

**PROPOSTA DE APLICAÇÃO DA ANÁLISE DE VARIÂNCIA COM MODELO
AUTOREGRESSIVO PARA ANÁLISE DE VARIEDADES DE TRIGO (*Triticum aestivum* L.)**

DIOGO FRANCISCO ROSSONI¹, MARIELE VILELA BERNARDES PRADO², JAIR ROCHA DO PRADO³

RESUMO

Para a realização da ANOVA, os erros devem ser independentes e identicamente distribuídos segundo uma normal. Logo, caso isso não ocorra ou haja autocorrelação espacial entre os dados, a ANOVA é seriamente afetada. Assim, é importante o estudo e utilização de métodos de análise para experimentos em campo que levem em consideração a autocorrelação espacial. Com o conhecimento das posições relativas das amostragens (dados referenciados), a variabilidade espacial passa a ser utilizada como um fator positivo, identificando interações importantes nas conclusões experimentais.

Para esse estudo propõe-se uma metodologia que considera a dependência espacial nas análises: a análise de variância com modelo autoregressivo (ANOVA-AR). Comparando-se a ANOVA-AR com a ANOVA clássica, aplicados a dados da produção de variedades de trigo, constatou-se melhora na análise e na explicação das variações do experimento, através da redução do Quadrado Médio do Erro (QME), da redução da Soma Quadrada dos Blocos e da atribuição de 3,6% da variação ao parâmetro ρ .

Palavras-chaves: Dependência espacial, modelo autoregressivo, ANOVA-AR

INTRODUÇÃO

A análise de variância (ANOVA) é utilizada como forma de comparar as médias de tratamentos obtidas através de experimento. Para executarmos uma ANOVA, deve-se respeitar os princípios básicos da experimentação: repetição, aleatorização e controle local. Segundo Banzatto e Kronka (1992) o princípio de repetição consiste na repetição do experimento básico e tem por finalidade propiciar a obtenção de uma estimativa do erro experimental. O princípio de aleatorização tem por finalidade propiciar a todos os tratamentos a mesma probabilidade de serem designados a qualquer das unidades experimentais. É suposto que nenhum tratamento é favorecido por estar em um local com melhores condições de campo. Pode-se considerar também que a aleatorização é usada para satisfazer a condição de independência das observações. O controle local tem o intuito de dividir um ambiente heterogêneo em sub-ambientes homogêneos, tornando o delineamento experimental mais eficiente, pela redução do erro experimental.

Para a realização da ANOVA, os erros devem ser independentes e identicamente distribuídos segundo uma normal. Logo, caso isso não ocorra ou haja autocorrelação espacial entre os dados, a ANOVA é seriamente afetada. Assim, é importante o estudo e utilização de métodos de análise para experimentos em campo que levem em consideração a autocorrelação espacial.

¹ Mestrando em Estatística e Experimentação Agropecuária, DEX/UFLA diogo.rossoni@gmail.com

² Mestranda em Estatística e Experimentação Agropecuária, DEX/UFLA mari_bernardes@yahoo.com.br

³ Mestrando em Estatística e Experimentação Agropecuária, DEX/UFLA jairmat1@yahoo.com.br

MATERIAL E MÉTODOS

Os dados foram coletados no Centro de Pesquisa Agrícola da Universidade do Estado de Montana-USA e são referentes a produção de trigo (*Triticum aestivum L.*), com um total de 102 observações georeferenciadas, com 34 variedades de trigo organizadas em um DBC com 3 blocos.

A Análise de Variância com modelo autoregressivo (ANOVA_AR) utiliza o modelo AR, mais conhecido como SAR (espacial autoregressivo ou *spatial lag model*), que descreve a variação espacial no vetor resposta $Y_{n \times 1}$ e é definido por:

$$Y = \rho WY + X\beta + \varepsilon \quad (0.1)$$

em que:

Y é um vetor $n \times 1$ de valores observados;

ρ é um parâmetro espacial autoregressivo;

W é uma matriz $n \times n$ com atribuições de peso da vizinhança espacial;

X é uma matriz $n \times p$ das observação das variáveis independentes;

β é um vetor $p \times 1$ dos parâmetros;

ε é um vetor $n \times 1$ dos erros inerentes a cada observação.

A matriz W é obtida através da multiplicação de duas outras matrizes D e C ($W = D \times C$).

A matriz C de dimensões $n \times n$ é binária, e descreve a vizinhança das parcelas experimentais. Cada elemento c_{ij} dessa matriz pode ser definido por:

$$c_{ij} = \begin{cases} 1 & \text{se } c_{ij} \text{ é adjacente a } c_{i+1,j}, \\ 1 & \text{se } c_{ij} \text{ é adjacente a } c_{i-1,j}, \\ 1 & \text{se } c_{ij} \text{ é adjacente a } c_{i,j+1}, \\ 1 & \text{se } c_{ij} \text{ é adjacente a } c_{i,j-1}, \\ 0 & \text{caso contrário.} \end{cases}$$

A matriz D é uma matriz diagonal com os elementos $\frac{1}{k_i}$, em que k_i é a soma dos valores da linha i da matriz C

Estimação do parâmetro ρ

A estimação do parâmetro ρ do modelo AR será pelo método de máximo verossimilhança (MV). A MV é baseada no princípio de selecionar valores para os parâmetros que maximizem a probabilidade de ter obtido os dados observados. Smirnov e Anselin (2001) propuseram diversas técnicas para a estimação de ρ , como decomposição de autovalores, método de decomposição matricial através da decomposição de Cholesky e aproximação de funções.

Neste estudo utilizou-se a decomposição de autovalores.

Decomposição de autovalores

A solução original da estimação por MV de um modelo autoregressivo espacial, originalmente proposta por Ord (1975), consiste em explorar a decomposição do Jacobiano $|I - \rho W|$ em termos dos autovalores ω_i (com $i = 1, 2, \dots, N$) da matriz W , dada por:

$$|I - \rho W| = \prod_{i=1}^n (1 - \rho \omega_i) \quad (0.2)$$

ou

$$\ln |I - \rho W| = \sum_{i=1}^n \ln(1 - \rho \omega_i) \quad (0.3)$$

A partir da equação (0.2) ou (0.3) obtém-se um polinômio que não têm solução única e que deve ser resolvido iterativamente.

Análise de variância de modelo autoregressivo (ANOVA-AR)

A análise de variância de modelo autoregressivo (ANOVA-AR), foi proposta por Long (1996). A idéia básica consiste em transformar observações ditas autocorrelacionadas em observações não-correlacionadas. Para tanto, após obtermos a estimativa ρ deve-se proceder o ajuste dos dados observados através da equação (0.4)

$$Y_{adj} = Y - (\hat{\rho} W Y - \hat{\rho} \beta_0) \quad (0.4)$$

em que:

Y é um vetor $n \times 1$ de valores observados;

$\hat{\rho}$ é a estimativa do parâmetro espacial autoregressivo;

W é uma matriz $n \times n$ com atribuições de peso da vizinhança espacial;

β_0 é a média dos valores observados;

Y_{adj} é um vetor $n \times 1$ de valores ajustados;

Com os valores de Y_{adj} obtém-se uma nova tabela de Análise de Variância. Esta tabela é utilizada como base para a construção da ANOVA-AR (Tabela 1).

Tabela 1: Análise de variância de modelo autoregressivo (ANOVA-AR)

FV	GL	SQ	QM	F
ρ	1	$SQ\rho$	-----	-----
Parâmetros	p	SQR_{adj}	$QMR_{adj} = SQR_{adj} / p$	QMR_{adj} / QME_{adj}
Resíduo	$n - p - 2$	SQE_{adj}	QME_{adj}	
Total	$n - 1$	SQT		

O valor da Soma Quadrada da fonte de variação ρ ($SQ\rho$) é obtido através da diferença entre a Soma de Quadrado Total (SQT) da Análise de Variância dos dados não ajustados e a Soma de Quadrado Total Ajustada (SQT_{adj}) da Análise de Variância com dados ajustados pela equação (0.4), isto é:

$$SQ\rho = SQT - SQT_{adj}$$

O Quadrado Médio do Erro também deve ser ajustado por:

$$QME_{adj} = \frac{SQE_{adj}}{(n - p - 2)}$$

em que:

n é o número de observações;

p é o número de parâmetros.

Todas as análises estatísticas foram feitas utilizando o software R.

Para a construção das matrizes W , C e D , utilizou-se uma vizinhança adjacente de distancia

1.

RESULTADOS E DISCUSSÃO




Figura 1: Vizinhança adjacente entre as amostras

Pode-se observar na Figura 1, que a vizinhança em diagonal não foi considerada devido a distância estipulada.

A matriz W de dimensões 102×102 será expressa de forma resumida.

$$W = \begin{pmatrix} 0 & 1/2 & 0 & \dots & 0 \\ 1/3 & 0 & 1/3 & & 0 \\ \vdots & & & & \\ & & & 0 & 1/3 \\ & & & 1/2 & 0 \end{pmatrix}_{102 \times 102}$$

XIX CONGRESSO DE PÓS-GRADUAÇÃO DA UFLA
27 de setembro a 01 de outubro de 2010

Após obter os autovalores da matriz W calculou-se o valor do coeficiente de autocorrelação ρ , tendo sido obtido o valor de 0,17545.

Com este valor foi possível transformar os dados correlacionados em dados não correlacionados através da equação (0.4)

Tabela 2: Análise de variância clássica (ANOVA)

	<i>GL</i>	<i>SQ</i>	<i>QM</i>	<i>F-value</i>	<i>p-value</i>
bloco	2	312510	156255	1,4	0,2552
cultivar	33	15605390	472891	4,2	0,0003
Resíduos	66	7395029	112046		

Tabela 3: Análise de variância com modelo autoregressivo (ANOVA-AR)

	<i>GL</i>	<i>SQ</i>	<i>QM</i>	<i>F-value</i>	<i>p-value</i>
ρ	1	831795			
bloco	2	195808	97904	0,945763	0,393662
cultivar	33	15556620	471413	5	0,000001
Resíduos	65	6728706	103518,6		

CONCLUSÃO

Comparando a ANOVA com a ANOVA-AR pode-se perceber que houve uma pequena redução na variabilidade do experimento expressa através da redução do quadrado médio do erro (QME). A variabilidade que era atribuída ao fator bloco teve uma redução de 37%.

O parâmetro de autocorrelação, ρ , explicou 3,56% da variabilidade do experimento.

REFERENCIAL BIBLIOGRÁFICO

BANZATTO D.A.; KRONKA S.N. **Experimentação agrícola**. Jaboticabal, FUNEP, 1992. 246p.

LONG,D.S. **Spatial statistics for analysis of variance of agronomic field trials**. P 251-278. Practical Handbook of Spatial Statistics, 1996.

XIX CONGRESSO DE PÓS-GRADUAÇÃO DA UFLA
27 de setembro a 01 de outubro de 2010

ORD, J.K.; **Estimation methods for models of spatial interaction.** J. Amer. Statist. Assoc. v.70, 1975, p. 120-126.

R DEVELOPMENT CORE TEAM (2010). **R: A language and environment for statistical computing.** R Foundation for Statistical Computing Vienna, Austria. ISBN 3-900051-07-0, URL <http://www.R-project.org>.

SMIRNOV O.; ANSELIN L.; **Fast maximum likelihood estimation of very large spatial autoregressive models: a characteristic polynomial approach.** Computacional Statistics & Data Analysis, v. 35, 2001, p. 301-319.