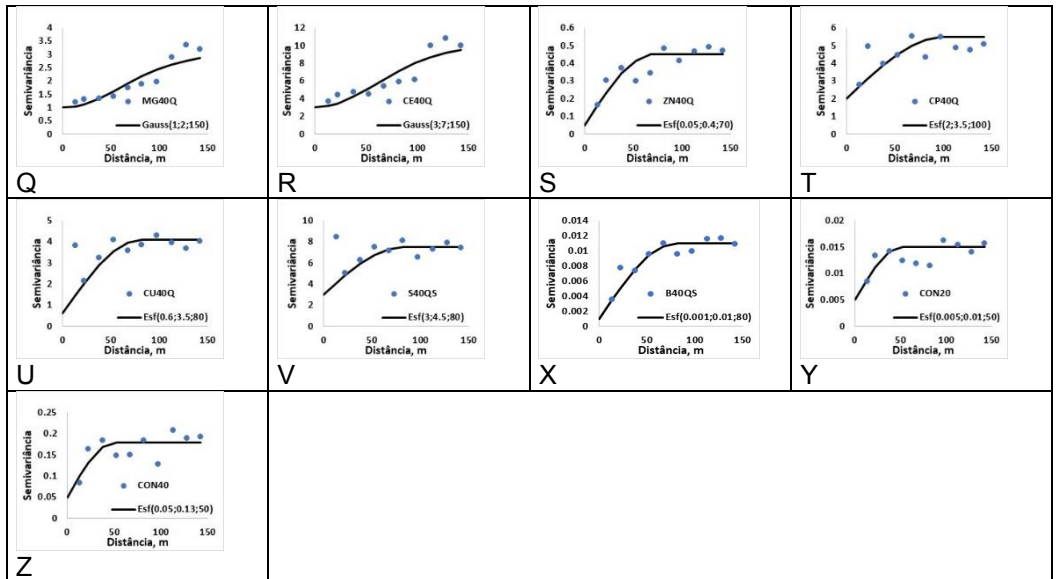
Para ilustrar a dependência espacial que ocorreu na grade de 74 pontos para a maioria das variáveis, os semivariogramas ajustados estão representados na Figura 3 para produção e tecido vegetal, na Figura 4 para física e química do solo e para índices de vegetação na Figura 5. Os ajustes fornecem os parâmetros efeito pepita, variância estrutural e alcance indicados nas legendas dos gráficos.



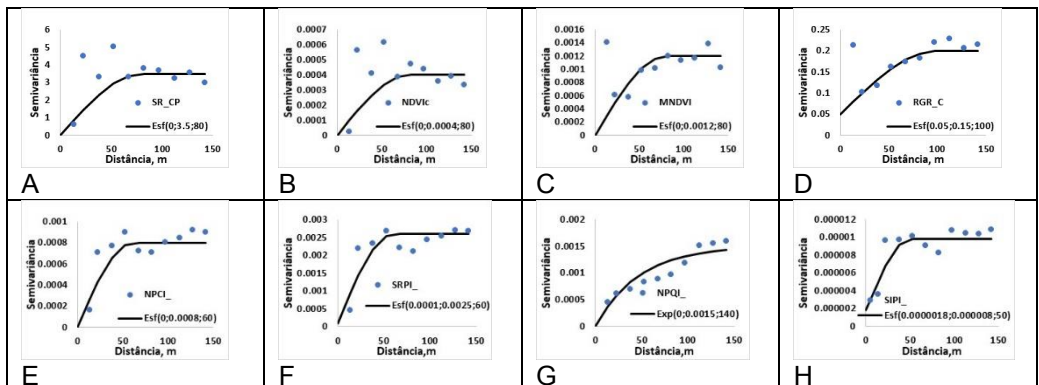


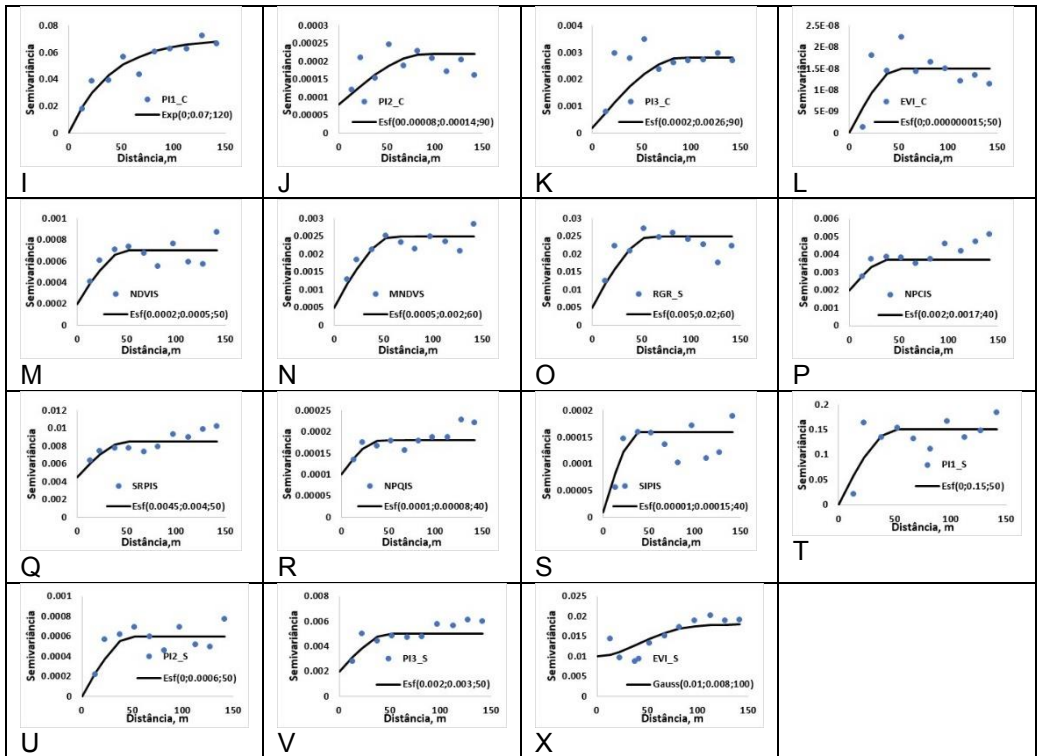
**Figura 3.** Semivariogramas ajustados e parâmetros de ajuste (Modelo (C0;C1;a)) para variáveis de produção e tecido vegetal que apresentaram dependência espacial na grade de 74 pontos: Brix (A); acidez total (B); quantidade de cachos em 3 plantas (C); peso de 3 cachos em gramas (D); produtividade em gramas (E); porcentagens de nitrogênio (F), fósforo (G), potássio (H), cálcio (I), magnésio (J) e enxofre (K); teores de cobre (L), ferro (M), manganês (N) e boro (O), em mg/kg.





**Figura 4.** Semivariogramas ajustados e parâmetros de ajuste (Modelo (C0;C1;a)) para variáveis de física e química do solo que apresentaram dependência espacial na grade de 74 pontos: porcentagens de areia a 20 cm (A) e 40 cm (D) de profundidade, de silte a 20 cm (B) e 40 cm (E) de profundidade e de argila a 20 cm (C) e 40 cm (F) de profundidade; pH em água (G), teores de fósforo (H), potássio (I) e boro (N) em  $\text{mg}/\text{dm}^3$ ; teores de potássio (J), cálcio (K) e magnésio em  $\text{cmolc}/\text{dm}^3$  (L) e capacidade de troca de cátions efetiva (M) a 20 cm de profundidade; teores de fósforo (O), zinco (S), cobre (U), enxofre (V) e boro (X), em  $\text{mg}/\text{dm}^3$ ; teores de cálcio (P) e magnésio (Q), em  $\text{cmolc}/\text{dm}^3$ ; capacidade de troca de cátions efetiva (R) e a  $\text{pH}=7$  (T) a 40 cm de profundidade; condutividade elétrica do solo a 20 cm (Y) e 40 cm (Z) de profundidade, em  $\text{mS}/\text{m}$ .



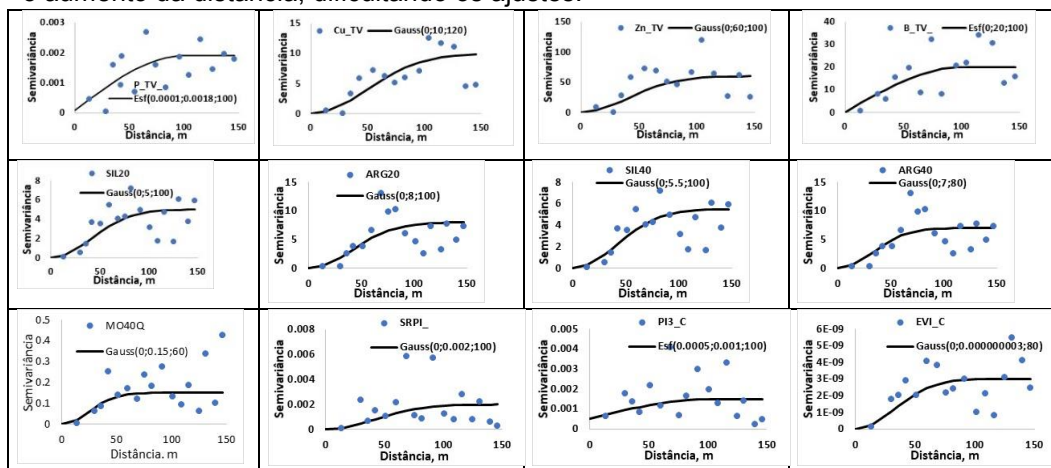


**Figura 5.** Semivariogramas ajustados e parâmetros de ajuste (Modelo (C0;C1;a)) para variáveis de Índices de Vegetação com *proble*: Simple Ratio (SR) (A); Normalized Difference Vegetation Index (NDVI) (B); modified NDVI (mNDVI) (C), Red Green Ratio (RGR) (D), Normalized Pigment Chlorophyll Ratio Index (NPCI) (E); Simple Ratio Pigment Index (SRPI) (F); Normalized Phaeophytinization Index (NPQI) (G); Structure Insensitive Pigment Index (SIPI) (H); Performance Index (PI) nos períodos 1 (I), 2 (J) e 3 (K); Enhanced Vegetation Index (EVI) (L); e sem *proble*: NDVI (M); mNDVI (N); RGR (O); NPCI (P); SRPI (Q); NPQI (R); SIPI (S); PI nos períodos 1 (T), 2 (U) e 3 (V); EVI (X), que apresentaram dependência espacial na grade de 74 pontos.

Com a redução do número de pontos de 74 para 37 e 15 pontos houve grande redução no número de variáveis com dependência espacial, principalmente na grade de 15 pontos. Das 63 variáveis que apresentaram variabilidade espacial na grade de 74 pontos, 52 também apresentaram dependência espacial na grade de 37 pontos, ou seja, reduzindo a metade dos pontos, ainda é possível garantir 83% de dependência espacial para o total de variáveis. Isso evidencia ser possível essa redução de pontos de amostragem, desde que distribuídos adequadamente em toda

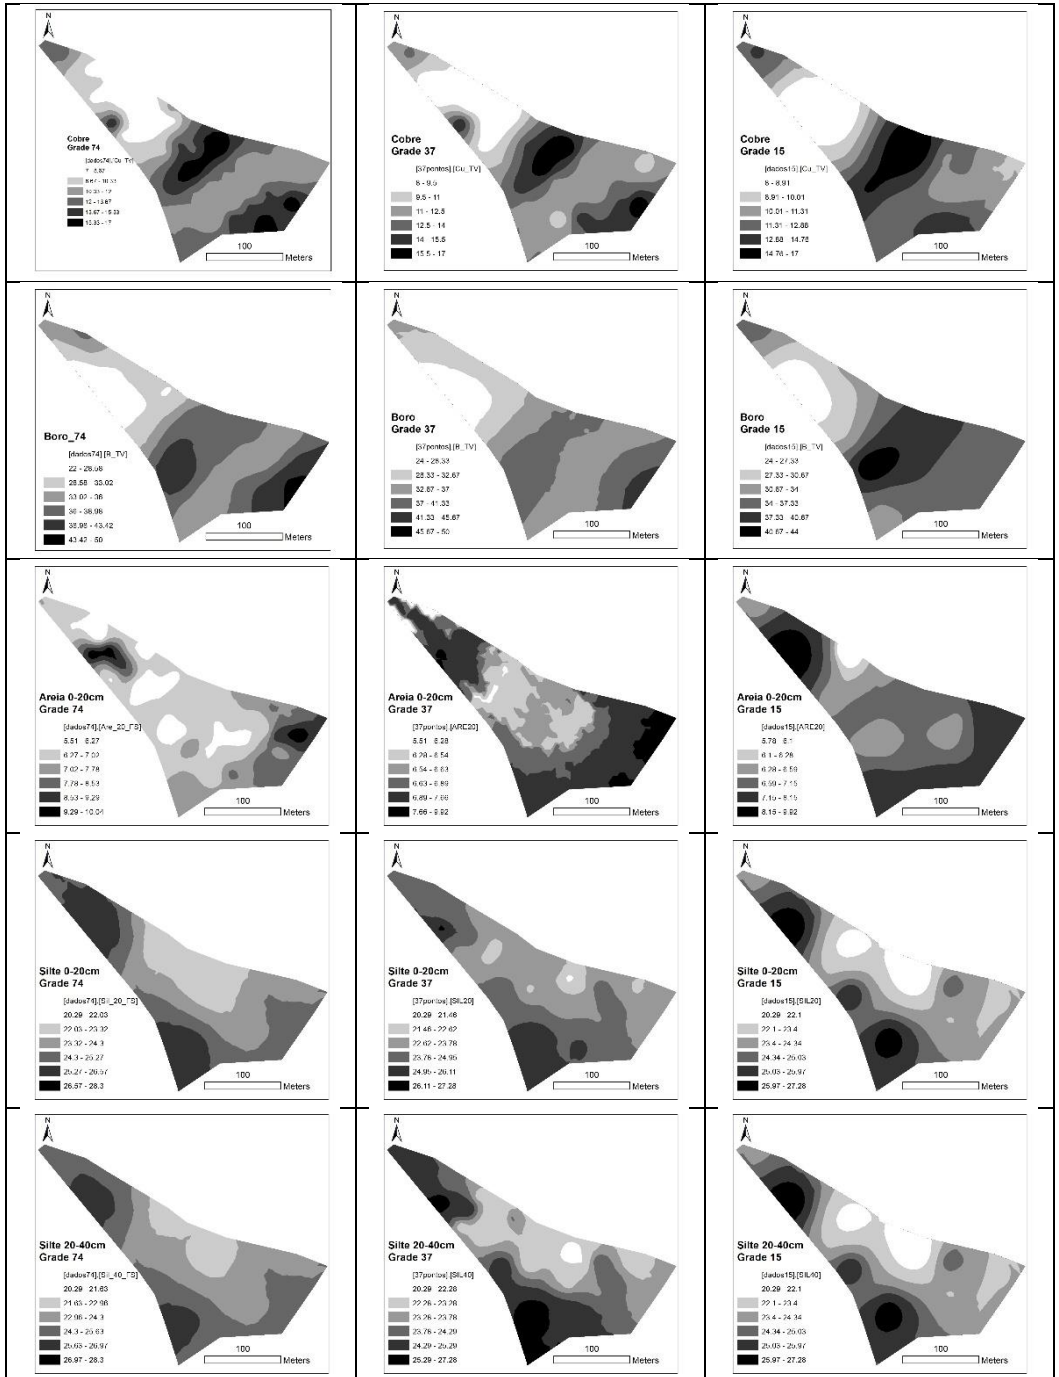
área de estudo, gerando economia de tempo e recursos no processo de obtenção das informações e conseqüentemente menor custo de produção. No entanto, os resultados não indicam uma alternativa adequada reduzir para menos da metade dos pontos como na grade de 15 pontos onde foram identificadas apenas 19% das variáveis com variabilidade espacial comparadas com a grade original de 74 pontos.

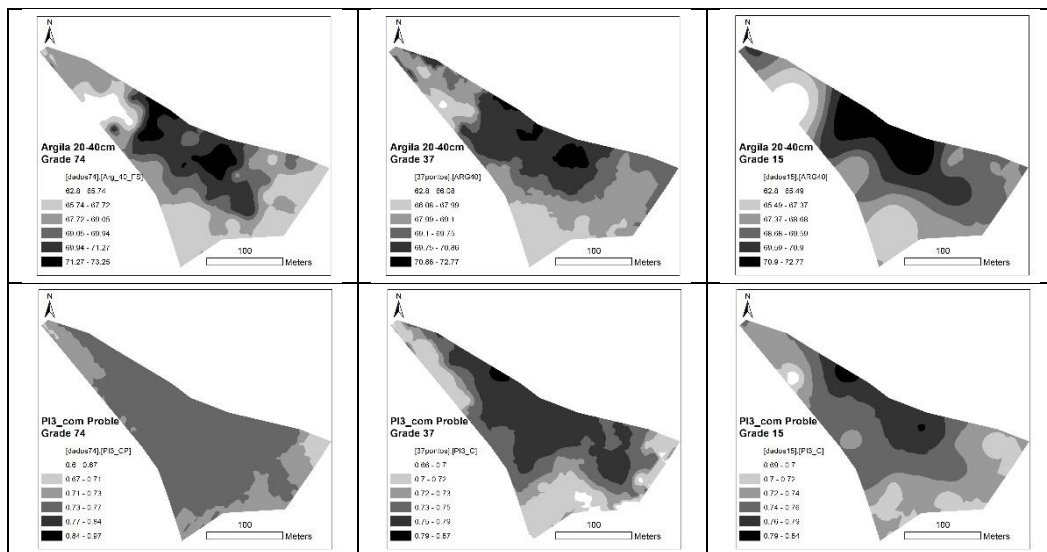
Para ilustrar o prejuízo na identificação da variabilidade espacial com a redução do número de pontos na grade de 15 pontos, na Figura 6 são representados os 19% dos ajustes do semivariograma nessa grade amostral. Verifica-se que mesmo com os ajustes a distribuição das semivariâncias não apresentaram crescimento com o aumento da distância, dificultando os ajustes.



**Figura 6.** Semivariogramas ajustados e parâmetros de ajuste (Modelo (C0;C1;a)) para variáveis que apresentaram dependência espacial na grade de 15 pontos.

Na Figura 7 estão representados os mapas obtidos por interpolação de valores a um metro de distância pelo método da krigagem ordinária para as variáveis que apresentaram dependência espacial nas 3 grades utilizadas. Quando comparadas as mesmas variáveis para as 3 grades, não houve mudanças no padrão espacial em relação às manchas de variabilidade espacial. Portanto, o prejuízo é maior em relação à redução do número de variáveis que deixam de apresentar dependência quando se reduz o número de pontos de amostragem de 74 para 15 pontos.





**Figura 7.** Mapas interpolados para as variáveis que apresentaram dependência espacial nas 3 grades de amostragem.

Em resumo, a análise geoestatística mostrou que apenas 12 atributos (Tabela 4) apresentaram dependência espacial para todas as grades amostrais utilizadas neste trabalho (74, 37 e 15 amostras).

**Tabela 4.** Atributos que apresentaram dependência espacial considerando as três grades amostrais estudadas.

Atributo	Sigla	Grupos
Fósforo (Tecido Vegetal)	P_TV	I e II
Cobre (Tecido Vegetal)	Cu_TV	I e II
Zinco (Tecido Vegetal)	Zn_TV	I e II
Boro (Tecido Vegetal)	B_TV	I e II
Silte à 20 cm	SIL20	I e III
Argila à 20 cm	ARG20	I e III
Silte à 40 cm	SIL40	I e III
Argila à 40 cm	ARG40	I e III
Matéria Orgânica à 40 cm	MO40Q	I e IV
Single Rate Pigment Index	SRPI	I e IV
PI Index	PI3_C	I e IV
Enhanced Vegetation Index	EVI_C	I e IV

Segundo a Tabela 4, para efeito de utilização como dados de entrada para os algoritmos de agrupamento, foram considerados: para o grupo I todos os atributos; para o grupo II, atributos relacionados ao tecido vegetal; para o grupo III, atributos relacionados ao solo; e para o grupo IV, atributos relacionados aos índices de vegetação. Considerando cada um desses 4 grupos e seus respectivos mapas interpolados (com grades iniciais de 15, 37 e 74 amostras), foram gerados agrupamentos utilizando 12 diferentes combinações de dados de entrada.

Considerando os mapas gerados a partir das análises geoestatísticas, para cada um dos experimentos, realizados com diferentes atributos de entrada (grupos I, II, III e IV), discutimos a redução de variância da produtividade e a concordância dos mapas de ZM gerados com diferentes grupos de atributos com relação aos mapas de ZM gerados com o atributo de produtividade. A variável  $n$  indica a quantidade de amostras (pontos) de campo utilizadas antes da interpolação espacial; a variável  $p$  indica a quantidade de atributos (variáveis) utilizados; e a variável  $k$  indica o número de grupos ou ZMs utilizados.

**Tabela 5.** Mapas de ZM obtidos considerando o grupo I (todos os atributos).


n/k	2	3	4	5
74				
37				
15				

**Tabela 6.** Redução da Variância para mapas de ZM considerando o grupo I (todos os atributos).

n / k	2	3	4	5
74	2,20	5,72	32,03	32,27
37	0,25	1,46	10,11	30,47
15	27,00	28,68	30,84	34,19



Nesse primeiro experimento, a utilização de uma quantidade maior de atributos com variabilidade espacial detectada ( $p=12$ ) contribuiu de maneira positiva para a geração de mapas de ZM com boa qualidade com relação à distribuição espacial, independentemente do valor de  $n$  (Tabela 5). Considerando os valores de  $VR$  exibidos na Tabela 6, é possível observar que a utilização de  $n=15$  proporcionou ganhos de redução da variância da produtividade maiores até mesmo do que a utilização da própria grade original de  $n=74$  amostras, para a maioria dos valores de  $k$ . Adicionalmente, para  $n=15$ , já é possível observar um alto valor de  $VR$  para  $k=2$ , que segue aumentando gradativamente até atingir o seu maior valor para  $k=5$ . Para as outras grades ( $n=74$  e  $n=37$ ), esses valores são atingidos apenas pelos mapas com  $k=4$  e  $k=5$  ZM. Em uma análise complementar, foi utilizado o índice Kappa para comparar os mapas de ZM considerando apenas os dados de produtividade (ZM-Prod), com os mapas de ZM obtidos considerando os atributos do grupo I (ZM-I) (Figura 7).

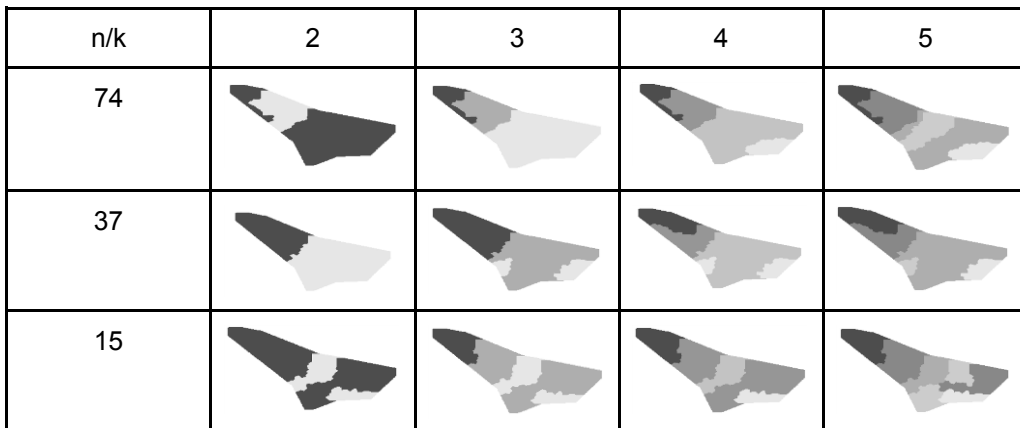


**Figura 8.** Índice Kappa para verificação de concordância entre mapas de ZM obtidos a partir de dados de produtividade (ZM-Prod) vs. mapas de ZM obtidos a partir de atributos do grupo I (ZM-I).

Os valores de *kappa* exibidos na Figura 8 mostram uma forte concordância entre os mapas ZM-Prod e ZM-I para  $k=2$ , considerando a grade amostral original com  $n=15$ . A maioria dos casos mostrou concordância entre moderada e razoável, sendo que os mapas obtidos com  $n=15$  se mostraram relativamente superiores aos outros para metade dos casos ( $k=2$  e  $k=3$ ).

Esses resultados mostram que, considerando o contexto da área e cultura em estudo, quando é utilizada quantidade significativa de atributos com bons indicativos de variabilidade espacial, tanto do solo quanto da cultura, o manejo utilizando AP pode ser realizado de maneira satisfatória com cerca de 4 amostras por hectare.

**Tabela 7.** Mapas de ZM obtidos considerando o grupo II (tecido vegetal).

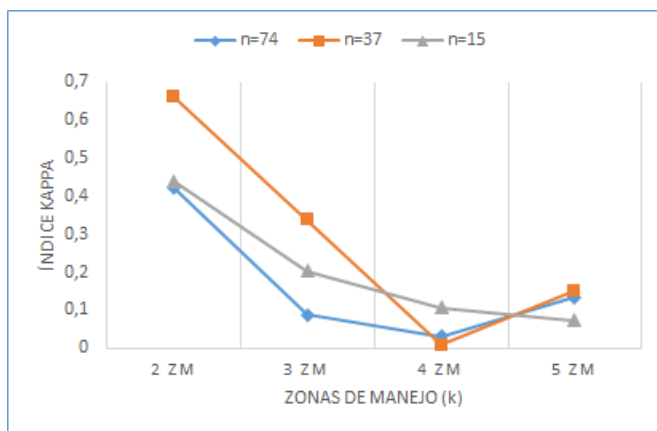


**Tabela 8.** Redução da Variância para mapas de ZM considerando o grupo II (tecido vegetal).

n/k	2	3	4	5
74	15,34	27,13	28,83	40,86
37	28,34	30,16	30,17	48,82
15	19,37	29,81	36,46	51,99

De maneira similar ao experimento anterior, mesmo com a utilização de poucos atributos ( $p=4$ ), a redução de variância da produtividade considerando os mapas de ZM gerados é substancial, principalmente quando utilizamos grades menores, com  $n=15$  e  $n=37$  amostras (Tabela 8). Isso indica que o manejo utilizando

AP considerando exclusivamente dados relacionados ao tecido vegetal pode ser satisfatório em um intervalo entre 4 a 10 amostras por hectare para a área de estudo, sem comprometer a qualidade final dos mapas (Tabela 7). A análise utilizando o índice Kappa também mostra uma maior concordância entre os mapas ZM-Prod com os mapas ZM-II obtidos a partir de dados com grades amostrais originais de menor resolução espacial (Figura 9).




**Figura 9.** Índice Kappa para verificação de concordância entre mapas de ZM obtidos a partir de dados de produtividade (ZM-Prod) vs. mapas de ZM obtidos a partir de atributos do grupo II (ZM-II).

**Tabela 9.** Mapas de ZM obtidos considerando o grupo III (solo).

Grade Original / Nro. Grupos	2	3	4	5
74				
37				
15				

**Tabela 10.** Redução da Variância para mapas de ZM considerando o grupo III (solo).













Grade Original / Nro. Grupos	2	3	4	5
74	0,39	3,46	4,15	23,68
37	0,96	7,73	11,15	15,63
15	81,52	100	100	100

**Figura 10.** Índice Kappa para verificação de concordância entre mapas de ZM obtidos a partir de dados de produtividade (ZM-Prod) vs. mapas de ZM obtidos a partir de atributos do grupo III (ZM-III).

Os experimentos utilizando apenas dados de solo ( $p=5$ ) mostraram uma boa redução da variância da produtividade para todos valores de  $n$ , mantendo mapas de ZM bem distribuídos espacialmente (Tabela 10). Nesse caso pode ser observado, a partir da Tabela 9, que para a grade  $n=15$ , os valores de  $VR$  foram muito superiores em comparação com as outras grades, chegando ao valor máximo de 100 suportado

pelo cálculo do VR nos casos onde  $k=3$ ,  $k=4$  e  $k=5$ . Esse resultado também é refletido nos valores de  $kappa$  (Figura 10), que mostram uma maior concordância dos mapas de ZM-III obtidos com  $n=15$  com os mapas de ZM-Prod na maioria dos casos. No entanto, amostragem por uma grade considerando  $n=15$  não foi suficiente para expressar uma adequada variabilidade espacial, reduzindo muito o número de variáveis de solo para mapeamento. Uma alternativa prática para identificar rapidamente essa baixa variabilidade antes de efetivamente realizar as amostragens de solo seria a utilização de sensores de campo capazes de coletar informações contínuas, como a condutividade elétrica aparente do solo (CEa). A CEa tem alta correlação com textura e produtividade, podendo fornecer indicativos bastante confiáveis para uma amostragem guiada com relação à variabilidade espacial.


**Tabela 11.** Mapas de ZM obtidos considerando o grupo IV (índices de vegetação).

Grade Original / Nro. Grupos	2	3	4	5
74				
37				
15				

**Tabela 12.** Redução da Variância para mapas de ZM considerando o grupo IV (índices de vegetação).

Grade Original / Nro. Grupos	2	3	4	5
74	1,63	3,07	16,52	16,74
37	23,26	24,76	51,31	51,69

15	22,51	22,54	42,28	43,25
----	-------	-------	-------	-------



**Figura 11.** Índice Kappa para verificação de concordância entre mapas de ZM obtidos a partir de dados de produtividade (ZM-Prod) vs. mapas de ZM obtidos a partir de atributos do grupo IV (ZM-IV).

O último experimento, utilizando apenas índices de vegetação, mostrou uma tendência maior de utilização das grades  $n=37$  e  $n=15$ , que apresentaram mapas de ZM com uma distribuição espacial melhor definida em comparação com os mapas obtidos com dados na grade  $n=74$  (Tabela 11). Assim como ocorre para os atributos relacionados ao tecido vegetal, os índices de vegetação são mais sensíveis à variabilidade quando comparados com as amostragens de solo e, para esse caso em específico, a grade com  $n=37$  aparenta ser a mais adequada (10 amostras por hectare) conforme dados de VR exibidos na Tabela 12. Essa afirmação pode ser reforçada pelos resultados obtidos com o índice Kappa, exibidos na Figura 11, onde os mapas de ZM-IV gerados a partir da grade  $n=37$  mostraram maior concordância com ZM-Prod para todos valores de  $k$ .

Com base nestes resultados, é possível inferir um impacto positivo no trabalho da AP junto ao produtor de frutas, que hoje apresenta restrições no uso da tecnologia dado às pequenas áreas envolvidas e o grande número de pontos de amostragens exigidos pela geoestatística tradicional. Adicionalmente, indica ser possível a inclusão da economicidade e escalabilidade de trabalho de coleta de dados de campo para a fruticultura de precisão, permitindo ainda estabelecer os níveis de acurácia que o produtor deseja atingir para sua análise. Caso ele necessite de estudos com maior exatidão, pode demandar os levantamentos com maior

número de amostragens na grade, mas caso o aspecto econômico seja o impeditivo para a adoção da tecnologia da fruticultura de precisão, ele pode reduzir as amostras da grade até os níveis mínimos apontados nesta pesquisa com razoável segurança.

Outro aspecto a ser considerado é a necessidade de continuidade deste trabalho, pois à medida que mais áreas e dados de outras culturas perenes puderem ser analisados sob os aspectos apresentados nesta pesquisa, maiores serão as margens de acerto para uma melhor tomada de decisão quanto à definição do número de pontos de uma grade em fruticultura. Ainda é conveniente apontar o problema da temporalidade dos dados, principalmente quanto àqueles vinculados à fisiologia de plantas, que podem variar rapidamente de uma safra para outra, necessitando maiores análises para a definição dos cenários ideais para o estabelecimento da grade amostral mínima definitiva.

## Conclusões

---

Este trabalho de pesquisa teve como principal objetivo propor uma metodologia, a partir de dados coletados em campo e ferramentas estatísticas e computacionais, para sugerir grades amostrais em diferentes resoluções espaciais para monitoramento de dados da cultura e do solo para adoção de AP no manejo de frutas em parreirais de videira.

Os resultados obtidos mostraram que a utilização de conjuntos de atributos que consideram diferentes fatores ao mesmo tempo (solo, tecido vegetal e índices de vegetação) proporcionam uma riqueza de informações suficiente para que sejam utilizadas grades amostrais limitadas, com cerca de 4 amostras por hectare, capazes de identificar de maneira satisfatória a variabilidade espacial da área e permitir a adoção de ferramentas de AP. Devido à variabilidade espacial do solo ser menor, em comparação à variabilidade espacial dos atributos relacionados à cultura, os resultados mostraram que a utilização exclusiva desses atributos também indica uma grade de 4 amostras por hectare como suficiente para a utilização de AP. Já para o uso exclusivo de índices de vegetação e/ou atributos de tecido vegetal, a tendência é que sejam utilizadas pelo menos 10 amostras por hectare.

Apesar de este trabalho ter sido realizado considerando dados de uma área experimental contendo três espécies distintas de uva, conjuntos de dados obtidos em outras áreas, inclusive fatores que podem proporcionar diferentes resultados, como o microclima, seriam importantes para completar essa análise e generalizar a metodologia proposta. A questão temporal também deve ser observada, ou seja, é importante considerar em uma próxima etapa o acúmulo de observações dos mesmos atributos em mais de uma safra, mesmo que em uma mesma área, com o intuito de atenuar eventuais problemas que possam ocorrer com relação aos fatores de microclima. De qualquer maneira, as indicações propostas neste trabalho podem

servir para estimular o uso de ferramentas de AP por parte dos produtores de uva, em parreirais onde o manejo considerando a variabilidade espacial poderá trazer benefícios relacionados tanto à economia de mão de obra e de insumos, quanto ao aumento da produtividade e da lucratividade.

## Referências

---

BETZEK, N. M.; SOUZA, E. G. de; BAZZI, C. L.; SCHENATTO, K.; GAVIOLI, A. Rectification methods for optimization of management zones. **Computers and Electronics in Agriculture**, v. 146, p. 1-11, Mar. 2018. DOI: 10.1016/j.compag.2018.01.014.

COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37-46, Apr. 1960. DOI: 10.1177/001316446002000104.

DOBERMANN, A.; PING, J. L.; ADAMCHUK, V. I.; SIMBAHAN, G. C.; FERGUSON, R. B. Classification of crop yield variability in irrigated production fields. **Agronomy Journal**, v. 95, n. 5, p. 1105-1120, 2003. DOI: 10.2134/agronj2003.1105.

FAYYAD, U.; PIATETSKY-SHAPIO, G.; SMYTH, P. The KDD process for extracting useful knowledge from volumes of data. **Communications of the ACM**, v. 39, n. 11, p. 27-34, Nov. 1996. DOI: 10.1145/240455.240464.

GAVIOLI, A.; SOUZA, E. G. de; 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, May 2019. DOI: 10.1016/j.biosystemseng.2019.02.019.

GOOVAERTS, P. **Geostatistics for natural resources evaluation**. New York: Oxford University Press, 1997. 483 p. (Applied geostatistics series).

KAUFMAN, L.; ROUSSEEUW, P. J. **Finding groups in data: an introduction to cluster analysis**. Hoboken: John Wiley & Sons, 2009. (Wiley series in probability and statistics).

KITCHEN, N. R.; SUDDUTH, K. A.; MYERS, D. B.; DRUMMOND, S. T.; HONG, S. Y. Delineating productivity zones on claypan soil fields using apparent soil electrical conductivity. **Computer and Electronics in Agriculture**, v. 46, n. 1-3, p. 285-308, Mar. 2005. DOI: 10.1016/j.compag.2004.11.012.



MCQUITTY, L. L. Similarity analysis by reciprocal pairs for discrete and continuous data. **Educational and Psychological measurement**, v. 26, n. 4, p. 825-831, Dec.1966. DOI: 10.1177/001316446602600402.

MOLIN, J. P.; AMARAL, L. R. do; COLAÇO, A. F. **Agricultura de precisão**. São Paulo: Oficina de textos, 2015.

OLIVEIRA, R. P. de; GREGO, C. R; BRANDÃO, Z. N. (Ed.). **Geoestatística aplicada na agricultura de precisão utilizando o Vesper**. Brasília, DF: Embrapa, 2015. 159 p.

OLIVER, M. A.; WEBSTER, R. Kriging: a method of interpolation for geographical information systems. **International Journal of Geographical Information System**, v. 4, n. 3, p. 313-332, 1990. DOI: 10.1080/02693799008941549.

REZENDE, S. O. (Coord.). **Sistemas inteligentes: fundamentos aplicações**. Barueri: Manole, 2003.

RUß, G.; KRUSE, R. Exploratory hierarchical clustering for management zone delineation in precision agriculture. In: INDUSTRIAL CONFERENCE, 11., 2012, New York. **Advances in data mining: applications and theoretical aspects: proceedings**. Heidelberg: Springer, 2011. p. 161–173. (Lecture notes in artificial intelligence, v. 6870). DOI: 10.1007/978-3-642-23184-1\_13.

SANTOS, R. T.; SARAIVA, A. M. A reference process for management zones delineation in precision agriculture. **IEEE Latin America Transactions**, v. 13, n. 3, p. 727-738, Mar. 2015. DOI: 10.1109/TLA.2015.7069098.

SOARES, A. **Geoestatística para as ciências da terra e do ambiente**. Lisboa: IST Press, 2006. 214 p. (Coleção ensino da ciência e da tecnologia; 9).

SOBJAK, R; SOUZA, E. G. de; BAZZI, C. L.; URIBE-OPAZO, M. A.; BETZEK, N. M. Redundant variables and the quality of management zones. **Engenharia Agrícola**, v. 36, n. 1, p. 78-93, 2016. DOI: 10.1590/1809-4430-Eng.Agric.v36n1p78-93/2016.

SPERANZA, E. A. **Mineração de dados espaciais aplicada no delineamento de unidades de gestão diferenciada em agricultura de precisão**. 2017. 340 p. Tese (Doutorado em Ciência da Computação) - Universidade Federal de São Carlos, São Carlos.

VALLADARES, G. S.; AZEVEDO, E. C. de; CAMARGO, O. A. de; GREGO, C. R.; RASTOLDO, A. M. C. S. Variabilidade espacial e disponibilidade de cobre e zinco em

solos de vinhedo e adjacências. **Bragantia**, v. 68, n.3, p.733-742, 2009. DOI: 10.1590/S0006-87052009000300021.

VENDRAMIN, L.; CAMPELLO, R. J. G. B.; HRUSCHKA, E. R. Relative clustering validity criteria: a comparative overview. **Statistical Analysis and Data Mining**, v. 3, n. 4, p. 209–235, Aug. 2010. DOI: 10.1002/sam.10080.

VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAIS, R. F. de; ALVAREZ V, V. H.; SCHAEFER, C. E. G. R. (Ed.). **Tópicos em ciência do solo**. Viçosa: Sociedade Brasileira de Ciência do Solo, 2000. v. 1, p. 1-54.



---

*Agricultura Digital*