

SIMULAÇÃO SEQUENCIAL DIRETA NA IDENTIFICAÇÃO E QUANTIFICAÇÃO DE INCERTEZAS ASSOCIADA À ESTIMAÇÃO DA PRODUÇÃO DE CAFÉ CONILON

WAYLSON ZANCANELLA QUARTEZANI¹ & CÉLIA REGINA LOPEZ ZIMBACK²

RESUMO: Os métodos de interpolação como a krigagem, que são modelos de estimação, expressam os valores extremos locais de um dado ponto, e não o comportamento simultâneo do conjunto de pontos, o qual só é possível por meio de simulações. A simulação não gera imagens com as características mais prováveis da variável, mas sim, um conjunto de imagens equiprováveis com a mesma variabilidade espacial dos valores experimentais. A simulação permite determinar incertezas espaciais obtidas pela variabilidade do conjunto de imagens equiprováveis da variável em estudo. Portanto, o trabalho teve por objetivo aplicar a Simulação Sequencial Direta (DSS) na identificação e quantificação de incertezas associada à estimação por krigagem da produção de café conilon. O trabalho foi realizado numa lavoura comercial de café conilon no Município de São Mateus (ES). Foram marcados pontos de amostragem, em uma área irregular de 18,567 ha, com os pontos espaçados irregularmente (não equidistantes) e formados por amostragem composta de 3 plantas, totalizando 87 células de amostragem, para produção do café maduro (CM), proveniente da safra de 2010. O coeficiente de Variação (CV) foi classificado como muito alto (CV > 40,3 %), indicando variabilidade alta na produção. O variograma esférico (esf) e alcance (a) de 150 metros, para as direções analisadas, expressaram a continuidade espacial de um processo isotrópico. A estimação da produção CM possibilitou identificar duas regiões com alta produção, diferente das demais, evidenciando um manejo diferenciado ao longo da área de estudo. Com as simulações atendendo aos pressupostos de mesma distribuição e variografia dos dados originais, com a DSS foi possível identificar e quantificar áreas de incertezas, associadas à estimação da produção de CM, em 26,43 % (5 ha) da área total.

Palavras-chave: Geoestatística, krigagem, mapa de variância.

¹ Faculdade Capixaba de Nova Venécia, Engenharias, atua nos temas: geoestatística para estimação e simulação estocástica; estatística básica, experimental e multivariada, geoprocessamento: sig, sensoriamento remoto (sr) e índices de vegetação (iv); ciências do solo (física e fertilidade), agricultura de precisão. E-mail: waylson@yahoo.com.br

² Prof. do Departamento de Solos e Recursos Ambientais, FCA/UNESP – Botucatu/SP, Brasil atuando, principalmente, nos seguintes temas: Solos, Sistema de Informação Geográfica - SIG, CAD, GPS, Levantamento de Solos, Geoestatística e Sensoriamento Remoto. E-mail: czimback@gmail.com

DIRECT SEQUENTIAL SIMULATION IN IDENTIFICATION AND QUALIFICATION OF UNCERTAINTIES ASSOCIATED WITH PRODUCTION ESTIMATION OF DIFFERENT COFFEE TYPES

SUMMARY: *Interpolation methods such as kriging, are estimation models, express the extreme local values of a given point, and not the concurrent behavior of the set of points, which is only possible by means of simulations. The simulation does not generate images with the most probable characteristics of the variable, but rather, a set of images equipped with the same spatial variability of the experimental values. The simulation allows to determine spatial variability obtained by the uncertainties of equipped images of the variable under study. Therefore, the study aimed to apply the Direct Sequential Simulation (DSS) in the identification and quantification of uncertainty associated with the estimation by kriging in coffee production. The study was carried out in a commercial crop of different coffee in the municipality of São Mateus (ES). Sampling points were scored, in an irregular area of 18.567 ha, with irregularly spaced points (not offsets) and formed by sampling consisted of 3 plants totaling 87 sampling cells for production of mature coffee (CM) from the 2010 harvest. The coefficient of variation (CV) was rated as very high ($CV > 40.3\%$), indicating high variability in production. The spherical variogram (esf) and range from 150 meters, for directions analyzed expressed an isotropic spatial continuity. The production CM made it possible to identify two regions with high production, different from the other, evidencing a differentiated management throughout the study area. With simulations taking into account the assumptions of same distribution and variogram of the original data, the DSS was unable to identify and quantify areas of uncertainty associated with the estimation of the production of CM, 26.43% (5 ha) of the total area.*

Keywords: *Geostatistics, kriging, variance map.*

1 INTRODUÇÃO

Os modelos de simulação estocástica têm como objetivo a elaboração de imagens “virtuais” da realidade que refletem as características do recurso natural, a variabilidade do conjunto de amostras, a lei de distribuição da variável em estudo e a continuidade espacial, tal qual é revelada pelos variogramas ou covariâncias, condições estas, que não são abrangidas pelos modelos de estimação. Estes modelos fornecem um conjunto de imagens equiprováveis com a mesma variabilidade espacial dos dados experimentais,

de modo que em todas as imagens sejam reproduzidas as mesmas estatísticas de variabilidade espacial (histograma e variograma ou covariância espacial), quantificados pelas amostras (SOARES, 2006).

A distribuição de probabilidade da estimativa local é realizada no âmbito da indicatríz ou do formalismo multiGaussiano. Mas vale ressaltar que as principais desvantagens de ambos os métodos são, direta ou indiretamente relacionados com a necessidade de transformar a variável original (SOARES, 2001). Para solucionar este problema, Soares (2001) propôs a utilização da Simulação Sequencial Direta (DSS), onde este algoritmo de simulação difere da Simulação Sequencial Gaussiana tradicional por não requerer uma transformação prévia das variáveis originais para uma distribuição do tipo gaussiano.

Simulação Sequencial Direta (DSS) significa simular sem qualquer transformação da variável original e tem sido amplamente utilizada para a caracterização espacial de variáveis categóricas (SOARES, 1998). Journel (1994) introduziu o primeiro passo para a simulação de uma variável contínua sem qualquer transformação prévia: ele demonstrou que a simulação direta de uma variável contínua, conseguiu reproduzir o modelo de covariância, porém ele não conseguiu reproduzir o histograma da variável contínua. Segundo Soares (2006), isso ocorreu devido às leis de distribuição não poderem ser totalmente caracterizadas somente pelas médias e variâncias locais das variáveis originais. Esta foi a razão pela qual este princípio só foi transformado num modelo, precisamente quando a reprodução do histograma da variável original, foi assegurando por Soares em 2001.

A ideia da Simulação Sequencial Direta (DSS) nasceu do seguinte postulado: se as leis de distribuições locais de $Z(x)$ são centradas no estimador de krigagem simples com a variância condicional local igual à variância de krigagem $\sigma_{ks}^2(x_0)$, então as covariâncias espaciais ou variogramas são necessariamente reproduzidos nos mapas finais simulados (JOURNEL, 1994). Bourgault (1997) demonstrou na prática essa afirmação com vários tipos de distribuições. O problema é que este princípio garante a reprodução dos variogramas, mas não a do histograma da variável original (SOARES, 2006).

Soares (2001) postulou que o modelo de Simulação Sequencial Direta reside na utilização das médias e variâncias locais, não para definir as leis de distribuição locais como na Simulação Sequencial Gaussiana, mas para reamostrar a lei de distribuição global.

Os métodos de interpolação como a krigagem são modelos de estimação cujo objetivo é a inferência espacial das características médias de uma dada variável, que consegue expressar os valores locais de um dado ponto, mas não o comportamento simultâneo do conjunto de pontos. Este só é possível com várias realizações da distribuição conjunta no espaço dos valores da variável, que pode ser feito por meio de simulações. Portanto, com a simulação não se pretende apenas obter a imagem mais provável das características de um dado recurso, mas sim, um conjunto de imagens equiprováveis com a mesma variabilidade espacial dos valores experimentais. Este conjunto de imagens representativas do fenômeno espacial permite a obtenção de incertezas espaciais pela variabilidade do conjunto de imagens equiprováveis, possibili-

tando visualizar o comportamento extremo das características internas ou morfológicas de um dado recurso natural e simultaneamente, quantificar a incerteza espacial dessas características (SANTOS, 2003).

A quantificação da incerteza espacial torna-se essencial quando na análise de avaliação do estimador (interpolado), que reflete diretamente no real valor da variável, para estimação em pontos não amostrados no campo, sendo que, quanto maior a variância do ponto simulado, maior será a incerteza espacial associado a sua estimação. Portanto, o trabalho teve como objetivo a aplicação da Simulação Sequencial Direta para a identificação e quantificação de áreas de incertezas associada à estimação por krigagem da produção de café conilon.

2 MATERIAL E MÉTODOS

O trabalho foi realizado em lavoura de café conilon localizada no Município de São Mateus (ES), com coordenadas geográficas centrais: 18°45'38" de latitude Sul e 40°04'40" de longitude O de Greenwich e altitude média de 78 m. O solo da área é classificado como LATOSSOLO VERMELHO-AMARELO Distrófico, textura franco argiloso arenosa, com relevo plano a suave ondulado, segundo o Sistema Brasileiro de Classificação de Solos (EMBRAPA, 2006). A espécie de café cultivada é a *Coffea canephora* Pierre, Var. conilon. Foram demarcados pontos de amostragens, espaçados a diferentes distâncias (não equidistantes), situados dentro de uma área irregular de 185.670 m² (18,567 ha). Em 5 regiões ao longo da malha foi feito um adensamento dos pontos, com a amostragem de 5 pontos a uma distância menor, para evitar que os variogramas apresentassem Efeito Pepita Puro, nos casos em que o alcance ou a dependência espacial da variável em estudo fossem menores que a distância de amostragem. Cada célula foi constituída pela amostragem de 3 plantas, na mesma fileira, para a coleta da variável produção do café maduro (CM), constituindo, portanto, uma amostragem composta, totalizando 87 células amostrais. O georreferenciamento correspondeu ao centro de cada célula (planta do meio) e as coordenadas foram obtidas com o auxílio de um GPS topográfico. Foi utilizado o sistema de coordenadas UTM (Universal Transverso de Mercator) no Datum WGS-84. A Figura 1 ilustra o Modelo Numérico de Elevação (MNE) da área em estudo com o esquema de distribuição dos pontos na malha amostral e a divisão da lavoura em talhões.

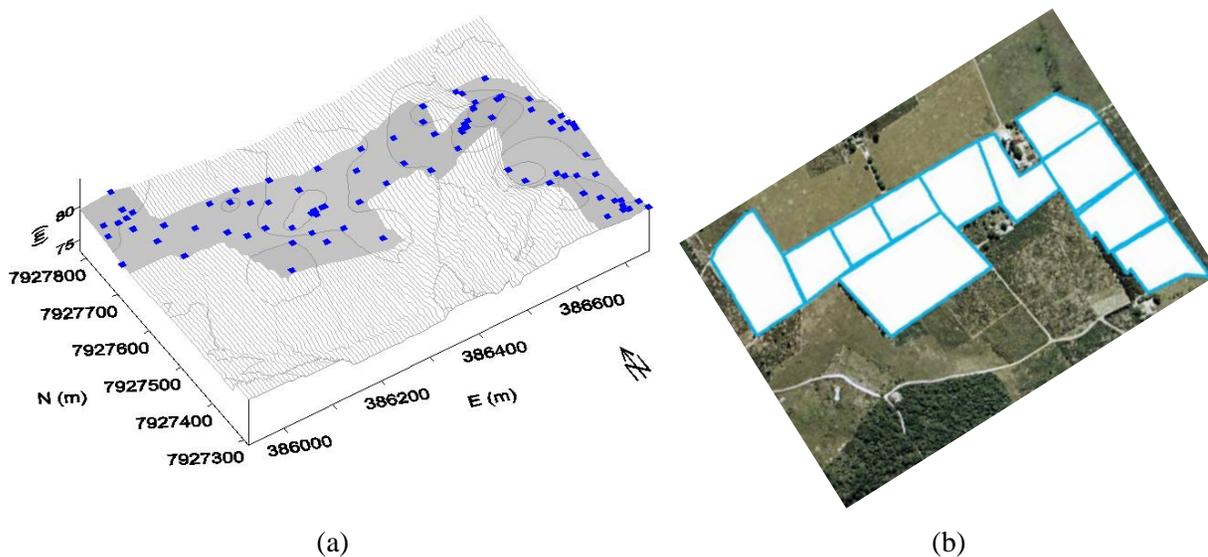


Figura 1 - (a) Modelo Numérico de Elevação da área em estudo com a distribuição dos pontos amostrais na malha; (b) Divisão da lavoura de café em talhões.

A colheita iniciada em abril foi feita quando os grãos iniciaram o amadurecimento (Figura 2A), o que na região Norte do ES, para o café conilon, ocorre nos meses de abril e maio. Os grãos de café de cada célula amostral (composto de três plantas) foram derrichados manualmente em peneiras (Figura 2B), colocados em sacos identificados (Figura 2C) pesados em balança comercial (Figura 2D) para a determinação da variável (CM) em kg. A Figura 2 apresenta os processos de obtenção da produção de café maduro (CM), determinada a partir da colheita de café úmido (verde e maduro) proveniente da safra de 2010.

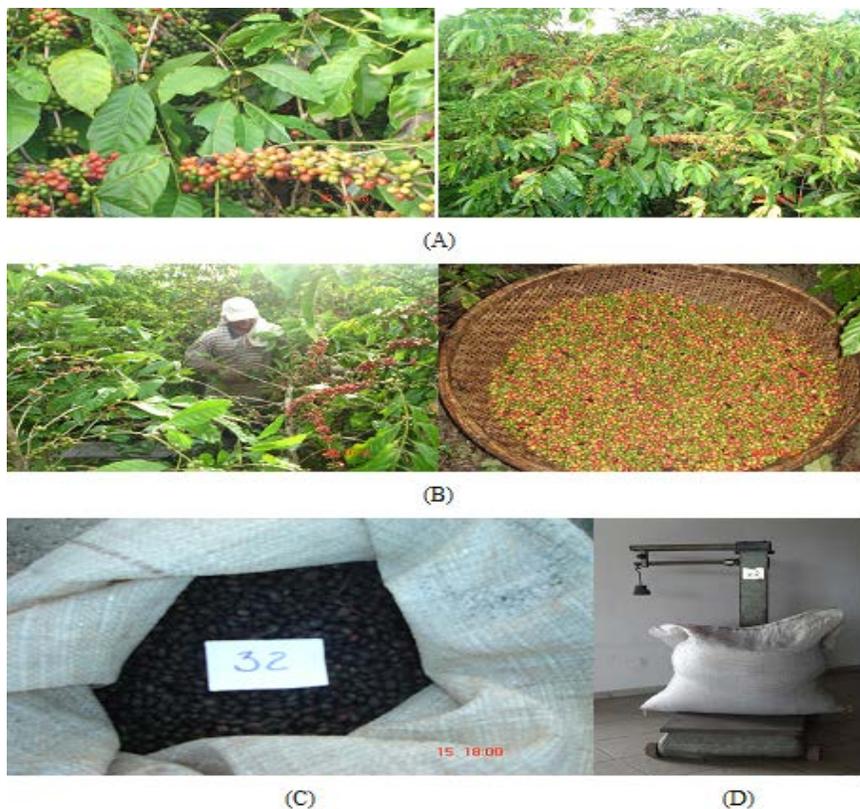


Figura 2 - Processos de obtenção da variável CM: (A) estágio de maturação dos frutos para colheita; (B) colheita manual com derriça em peneira; (C) identificação das amostras; (D) Pesagem das amostras em balança comercial.

Fonte: Quartezani (2010).

A análise estatística, foi realizada nos programas MÓDULO geoDATA do geoMS v. 1.0 (CMRP, 2000) e no Statística 7.0 (STAT SOFT, 2001). Para análise geoestatística, o programa adotado foi o geoMS v. 1.0 com a utilização dos MÓDULOS geoVAR; geoVAG; geoMOD, geoKRIG e geoDSS. A parte gráfica visual, com os mapas, foi construída no MÓDULO geoVIEW do geoMS. A análise estatística dos dados foi realizada no intuito de identificar, descrever e avaliar algumas estatísticas de interesse como as medidas de posição e dispersão, utilizando a análise estatística descritiva proposta por Vieira (2000). Os dados foram submetidos à análise geoestatística no intuito de verificar a existência da dependência espacial, com o ajuste do variograma clássico de Matheron. Definidos os parâmetros efeito pepita, alcance e patamar, a estimativa dos valores em posições não amostradas no campo, foi obtida pela técnica de interpolação por krigagem. A krigagem foi utilizada para a estimativa da variável CM. Com a malha de pontos interpolados, tem-se um maior detalhamento da área em estudo, e uma melhor visualização do comporta-

mento da variável na região, devido ao aumento do número de observações. A grade interpolada foi utilizada para a criação de mapa temático da variável, com a obtenção desse mapa possibilitando o estabelecimento de zonas de manejo.

A metodologia proposta consistiu na estimação e simulação da variável produção de café (CM) baseado nos procedimentos de interpolação por krigagem e estocásticos por Simulação Sequencial Direta, no intuito de gerar mapa de variância com o objetivo de identificar e quantificar as incertezas associadas às estimações da variável CM na área de estudo. A simulação estocástica de imagens da variável dominante CM - $Z_1(x)$ foi efetuada através do método de Simulação Sequencial Direta, condicionada aos dados experimentais.

A partir dos vários mapas equiprováveis da variável CM, simulados, pode-se representar em cada ponto o valor de CM mais provável assim como as zonas de maior e menor incerteza. Se escolhermos $Z_1(x)$ como variável primária, ou seja, a variável mais importante ou que evidencia uma maior continuidade espacial, a Simulação Sequencial Direta é resumida nas seguintes etapas: (Soares, 2001):

1. Escolha de uma sequência aleatória de nós de uma malha regular que permita a visita de todos os nós x_u .
2. Em cada nó x_u :
3. Simulação do valor de $z_1^s(x_u)$ utilizando o algoritmo de Simulação Sequencial Direta (DSS):
 - Estimação da média e variância de $Z_1(x)$, $Z_1(x_u)$ e $\sigma_2^{sk}(x_u)$ por krigagem simples (SK). Reamostrar localmente o histograma de $Z_1(x_u)$, utilizando, por exemplo, uma transformação gaussiana (ϕ_1) da variável primária $Z_1(x)$; cálculo de $y(x_u) = \phi_1(Z_1(x_u))$;
 - Geração de um número aleatório p a partir de uma lei uniforme $U(0,1)$;
 - Geração do valor y^s a partir de $G(y(x_u), \sigma_2^{sk}(x_u), p)$;

$$y^s = G^{-1}(y(x_u), \sigma_2^{sk}(x_u), p);$$

4. Retorno do valor simulado da variável primária $z_1^s(x_u) = \phi_1^{-1}(y^s)$.
5. Continuar para o nó seguinte até todos os nós estarem simulados.

Segundo Soares (2006), do ponto de vista quantitativo, com um modelo de simulação pretende-se reproduzir, na imagem simulada, a variabilidade do fenômeno em estudo basicamente através de duas estatísticas: a função de distribuição de $Z(x) - F_z(z) = \text{prob} \{Z(x) < z\}$, que garante a frequência das diferentes classes do histograma e variograma $\gamma(h)$ que reproduz a continuidade espacial de $Z(x)$. Concretamente, se designarmos por $Z_c(x)$ o conjunto de valores simulados e por $Z(x_u)$, $x_u = 1, \dots, n$, os n valores experimentais, a imagem simulada deve cumprir as seguintes condições:

1. Para qualquer valor z : $\text{prob} \{Z(x_u) < z\} = \text{prob} \{Z_c(x) < z\}$;

2. $\gamma(h) = \gamma_c(h)$, sendo $\gamma(h)$ e $\gamma_c(h)$ os variogramas dos valores experimentais e dos valores simulados, respectivamente;
3. Condicionamento dos valores experimentais: em qualquer ponto experimental x_u , o valor $Z(x_u)$ e o valor simulado $Z_c(x_u)$ coincidem – $Z(x_u) = Z_c(x_u)$. Isso significa que, além de ter a mesma variabilidade, a imagem simulada passa pelos pontos experimentais. Passar pelos pontos experimentais significa não só a coincidência espacial dos valores das amostras e dos valores simulados, mas também a influência dos valores das amostras nos mapas simulados que é determinada pela maior ou menor continuidade estrutural denunciada nos modelos dos variogramas.

Satisfeito os pressupostos impostos pela DSS, foram gerados os mapas da média e variância provenientes da realização de 50 simulações, objetivando a estimação da variável primária e quantificação de áreas de incertezas associadas à estimação da variável CM por krigagem, respectivamente.

Na quantificação da incerteza, estabeleceu um limite de corte fixo para a variância igual a 80, onde para a variância das simulações acima deste valor, a incerteza da estimação da variável CM por krigagem naquele ponto foi considerada alta. Este valor correspondeu ao Perc₉₅ da variância das simulações, valor abaixo do qual estão 95 % dos valores de variância e 5% acima do mesmo.

3 RESULTADOS E DISCUSSÃO

A Tabela 1 apresenta as estatísticas básicas de posição e de dispersão e os testes de normalidade dos dados para a variável de planta CM.

Tabela 1 - Análise estatística descritiva da variável de planta CM em estudo

Variável	Parâmetros									
	n ¹	Min (kg)	Máx (kg)	Média (kg)	Md ² (kg)	S ³	CV ⁴	C _s ⁵	S-W ⁶	K-S ⁷
CM ⁸	87	0,10	39,90	19,16	21,20	11,11	58,03	-0,12	0,001*	0,106 ^{ns}

¹números de pontos; ²mediana; ³desvio-padrão; ⁴coeficiente de variação; ⁵coeficiente de assimetria; ⁶distribuição normal pelo teste de Shapiro-Wilk (S-W) ao nível de 5% de probabilidade; ⁷distribuição normal pelo teste de kolmogorov-Smirnov (K-S); ⁸produção de café maduro; * significativo a 5% pelo teste de S-W, indicando distribuição não normal dos dados; ^{ns} não significativo a 5% pelo teste de K-S, indicando distribuição normal dos dados.

Nas medidas estatísticas a média apresentou menor valor que a mediana, indicando uma assimetria negativa, porém a diferença foi mínima, com o coeficiente de assimetria próximo de zero ($C_s = -0,12$). Quanto mais próximo de 0 (zero) for o valor do C_s e quanto mais próximos forem os valores da média e mediana, tanto mais próximo à distribuição estará da normal, como confirmado pelo teste Kolmogorov-Smirnov (K-S). Porém, o teste de Shapiro-Wilk (S-W) ao nível de 5% de probabilidade, indicou distribuição não normal dos dados. Quando a distribuição dos dados não é normal, a média é muito influenciada por valores extremos, tornando uma medida de tendência central não representativa do conjunto de dados. No entanto, a normalidade não é uma exigência da geoestatística para sua aplicabilidade, mas sim, apenas conveniente que a variável não apresente extremidades da distribuição muito longas, para não comprometer as análises.

O coeficiente de variação ($CV = 58,03\%$) foi muito alto ($> 40,3\%$), segundo classificação de Costa et al. (2002), para dados de produção de plantas. Este valor de CV indicando alta variabilidade da produção, evidenciando que o manejo da cultura sofre alterações ao longo da área, podendo essas alterações estar em função da divisão da área em talhões (Figura 1b), que acabam correspondendo a zonas de manejo diferenciado. A Figura 3 apresenta o histograma com a distribuição de frequência da variável primária CM.

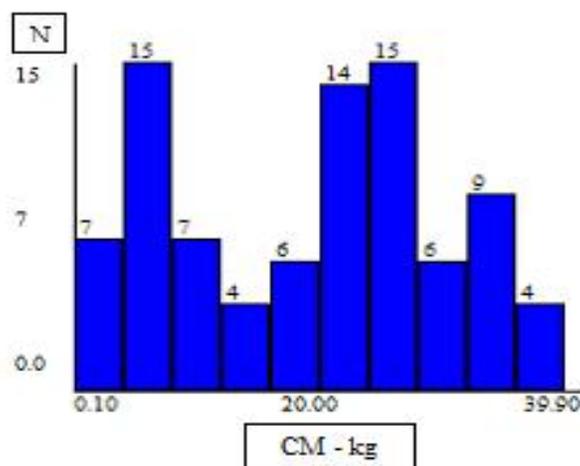


Figura 3 - Histograma da distribuição de frequência da variável de planta Café Maduro (CM).

Na Figura 4 são apresentados os modelos teóricos ajustados aos variogramas experimentais da variável primária CM, para as direções E-W (90°) e NW-SE (-45°).

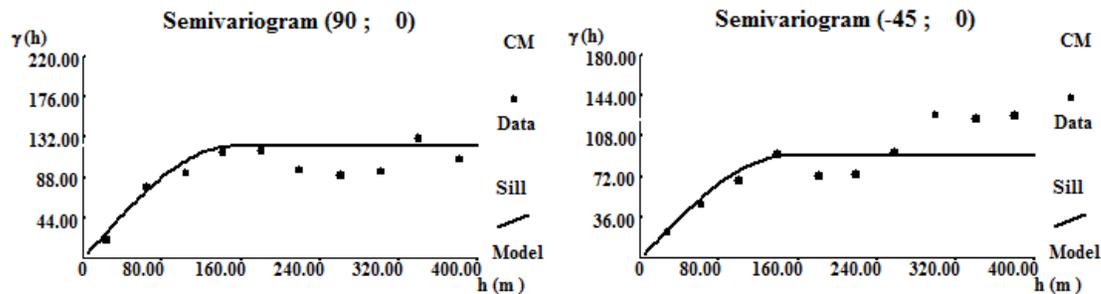


Figura 4 - Variogramas da variável CM para as direções E-W (90°) e NW-SE (-45°), respectivamente.

Observa-se que a variável CM apresentou como parâmetros, modelo Esférico (Esf), valor zero de Efeito Pepita ($C_0 = 0$) e uma alcance(a) de 150 metros, para os variogramas nas 2 direções analisadas. Segundo Soares (2006), a continuidade espacial de um recurso natural pode variar com as diferentes direções do espaço, e ainda, na situação em que a variável em estudo se estende preferencialmente, de um modo mais contínuo, numa direção particular, da origem a uma estrutura anisotrópica. Na Figura 4 verifica-se que os variogramas tem ajuste ao mesmo modelo, porém com patamares diferentes, entre as direções, o que classificaria uma anisotropia zonal, onde a continuidade espacial ao longo de um estrato contrasta significativamente com a variabilidade entre estratos (SOARES, 2006). Porém os ajustes dos variogramas encontrados foram influenciados pela disponibilidade de pontos em cada direção, tanto que, os ajustes com patamares mais bem definidos foram encontrado para o variograma E-W (90°), seguido do NW-SE (-45°), devido a maior disponibilidade de pontos amostrais nestas direções. Já os variogramas N-S (0°) e NE-SW (45°) não atingiram o patamar, pois a malha amostral apresenta a menor dimensão nestas direções. Esta continuidade espacial de 150 metros encontrada pelos variogramas, corresponde a um valor próximo das dimensões (comprimento e largura) médias dos talhões de café na área (Figura 1b). Na prática, isso implica num possível manejo diferenciado em função dos talhões. Por esse motivo, e ainda, devido a insuficiência de pontos em algumas direções, admitiu que o variograma omnidirecional modelizado para a variável CM expressa a continuidade espacial característica de um processo aleatório isotrópico. Sendo assim, todos os processos subsequentes foram assentados na isotropia indicada pela estrutura do variograma omnidirecional.

Ajustado o variograma teórico aos dados experimentais, foi possível determinar a continuidade espacial da produção do café utilizando a krigagem como estimador. A Figura 5 apresenta o mapa e histograma da variável CM interpolada por krigagem.

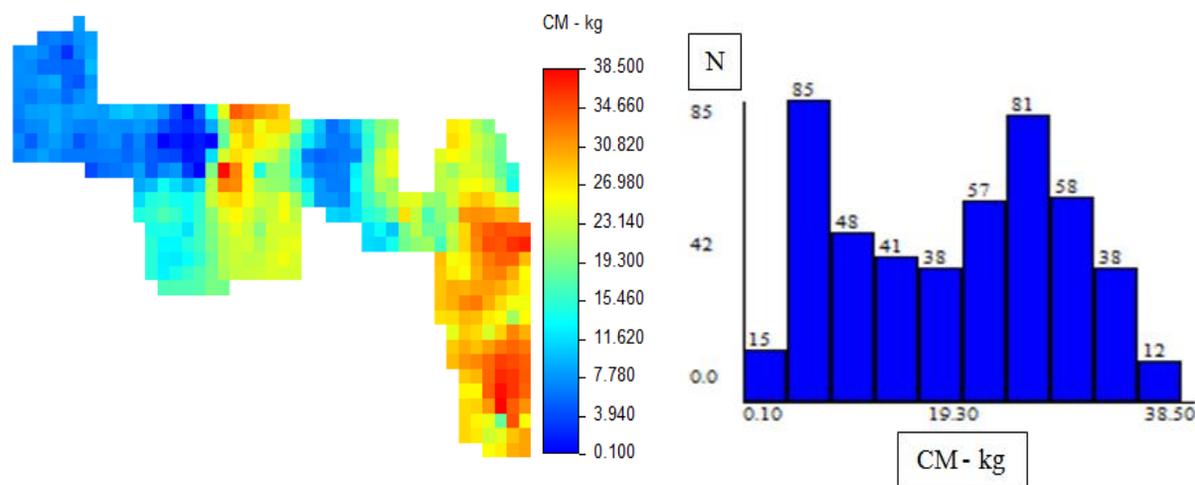


Figura 5 - Mapa e histograma (distribuição de frequência) da krigagem para a variável primária CM.

O mapa da Figura 5 evidencia a existência de duas regiões que diferenciam-se das demais ao longo da área de estudo. As duas regiões, uma ao centro da área e a outra mais a direita, corresponde aos valores máximos de produção de café no mapa de krigagem. Isso indica que a produção apresenta uma grande variação na área, comprovada também pelo alto valor do CV apresentado na análise estatística para a variável CM, e que, isso pode ocorrer em função de um manejo diferenciado, principalmente nas duas áreas de maior produção, especificadas.

Comparando o histograma da Figura 5, com o histograma dos dados amostrados da variável CM, da Figura 3, observa-se que as distribuições apresentam frequências com comportamentos semelhantes, provando que a krigagem está estimando a realidade da variável CM no campo. Outra comprovação é dada pelas semelhanças entre as medidas estatísticas de posição e dispersão, da krigagem com os dados de campo, como mostra a Tabela 2.

Tabela 2 - Estatísticas dos valores estimados por krigagem da variável CM

Variável	Estatísticos			
	Média (kg)	Mediana (kg)	Coefficiente de Variação	Assimetria
CM	19,16	21,20	57,7	-0,12

O que torna a krigagem um estimador ótimo é o fato de ser não tendenciosa e com variância mínima. Por ser uma média móvel ponderada, o interpolador promove uma suavização na distribuição dos valores, como se observa no histograma da Figura 5. Segundo Soares (2006) os ponderadores do estimador de krigagem são calculados pelo critério de minimização da variância dos erros, assumindo que

os erros têm uma distribuição média nula e variância espacial igual a variância de estimação. No entanto, esta mesma variância pode ser utilizada como critério para inferir a qualidade do estimador e, inclusi, pode ser quantificada na medição de erro. Para tanto, é necessário a determinação da incerteza espacial, resultante do comportamento simultâneo do conjunto de imagens da variáveis por meio dos modelos geoestatísticos de simulação. Neste caso, a medida de incertezas pode ser feita pela geração de mapas de variância, onde a grande vantagem é permitir o cálculo de zonas de incerteza, em torno das formas estimadas.

Para que atenda aos pressupostos, as simulações devem apresentar histograma, estatísticas e variogramas semelhantes aos dados amostrais. Na Figura 6 são apresentados o mapa, histograma e variografia da simulação 1, de uma série de 50 simulações da variável CM por DSS. A Figura 6 apresenta estes parâmetros atendendo perfeitamente aos pressupostos, com distribuição de frequência semelhantes aos dados amostrais, conforme histograma da Figura 3 e variografia com alcance de 150 metros, de acordo com os variogramas da Figura 4.

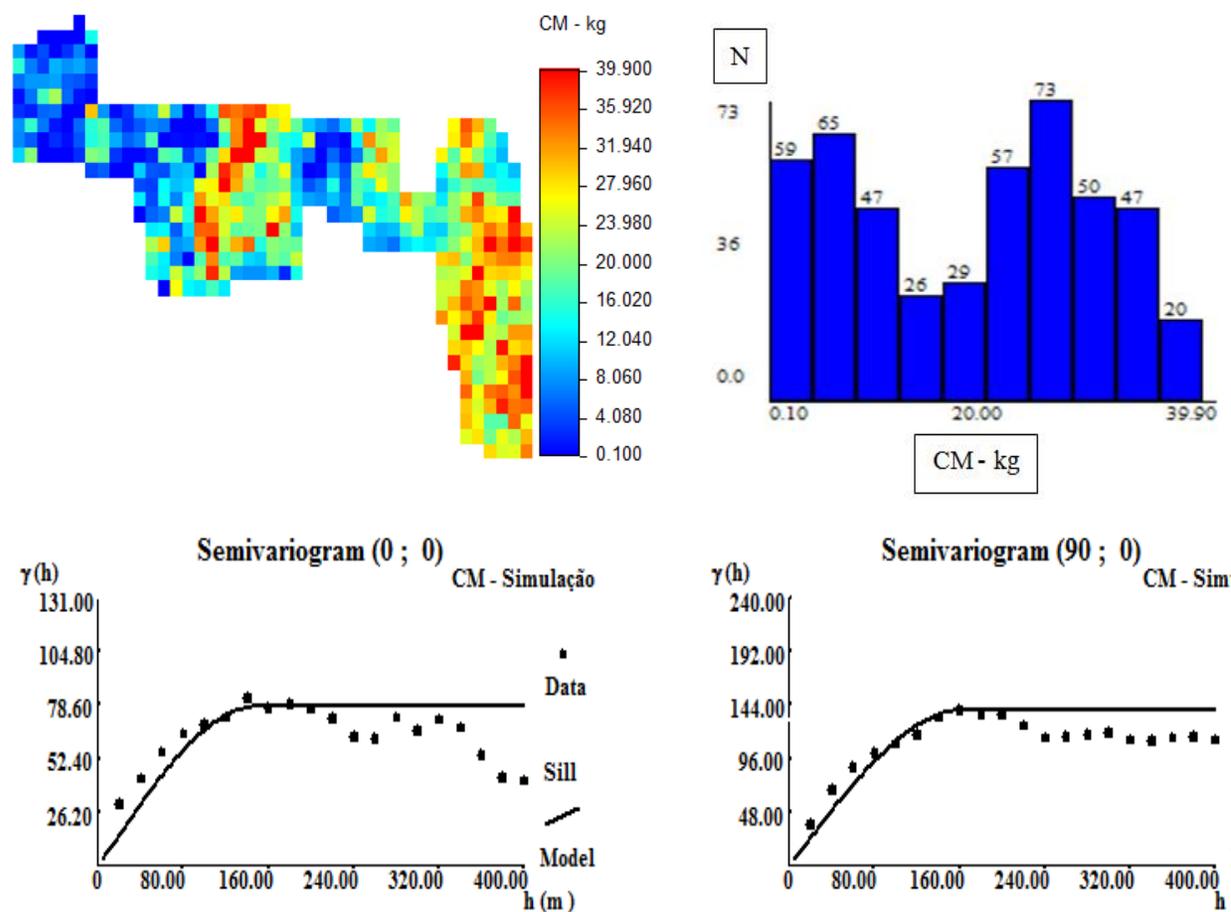


Figura 6 - Mapa, histograma e variogramas da simulação 1, de uma série de 50 simulações para a variável CM por DSS. Qual é correto

A Figura 7 apresenta o mapa da variância das 50 simulações realizadas e o histograma das incertezas associadas a variável CM por DSS.

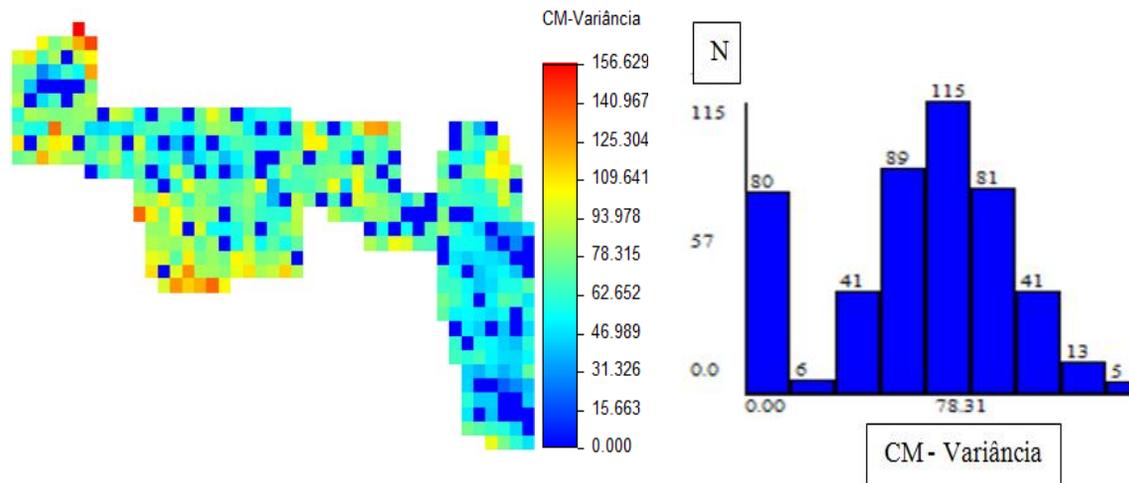


Figura 7 - Mapa de variância e histograma das incertezas associadas a variável CM por DSS.

No mapa da Figura 7, os valores de variância 0 (zero) representados pelos pontos em azul escuro, correspondem ao local de amostragem da variável CM. Isso porque, ao longo da realização das simulações pelo método de DSS, os valores reais de campo da variável primária CM são respeitados, por isso a variância nesses pontos é nula. No histograma do mapa de variância da Figura 7 esses pontos são representados pela coluna de frequência elevada no início da distribuição. Os pontos com maior variância estão presentes nas regiões periféricas do mapa, com a variância diminuindo à medida que se aproxima dos pontos amostrados. Isso ocorre porque a influência dos dados de campo na estimação da variável CM é máxima quando o ponto a estimar coincide com uma observação de campo e vai diminuindo com o aumento da distância. No mapa fica evidente que a insuficiência de pontos amostrados em algumas regiões contribui para uma elevação da variância. E ainda, o coeficiente de Assimetria (C_s) da distribuição de frequência da Figura 7 apresentou assimetria negativa (-0,41), comprovando uma maior concentração de valores de variância acima da variância média, sendo que, quanto maior os valores de variância, maior a incerteza associada à estimação da variável CM. Isto implica em maior diferença entre o valor estimado pela krigagem e o possível valor real da variável no campo para um mesmo ponto. Sendo assim, valores da variável CM, considerado alto em algum ponto, pode não ser tão alto, assim como o contrário. Este comportamento compromete a real espacialização da produção de café e conseqüentemente a possibilidade de um manejo diferenciado na área, baseado no mapeamento da produção.

Para a quantificação da incerteza associada a variável primária CM, estabeleceu um limite de corte fixo para a variância igual a 80, sendo este valor baseado no Perc₉₅ da variância. Na Figura 8 é apresentado o mapa de quantificação das incertezas associadas a variável primária CM pela DSS.

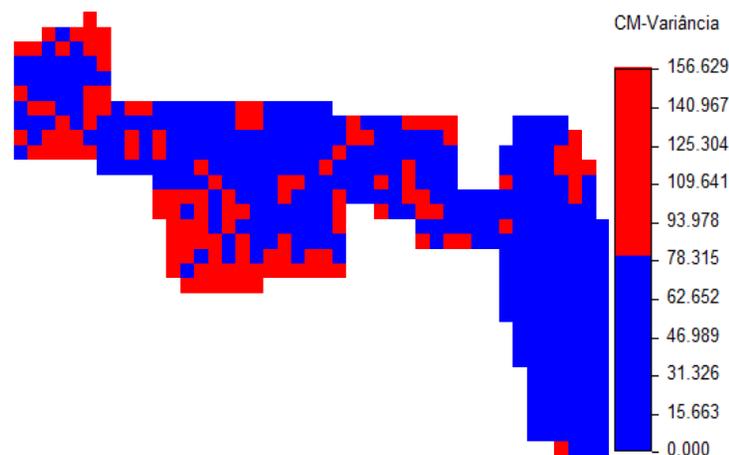


Figura 8 - Mapa de quantificação da incerteza associada a variável CM pela DSS com limite de corte em função do valor médio do Perc₉₅.

Os Pixels em vermelho no mapa da Figura 8 representam pontos de incerteza, baseado no valor de corte 80 da variância. Esses pixels indicam regiões no mapa onde a amostragem dos pontos da variável primária foi ineficiente para uma estimacão mais precisa da variável no campo. Observa-se no mapa que às incertezas quantificadas pela DSS, apresentam-se principalmente nas extremidades da área, onde a densidade de pontos foi menor. As áreas de incertezas quantificadas por % e ha, no mapa da Figura 8, corresponderam a 26,43 % (5 ha) de incerteza na área total, evidenciando assim, parte da área, classificada com grande incerteza espacial, incerteza esta que compromete a estimacão da variável, colocando a prova o possível valor da variável CM estimada pela krigagem, ou ainda, gerando dúvidas quanto à diferença entre o valor medido e estimado para um mesmo ponto. Desta forma, a simulacão torna-se uma ferramenta útil na identificacão dessas áreas de incerteza.

4 CONCLUSÕES

A aplicacão da Simulacão Sequencial Direta identificou e quantificou áreas de incertezas, associadas à estimacão da variável producao de café maduro, por krigagem, em 26,43 % (5 ha) da área total. Evidenciando a eficiencia da ferramenta para identificacão de áreas de incerteza na estimacão da cultura.

5 REFERÊNCIAS

BOURGAULT, G. Using non-Gaussian distributions in geostatistical simulations: **Mathematical Geology**, Montreal, v. 29, n. 3, p. 315-334, 1997.

CMRP.**GeoMS** - Geostatistical Modeling Software. v. 1.0. Lisboa: IST, 2000.

COSTA, N. H. A. D.; SERAPHIN, J. C.; ZIMMERMANN, F. J. P. Novo método de classificação de coeficientes de variação para a cultura do arroz de terras altas. **Pesquisa Agropecuária Brasileira**, Brasília, v. 37, n. 3, p. 243-249, mar. 2002.

EMBRAPA. **Sistema brasileiro de classificação de solos**. 2 ed. Rio de Janeiro: Embrapa Solos, 2006. 3060 p.

GUIMARÃES, E. C. Geoestatística básica e aplicada. In: UNIVERSIDADE FEDERAL DE UBERLÂNDIA. **Núcleo de estudos estatísticos e biométricos**. Uberlândia: UFU, 2004. 77 p.

JOURNEL, A. G. Modeling uncertainty: some conceptual thoughts, In: DIMITRAKOPOULOS, R. (Ed.). **Geostatistics for the next century**. Dordrecht: Kluwer Academic, 1994. p. 30-43.

MICROSOFT Excel, version 4.1: [S.l.]: Microsoft Coporation, 1998. 1 CD-ROM.

SANTOS, C.; ALMEIDA, J. C. Caracterização de um índice de produtividade nos povoamentos de pinheiro-bravo em Portugal. **Finisterra: Revista Portuguesa de Geografia**, Lisboa, v. 38, n. 75, p. 51-65, 2003.

SOARES, A. Direct sequential simulation and co-simulation. **Mathematical Geology**, Montreal, v. 33, n. 8, p. 911-926, 2001.

SOARES, A. **Geoestatística para as ciências da terra e do ambiente**. 2. ed. Lisboa: IST, 2006. 214 p.

SOARES, A. Sequential indicator simulation with correction for local probabilities. **Mathematical Geology**, Montreal, v. 30, n. 6, p. 761-765, 1998.

STAT SOFT. **Programa Statistica for Windows**, versão 7.0. Tulsa, 2001. 1 CD-ROM.

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