

**Associação das Técnicas  
Multivariada e Geoestatística  
na Estimativa e Interpretação  
de Mapas de Produção**



MAPAS

DE

PRODUÇÃO

## **República Federativa do Brasil**

*Fernando Henrique Cardoso*  
Presidente

## **Ministério da Agricultura, Pecuária e Abastecimento**

*Marcus Vinicius Pratini de Moraes*  
Ministro

## **Empresa Brasileira de Pesquisa Agropecuária - Embrapa**

### **Conselho de Administração**

*Márcio Fortes de Almeida*  
Presidente

*Alberto Duque Portugal*  
Vice-Presidente

*Dietrich Gerhard Quast*  
*José Honório Accarini*  
*Sérgio Fausto*  
*Urbano Campos Ribeiral*  
Membros

### **Diretoria Executiva da Embrapa**

*Alberto Duque Portugal*  
Diretor-Presidente

*Bonifácio Hideyuki Nakasu*  
*Dante Daniel Giacomelli Scolari*  
*José Roberto Rodrigues Peres*  
Diretores-Executivos

### **Embrapa Informática Agropecuária**

*José Gilberto Jardine*  
Chefe-Geral

*Tércia Zavaglia Torres*  
Chefe-Adjunto de Administração

*Kleber Xavier Sampaio de Souza*  
Chefe-Adjunto de Pesquisa e Desenvolvimento

*Álvaro Seixas Neto*  
Supervisor da Área de Comunicação e Negócios

# **Relatório Técnico 11**

## **Associação das Técnicas Multivariada e Geoestatística na Estimativa e Interpretação de Mapas de Produção**

José Ruy Porto de Carvalho  
Pedro Marques da Silveira

**Embrapa Informática Agropecuária**  
**Área de Comunicação e Negócios (ACN)**

Av. Dr. André Tosello s/nº  
Cidade Universitária "Zeferino Vaz" – Barão Geraldo  
Caixa Postal 6041  
13083-970 – Campinas, SP  
Telefone/Fax: (19) 3789-5743  
URL: <http://www.cnptia.embrapa.br>  
Email: [sac@cnptia.embrapa.br](mailto:sac@cnptia.embrapa.br)

**Comitê de Publicações**

*Amarindo Fausto Soares*  
*Francisco Xavier Hemerly (Presidente)*  
*Ivanilde Dispato*  
*José Ruy Porto de Carvalho*  
*Marcia Izabel Fugisawa Souza*  
*Suzilei Almeida Carneiro*

Suplentes

*Fábio Cesar da Silva*  
*João Francisco Gonçalves Antunes*  
*Luciana Alvin Santos Romani*  
*Maria Angélica de Andrade Leite*  
*Moacir Pedroso Júnior*

Supervisor editorial: *Ivanilde Dispato*  
Normalização bibliográfica: *Marcia Izabel Fugisawa Souza*  
Capa: *Intermídia Publicações Científicas*  
Editoração eletrônica: *Intermídia Publicações Científicas*

**1ª edição**

**Todos os direitos reservados**

---

Carvalho, José Ruy Porto de.

Associação das técnicas multivariada e geoestatística na estimativa e interpretação de mapas de produção. / José Ruy Porto de Carvalho, Pedro Marques da Silveira. — Campinas : Embrapa Informática Agropecuária, 2001.

41 p. : il. — (Relatório técnico / Embrapa Informática Agropecuária ; 11)

ISSN 1517-0330

1. Análise multivariada. 2. Geoestatística. 3. Mapa de produção. 4. Agricultura de precisão. I. Silveira, Pedro Marques da. II. Título. III. Série.

CDD – 519.535 (21.ed.)

# Sumário

Resumo .....	5
Abstract.....	6
Introdução .....	7
Material de Métodos.....	7
Resultados e Discussão .....	11
Conclusões .....	39
Referências Bibliográficas .....	40



# Associação das Técnicas Multivariada e Geoestatística na Estimativa e Interpretação de Mapas de Produção

---

*José Ruy Porto de Carvalho<sup>1</sup>*

*Pedro Marques da Silveira<sup>2</sup>*

## Resumo

O objetivo deste trabalho foi estudar, mediante a geoestatística e análise multivariada, a variabilidade espacial da produção de milho e feijão e investigar metodologia que permita a estimativa da produção, através da redução de variáveis envolvidas, cultivadas em Latossolo Vermelho-Escuro, textura argilosa, durante cinco anos consecutivos (1992-1996), sob três sistemas de preparo (Arado, Grade e Plantio Direto) na Embrapa Arroz e Feijão, em Santo Antônio de Goiás, GO. O método dos componentes principais reduziu consideravelmente a dimensão do problema, facilitando a interpretação. Entretanto os modelos de regressão linear múltipla baseados nos componentes principais como variáveis regressoras, apresentaram estimativa da produção mais distantes dos valores obtidos quando do uso do modelo baseado na variáveis originais.

Termos para indexação: Agricultura de precisão; Regressão linear múltipla; Componentes principais; Sistemas de preparo do solo.

---

<sup>1</sup> Ph.D. em Estatística, Pesquisador da Embrapa Informática Agropecuária, Caixa Postal 6041, Barão Geraldo – 13083-970 – Campinas, SP.

<sup>2</sup> Dr. em Irrigação, Pesquisador da Embrapa Arroz e Feijão, Caixa Postal 179 – 75375-000 – Santo Antônio de Goiás, GO.

# **Association Among Multivariate and Geostatistics Techniques to Estimate and Interpret Yield Mapping**

---

## **Abstract**

Spatial variability of maize and beans yield under three soil preparation systems (moldboard plough, harrow disc and no-tillage) was studied using multivariate and geostatistical concepts in clayey Oxisol, in Santo Antônio de Goiás, GO, at Embrapa Rice & Beans, for five consecutive years (1992-1996). The principal component methodology reduced the dimension of the problem considerably, facilitating the interpretation. However, the models of multiple linear regression based on the principal components as regression variables presented estimate of the yield most distant of the values obtained when the model, based on the original variables, are used.

Index terms: Precision agriculture; Linear multiple regression; Principal components; Soil preparation systems.



## **Introdução**

Avanços tecnológicos na agropecuária têm mostrado a importância de se medir a variação espacial e temporal de propriedades que afetam o rendimento das culturas, com o objetivo de otimizar o aproveitamento de recursos e diminuir custos. O gerenciamento do processo de produção em função da variabilidade é o que se convencionou chamar Agricultura de Precisão. Seu objetivo é correlacionar causas e efeitos a partir de séries históricas de dados e de sua distribuição espacial.

Cientistas da área de solos se preocupam com o problema de variação espacial e temporal dos solos desde o começo do século. Somente nas décadas de 50 e 60, com o avanço na teoria de estatística espacial, é que os cientistas começaram a perceber a potencialidade desta ferramenta para o manuseio de dados quantitativos, facilitando a compreensão da variabilidade do solo (Burrough et al., 1994).

Recentemente, os pesquisadores em diversas áreas de estudo têm utilizado na análise e interpretação de seus resultados, as técnicas de geoestatística e análise multivariada. Korre (1999) estudando as fontes de contaminação do solo por metais pesados utilizou, para sua determinação, análise de principal componentes e interpolador de krigagem. Castrignano et al. (1998) utilizaram componentes principais e geoestatística para dividir uma área de quatro hectares em subáreas homogêneas com relação a propriedade do solo.

O objetivo deste trabalho foi estudar, através da geoestatística e análise multivariada, a variabilidade espacial da produção de milho e feijão e investigar metodologia que permita a estimativa da produção, através da redução das variáveis envolvidas sob três sistemas de preparo (arado, grade e plantio direto).

## **Material e Métodos**

O experimento foi realizado na Fazenda Capivara, da Embrapa Arroz e Feijão, localizada em Goiânia – GO, em um Latossolo Vermelho-Escuro distrófico, textura argilosa, cultivado durante cinco anos (1992–1996), com as culturas de milho de verão e feijoeiro no inverno, sob irrigação por

aspersão, sistema de pivô central. Essas culturas foram plantadas sob três tratamentos de preparo do solo: arado de aiveca, grade aradora e plantio direto. No tratamento arado, foi usado arado de três aivecas, incorporando ao solo os resíduos das culturas até a profundidade de 30 cm, seguido de uma gradagem com grade destorroadora. Na aração com grade aradora, foi usada uma grade de 20 discos, incorporando ao solo os resíduos até 15 cm. O plantio direto foi feito com plantadora apropriada, a qual proporcionou a abertura de pequenos sulcos para a deposição das sementes, deixando todo o resíduo das culturas na superfície do solo. No início do quarto ano de plantio foram aplicados 2,5 t/ha de calcário em toda área experimental. Nos tratamentos de arado e de grade, o corretivo foi incorporado ao solo, e no plantio direto permaneceu na superfície. Foi utilizado 400 kg/ha, da fórmula 5-30-5 no plantio de cada cultura.

Uma amostra para análise química foi coletada no final de 1996, nos três tratamentos, em uma malha quadrada de 49 pontos (7 x 7), espaçados de 4m x 4m, nas profundidades de 0-5 cm e 5-20 cm, sendo estas profundidades definidas no sentido de verificar, ou não, o acúmulo superficial de fertilizantes. Foram determinados pH, P, K, Ca, Mg, Cu, Zn, Fe, Mn, e B conforme Embrapa (1997). Além disso, foram calculadas as variáveis de produção, em Kg/ha, porcentagem de matéria orgânica e argila, em g/ha, para milho e feijão, nos três sistemas de preparo. De posse dos dados, foram constituídas 25 variáveis para cada sistema de preparo e para cada cultura, resultando em um total de 150 variáveis.

Vieira et al. (1983) afirma que a dependência espacial entre as observações pode ser expressa através do semivariograma, estimado pela seguinte equação:

$$\gamma^*(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (1)$$

onde  $N(h)$  é o número de pares de valores medidos  $Z(x_i)$ ,  $Z(x_i+h)$ , separados pela distância  $h$ , se a variável for escalar (Vieira et al., 1983). O gráfico de  $\gamma^*(h)$  versus os valores correspondentes de  $h$ , chamado semivariograma, é uma função do vetor  $h$ , e portanto depende de ambos, magnitude e direção de  $h$ . Modelos matemáticos devem ser ajustados aos semivariogramas, os quais permitem visualizar a natureza da variação espacial das variáveis estudadas, além de serem necessários para outras aplicações, como por exemplo, krigagem.

Os seguintes modelos matemáticos foram ajustados aos semivariogramas:

a) Modelo esférico:

$$\gamma(h) = C_0 + C_1 \left[ \frac{3}{2} \left( \frac{h}{a} \right) - \frac{1}{2} \left( \frac{h}{a} \right)^3 \right], \quad 0 < h < a \quad (2)$$

$$\gamma(h) = C_0 + C_1, \quad h \geq a$$

b) Modelo exponencial:

$$\gamma(h) = C_0 + C_1 \left[ 1 - \exp\left(-3 \frac{h}{a}\right) \right], \quad 0 < h < d \quad (3)$$

onde d é a máxima distância na qual o semivariograma é definido.

c) Modelo gaussiano:

$$\gamma(h) = C_0 + C_1 \left[ 1 - \exp\left(-3 \left( \frac{h}{a} \right)^2 \right) \right], \quad 0 < h < d \quad (4)$$

Para os três modelos citados, ( $C_0$ ) é o efeito pepita, ( $C_0 + C_1$ ) é o patamar e (a) é o alcance do semivariograma.

Os valores obtidos através da krigagem são não viciados e têm variância mínima (Vieira et al., 1983) e ideais para a construção de mapas de isolinhas ou tridimensionais para verificação e interpretação da variabilidade espacial. As informações mostradas nestes gráficos de isolinhas são muito úteis para melhor entender a variabilidade das propriedades do solo no campo e para identificar áreas que necessitam diferentes tipos de preparo.

No planejamento de um ensaio experimental geralmente o pesquisador exerce domínio sobre as condições sob as quais deseja investigar as respostas delas oriunda. Entretanto, existem situações em que o controle dos fatores experimentais não é exercido pelo pesquisador e, assim sendo, torna-se necessário obter um grande número de observações para que uma determinada variável possa experimentar uma variação, de tal forma que seu efeito possa ser detectado sobre as respostas desejadas.

As situações onde muitas variáveis são pesquisadas simultaneamente buscando-se uma relação entre elas é o objetivo da análise multivariada. De um modo geral, as técnicas multivariadas são usadas para redução e simplificação de dados, agrupamento de dados, estudo da dependência entre variáveis e construção de teste de hipótese. Neste trabalho, foram usadas as técnicas multivariadas de componentes principais e regressão linear múltipla, com o objetivo de reduzir o número de variáveis, criando novas variáveis interpretativas.

A análise de componentes principais é uma técnica usada na determinação das relações entre as variáveis quantitativas, na redução de dados e na determinação de relações lineares (Bueno, 2001). A técnica de componentes principais consiste na aplicação de uma transformação matemática na matriz de dados  $\mathbf{X}$ , de modo a obtermos  $\mathbf{m}$  novas variáveis (componentes principais) que são combinações lineares das variáveis originais e tem a propriedade de serem ortogonais entre si. O primeiro componente principal é formado pela combinação linear das variáveis originais que possui a maior variância, o segundo componente responde pela próxima maior variância e assim sucessivamente. Geralmente, grande parte da variabilidade contida nas variáveis originais se concentra num pequeno número de componentes ou fatores. As novas variáveis (componentes principais) podem ser usadas no lugar das variáveis originais, considerando que sempre alguma informação é perdida (Hoffmann, 1992).

É de se esperar a existência de correlação entre as características estudadas em uma determinada área. Algumas ferramentas da estatística clássica, como a correlação de Pearson, são utilizadas para se estimar as correlações entre parâmetros em estudo, e podem ser utilizadas como análise prévia a ajustes de modelos de regressão, com o objetivo de serem realizadas previsões. Sá (2001) utilizou a regressão linear múltipla para explorar as relações entre atributos do solo e topográficos, mostrando ser uma ferramenta muito útil na geração de modelos de previsão de alguns atributos chaves da fertilidade de solo, tais como argila, matéria orgânica, capacidade de troca de cátions e densidade de solo. O uso de regressões lineares simples e múltiplas é assunto de grande destaque na Agricultura de Precisão, principalmente na tentativa de se explicar a produção através de fatores físicos, químicos e mecânicos do solo.

Uma variável resposta  $Y$  pode ser estimada por uma combinação linear de variáveis dependentes  $X$ , onde os  $\beta$  parâmetros da equação:

$$Y_i = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon_i$$

para  $i = 1, \dots, n$  observações obtidas através do procedimento de regressão (Proc Reg) (SAS Institute, 1985), que usa o princípio de mínimo quadrado para produzir estimativa dos parâmetros da equação sem vício e com variância mínima.

Com a finalidade de encontrar um modelo para produtividade, foram ajustados modelos de regressão linear múltipla, tanto utilizando-se as variáveis originais, quanto utilizando-se as componentes principais. Mapas interpolados através do método de krigagem foram feitos sobre a produção observada e a produção estimada obtida pela regressão nas variáveis originais e pela regressão nas componentes principais, para os três sistemas de preparo e para cada cultura.

## Resultados e Discussão

Para a análise de regressão múltipla em função das variáveis originais, foram usadas 24 variáveis nas duas profundidades 5 e 20 cm's, para cada sistema de preparo (arado, grade e plantio direto). As variáveis dependentes foram os seis tipos de produção de milho e feijão (milhoar, feijãoar, milhogr, feijãoogr, milhopd e feijãopd). As Tabelas de 1 a 6 mostram a significância estatística de cada variável inserida na análise.

**Tabela 1.** Variável dependente milhoar. Coeficientes de regressão linear múltipla para as propriedades químicas do solo, seu erro padrão e respectivo teste t de Student com sua probabilidade de significância.

<i>Variável</i>	<i>Q</i>	<i>Coeficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr&gt; t </i>
Constante	1	12998	9527.44137	1.36	0.1852
phar5	1	-571.04698	1549.45557	-0.37	0.7157
caar5	1	199.87465	873.02619	0.23	0.8209
mgar5	1	1018.43245	951.73858	1.07	0.2952
par5	1	-81.54357	82.71851	-0.99	0.3341
kar5	1	-2.96879	6.53520	-0.45	0.6537
phar20	1	-505.65023	1543.16904	-0.33	0.7460
caar20	1	446.04847	875.27271	0.51	0.6150
mgar20	1	-846.55344	803.98756	-1.05	0.3029
par20	1	79.30012	62.03534	1.28	0.2134
kar20	1	11.56233	8.29697	1.39	0.1762
Cuar5	1	852.12021	662.47912	1.29	0.2106
Znar5	1	50.97809	83.15541	0.61	0.5456
Fear5	1	6.57195	12.59433	0.52	0.6066
Mnar5	1	-15.83718	128.45969	-0.12	0.9029
Bar5	1	-1132.11309	720.04470	-1.57	0.1290
MOar5	1	-1309.30588	1516.83677	-0.86	0.3966
ARar5	1	-0.12663	8.05182	-0.02	0.9876
Cuar20	1	-662.77216	415.97358	-1.59	0.1242
Znar20	1	22.32439	120.03708	0.19	0.8540
Fear20	1	10.93203	10.51445	1.04	0.3088
Mnar20	1	-131.21599	139.82764	-0.94	0.3574
Bar20	1	-726.17512	708.88069	-1.02	0.3159
MOar20	1	202.36341	1289.32023	0.16	0.8766
ARar20	1	2.98836	6.29946	0.47	0.6395

**Tabela 2.** Variável dependente milhogr. Coeficientes de regressão linear múltipla para as propriedades químicas do solo, seu erro padrão e respectivo teste t de Student com sua probabilidade de significância.

<i>Variável</i>	<i>GL</i>	<i>Coeficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr&gt; t </i>
Constante	1	4728.07153	4749.25934	1.00	0.3294
phgr5	1	264.06396	576.09248	0.46	0.6508
cagr5	1	-1413.89724	621.30641	-2.28	0.0321
mggr5	1	-141.29051	393.42614	-0.36	0.7226
pgr5	1	-11.08090	25.37063	-0.44	0.6662
kgr5	1	-1.13080	3.11665	-0.36	0.7199
phgr20	1	260.02081	841.22483	0.31	0.7599
cagr20	1	141.13372	709.48382	0.20	0.8440
mggr20	1	442.09013	559.07905	0.79	0.4368
pgr20	1	52.85683	24.35741	2.17	0.0401
kgr20	1	-3.60979	4.03556	-0.89	0.3799
Cugr5	1	-364.10291	375.34127	-0.97	0.3417
Zngr5	1	339.29753	151.50192	2.24	0.0346
Fegr5	1	0.00487	9.79823	0.00	0.9996
Mngr5	1	113.24883	138.82331	0.82	0.4227
Bgr5	1	-573.33062	539.88964	-1.06	0.2988
MOgr5	1	755.45616	1168.27131	0.65	0.5240
ARgr5	1	1.97065	3.94716	0.50	0.6221
Cugr20	1	-381.46061	250.20674	-1.52	0.1404
Zngr20	1	19.57693	132.69285	0.15	0.8839
Fegr20	1	9.30320	5.96907	1.56	0.1322
Mngr20	1	-3.14630	124.91050	-0.03	0.9801
Bgr20	1	-362.68043	548.07254	-0.66	0.5144
MOgr20	1	-1261.81017	1116.31109	-1.13	0.2695
ARgr20	1	-3.23701	3.82064	-0.85	0.4052

**Tabela 3.** Variável dependente milhopd. Coeficientes de regressão linear múltipla para as propriedades químicas do solo, seu erro padrão e respectivo teste t de Student com sua probabilidade de significância.

<i>Variável</i>	<i>Q</i>	<i>Coeficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr&gt; t </i>
Constante	1	2401.34883	6320.75072	0.38	0.7073
phpd5	1	-751.96781	792.61296	-0.95	0.3522
capd5	1	65.19683	502.19663	0.13	0.8978
mgpd5	1	-477.11782	740.11121	-0.64	0.5253
ppd5	1	-11.81479	7.19118	-1.64	0.1134
kpd5	1	0.85468	3.73022	0.23	0.8207
phpd20	1	1111.94651	1136.92419	0.98	0.3378
capd20	1	-565.41745	960.74445	-0.59	0.5617
mgpd20	1	1017.20841	648.27074	1.57	0.1297
ppd20	1	5.05707	8.66042	0.58	0.5647
kpd20	1	-0.52050	7.75005	-0.07	0.9470
Cupd5	1	-186.37683	267.44141	-0.70	0.4926
Znpd5	1	102.38618	118.62592	0.86	0.3966
Fepd5	1	-1.77069	12.13995	-0.15	0.8853
Mnpd5	1	12.53985	101.52117	0.12	0.9027
Bpd5	1	-384.26469	957.67803	-0.40	0.6918
MOpd5	1	947.20730	1414.55819	0.67	0.5095
ARpd5	1	-3.48311	5.92794	-0.59	0.5623
Cupd20	1	29.90082	210.51401	0.14	0.8882
Znpd20	1	37.89870	62.47402	0.61	0.5498
Fepd20	1	3.71270	8.21773	0.45	0.6555
Mnpd20	1	-136.64751	99.36601	-1.38	0.1818
Bpd20	1	-780.62308	809.07787	-0.96	0.3443
MOpd20	1	799.67237	1802.13689	0.44	0.6612
ARpd20	1	7.90372	6.30834	1.25	0.2223



**Tabela 4.** Variável dependente feijãoar. Coeficientes de regressão linear múltipla para as propriedades químicas do solo, seu erro padrão e respectivo teste t de Student com sua probabilidade de significância.

<i>Variável</i>	<i>GL</i>	<i>Coeficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr&gt; t </i>
Constante	1	-629.34398	7004.50890	-0.09	0.9292
phar5	1	514.14327	1139.14900	0.45	0.6558
caar5	1	-101.61480	641.84281	-0.16	0.8755
mgar5	1	-384.29071	699.71161	-0.55	0.5879
par5	1	34.42470	60.81408	0.57	0.5766
kar5	1	1.13996	4.80464	0.24	0.8145
phar20	1	131.17181	1134.52719	0.12	0.9089
caar20	1	45.87260	643.49444	0.07	0.9438
mgar20	1	-372.91263	591.08609	-0.63	0.5341
par20	1	15.71207	45.60795	0.34	0.7335
kar20	1	3.47944	6.09987	0.57	0.5737
Cuar5	1	-756.28309	487.05006	-1.55	0.1336
Znar5	1	-73.22258	61.13528	-1.20	0.2427
Fear5	1	-3.25805	9.25927	-0.35	0.7280
Mnar5	1	163.60674	94.44267	1.73	0.0960
Bar5	1	-27.00583	529.37187	-0.05	0.9597
MOar5	1	-143.35552	1115.16789	-0.13	0.8988
ARar5	1	-6.94365	5.91964	-1.17	0.2523
Cuar20	1	152.97219	305.82090	0.50	0.6215
Znar20	1	-96.29394	88.25043	-1.09	0.2860
Fear20	1	0.31746	7.73015	0.04	0.9676
Mnar20	1	-121.71281	102.80031	-1.18	0.2480
Bar20	1	125.13306	521.16418	0.24	0.8123
MOar20	1	465.63669	947.89930	0.49	0.6277
ARar20	1	5.36822	4.63132	1.16	0.2578

**Tabela 5.** Variável dependente feijãoogr. Coeficientes de regressão linear múltipla para as propriedades químicas do solo, seu erro padrão e respectivo teste t de Student com sua probabilidade de significância.

<i>Variável</i>	<i>GL</i>	<i>Coefficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr&gt; t </i>
Constante	1	2244.52980	2946.05783	0.76	0.4536
phgr5	1	207.39125	357.36136	0.58	0.5671
cagr5	1	114.32681	385.40844	0.30	0.7693
mogr5	1	-125.97453	244.04988	-0.52	0.6104
pgr5	1	7.78135	15.73789	0.49	0.6255
kgr5	1	1.47427	1.93332	0.76	0.4532
phgr20	1	26.89928	521.82810	0.05	0.9593
cagr20	1	-136.72650	440.10660	-0.31	0.7587
mogr20	1	-32.96446	346.80760	-0.10	0.9251
pgr20	1	-2.40514	15.10938	-0.16	0.8749
kgr20	1	1.59195	2.50334	0.64	0.5308
Cugr5	1	480.07450	232.83148	2.06	0.0502
Zngr5	1	-170.42461	93.97958	-1.81	0.0823
Fegr5	1	-3.53935	6.07803	-0.58	0.5658
Mngr5	1	45.18836	86.11479	0.52	0.6046
Bgr5	1	79.99393	334.90403	0.24	0.8132
MOgr5	1	-1015.73954	724.70139	-1.40	0.1738
ARgr5	1	-3.91453	2.44850	-1.60	0.1230
Cugr20	1	118.65860	155.20810	0.76	0.4520
Zngr20	1	-41.56934	82.31196	-0.51	0.6181
Fegr20	1	-2.98151	3.70273	-0.81	0.4286
Mngr20	1	-53.25904	77.48441	-0.69	0.4985
Bgr20	1	299.40809	339.98004	0.88	0.3872
MOgr20	1	323.40040	692.46945	0.47	0.6447
ARgr20	1	2.48825	2.37002	1.05	0.3042

**Tabela 6.** Variável dependente feijãopd. Coeficientes de regressão linear múltipla para as propriedades químicas do solo, seu erro padrão e respectivo teste t de Student com sua probabilidade de significância.

<i>Variável</i>	<i>G</i>	<i>Coeficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr&gt; t </i>
Constante	1	2604.13700	2926.38248	0.89	0.3824
phpd5	1	-729.08645	366.96411	-1.99	0.0585
capd5	1	343.09494	232.50710	1.48	0.1530
mgpd5	1	330.89617	342.65684	0.97	0.3438
ppd5	1	1.81683	3.32937	0.55	0.5903
kpd5	1	3.03173	1.72702	1.76	0.0919
phpd20	1	645.49203	526.37340	1.23	0.2320
capd20	1	100.26263	444.80567	0.23	0.8236
mgpd20	1	-579.15776	300.13652	-1.93	0.0656
ppd20	1	5.47070	4.00960	1.36	0.1851
kpd20	1	-4.80380	3.58812	-1.34	0.1932
Cupd5	1	-95.45405	123.82008	-0.77	0.4483
Znpd5	1	4.74989	54.92145	0.09	0.9318
Fepd5	1	-9.04896	5.62056	-1.61	0.1205
Mnpd5	1	8.67361	47.00229	0.18	0.8551
Bpd5	1	462.60569	443.38597	1.04	0.3072
MOpd5	1	-974.03632	654.91244	-1.49	0.1500
ARpd5	1	2.48707	2.74452	0.91	0.3738
Cupd20	1	100.60147	97.46382	1.03	0.3123
Znpd20	1	-23.44959	28.92423	-0.81	0.4255
Fepd20	1	-4.13073	3.80465	-1.09	0.2884
Mnpd20	1	-88.12390	46.00449	-1.92	0.0674
Bpd20	1	-157.69001	374.58704	-0.42	0.6775
MOpd20	1	1128.08196	834.35371	1.35	0.1890
ARpd20	1	-0.24540	2.92064	-0.08	0.9337

Com exceção das variáveis dependentes feijãoar e milhogr, os demais coeficientes para as demais variáveis dependentes podem ser considerados iguais a zero a 5% de probabilidade. Apesar do modelo ser estatisticamente adequado, deve-se enfatizar que o modelo completo é instável por existirem coeficientes no modelo que são estatisticamente iguais a zero. Este modelo deveria ser reduzido, mas para efeito de comparação com os demais procedimentos, nenhuma redução de informação será realizada. Os coeficientes de determinação ( $R^2=33,93\%$  para milhoar,  $R^2=55,59\%$  para milhogr,  $R^2=49,10\%$  para milhopd,  $R^2=68,26\%$  para feijãoar,  $R^2=46,33\%$  para feijãogr,  $R^2=52,873\%$  para feijãopd) mostram o quanto o modelo de regressão explica da variabilidade total da variável produção.

Os 11 componentes principais foram obtidos através das 24 variáveis originais, conforme podem ser vistos nas Tabelas 7, 8 e 9, explicando 90,84% da variabilidade total no sistema arado, 89,59% no sistema grade e 90,24% no sistema plantio direto. A variável resposta é a produção de milho e feijão para cada sistema de preparo.

**Tabela 7.** Autovalores da matriz de correlação das variáveis originais para produção de milho e feijão no sistema de plantio - Arado.

	<i>Autovalor</i>	<i>Diferença</i>	<i>Proporção</i>	<i>Prop. Acumulada</i>
1	7.84922366	4.73297743	0.3271	0.3271
2	3.11624623	0.95003163	0.1298	0.4569
3	2.16621460	0.30590124	0.0903	0.5472
4	1.86031336	0.14916130	0.0775	0.6247
5	1.71115206	0.36481754	0.0713	0.6960
6	1.34633452	0.30080329	0.0561	0.7521
7	1.04553123	0.13007966	0.0436	0.7956
8	0.91545157	0.22366492	0.0381	0.8338
9	0.69178665	0.03952200	0.0288	0.8626
10	0.65226464	0.20500276	0.0272	0.8898
11	0.44726188	0.08080650	0.0186	0.9084
12	0.36645538	0.03552899	0.0153	0.9237
13	0.33092639	0.02003185	0.0138	0.9375
14	0.31089454	0.05317465	0.0130	0.9504
15	0.25771989	0.04183861	0.0107	0.9612
16	0.21588129	0.04274731	0.0090	0.9702
17	0.17313398	0.00855789	0.0072	0.9774
18	0.16457609	0.06657325	0.0069	0.9842
19	0.09800284	0.00493758	0.0041	0.9883
20	0.09306526	0.01509930	0.0039	0.9922
21	0.07796595	0.02687471	0.0032	0.9954
22	0.05109124	0.01503015	0.0021	0.9976
23	0.03606109	0.01361543	0.0015	0.9991
24	0.02244566		0.0009	1.0000

**Tabela 8.** Autovalores da matriz de correlação das variáveis originais para produção de milho e feijão no sistema de plantio - Grade.

	<i>Autovalor</i>	<i>Diferença</i>	<i>Proporção</i>	<i>Prop. Acumulada</i>
1	5.56180498	1.80199881	0.2317	0.2317
2	3.75980617	0.80940270	0.1567	0.3884
3	2.95040347	0.65980485	0.1229	0.5113
4	2.29059862	0.35499344	0.0954	0.6068
5	1.93560518	0.74308766	0.0807	0.6874
6	1.19251753	0.18659239	0.0497	0.7371
7	1.00592513	0.12393589	0.0419	0.7790
8	0.88198924	0.10571014	0.0367	0.8158
9	0.77627910	0.14978989	0.0323	0.8481
10	0.62648921	0.10557548	0.0261	0.8742
11	0.52091373	0.05898989	0.0217	0.8959
12	0.46192384	0.06856933	0.0192	0.9152
13	0.39335450	0.02385816	0.0164	0.9316
14	0.36949634	0.09333417	0.0154	0.9470
15	0.27616217	0.01125852	0.0115	0.9585
16	0.26490365	0.05877467	0.0110	0.9695
17	0.20612898	0.05206543	0.0086	0.9781
18	0.15406355	0.04621971	0.0064	0.9845
19	0.10784384	0.01758091	0.0045	0.9890
20	0.09026293	0.02263832	0.0038	0.9928
21	0.06762460	0.01595740	0.0028	0.9956
22	0.05166721	0.01024408	0.0022	0.9977
23	0.04142313	0.02861023	0.0017	0.9995
24	0.01281290		0.0005	1.0000

**Tabela 9.** Autovalores da matriz de correlação das variáveis originais para produção de milho e feijão no sistema de plantio - Plantio Direto.

	<i>Autovalor</i>	<i>Diferença</i>	<i>Proporção</i>	<i>Prop. Acumulada</i>
1	5.81906512	2.08464351	0.2425	0.2425
2	3.73442161	0.89235461	0.1556	0.3981
3	2.84206700	0.73210394	0.1184	0.5165
4	2.10996306	0.32838431	0.0879	0.6044
5	1.78157875	0.41741923	0.0742	0.6786
6	1.36415951	0.15615716	0.0568	0.7355
7	1.20800236	0.25766997	0.0503	0.7858
8	0.95033239	0.27283853	0.0396	0.8254
9	0.67749385	0.03809806	0.0282	0.8536
10	0.63939579	0.10896471	0.0266	0.8803
11	0.53043108	0.07850133	0.0221	0.9024
12	0.45192975	0.07589964	0.0188	0.9212
13	0.37603011	0.05966296	0.0157	0.9369
14	0.31636715	0.05033302	0.0132	0.9501
15	0.26603414	0.03797011	0.0111	0.9611
16	0.22806402	0.05236098	0.0095	0.9706
17	0.17570304	0.01782643	0.0073	0.9780
18	0.15787661	0.04377166	0.0066	0.9845
19	0.11410495	0.02492749	0.0048	0.9893
20	0.08917746	0.01892818	0.0037	0.9930
21	0.07024927	0.02117606	0.0029	0.9959
22	0.04907321	0.01845956	0.0020	0.9980
23	0.03061365	0.01274752	0.0013	0.9993
24	0.01786613		0.0007	1.0000

O modelo de regressão linear múltipla ajustado que descreve a relação entre a produção e os 11 componentes principais podem ser vistos nas Tabelas de 10 a 15.

**Tabela 10.** Coeficientes de regressão linear múltipla utilizando os 11 componentes principais e respectivos testes t de student e probabilidade de significância. Variável dependente produção de milho para o sistema de plantio arado.

<i>Variável</i>	<i>GL</i>	<i>Coeficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr &gt; t </i>
Constante	1	6381.79592	95.56330	66.78	<.0001
Prin1	1	-5.65788	34.46317	-0.16	0.8705
Prin2	1	32.96380	54.69563	0.60	0.5504
Prin3	1	-29.45342	65.60211	-0.45	0.6561
Prin4	1	-24.06392	70.79058	-0.34	0.7358
Prin5	1	84.88665	73.81154	1.15	0.2575
Prin6	1	-19.79951	83.21317	-0.24	0.8132
Prin7	1	43.79817	94.42784	0.46	0.6455
Prin8	1	22.07768	100.91387	0.22	0.8280
Prin9	1	-17.85965	116.08670	-0.15	0.8786
Prin10	1	101.77867	119.55194	0.85	0.4001
Prin11	1	-30.38462	144.37354	-0.21	0.8345

**Tabela 11.** Coeficientes de regressão linear múltipla utilizando os 11 componentes principais e respectivos testes t de student e probabilidade de significância. Variável dependente produção de feijão para o sistema de plantio arado.

<i>Variável</i>	<i>GL</i>	<i>Coeficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr &gt; t </i>
Constante	1	1418.44490	65.85395	21.54	<.0001
Prin1	1	-13.10243	23.74903	-0.55	0.5845
Prin2	1	17.14652	37.69149	0.45	0.6518
Prin3	1	-28.60588	45.20729	-0.63	0.5308
Prin4	1	-18.24481	48.78274	-0.37	0.7105
Prin5	1	3.65601	50.86452	0.07	0.9431
Prin6	1	65.54718	57.34331	1.14	0.2604
Prin7	1	44.36489	65.07149	0.68	0.4996
Prin8	1	112.40722	69.54110	1.62	0.1145
Prin9	1	74.58654	79.99690	0.93	0.3572
Prin10	1	18.50961	82.38484	0.22	0.8235
Prin11	1	-110.92905	99.48974	-1.11	0.2720



**Tabela 12.** Coeficientes de regressão linear múltipla utilizando os 11 componentes principais e respectivos testes t de student e probabilidade de significância. Variável dependente produção de milho para o sistema de plantio grade.

<i>Variável</i>	<i>GL</i>	<i>Coeficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr &gt; t </i>
Constante	1	6152.10204	76.12150	80.82	<.0001
Prin1	1	30.99413	32.61196	0.95	0.3481
Prin2	1	66.98118	39.66450	1.69	0.0997
Prin3	1	101.08223	44.77587	2.26	0.0300
Prin4	1	8.97127	50.81714	0.18	0.8608
Prin5	1	7.60318	55.28106	0.14	0.8914
Prin6	1	-112.84265	70.42914	-1.60	0.1176
Prin7	1	-60.82087	76.68350	-0.79	0.4328
Prin8	1	-14.32564	81.89419	-0.17	0.8621
Prin9	1	113.79195	87.29227	1.30	0.2004
Prin10	1	9.16743	97.16905	0.09	0.9253
Prin11	1	-58.14285	106.56188	-0.55	0.5886

**Tabela 13.** Coeficientes de regressão linear múltipla utilizando os 11 componentes principais e respectivos testes t de student e probabilidade de significância. Variável dependente produção de feijão para o sistema de plantio grade.

<i>Variável</i>	<i>GL</i>	<i>Coeficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr &gt; t </i>
Constante	1	2093.86327	45.35279	46.17	<.0001
Prin1	1	-16.46379	19.43004	-0.85	0.4023
Prin2	1	18.52358	23.63191	0.78	0.4381
Prin3	1	50.23981	26.67723	1.88	0.0675
Prin4	1	-20.45140	30.27659	-0.68	0.5036
Prin5	1	55.20711	32.93617	1.68	0.1021
Prin6	1	30.16982	41.96131	0.72	0.4767
Prin7	1	1.09924	45.68763	0.02	0.9809
Prin8	1	-12.40308	48.79213	-0.25	0.8007
Prin9	1	10.56420	52.00828	0.20	0.8402
Prin10	1	5.15870	57.89282	0.09	0.9295
Prin11	1	18.94451	63.48901	0.30	0.7671

**Tabela 14.** Coeficientes de regressão linear múltipla utilizando os 11 componentes principais e respectivos testes t de student e probabilidade de significância. Variável dependente produção de milho para o sistema de plantio direto.

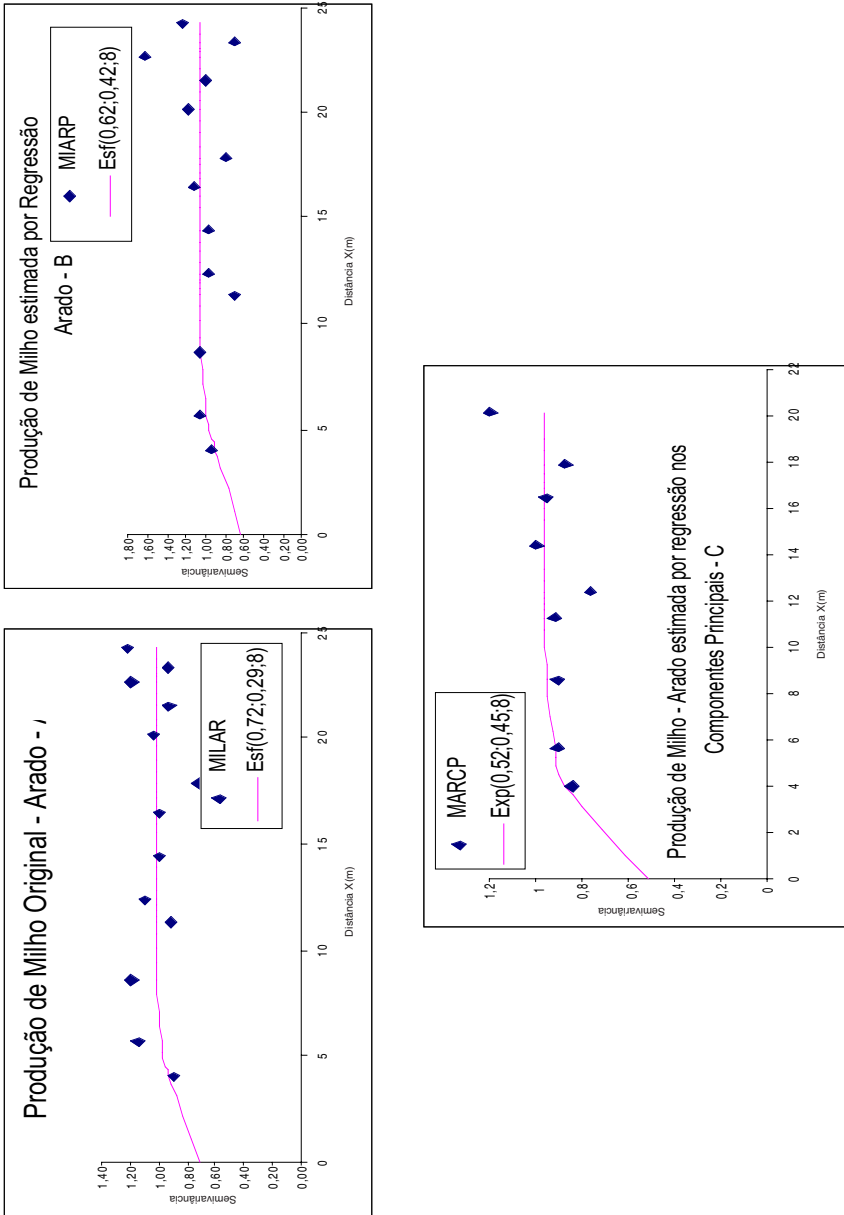
<i>Variável</i>	<i>GL</i>	<i>Coefficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr &gt; t </i>
Constante	1	5960.63265	89.46997	66.62	<.0001
Prin1	1	-38.99374	37.47383	-1.04	0.3048
Prin2	1	27.23532	46.77815	0.58	0.5639
Prin3	1	-116.00456	53.62132	-2.16	0.0370
Prin4	1	21.54148	62.23250	0.35	0.7312
Prin5	1	-105.32895	67.72549	-1.56	0.1284
Prin6	1	-24.96405	77.39664	-0.32	0.7489
Prin7	1	51.49091	82.24714	0.63	0.5351
Prin8	1	-132.65541	92.72929	-1.43	0.1609
Prin9	1	-182.55920	109.82520	-1.66	0.1049
Prin10	1	135.50626	113.04980	1.20	0.2383
Prin11	1	152.97773	124.11956	1.23	0.2255

**Tabela 15.** Coeficientes de regressão linear múltipla utilizando os 11 componentes principais e respectivos testes t de student e probabilidade de significância. Variável dependente produção de feijão para o sistema de plantio direto.

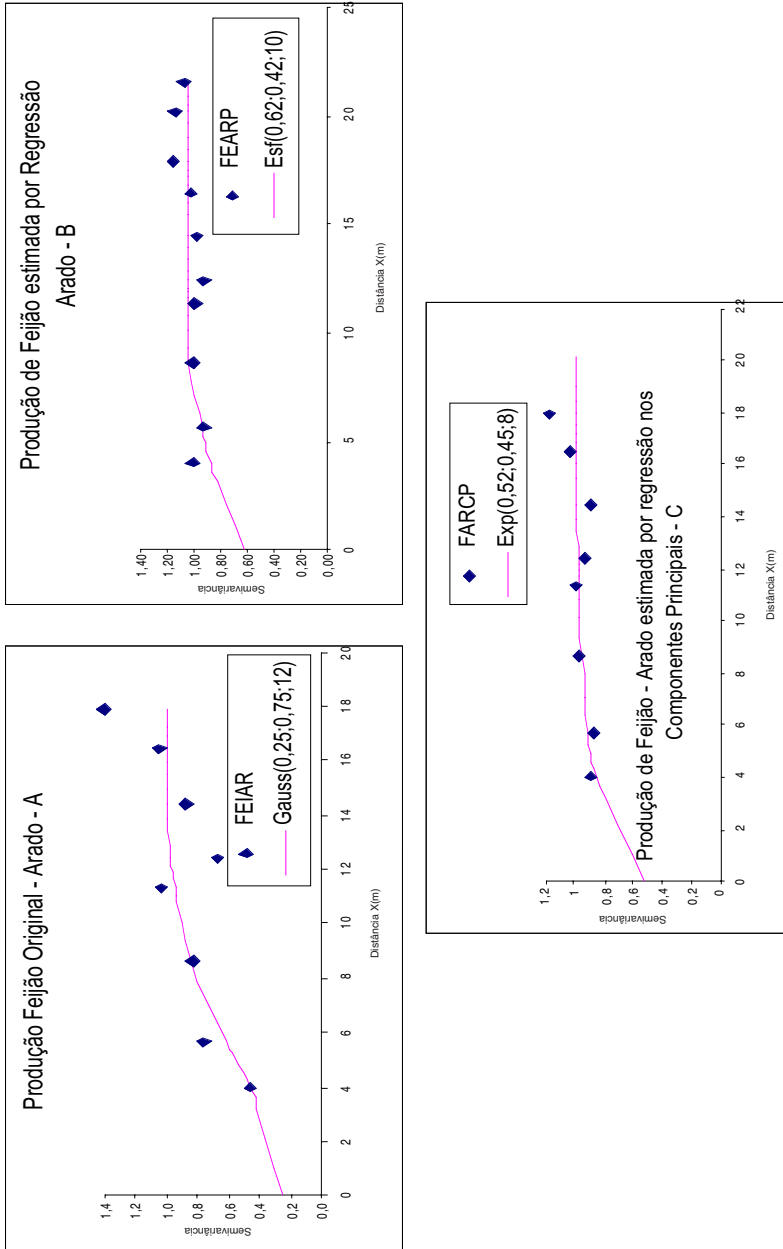
<i>Variável</i>	<i>GL</i>	<i>Coefficientes</i>	<i>Erro Padrão</i>	<i>t-Student</i>	<i>Pr &gt; t </i>
Constante	1	2103.71837	46.32171	45.42	<.0001
Prin1	1	-22.38690	19.40150	-1.15	0.2560
Prin2	1	-41.78316	24.21867	-1.73	0.0928
Prin3	1	10.03795	27.76162	0.36	0.7197
Prin4	1	-22.67085	32.21993	-0.70	0.4861
Prin5	1	-6.02472	35.06384	-0.17	0.8645
Prin6	1	42.60916	40.07093	1.06	0.2945
Prin7	1	5.33075	42.58220	0.13	0.9011
Prin8	1	75.04281	48.00918	1.56	0.1265
Prin9	1	-52.57771	56.86033	-0.92	0.3611
Prin10	1	-22.52257	58.52981	-0.38	0.7026
Prin11	1	-0.50599	64.26101	-0.01	0.9938

Os coeficientes de determinação ( $R^2=7,83\%$  para milhoar,  $R^2=33,79\%$  para feijãoar,  $R^2=27,64\%$  para milhogr,  $R^2=19,33\%$  para feijãoogr,  $R^2=31,36\%$  para milhopd,  $R^2=20,53\%$  para feijãoopd) mostram o quanto o modelo de regressão explica da variabilidade total da produção. Como no caso anterior, estes modelos podem ser simplificados, pela exclusão dos componentes que apresentarem o valor da probabilidade muito alto, como é o caso do Prin1 na Tabela 10 e outros. Entretanto, nenhuma exclusão foi feita, para que uma comparação mais eficiente com as variáveis originais pudesse ser feita.


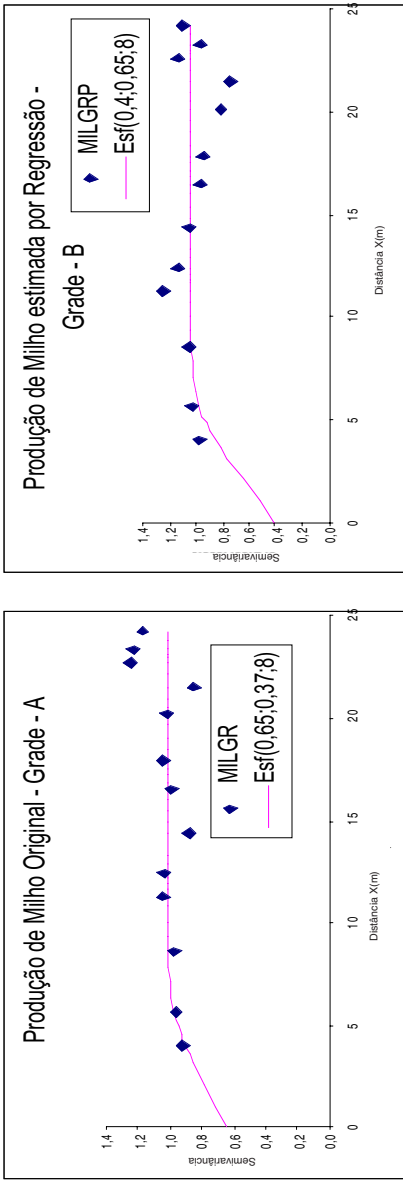
Através do programa de geoestatística desenvolvido por Vieira et al. (1983), foi realizada a análise geoestatística da produção original, produção estimada por regressão linear múltipla e produção estimada por componentes principais para cada sistema de preparo do solo e para cada cultura. Foi ajustado três modelos de semivariogramas (equações 2, 3 e 4) correspondentes aos modelos esférico, exponencial e gaussiano, como mostram as Fig. 1 a 6, para cada cultura e cada sistema de preparo. A validação desses modelos foi realizada através do procedimento de autovalidação "Jack-Knifing" (Vieira et al. 1983).



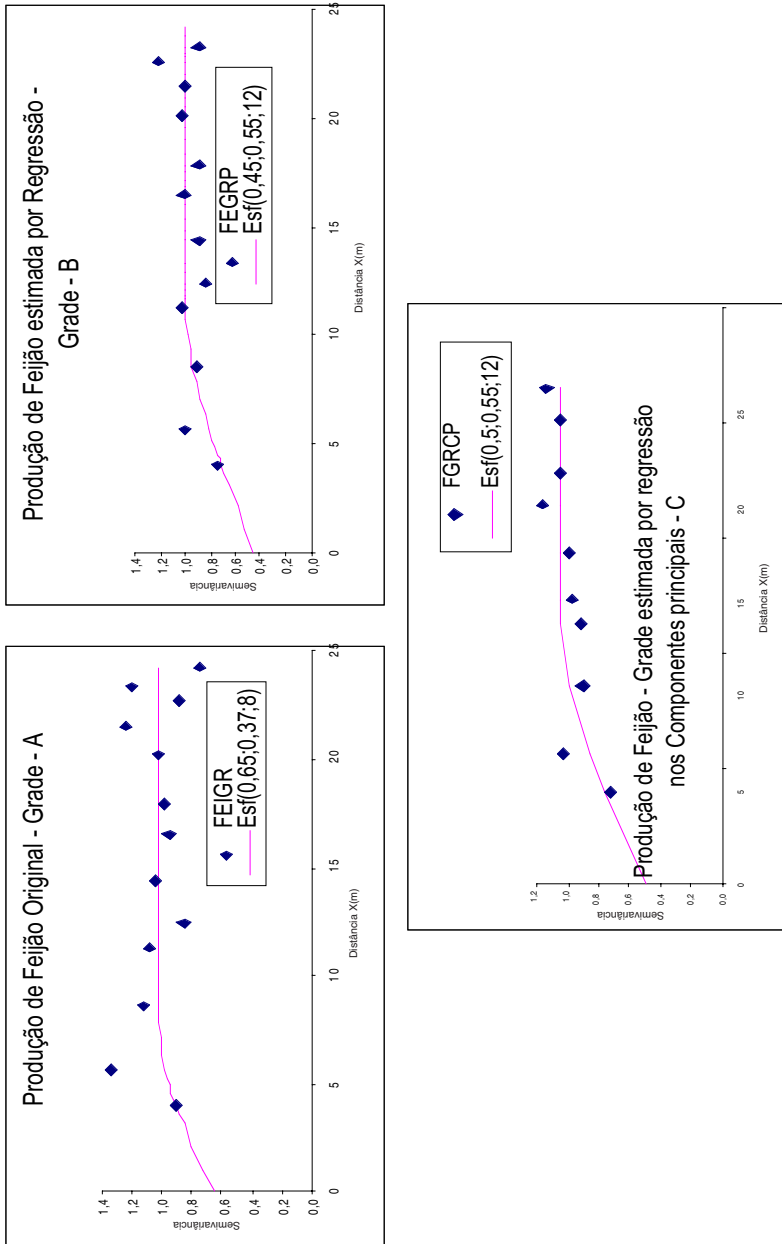
**Fig. 1.** Semivariograma ajustado ao sistema de preparo arado para milho. A - produção original, B - produção estimada por regressão linear múltipla e C - produção estimada por componentes principais. Modelo esférico com efeito pepita = 0,72, patamar = 0,29 e alcance = 8 [ $Esf(0,72; 0,29; 8)$ ] ajustado para A, esférico com efeito pepita = 0,62, patamar = 0,42 e alcance = 8 [ $Esf(0,62; 0,42; 8)$ ] para B e exponencial com efeito pepita = 0,52, patamar = 0,45 e alcance = 8 [ $Exp(0,52; 0,45; 8)$ ] para C.



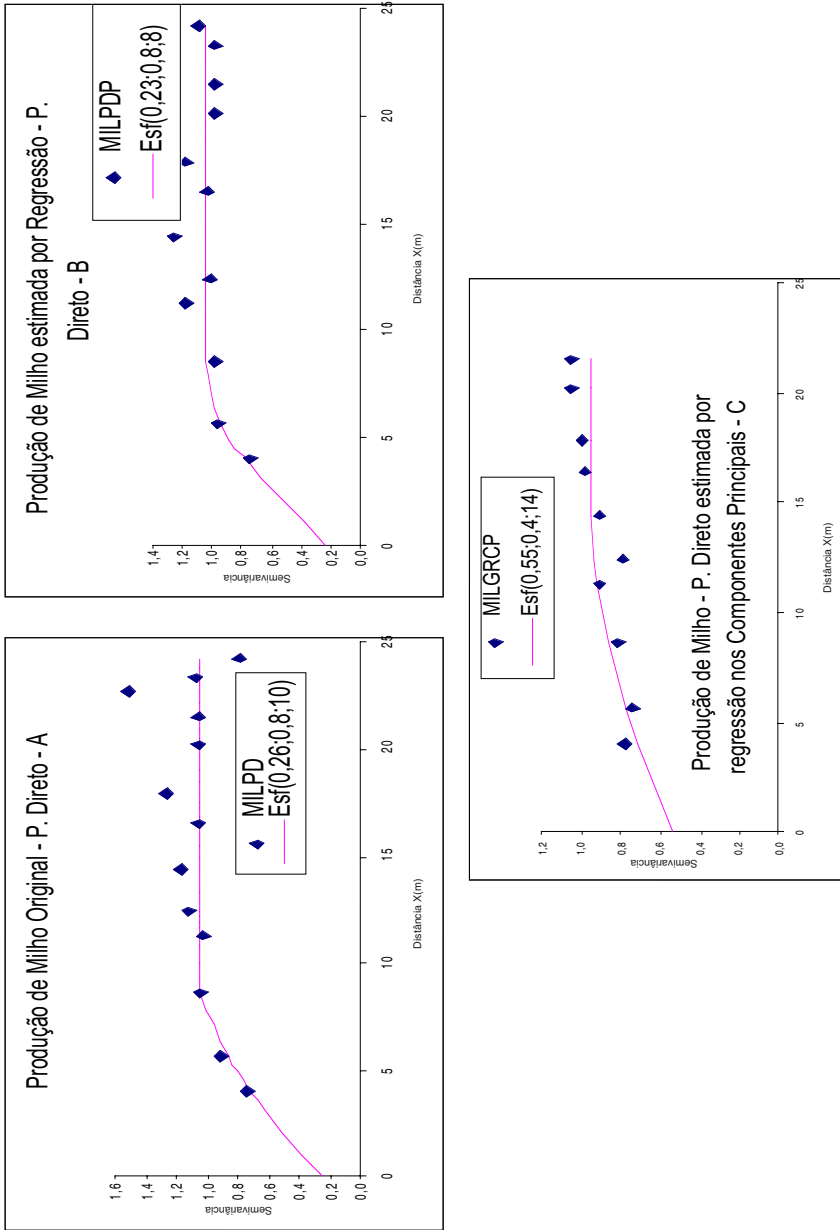
**Fig. 2.** Semivariograma ajustado ao sistema de preparo arado para feijão. A - produção original, B - produção estimada por regressão linear múltipla e C - produção estimada por componentes principais. Modelo gaussiano com efeito pepita = 0,25, patamar = 0,75 e alcance = 12 [Gauss(0,25; 0,75; 12)] ajustado para A, esférico com efeito pepita = 0,62, patamar = 0,42 e alcance = 10 [Esf(0,62; 0,42; 10)] para B e exponencial com efeito pepita = 0,45, patamar = 0,45 e alcance = 8 [(Exp(0,52; 0,45; 8)] para C.



**Fig. 3.** Semivariograma ajustado ao sistema de preparo grade para milho. A - produção original, B - produção estimada por regressão linear múltipla e C - produção estimada por componentes principais. Modelo esférico com efeito pepita = 0,65, patamar = 0,37 e alcance = 8 [Esf(0,65; 0,37; 8)] ajustado para A, esférico com efeito pepita = 0,4, patamar = 0,65 e alcance = 8 [Esf(0,4; 0,65; 8)] para B e esférico com efeito pepita = 0,45, patamar = 0,5 e alcance = 12 [(Esf(0,45; 0,5; 12)] para C.

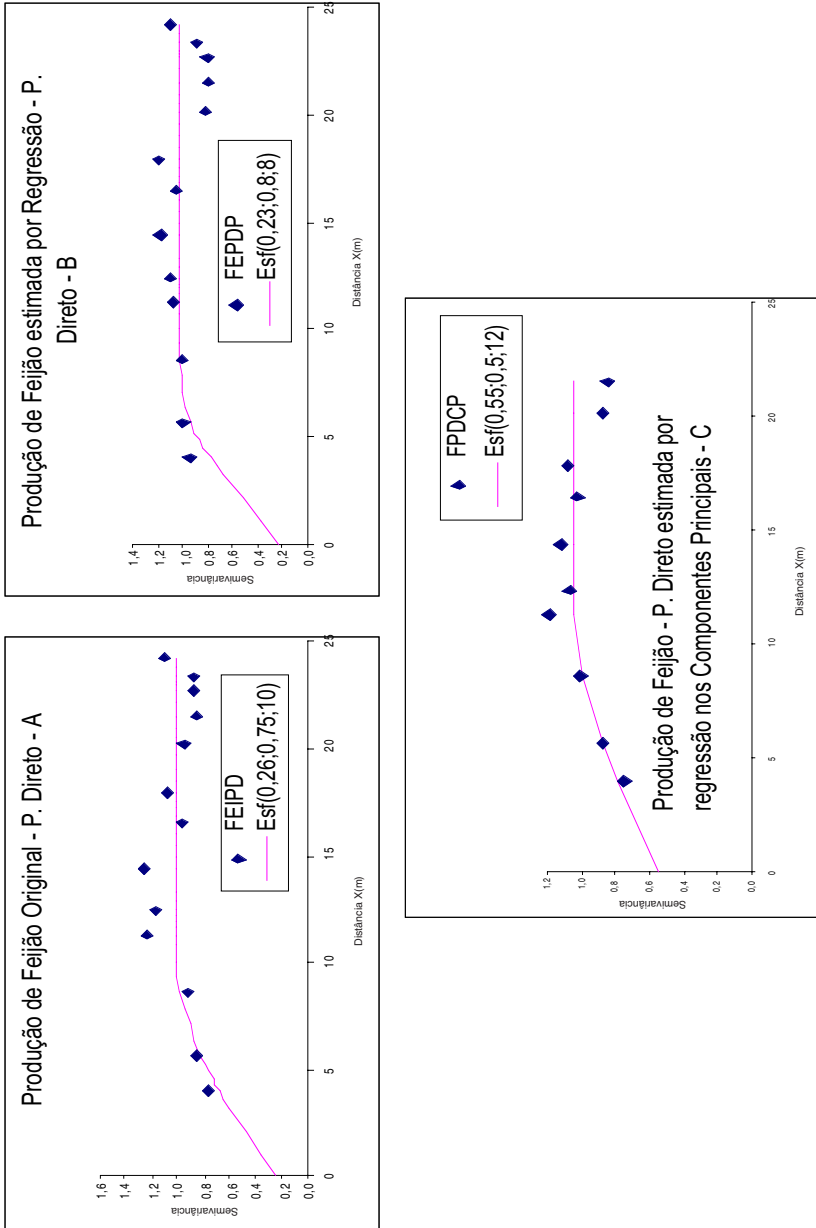


**Fig. 4.** Semivariograma ajustado ao sistema de preparo grade para feijão. A - produção original, B - produção estimada por regressão linear múltipla e C - produção estimada por componentes principais. Modelo esférico com efeito pepita = 0,65, patamar = 0,37 e alcance = 8 [Esf(0,65; 0,37; 8)] ajustado para A, esférico com efeito pepita = 0,45, patamar = 0,56 e alcance = 12 [Esf(0,45; 0,6; 12)] para B e esférico com efeito pepita = 12 [(Esf(0,5; 0,55; 12))] para C.



**Fig. 5.** Semivariograma ajustado ao sistema de preparo plantio direto para milho. A - produção original, B - produção estimada por regressão linear múltipla e C - produção estimada por componentes principais. Modelo esférico com efeito pepita = 0,28, patamar = 0,8 e alcance = 10 [Esf(0,28; 0,8; 10)] ajustado para A, esférico com efeito pepita = 0,28, patamar = 0,8 e alcance = 8 [Esf(0,28; 0,8; 8)] para B e esférico com efeito pepita = 0,4 e alcance = 14 [Esf(0,55; 0,4; 14)] para C.





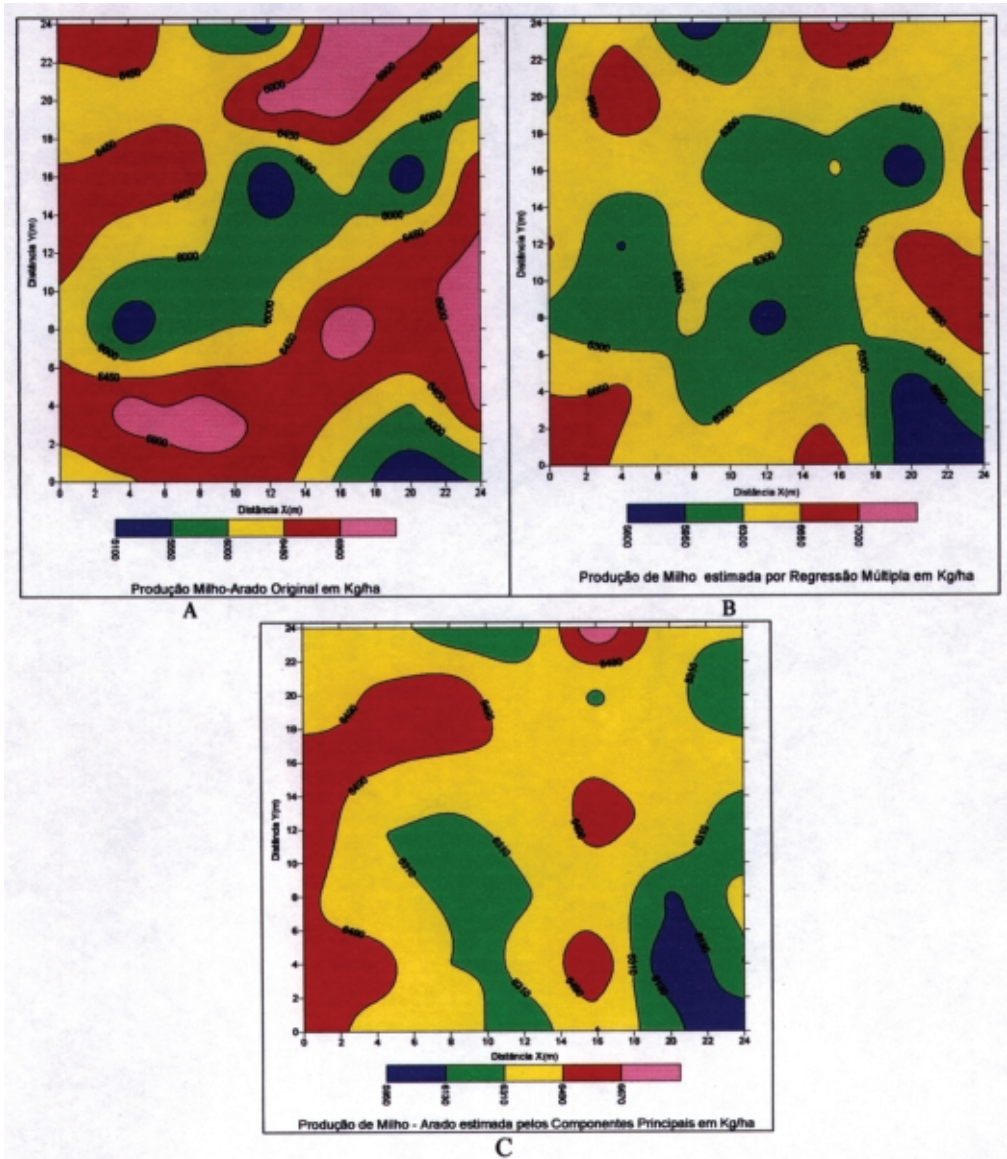
**Fig. 6.** Semivariograma ajustado ao sistema de preparo plantio direto para feijão. A - produção original, B - produção estimada por regressão linear múltipla e C - produção estimada por componentes principais. Modelo esférico com efeito pepita = 0,28, patamar = 0,75 e alcance = 10 [Est(0,28; 0,75; 10)] ajustado para A, esférico com efeito pepita = 0,28, patamar = 0,8 e alcance = 8 [Est(0,28; 0,8; 8)] para B e esférico com efeito pepita = 0,55, patamar = 0,5 e alcance = 12 [Est(0,55; 0,5; 12)] para C.

As dezoito combinações entre variáveis de produção, sistemas de preparo e culturas apresentaram isotropia, ou seja, variabilidade independente da direção escolhida na parcela experimental. O modelo esférico ajustado às semivariâncias predominou em quinze do total de dezoito combinações. Em duas, o modelo exponencial foi o que melhor se ajustou e em uma o modelo gaussiano. Das combinações que apresentaram dependência espacial, somente cinco (Produção de milho observada com 24% e estimado por regressão múltipla com 22%, para plantio direto e produção de feijão com 25% para arado e produção de feijão observado com 25% e estimado por regressão múltipla com 22% para plantio direto) podem ser consideradas como forte dependência (efeito pepita  $\leq 25\%$  do patamar), e o restante como moderada (efeito pepita entre 26-75% do patamar), segundo Cambardella et al. (1994). Os semivariogramas para as combinações com forte dependência espacial estão representados nas Fig. 5A e 5B para milho e Fig. 2A, 6A e 6B para feijão, com o modelo esférico predominado, com exceção da Fig. 2A aonde predominou o modelo gaussiano. O semivariograma para produção de milho estimado por componentes principais (Fig. 5C), sob preparo com plantio direto apresentou maior alcance.

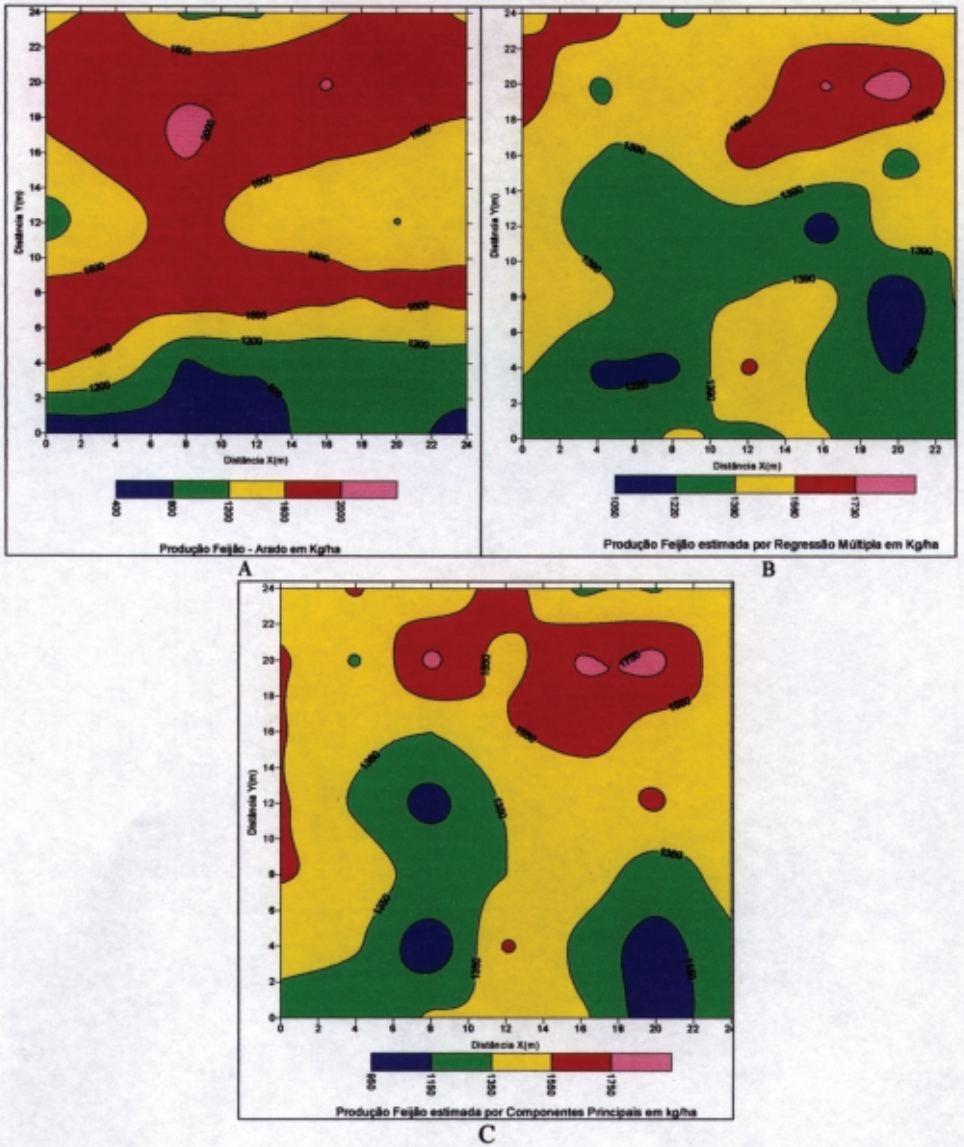
O alcance é de fundamental importância para a interpretação dos semivariogramas. Ele indica a distância até onde os pontos amostrais estão correlacionados entre si (Vieira et al., 1983; Souza et al., 1997; Vieira, 1997), ou seja, os pontos localizados em uma área cujo raio seja o alcance, são mais semelhantes do que aqueles separados por distância maiores.

Segundo McBratney & Webster (1983) e Souza et al. (1997), uma das principais utilizações dos semivariogramas é na determinação do número ideal de amostras para a estimação das características químicas do solo. Com o conhecimento do alcance da dependência espacial, define-se o raio de amostragem e para garantir em uma amostragem futura nas mesmas condições do experimento em questão, a independência dos pontos amostrais, a minimização do erro-padrão da média e também para diminuir o trabalho na coleta e no número de amostras, o intervalo de amostragem deve ser duas vezes o alcance. Entretanto, a independência dos pontos amostrais garantiriam a construção do histograma, mas não trariam informações sobre a distribuição espacial dos valores a eles alocado.

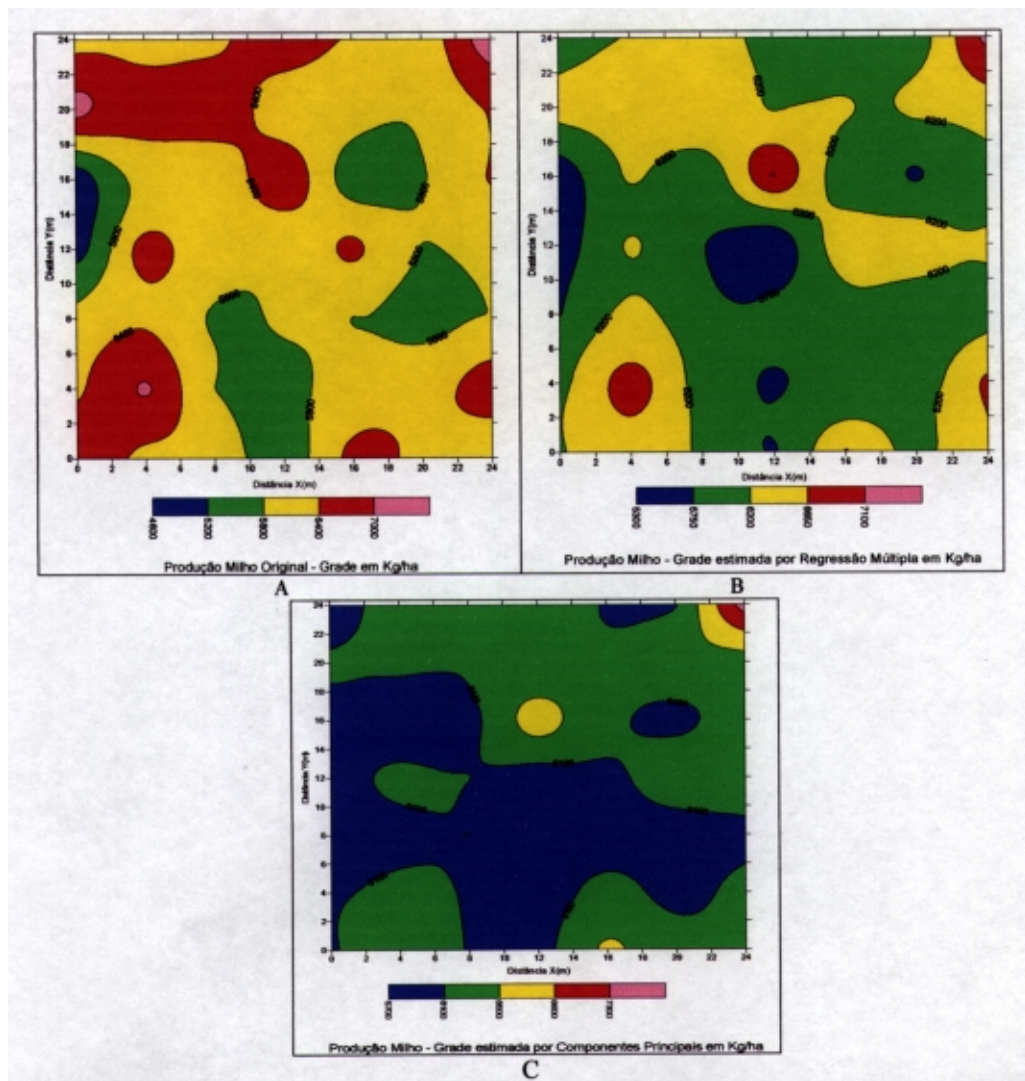
Os gráficos de isolinhas estimados por krigagem simples (Vieira et al., 1983) para as três variáveis produção em kg/ha, três sistemas de preparo e duas culturas, são apresentados nas Fig. 7 a 12, com os valores agrupados em cinco classes em ordem crescente.



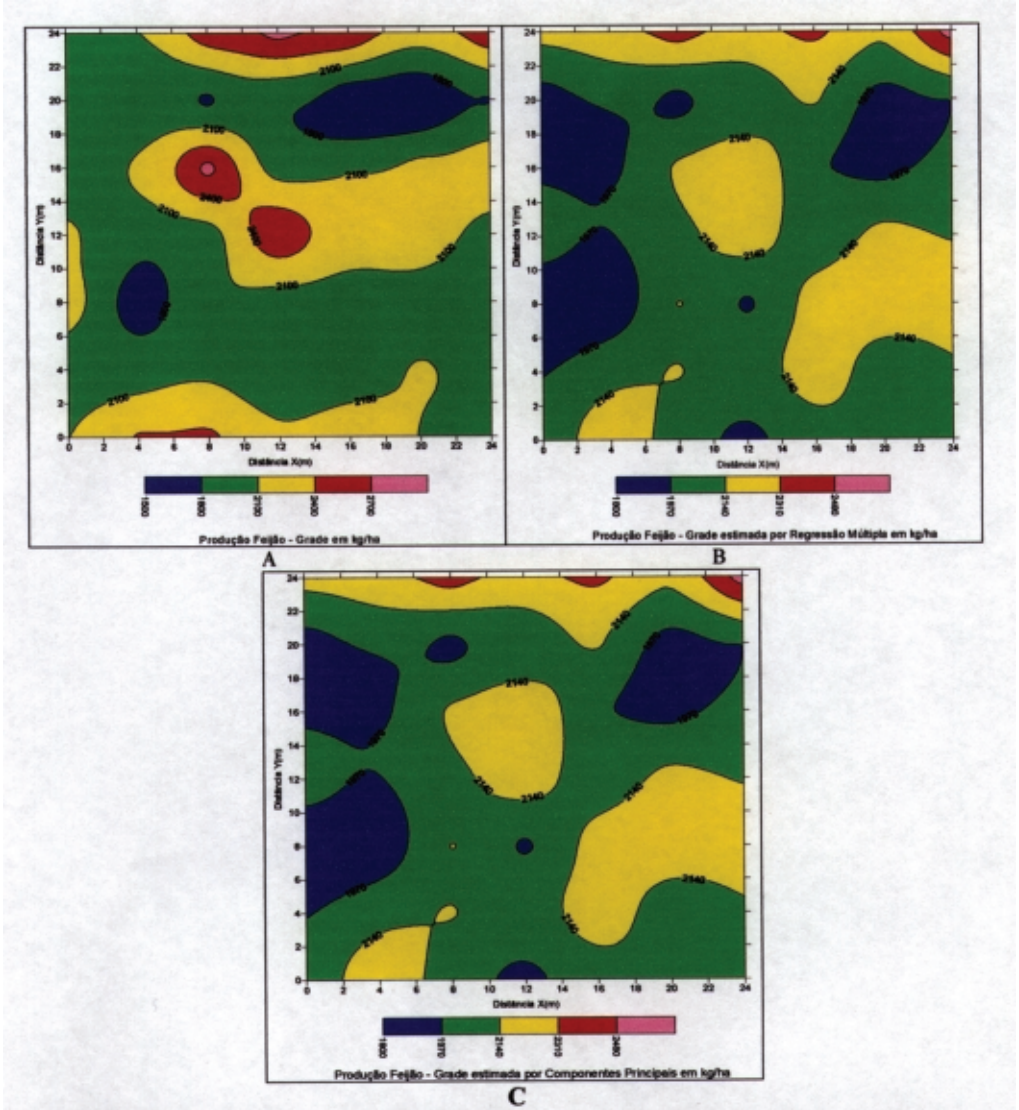
**Fig. 7.** Mapas de produção correspondentes a produção observada A, produção estimada por regressão linear múltipla B e produção estimada por componentes principais C, para o sistema de preparo arado e a cultura do milho.



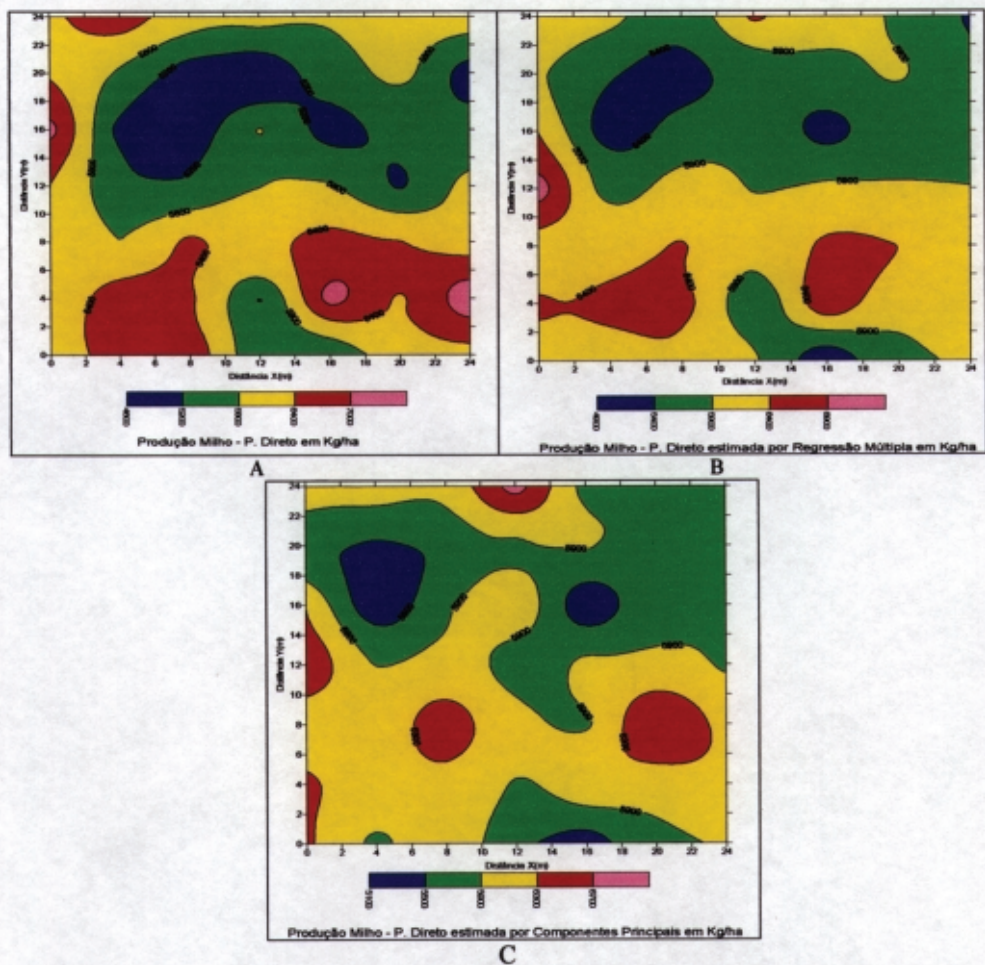
**Fig. 8.** Mapas de produção correspondentes a produção observada A, produção estimada por regressão linear múltipla B e produção estimada por componentes principais C, para o sistema de preparo arado e a cultura do feijão.



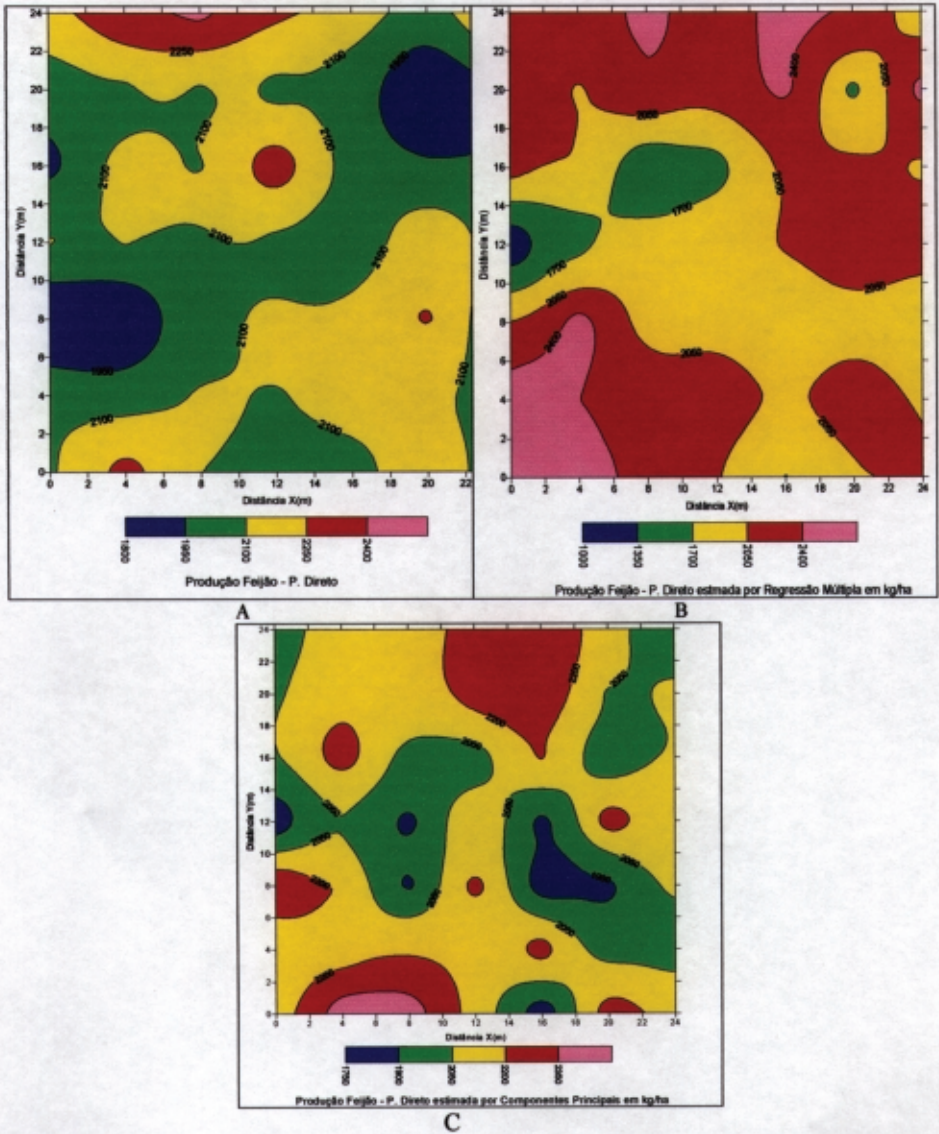
**Fig. 9.** Mapas de produção correspondentes a produção observada A, produção estimada por regressão linear múltipla B e produção estimada por componentes principais C, para o sistema de preparo grade e a cultura do milho.



**Fig. 10.** Mapas de produção correspondentes a produção observada A, produção estimada por regressão linear múltipla B e produção estimada por componentes principais C, para o sistema de preparo grade e a cultura do feijão.



**Fig. 11.** Mapas de produção correspondentes a produção observada A, produção estimada por regressão linear múltipla B e produção estimada por componentes principais C, para o sistema de preparo plantio direto e a cultura do milho.



**Fig. 12.** Mapas de produção correspondentes a produção observada A, produção estimada por regressão linear múltipla B e produção estimada por componentes principais C, para o sistema de preparo plantio direto e a cultura do feijão.



Como era de se esperar, a semelhança entre os mapas interpolados pelos valores observados da produção (Fig. 7A, 8A, 9A, 10A, 11A e 12A) e os mapas interpolados pelos valores estimados utilizando-se a regressão linear múltipla com os valores originais (Fig. 7B, 8B, 9B, 10B, 11B e 12B) parece visualmente maior do que os mapas interpolados para valores ajustados utilizando-se os componentes principais (Fig. 7C, 8C, 9C, 10C, 11C e 12C). Isso ocorre porque, sendo a análise de componentes principais uma técnica de redução através de combinações lineares das próprias variáveis originais, existe uma perda de informação, pois somente 90,84% da variabilidade total no sistema arado, 89,59% no sistema grade e 90,24% no sistema plantio direto foram usadas do total de variabilidade existente no conjunto de variáveis originais (Tabelas 7, 8 e 9). Esta perda de informação reflete-se claramente no coeficiente de determinação ( $R^2=33,93\%$  para milhoar,  $R^2=55,59\%$  para milhogr,  $R^2=49,10\%$  para milhopd,  $R^2=68,26\%$  para feijãoar,  $R^2=46,33\%$  para feijãoogr,  $R^2=52,873\%$  para feijãoopd) para a regressão linear múltipla nas variáveis originais e ( $R^2=7,83\%$  para milhoar,  $R^2=33,79\%$  para feijãoar,  $R^2=27,64\%$  para milhogr,  $R^2=19,33\%$  para feijãoogr,  $R^2=31,36\%$  para milhopd,  $R^2=20,53\%$  para feijãoopd) para a regressão linear múltipla baseada nos componentes principais.

## Conclusões

1. Houve uma grande predominância do modelo esférico ajustado às semivariâncias, independente do sistema de preparo usado.
2. Os sistemas de preparo do solo (arado, grade e plantio direto) não apresentaram nenhuma influência direta na estimativa de produção utilizando tanto as variáveis originais, como os componentes principais.
3. Pela análise de regressão, os modelos utilizando os componentes principais como variáveis regressoras, apresentaram estimativas de produção mais distantes dos valores observados, quando comparados visualmente com as estimativas obtidas pelos modelos utilizando as variáveis originais.
4. Torna-se duvidoso o ganho que se tem com a propriedade dos componentes principais serem não correlacionados, comparado com a perda da informação quando do seu uso.

## Referências Bibliográficas

- BUENO, B. F. **Aplicação de técnicas multivariadas em mapeamento e interpretação de parâmetros do solo**. 2001. 84 f. Dissertação (Mestrado) - Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas.
- BURROUGH, P. A.; BOUMA, J.; YATES, S. R. The state of the art in pedometrics. **Geoderma**, v. 62, n. 1/3, p. 311-326, 1994.
- CAMBARDELLA, C. A.; MOORMAN, T. B.; NOVAK, J. M.; PARKIN, T. B.; KARLEN, D. L.; TURCO, R. F.; KONOPKA, A. E. Field-scale variability of soil properties in Central Iowa soils. **Soil Science Society of America Journal**, Madison, v. 58, n. 5, p. 1501-1511, 1994.
- CASTRIGNANO, A.; MAZZONCINI, M.; GIUGLIARINI, L. Spatial characterization of soil properties. **Advances in GeoEcology**, Reiskirchen, v. 31, p. 105-111, 1998.
- EMBRAPA. Centro Nacional de Pesquisa de Solos. **Manual de métodos de análise de solo**. 2. ed. rev. atual. Rio de Janeiro, 1997. 212. p. (Embrapa-CNPS. Documentos, 1).
- HOFFMANN, R. **Componentes principais e análise fatorial**. Piracicaba: ESALQ/USP-DESR, 1992. 25 p. (Série Didática, 76).

KORRE, A. Statistical and spatial assessment of soil heavy metal contamination in areas of poorly recorded complex sources of pollution. **Stochastic Environmental Research and Risk Assessment**, v. 13, p. 260-287, 1999.

McBRATNEY, A. B.; WEBSTER, R. How many observations are needed for regional estimation of soil properties? **Soil Science**, Baltimore, v. 135, n. 3, p. 177-183, 1983.

SÁ, M. F. M. **Abordagem quantitativa na predição espacial de atributos do solo e geração de zonas de manejo agrícola**. 2001. 117 f. Dissertação (Mestrado) – Escola Superior de Agricultura “Luiz de Queiroz” – Universidade de São Paulo, Piracicaba.

SAS INSTITUTE. **SAS - user's guide**: statistics, version 5. Cary, NC: 1985. 956 p.

SOUZA, L. S.; COGO, N. P.; VIEIRA, S. R. Variabilidade de propriedades físicas e químicas do solo em um pomar cítrico. **Revista Brasileira de Ciência do Solo**, Campinas, v. 21, n. 3, p. 1-10, 1997.

VIEIRA, S. R. Variabilidade espacial de argila, silte e atributos químicos em uma parcela experimental de um latossolo roxo de Campinas (SP). **Bragantia**, Campinas, v. 56, n. 1, p. 1-17, 1997.

VIEIRA, S. R.; HATFIELD, J. L.; NIELSEN, D. R.; BIGGAR, J. W. Geoestatistical theory and application to variability of some agronomical properties. **Hilgardia**, Berkeley, v. 51, n. 3, p. 1-75, 1983.

**Embrapa**

---

*Informática Agropecuária*

MINISTÉRIO DA AGRICULTURA,  
PECUÁRIA E ABASTECIMENTO

**GOVERNO  
FEDERAL**  
Trabalhando em todo o Brasil