

**RAFAEL SILVA RAMOS DOS ANJOS**

**ANÁLISE ESTATÍSTICA ESPACIAL DE EXPERIMENTOS DE HÍBRIDOS DE  
MILHO EM CONDIÇÕES CONTRASTANTES DE FÓSFORO NO SOLO**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Genética e Melhoramento, para obtenção do título de *Doctor Scientiae*.

Orientador: Pedro Crescêncio Souza Carneiro

Coorientadores: Lauro José Moreira Guimarães

Maria Marta Pastina

Rodrigo Oliveira de Lima

**VIÇOSA - MINAS GERAIS**

**2019**

**Ficha catalográfica preparada pela Biblioteca Central da Universidade  
Federal de Viçosa - Câmpus Viçosa**

T

A599a Anjos, Rafael Silva Ramos dos, 1989-  
2019 Análise estatística espacial de experimentos de híbridos de  
milho em condições contrastantes de fósforo no solo / Rafael  
Silva Ramos dos Anjos. – Viçosa, MG, 2019.  
131 f. : il. (algumas color.) ; 29 cm.

Orientador: Pedro Crescêncio Souza Carneiro.  
Tese (doutorado) - Universidade Federal de Viçosa.  
Inclui bibliografia.

1. Milho - Melhoramento genético. 2. Agricultura -  
Experimentação. 3. Projeto experimental. 4. *Zea mays*.  
I. Universidade Federal de Viçosa. Departamento de Biologia  
Geral. Programa de Pós-Graduação em Genética e  
Melhoramento. II. Título.

CDD 22. ed. 633.152

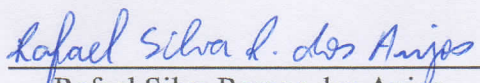
**RAFAEL SILVA RAMOS DOS ANJOS**

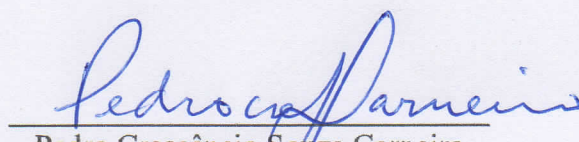
**ANÁLISE ESTATÍSTICA ESPACIAL DE EXPERIMENTOS DE HÍBRIDOS DE  
MILHO EM CONDIÇÕES CONTRASTANTES DE FÓSFORO NO SOLO**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Genética e Melhoramento, para obtenção do título de *Doctor Scientiae*.

APROVADA: 22 de novembro de 2019.

Assentimento:

  
Rafael Silva Ramos dos Anjos  
Autor

  
Pedro Crescêncio Souza Carneiro  
Orientador

## AGRADECIMENTOS

A Deus, pelo dom da vida.

À minha família, minha mãe Marília Aparecida Silva, minha avó Catarina Silvério da Silva, meu avô Joaquim Silvério da Silva (*in memoriam*), meu irmão Daniel Ramos dos Anjos Júnior, minha tia Maria Aparecida Silva e meu tio Sebastião Marques da Silva, pelo incentivo e apoio.

À minha noiva, Dardânia Soares Cristeli, pelo companheirismo e apoio.

Ao meu orientador, professor Pedro Crescêncio Souza Carneiro, pela orientação, apoio, confiança e amizade.

Aos meus coorientadores, pesquisador Lauro José Moreira Guimarães, pesquisadora Maria Marta Pastina e professor Rodrigo Oliveira de Lima, pela orientação, apoio e confiança.

Aos pesquisadores Paulo Evaristo de Oliveira Guimarães e Roberto dos Santos Trindade, por compartilhar conhecimentos e experiências.

Aos colaboradores da Embrapa Milho e Sorgo, Fábio Rabello Soares, Eduardo Elias de Faria, Daniel Sousa Aguiar, Malcon José Silva, Antônio Pereira Costa, Antônio dos Reis Fonseca, Elísio Evangelista e Celso Gonçalves Lourenço, por compartilhar experiências nas atividades desenvolvidas no Núcleo de Melhoramento de Milho.

Ao meu amigo Tiago de Souza Marçal, pelas discussões sobre análise estatística espacial e por compartilhar conhecimentos.

À Universidade Federal de Viçosa e ao Programa de Pós-Graduação em Genética e Melhoramento, pela oportunidade de realizar o curso de doutorado.

Aos secretários do Programa de Pós-Graduação em Genética e Melhoramento, Marco Tulio Cardoso e Odilon Soares Junior, pela atenção e disponibilidade de ajuda.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq),  
pela concessão da bolsa de estudo.

À Empresa Brasileira de Pesquisa Agropecuária – Embrapa Milho e Sorgo, pela  
oportunidade para o desenvolvimento do projeto de doutorado.

Ao Laboratório de Biometria da Universidade Federal de Viçosa, pela acolhida.

Aos membros da banca, o pesquisador Roberto dos Santos Trindade e os  
professores Pedro Crescêncio Souza Carneiro, Renato Ribeiro de Lima, Rodrigo Oliveira  
de Lima e Moyses Nascimento, pela disponibilidade e sugestões para o enriquecimento  
deste trabalho.

O presente trabalho foi realizado com apoio da Coordenação de  
Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de  
Financiamento 001.

A todos que contribuíram para realização deste trabalho.

**Muito obrigado!**

## RESUMO

ANJOS, Rafael Silva Ramos dos, D.Sc., Universidade Federal de Viçosa, novembro de 2019. **Análise estatística espacial de experimentos de híbridos de milho em condições contrastantes de fósforo no solo.** Orientador: Pedro Crescêncio Souza Carneiro. Coorientadores: Lauro José Moreira Guimarães, Maria Marta Pastina e Rodrigo Oliveira de Lima.

A heterogeneidade do solo é a principal causa do erro experimental em avaliações de genótipos em condições de campo. A variabilidade espacial da fertilidade do solo pode ocorrer em manchas ou gradientes em experimentos instalados em áreas com baixos teores de fósforo (P) no solo, causando tendências espaciais e comprometendo a independência entre resíduos. Mesmo em condições de alta adubação, onde espera-se maior homogeneidade na fertilidade do solo dentro da área experimental, fatores como a desuniformidade de distribuição de água na irrigação, competição intergenotípica entre parcelas e ocorrência de falhas no estande, também podem levar a um aumento da heterogeneidade ambiental, possibilitando a ocorrência de dependência espacial entre parcelas. Uma medida para atenuar o problema de dependência espacial é o uso da análise espacial pela flexibilização da matriz de covariância residual ( $R$ ). Assim, o objetivo deste estudo foi avaliar a eficiência de modelos estatísticos espaciais na análise de experimentos com híbridos de milho conduzidos em áreas com baixo teor de P no solo e em áreas sob alta adubação. Neste estudo foram considerados ensaios de valor de cultivo e uso (VCU) de híbridos de milho desenvolvidos pela Embrapa Milho e Sorgo, avaliados em condições de baixo P e alta adubação em três safras (2015/16, 2016/17 e 2017/18). Os ensaios foram conduzidos no campo experimental da Embrapa Milho e Sorgo, localizado no município de Sete Lagoas – MG. Cada ensaio de VCU foi constituído por 36 híbridos, sendo 32 híbridos experimentais em fase de pré-lançamento e quatro híbridos comerciais utilizados como testemunhas. Na análise dos experimentos de VCU, foram ajustados 16 modelos estatísticos diferentes. Dentre esses, os modelos tradicionais consideraram resíduos independentes (matriz  $R$  diagonal) e os modelos espaciais consideraram a modelagem da matriz  $R$  pelo processo autorregressivo de primeira ordem em duas dimensões ( $AR1 \times AR1$ ). Além disso, os modelos diferiram quanto ao delineamento experimental (blocos completos casualizados ou látice); quanto à inclusão de efeitos de tendência global de linhas e colunas; e quanto à inclusão da covariável estande. Nas condições de baixo P, os modelos estatísticos selecionados foram: (a) safras 2015/16 e 2016/17: modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ , sem o termo do erro independente ( $\eta$ ) e com inclusão do estande como

covariável; (b) safra 2017/18: modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ , sem o termo do erro independente ( $\eta$ ) e com inclusão do estande como covariável. Nas condições de alta adubação, os modelos selecionados foram: (a) safra 2015/16: modelo de blocos casualizados, com inclusão de estande como covariável e resíduos ( $e$ ) independentes; (b) safra 2016/17: modelo de blocos casualizados, com resíduos ( $e$ ) independentes; (c) safra 2017/18: modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ). De modo geral, o uso de um modelo estatístico espacial ( $AR1 \times AR1$ ), com delineamento em látice e estande como covariável, contribuiu para aumentar a acurácia seletiva em ensaios de híbridos de milho avaliados em condições de baixo P. Mesmo em condições de alta adubação, o uso de um modelo estatístico espacial ( $AR1 \times AR1$ ) também contribuiu para aumentar a acurácia seletiva, como ocorreu na safra 2017/18. Assim, conclui-se que a análise estatística espacial é eficiente na análise de ensaios de VCU de híbridos de milho conduzidos em condições de baixo P; e que modelos estatísticos espaciais devem ser testados em experimentos na condição de alta adubação.

**Palavras-chave:** Tendência espacial. Erros correlacionados. Delineamentos experimentais. Melhoramento de plantas. *Zea mays* L.

## ABSTRACT

ANJOS, Rafael Silva Ramos dos, D.Sc., Universidade Federal de Viçosa, November, 2019. **Spatial analysis of maize hybrid experiments under contrasting soil phosphorus conditions**. Adviser: Pedro Crescêncio Souza Carneiro. Co-advisers: Lauro José Moreira Guimarães, Maria Marta Pastina and Rodrigo Oliveira de Lima.

Soil heterogeneity is the main cause of experimental error in genotype evaluations under field conditions. The spatial variability of soil fertility can occur in patches or gradients in experiments installed in areas with low phosphorus (P), causing spatial trends and impairing independence among errors. Even under conditions of high fertilization, where greater homogeneity in soil fertility is expected within experimental area, factors such as uneven water distribution in irrigation, intergenotypic competition between plots and stand failures can also increase environmental heterogeneity. These factors may cause spatial dependence between plots. One procedure used to mitigate the spatial dependence problem is to use spatial analysis by modeling the residual covariance matrix ( $R$ ). Thus, this study aimed to evaluate the efficiency of spatial statistical models in the analysis of experiments with maize hybrids (*Zea mays* L.) installed in areas with low P and in areas with high fertilization. In this study were used experiments of Value for Cultivation and Use (VCU) of maize hybrids developed by *Embrapa Milho e Sorgo*, evaluated under conditions of low P and high fertilization in three seasons (2015/16, 2016/17 e 2017/18). The experiments were conducted in the experimental field of *Embrapa Milho e Sorgo*, situated in Sete Lagoas – MG. Each VCU experiment consisted of 36 hybrids, 32 experimental hybrids in the pre-launch phase and four commercial hybrids used as controls. Sixteen statistical models were adjusted for VCU experiments analysis. Traditional models considered independent errors (diagonal  $R$  matrix); and the spatial models considered the modeling of  $R$  matrix by the two-dimensional first-order autoregressive process ( $AR1 \times AR1$ ). In addition, the models differed in experimental design (randomized complete blocks or partially balanced lattice); in the inclusion of global trend effects of rows and columns; and in the inclusion of stand as covariate. Under low P conditions, the following models were selected: (a) 2015/16 and 2016/17 seasons: model with partially balanced lattice design, with errors ( $\xi$ ) modeled by process  $AR1 \times AR1$ , without independent error term ( $\eta$ ), and with inclusion of stand as covariate; (b) 2017/18 season: model with randomized complete block design, with errors ( $\xi$ ) modeled by process  $AR1 \times AR1$ , without independent error term ( $\eta$ ), and with inclusion of stand as covariate. Under high fertilization conditions, the following models were

selected: (a) 2015/16 season: model with randomized complete block design, with inclusion of stand as covariate, and with independent errors ( $e$ ); (b) 2016/17 season: model with randomized complete block design, and with independent errors ( $e$ ); (c) 2017/18 season: model with randomized complete block design, with errors ( $\xi$ ) modeled by process  $AR1 \times AR1$ , and with independent error term ( $\eta$ ). In general, the use of a spatial model ( $AR1 \times AR1$ ) with lattice design and stand as covariate, contributed to increase the selective accuracy in experiments of maize hybrids evaluated under low P. Even under conditions of high fertilization, the use of a spatial models ( $AR1 \times AR1$ ) also contributed to increase the selective accuracy, as occurred in the 2017/18 season. The conclusions of this study were that the spatial analysis was efficient in the analysis of VCU experiments of maize hybrids conducted under low P conditions; and that the spatial models should be tested for experiments under condition of high fertilization.

**Keywords:** Spatial trend. Correlated errors. Experimental designs. Plant breeding. *Zea mays* L.

## SUMÁRIO

|  |    |
|--|----|
| <b>INTRODUÇÃO GERAL</b> .....  | 11 |
| <b>REFERÊNCIAS</b> .....   | 15 |
| <b>CAPÍTULO I: ANÁLISE ESTATÍSTICA ESPACIAL DE EXPERIMENTOS DE HÍBRIDOS DE MILHO EM CONDIÇÕES DE BAIXO TEOR DE FÓSFORO NO SOLO</b><br>.....              | 17 |
| <b>1. Resumo</b> .....   | 18 |
| <b>2. Introdução</b> .....   | 19 |
| <b>3. Material e métodos</b> .....   | 22 |
| <b>3.1. Material genético e ensaios</b> .....  | 22 |
| <b>3.2. Modelos lineares mistos espaciais</b> .....  | 23 |
| <b>Tabela 1</b> .....  | 27 |
| <b>4. Resultados</b> .....   | 30 |
| <b>4.1. Efeito de genótipos sobre a variável estande (safras 2015/16, 2016/17 e 2017/18)</b> .   | 30 |
| <b>Tabela 2</b> .....  | 31 |
| <b>4.2. Seleção de modelos para análise da característica produtividade de grãos</b> .....   | 32 |
| <b>4.2.1. Produtividade de grãos – safra 2015/16</b> .....   | 32 |
| <b>Tabela 3</b> .....  | 33 |
| <b>Tabela 4</b> .....  | 35 |
| <b>Tabela 5</b> .....  | 37 |
| <b>4.2.2. Produtividade de grãos – safra 2016/17</b> .....   | 38 |
| <b>Tabela 6</b> .....  | 39 |
| <b>Tabela 7</b> .....  | 41 |
| <b>4.2.3. Produtividade de grãos – safra 2017/18</b> .....   | 42 |
| <b>Tabela 8</b> .....  | 43 |
| <b>Tabela 9</b> .....  | 44 |
| <b>Tabela 10</b> .....   | 47 |
| <b>Tabela 11</b> .....   | 48 |
| <b>4.3. Produtividade de grãos – Importância dos delineamentos e de diferentes efeitos na análise espacial (safras 2015/16, 2016/17 e 2017/18)</b> ..... | 49 |
| <b>5. Discussão</b> .....  | 53 |
| <b>Quadro 1</b> .....  | 58 |
| <b>6. Conclusão</b> .....  | 62 |
| <b>7. Referências</b> .....  | 63 |
| <b>8. Material Suplementar</b> .....   | 67 |

|  |     |
|--|-----|
| <b>CAPÍTULO II: ANÁLISE ESTATÍSTICA ESPACIAL DE EXPERIMENTOS DE HÍBRIDOS DE MILHO EM CONDIÇÕES DE ALTA ADUBAÇÃO</b> .....                                  | 73  |
| <b>1. Resumo</b> .....   | 74  |
| <b>2. Introdução</b> .....   | 75  |
| <b>3. Material e métodos</b> .....   | 77  |
| <b>3.1. Material genético e ensaios</b> .....  | 77  |
| <b>3.2. Modelos lineares mistos espaciais</b> .....  | 79  |
| <b>Tabela 1</b> .....  | 82  |
| <b>4. Resultados</b> .....   | 85  |
| <b>4.1. Efeito de genótipos sobre a variável estande (safras 2015/16, 2016/17 e 2017/18)</b> .   | 85  |
| <b>Tabela 12</b> .....   | 86  |
| <b>4.2. Seleção de modelos para análise da característica produtividade de grãos</b> .....   | 87  |
| <b>4.2.1. Produtividade de grãos – safra 2015/16</b> .....   | 87  |
| <b>Tabela 13</b> .....   | 88  |
| <b>Tabela 14</b> .....   | 90  |
| <b>Tabela 15</b> .....   | 92  |
| <b>4.2.2. Produtividade de grãos – safra 2016/17</b> .....   | 93  |
| <b>Tabela 16</b> .....   | 94  |
| <b>Tabela 17</b> .....   | 95  |
| <b>Tabela 18</b> .....   | 96  |
| <b>4.2.3. Produtividade de grãos – safra 2017/18</b> .....   | 97  |
| <b>Tabela 19</b> .....   | 98  |
| <b>Tabela 20</b> .....   | 100 |
| <b>Tabela 21</b> .....   | 101 |
| <b>4.3. Produtividade de grãos – Importância dos delineamentos e de diferentes efeitos nos modelos ajustados (safras 2015/16, 2016/17 e 2017/18)</b> ..... | 102 |
| <b>Quadro 2</b> .....  | 106 |
| <b>Tabela 22</b> .....   | 108 |
| <b>Tabela 23</b> .....   | 110 |
| <b>5. Discussão</b> .....  | 110 |
| <b>6. Conclusão</b> .....  | 118 |
| <b>7. Referências</b> .....  | 119 |
| <b>8. Material Suplementar</b> .....   | 122 |
| <b>CONSIDERAÇÕES GERAIS</b> .....  | 129 |

## INTRODUÇÃO GERAL

O milho (*Zea mays* L.) é uma das principais espécies agrícolas produzidas mundialmente, de modo que a grande variedade de raças e cultivares da espécie apresentam diferentes características que permitem o cultivo do milho nas mais variadas condições climáticas e épocas de cultivo (MÔRO & FRITSCHÉ-NETO, 2015). Segundo Bender et al. (2013), os avanços contínuos em melhoramento de plantas, biotecnologia e manejo cultural têm resultado em aumentos significativos nas médias de produtividade de grãos na cultura do milho.

No Brasil, entre as culturas graníferas, o milho foi responsável pela segunda maior produção de grãos na safra 2018/19, correspondendo a 100.046.300 toneladas (BRASIL, 2019). Nessa safra, a área cultivada com a cultura do milho foi de 17.496.200 hectares, de modo que a produtividade média da cultura no país foi de 5.718 kg ha<sup>-1</sup> (BRASIL, 2019). Apesar dos elevados patamares de produção recentemente alcançados, a produtividade média de milho no Brasil encontra-se aquém do potencial dos materiais genéticos disponíveis. Segundo Vergütz & Novais (2015), as tabelas tradicionalmente usadas para recomendações de fertilizantes no Brasil (RIBEIRO et al., 1999; RAIJ et al., 1997; SOUZA & LOBATO, 2004; TEDESCO et al., 2004) foram desenvolvidas para materiais genéticos menos produtivos do que os cultivares atuais, de modo que estas tabelas recomendam quantidades de fertilizantes menores do que as necessárias para alcançar o máximo de produtividade nos cultivares modernos de milho. Segundo Bender et al. (2013), as doses de nutrientes recomendadas nas atuais adubações são menores que o total de nutrientes exportados pela cultura, resultando em significativo decréscimo nos níveis de nutrientes nos solos ao longo dos anos.

No contexto de fertilidade do solo, verifica-se que um dos fatores mais limitantes à produtividade agrícola em solos tropicais é a baixa disponibilidade de fósforo (P) no solo (BALIGAR et al., 1997). Comparado com outros macronutrientes, a concentração

de P inorgânico ( $P_i$ ) na solução do solo está abaixo da concentração ótima para a produção de grãos, fazendo do P um dos macronutrientes menos disponíveis no solo (VANCE et al., 2003). Além disso, o P é um dos nutrientes com difusão mais lenta, criando uma zona de deficiência na rizosfera. O problema ainda é agravado pelo fato de que o  $P_i$  pode se fixar ao cálcio (Ca) em solos calcários e ao ferro (Fe) e alumínio (Al) em solos ácidos, reduzindo sua solubilidade e disponibilidade para as plantas (MARSCHNER, 1995). Nesse sentido, nos diversos sistemas de produção agrícola, principalmente nos solos tropicais, são necessárias aplicações de grandes quantidades de P no solo para garantir a produtividade, uma vez que a eficiência de absorção do fosfato adicionado pode ser inferior a 20% (ZHU et al., 2003). Outro grande problema relacionado ao P é que ele constitui um recurso natural não renovável e seu uso indiscriminado pode levar ao esgotamento das jazidas (VANCE & CHIOU, 2011). Assim, verifica-se que a adoção de cultivares que utilizam melhor o P disponível pode proporcionar maior eficiência agrícola, de modo que a seleção de híbridos de milho mais eficientes no uso de P são de grande relevância para maior sustentabilidade da agricultura no Brasil.

A forma mais confiável para a seleção de genótipos eficientes no uso de P, é a avaliação de genótipos no campo utilizando áreas contrastantes quanto a disponibilidade de P e conduzindo os experimentos até a fase de produção (PARENTONI et al., 2011). Nos experimentos de campo instalados em áreas que naturalmente apresentam baixos teores de P no solo, a variabilidade espacial da fertilidade do solo é preocupante e pode ocorrer em escala métrica (VIANA et al., 2009). Além disso, a variabilidade espacial da fertilidade do solo pode ocorrer em manchas ou gradientes, comprometendo a independência entre resíduos e fazendo com que resíduos de parcelas vizinhas sejam correlacionados. De acordo com Ramalho et al. (2012a,), a heterogeneidade do solo é a principal causa do erro experimental em avaliações de genótipos em condições de campo.

Na avaliação de genótipos em condições de altas adubações, com níveis adequados dos nutrientes, espera-se maior homogeneidade na fertilidade do solo dentro da área experimental. Segundo Ramalho et al. (2012a), o uso de adubações mais pesadas na implantação dos experimentos possibilita que pequenas diferenças de fertilidade que existam sejam encobertas pela adubação usada. No entanto, a uniformidade na fertilidade do solo não é garantia de homogeneidade ambiental nesses tipos de experimentos. Outros fatores, como a desuniformidade de distribuição de água na irrigação (RAMALHO et al., 2012b), a competição intergenotípica entre parcelas e a ocorrência de falhas no estande de parcelas (RAMALHO et al., 2012a), também contribuem para aumento da heterogeneidade ambiental e, conseqüentemente, aumento do erro experimental.

Uma medida para atenuar o problema da heterogeneidade ambiental dentro das áreas experimentais é o uso do princípio básico do controle local na experimentação (RAMALHO et al., 2012a), de modo que nos delineamentos experimentais busca-se estabelecer áreas mais homogêneas possíveis dentro de blocos. No entanto, as estratégias de controle local baseadas em blocagem podem ser ineficientes para tratar a presença de manchas ou gradientes ambientais dentro dos experimentos (RESENDE, 2002). As análises tradicionais de experimentos de campo consideram que todas as observações tomadas em posições adjacentes são não correlacionadas, de modo que a matriz de covariância residual é modelada como uma matriz diagonal (RESENDE & STURION, 2003). Porém, a dependência espacial pode existir e contribuir para o aumento da variação residual (RESENDE et al., 2018). Nessa situação, técnicas de análise espacial, através da flexibilização da matriz de covariância residual, permitem contornar a questão e podem propiciar uma seleção mais acurada (RESENDE et al., 2014).

Dentre os vários métodos para modelagem da matriz de covariância residual, o modelo de séries temporais autorregressivo separável de primeira ordem em duas dimensões (AR1 × AR1) tem se destacado (GRONDONA et al., 1996, GILMOUR et al.,

1997; RESENDE & STURION, 2003; RESENDE et al., 2018). O modelo AR1 × AR1 considera um erro correlacionado ( $\xi$ ) mais um erro aleatório independente ( $\eta$ ), de modo que o vetor de resíduos ( $e$ ) é particionado em:  $e = \xi + \eta$  (CULLIS & GLEESON, 1991; GILMOUR et al., 1997). De modo geral, o método de máxima verossimilhança restrita (REML) é usado para estimar os parâmetros do modelo AR1 × AR1 (RESENDE et al., 2018).

Assim, o objetivo deste estudo foi avaliar a eficiência de modelos estatísticos espaciais na análise da produtividade de grãos de experimentos de híbridos de milho conduzidos tanto em áreas com baixo teor de P no solo como em áreas sob altas adubações.

## REFERÊNCIAS

- BALIGAR, V.C.; FAGERIA, N.K. Nutrient use efficiency in acid soils: nutrient management and plant use efficiency. In: MONIZ, A.C.; FURLANI, A.M.C.; FAGERIA, N. K.; ROSOLEM, C.A.; CANTARELLS, H. (eds.) **Plant-soil interactions at low pH: sustainable agriculture and forestry production**. Campinas: Sociedade Brasileira de Ciência do Solo, 75-95, 1997.
- BENDER, R.R.; HAEGELE, J.W.; RUFFO, M.L.; BELOW, F.E. Nutrient uptake, partitioning, and remobilization in modern, transgenic insect-protected maize hybrids. **Agronomy Journal**, v. 105, n. 1, p. 161-170, 2013.
- BRASIL. COMPANHIA NACIONAL DE ABASTECIMENTO – CONAB. Brasília, 2019. **Grãos – Por Produtos**. Disponível em: <<https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras?limitstart=0>>. Acesso em: 29 out. 2019.
- CULLIS, B. R.; GLEESON, A. C. Spatial analysis of field experiments-an extension to two dimensions. **Biometrics**, p. 1449-1460, 1991.
- GILMOUR, A.R.; CULLIS, B.R.; VERBYLA, A.P. Accounting for natural and extraneous variation in the analysis of field experiments. **J Agric Biol Environ Stat**, v. 2, n. 3, p. 269-293, 1997.
- GRONDONA, M.O.; CROSSA, J.; FOX, P.N.; PFEIFFER, W.H. Analysis of variety yield trials using two-dimensional separable ARIMA processes. **Biometrics**, p. 763-770, 1996.
- MARSCHNER, H. **Mineral nutritional of higher plants**. 2nd. edn. Academic Press, Boston. 1995.
- MÔRO, G.V.; FRITSCHÉ-NETO, R. Importância e usos do milho no Brasil. In: BORÉM, A.; GALVÃO, J.C.C.; PIMENTEL, M.A. (eds.). **Milho: do plantio à colheita**. Ed. UFV, Viçosa, MG, 351 p., 2015.
- PARENTONI, S.N.; MENDES, F.F.; GUIMARÃES, L.J.M. Melhoramento para eficiência no uso de fósforo. In: FRITSCHÉ-NETO, R.; BORÉM, A. (eds). **Melhoramento de plantas para condições de estresses abióticos**. Editora Suprema, Visconde do Rio Branco, MG, 250p., 2011.
- RAIJ, B.V.; CANTARELLA, H.; QUAGGIO, J.A.; FURLANI, A.M.C. **Recomendações de adubação e calagem para o Estado de São Paulo**. 2 ed. Campinas: Instituto Agrônomo/Fundação IAC, 285 p., 1997.
- RAMALHO, M.A.P.; FERREIRA, D.F.; OLIVEIRA, A.C. **Experimentação em Genética e Melhoramento de Plantas**. 3. ed. Lavras, MG: Ed. UFLA, 2012a. 328p.
- RAMALHO, M.A.P.; ABREU, A.F.B.; SANTOS, J.B.; NUNES, J.A.R. **Aplicações da Genética Quantitativa no Melhoramento de Plantas Autógamas**. 1. ed. Lavras: Ed. UFLA, 2012b. 522 p.

RESENDE, M.D.V.; STURION, J.A. Análise estatística espacial de experimentos via modelos mistos individuais com erros modelados por processos ARIMA em duas dimensões. **Rev. Mat. Estat.**, v. 21, n. 1, p. 7-33, 2003.

RESENDE, M.D.V.; SILVA, F.F.; AZEVEDO, C.F. **Estatística matemática, biométrica e computacional**: modelos mistos, multivariados, categóricos e generalizados (REML/BLUP), inferência Bayesiana, regressão aleatória, seleção genômica, QTL-GWAS, estatística espacial e temporal, competição, sobrevivência. Viçosa, MG: Suprema, 2014. 881p.

RESENDE, M.D.V.; VIANA, J.M.S.; AZEVEDO, C.F.; SILVA, F.F.; DELIMA, R.O. Modelos Mistos e Inferência Bayesiana. In: DELIMA, R.O.; BORÉM, A. (eds). **Melhoramento de milho**. Ed. UFV, Viçosa, MG, 396 p., 2018.

RESENDE, M.D.V; **Genética biométrica e estatística no melhoramento de plantas perenes**. 1. ed. Embrapa Informação Tecnológica, 2002. 975 p.

RIBEIRO, A.C.; GUIMARÃES, P.T.G.; ALVAREZ V., V.H. **Recomendação para uso de corretivos e fertilizantes em Minas Gerais – 5ª aproximação**. Viçosa, MG: Comissão de Fertilidade do Solo do Estado de Minas Gerais – CFSEMG, 359 p., 1999.

SOUSA, D.M.G.; LOBATO, E. **Cerrado: correção do solo e adubação**. 2 ed. Planaltina, DF: Embrapa Cerrados, 416 p., 2004.

TEDESCO, M.J.; GIANELLO, C.; ANGHINONI, I.; BISSANI, C.A.; CAMARGO, F.A.O.; WIETHÖLTER, S. **Manual de adubação e calagem para os Estados do Rio Grande do Sul e de Santa Catarina**. 10 ed. Porto Alegre, RS: Comissão de Química e Fertilidade do Solo/Sociedade Brasileira de Ciência do Solo, 400 p., 2004.

VANCE, C.P.; UHDE-STONE, C.; ALLAN, D. Phosphorus acquisition and use: critical adaptations by plants for securing a nonrenewable resource. **New Phytologist**, v. 157, n. 3, p. 423-447, 2003.

VANCE, C.P., CHIOU, T.J. Phosphorus focus editorial. **Plant Physiology**, v. 156, p. 987-988, 2011.

VERGÜTZ, L.; NOVAIS, R.F. Recomendação corretivos e adubação. In: BORÉM, A.; GALVÃO, J.C.C.; PIMENTEL, M.A. (eds). **Milho: do plantio à colheita**. Ed. UFV, Viçosa, MG, 351 p., 2015.

VIANA, J.H.M.; RESENDE, A.V.; GUIMARÃES, C.T.; PARENTONI, S.N. Avaliação da variabilidade espacial do solo em experimentos de eficiência nutricional em milho, conduzidos em área com baixos teores de nutrientes: um estudo de caso. **Embrapa Milho e Sorgo-Boletim de Pesquisa e Desenvolvimento (INFOTECA-E)**. Sete Lagoas: Embrapa Milho e Sorgo, 2009.

ZHU, Y.G.; SMITH, A.F.; SMITH, S.E. Phosphorous efficiency and responses of barley (*Hordeum vulgare* L.) to arbuscular mycorrhizal fungi grown in highly calcareous soil. **Mycorrhiza**, v. 13, n. 2, p. 93-100, 2003.

## **CAPÍTULO I**

### **ANÁLISE ESTATÍSTICA ESPACIAL DE EXPERIMENTOS DE HÍBRIDOS DE MILHO EM CONDIÇÕES DE BAIXO TEOR DE FÓSFORO NO SOLO**

## 1. Resumo

Na avaliação de híbridos de milho (*Zea mays* L.) quanto à eficiência no uso de fósforo (P), os experimentos de campo são instalados em áreas que naturalmente apresentam baixos teores desse nutriente no solo. Nessa situação, variações naturais nos teores de P no solo podem ocorrer em manchas ou gradientes, causando tendências espaciais e contribuindo para aumento na variância residual. Uma medida para atenuar o problema da heterogeneidade do solo é o uso da análise espacial pela flexibilização da matriz de covariância residual ( $R$ ), usando-se o modelo autorregressivo separável de primeira ordem em duas dimensões ( $AR1 \times AR1$ ). Assim, o objetivo com este estudo foi avaliar a eficiência de modelos estatísticos espaciais na análise da produtividade de grãos de experimentos de híbridos de milho conduzidos em áreas com baixo teor de P no solo. Neste estudo foram considerados três ensaios de valor de cultivo e uso (VCU) de híbridos de milho (safras 2015/16, 2016/17 e 2017/18) avaliados em áreas com baixa disponibilidade de P. Na análise dos ensaios de VCU foram ajustados 16 modelos estatísticos diferentes. Dentre esses, os modelos tradicionais consideraram resíduos independentes (matriz  $R$  diagonal) e os modelos espaciais consideraram a modelagem da matriz  $R$  pelo processo  $AR1 \times AR1$ . Além disso, os modelos diferiram quanto ao delineamento experimental (blocos completos casualizados ou látice); quanto à inclusão de efeitos de tendência global de linhas e colunas; e quanto à inclusão da covariável estande. Os modelos estatísticos selecionados foram: (a) safras 2015/16 e 2016/17: modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ , sem o termo do erro independente ( $\eta$ ) e com inclusão do estande como covariável; (b) safra 2017/18: modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ , sem o termo do erro independente ( $\eta$ ) e com inclusão do estande como covariável. De modo geral, observou-se que a modelagem da matriz  $R$  pelo processo  $AR1 \times AR1$  e o uso do delineamento de látice contribuíram para melhorar os ajustes dos modelos. Além disso, a inclusão da covariável estande nos modelos contribuiu para maiores estimativas de herdabilidade e acurácia de seleção. Assim, conclui-se que a análise estatística espacial é eficiente na análise dos ensaios de VCU de híbridos de milho conduzidos em condições de baixo P.

**Palavras-chave:** *Zea mays* L. Tendência espacial. Erros correlacionados. Delineamentos experimentais. Melhoramento de plantas.

## 2. Introdução

O fósforo (P) é um dos dezessete elementos considerados essenciais para o crescimento e desenvolvimento das plantas (DECHEN & NACHTIGALL, 2007), participando de processos metabólicos como a transferência de energia, síntese de ácidos nucléicos, síntese e estabilidade de membranas, ativação e inativação enzimática, reações redox, sinalização, metabolismo de carboidratos e fixação de nitrogênio (CAVATTE et al., 2011). No entanto, a retenção do P no solo em formas não-lábeis, principalmente pela sua adsorção específica por oxidróxidos de ferro e alumínio (NOVAIS et al., 2007), a ocorrência do P em formas orgânicas e sua lenta taxa de difusão na solução do solo tornam o P o nutriente menos prontamente disponível na rizosfera (ARAÚJO & MACHADO, 2006).

Segundo Vergütz & Novais (2015), a cultura do milho é extremamente exigente quanto aos teores mínimos de P no solo, de modo que baixos teores desse nutriente no solo levam a produtividades limitadas. Os autores recomendam adubações com doses mais altas de nutrientes, incluindo o P, para melhor explorar todo o potencial de produtividade dos híbridos modernos de milho. No entanto, antes da adoção de elevadas adubações, deve-se considerar que os fertilizantes são de custo elevado e a produção de fertilizantes fosfatados depende de recursos minerais não renováveis (PARENTONI et al., 2011). No Brasil há insuficiência de P, sendo que as reservas nacionais são estimadas em 260 milhões de toneladas, correspondendo a 1,7% das reservas mundiais (BORÉM & RAMALHO, 2011). Além disso, em solos com elevado grau de intemperismo, como os latossolos de cerrado, o solo é um forte dreno de P e passa a competir com as plantas pelo nutriente (NOVAIS et al., 2007).

Segundo Parentoni et al. (2011), a seleção de genótipos eficientes no uso de P pode ser realizada avaliando plantas em fase vegetativa, usando experimentos com solução nutritiva ou vasos com restrição na disponibilidade de P. No entanto, os autores

ressaltam que a forma mais confiável para determinar a característica eficiência no uso de P é a avaliação de genótipos no campo, utilizando áreas contrastantes quanto a disponibilidade de P e conduzindo os experimentos até a fase de produção.

Em avaliações de genótipos em condições de campo, a heterogeneidade do solo é a principal causa do erro experimental (RAMALHO et al., 2012a). A variabilidade espacial de atributos do solo é uma característica natural ligada a fatores pedogenéticos e tem sido reportada na escala métrica (VIANA et al., 2009). Segundo Ramalho et al. (2012a), em condições tropicais, a ocorrência de chuvas de grandes intensidades e em curtos períodos torna frequente a erosão, o que intensifica a variação na fertilidade dos solos.

Na avaliação de genótipos de milho quanto à eficiência no uso de P, os experimentos de campo são instalados em áreas que naturalmente apresentam baixos teores de P no solo (PARENTONI & SOUZA JÚNIOR, 2008; MENDES et al., 2014), de modo que a variação na fertilidade dos solos é preocupante nesse tipo de experimento (VIANA et al., 2009). Assim, uma medida para atenuar o problema da heterogeneidade do solo é o uso do princípio básico do controle local na experimentação (RAMALHO et al., 2012a), de modo que os delineamentos experimentais buscam estabelecer áreas mais homogêneas possível dentro dos blocos.

No entanto, as estratégias de controle local baseadas em blocagem podem ser ineficientes para tratar a presença de manchas ou gradientes ambientais dentro dos experimentos (RESENDE, 2002). As análises tradicionais de experimentos de campo consideram que todas as observações tomadas em posições adjacentes são não correlacionadas, de modo que a matriz de covariância residual é modelada como uma matriz diagonal (RESENDE & STURION, 2003). Porém, a dependência espacial pode existir e contribuir para o aumento da variação residual (RESENDE et al., 2018). Nessa situação, técnicas de análise espacial, através da flexibilização da matriz de covariância

residual, permitem contornar a questão e podem propiciar uma seleção mais acurada (RESENDE et al., 2014).

Dentre os vários métodos para modelagem da matriz de covariância residual, o modelo de séries temporais autorregressivo separável de primeira ordem em duas dimensões (AR1 × AR1) tem se destacado (GRONDONA et al., 1996, GILMOUR et al., 1997; RESENDE & STURION, 2003; RESENDE et al., 2018). O modelo AR1 × AR1 considera um efeito de tendência ( $\xi$ ) mais o erro aleatório independente ( $\eta$ ), de modo que o vetor de resíduos ( $e$ ) é particionado em:  $e = \xi + \eta$  (CULLIS & GLEESON, 1991; Gilmour et al., 1997). De modo geral, o método de máxima verossimilhança restrita (REML) é usado para estimar os parâmetros do modelo AR1 × AR1 (RESENDE et al., 2018).

Além da heterogeneidade do solo, outro fator que contribui para aumentar o erro experimental na avaliação de produtividade de grãos, principalmente em ensaios com milho, é a desuniformidade de estande nas parcelas experimentais (RAMALHO et al., 2012a). Uma alternativa utilizada para uniformizar o número de plantas por parcela é a semeadura em excesso, seguida de desbastes para o estande desejado quando as plantas estão em estágio inicial de crescimento (CRUZ et al., 2014). No entanto, mesmo adotando esse procedimento, ao longo do desenvolvimento das plantas podem ocorrer fatores aleatórios, como pragas, que contribuem para a ocorrência de falhas nas parcelas (CRUZ et al., 2014). Assim, uma maneira de atenuar o problema de falhas de plantas nas estimativas de produção por parcelas, é considerar o efeito de estande nas análises estatísticas e incluí-lo nos modelos como covariável (RAMALHO et al., 2012a; CRUZ et al., 2014).

Assim, o objetivo com este estudo foi avaliar a eficiência de modelos estatísticos espaciais na análise da produtividade de grãos em experimentos de híbridos de milho

conduzidos em áreas com baixo teor de P no solo, além de avaliar o efeito de estande no ajuste desses modelos.

### **3. Material e métodos**

#### **3.1. Material genético e ensaios**

Neste trabalho foram avaliados híbridos de milho desenvolvidos pelo programa de melhoramento da Embrapa Milho e Sorgo (Centro Nacional de Pesquisa de Milho e Sorgo – CNPMS), na fase de ensaios de valor de cultivo e uso (VCU), considerando três safras consecutivas (2015/16, 2016/17 e 2017/18). Em cada safra, o ensaio de VCU foi constituído por 36 híbridos, sendo 32 híbridos experimentais em fase de pré-lançamento e quatro híbridos comerciais utilizados como testemunhas. Ressalta-se que a cada safra (VCU) novos híbridos experimentais foram incluídos e alguns excluídos ao longo dos VCUs.

Os ensaios foram conduzidos no campo experimental da Embrapa Milho e Sorgo, localizado no município de Sete Lagoas - MG (latitude de 19°26'52" S, longitude de 44°10'01" W e altitude de 720 m) em Latossolos Vermelho distróficos (EMBRAPA, 2006). As disponibilidades médias de P nesses solos (ensaios) foram menores ou iguais a 2,83 mg dm<sup>-3</sup>, sendo classificadas como muito baixas segundo Alvarez V. et al. (1999).

O delineamento experimental utilizado em todos os ensaios foi o látice quadrado quádruplo parcialmente balanceado (RAMALHO et al., 2012a). Cada ensaio de VCU foi instalado com  $v = k^2 = 36$  tratamentos, sendo  $v$  o número de tratamentos e  $k$  o número de parcelas por bloco. Como  $k = 6$  não é um número primo ou potência de número primo, não é possível obter um arranjo com quatro repetições ortogonais (PIMENTEL-GOMES, 2009). Assim, o arranjo das quatro repetições do látice quadrado quádruplo foi obtido duplicando-se o látice quadrado simples (RAMALHO et al., 2012a).

Cada parcela foi constituída por uma linha de 4,2 metros (m) de comprimento, com espaçamento de 0,70 m entre linhas e semeadura de 5 sementes  $m^{-1}$ . As adubações realizadas nos ensaios foram apenas com fontes de nitrogênio e potássio. Em cada ensaio, a adubação na semeadura foi constituída de 40  $kg\ ha^{-1}$  de nitrogênio (N) e 80  $kg\ ha^{-1}$  de potássio ( $K_2O$ ). A adubação de cobertura foi de 129  $kg\ ha^{-1}$  de N. Como não houve adubações com fontes de P ( $P_2O_5$ ) nas áreas experimentais utilizadas, apenas o P natural dos solos estava disponível para as plantas, definindo a condição de baixa disponibilidade desse nutriente.

As características avaliadas nos ensaios de VCU foram produção de grãos em quilogramas por parcela, umidade dos grãos em porcentagem, estande em número de plantas, número de plantas acamadas e/ou quebradas, altura de plantas em centímetros, altura de espigas em centímetros, número de dias da semeadura ao florescimento masculino e número de dias da semeadura ao florescimento feminino. A produção de grãos por parcela foi corrigida para 13% de umidade e convertida para produtividade de grãos em quilogramas por hectare ( $kg\ ha^{-1}$ ). O estande, em número de plantas por parcela, também foi convertido para número de plantas por hectare ( $plantas\ ha^{-1}$ ). Para os objetivos deste estudo foram utilizadas as características produtividade de grãos e estande por hectare.

### 3.2. Modelos lineares mistos espaciais

Segundo Henderson (1984), um modelo linear misto geral é da forma  $y = X\tau + Zu + e$ , com as seguintes distribuições e estruturas de médias e variâncias:  $u \sim N(0, G)$ ;  $e \sim N(0, R)$ ;  $E(y) = X\tau$  e  $Var(y) = V = ZGZ' + R$ , em que:

$y$ : vetor de observações;

$\tau$ : vetor paramétrico dos efeitos fixos, com a matriz de incidência X;

$u$ : vetor paramétrico dos efeitos aleatórios, com matriz de incidência Z;

$e$ : vetor de erros aleatórios;

$G$ : matriz de covariâncias dos efeitos aleatórios;

$R$ : matriz de covariâncias dos erros aleatórios;

$0$ : vetor nulo.

Assim, conhecendo-se  $G$  e  $R$ , a simultânea estimação dos efeitos fixos e predição dos efeitos aleatórios pode ser obtida pelas equações de modelo misto, dadas por:

$$\begin{bmatrix} X'R^{-1}X & X'R^{-1}Z \\ Z'R^{-1}X & Z'R^{-1}Z + G^{-1} \end{bmatrix} \begin{bmatrix} \hat{\tau} \\ \hat{u} \end{bmatrix} = \begin{bmatrix} X'R^{-1}y \\ Z'R^{-1}y \end{bmatrix}$$

Os modelos espaciais, tais como os modelos autorregressivos de primeira ordem em duas dimensões (AR1  $\times$  AR1) ajustados pelo método de análise de séries temporais, consideram um vetor aleatório de erros correlacionados ( $\xi$ ) e um vetor aleatório de erros independentes ( $\eta$ ), de modo que o vetor de erros ( $e$ ) é modelado como:  $e = \xi + \eta$  (CULLIS & GLEESON, 1991; GILMOUR et al., 1997).

Assim, os modelos autorregressivos de primeira ordem em duas dimensões (AR1  $\times$  AR1) são da forma  $y = X\tau + Zu + \xi + \eta$ , sendo a variância dos resíduos dada por  $Var(e) = Var(\xi + \eta) = R = \Sigma = \sigma_{\xi}^2 [\Sigma_c(\rho_c) \otimes \Sigma_r(\rho_r)] + I\sigma_{\eta}^2$ , em que  $\sigma_{\xi}^2$  é a variância devida aos erros correlacionados e  $\sigma_{\eta}^2$  é a variância dos erros não correlacionados (RESENDE et al., 2014). As matrizes  $\Sigma_c(\rho_c)$  e  $\Sigma_r(\rho_r)$  referem-se a matrizes de correlações autorregressivas de primeira ordem com parâmetros de autocorrelação  $\rho_c$  e  $\rho_r$  e ordem igual ao número de colunas (*columns* –  $c$ ) e número de linhas (*rows* –  $r$ ), respectivamente (RESENDE et al., 2018). Assim, considerando as autocorrelações de primeira ordem no sentido de linhas ( $\rho_{rows} = \rho_r$ ) e colunas ( $\rho_{columns} = \rho_c$ ), as matrizes de correlações autorregressivas são da seguinte forma:

$$\sum_c(\rho_c) = \begin{bmatrix} 1 & \rho_c^1 & \rho_c^2 & \rho_c^3 & \rho_c^{c-1} \\ \rho_c^1 & 1 & \rho_c^1 & \rho_c^2 & \rho_c^{c-2} \\ \rho_c^2 & \rho_c^1 & 1 & \rho_c^1 & \dots & \rho_c^{c-3} \\ \rho_c^3 & \rho_c^2 & \rho_c^1 & 1 & \rho_c^{c-4} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \rho_c^{c-1} & \rho_c^{c-2} & \rho_c^{c-3} & \rho_c^{c-4} & \dots & 1 \end{bmatrix}$$

$$\sum_r(\rho_r) = \begin{bmatrix} 1 & \rho_r^1 & \rho_r^2 & \rho_r^3 & \rho_r^{r-1} \\ \rho_r^1 & 1 & \rho_r^1 & \rho_r^2 & \rho_r^{r-2} \\ \rho_r^2 & \rho_r^1 & 1 & \rho_r^1 & \dots & \rho_r^{r-3} \\ \rho_r^3 & \rho_r^2 & \rho_r^1 & 1 & \rho_r^{r-4} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \rho_r^{r-1} & \rho_r^{r-2} & \rho_r^{r-3} & \rho_r^{r-4} & \dots & 1 \end{bmatrix}$$

Neste trabalho foram ajustados 16 modelos estatísticos (Tabela 1) para cada safra. Os oito primeiros modelos foram ajustados tanto para a variável produtividade de grãos como para a variável estande e seguem a seguinte sequência:

- a) Modelo 1: modelo de blocos casualizados;
- b) Modelo 2: modelo de látice parcialmente balanceado;
- c) Modelo 3: modelo de blocos casualizados, considerando no vetor de resíduos ( $e$ ) apenas os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  ( $e = \xi$ );
- d) Modelo 4: modelo de blocos casualizados, considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );
- e) Modelo 5: modelo de blocos casualizados, com efeito de linhas, efeito de colunas e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );

f) Modelo 6: modelo de látice parcialmente balanceado, considerando no vetor de resíduos ( $e$ ) apenas os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  ( $e = \xi$ );

g) Modelo 7: modelo de látice parcialmente balanceado, considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );

h) Modelo 8: modelo de látice parcialmente balanceado, com efeito de linhas, efeito de colunas e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ ).

Os próximos oito modelos (modelo 9 ao 16) foram ajustados para a característica produtividade de grãos. Os modelos 9, 10, 11, 12, 13, 14, 15 e 16 são correspondentes a sequência de modelos apresentados anteriormente (modelos 1, 2, 3, 4, 5, 6, 7 e 8), diferindo apenas pela inclusão da covariável estande nos respectivos modelos, como descrito a seguir:

a) Modelo 9: modelo de blocos casualizados, incluindo estande como covariável;

b) Modelo 10: modelo de látice parcialmente balanceado, incluindo estande como covariável;

c) Modelo 11: modelo de blocos casualizados, incluindo estande como covariável e considerando no vetor de resíduos ( $e$ ) apenas os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  ( $e = \xi$ );

d) Modelo 12: modelo de blocos casualizados, incluindo estande como covariável e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );

**Tabela 1.** Descrição dos modelos, com seus respectivos efeitos fixos ( $\tau$ ), aleatórios ( $u$ ) e resíduos. Do modelo 9 ao modelo 16 a covariável considerada foi estande

| Modelos   | Efeitos fixos ( $\tau$ ) <sup>†</sup> | Efeitos aleatórios ( $u$ ) <sup>‡</sup> | Resíduos <sup>§</sup> |
|---|---------------------------------------|---|-----------------------|
| 1 - DBC <sup>¶</sup>  | $\mu, r$                              | $g$                                     | $e$                   |
| 2 - Látice  | $\mu, r$                              | $g, b$                                  | $e$                   |
| 3 - DBC + AR1×AR1   | $\mu, r$                              | $g$                                     | $e = \xi$             |
| 4 - DBC + AR1×AR1 + $\eta$  | $\mu, r$                              | $g$                                     | $e = \xi + \eta$      |
| 5 - DBC + Linha + Coluna + AR1×AR1 + $\eta$                               | $\mu, r$                              | $g, l, c$                               | $e = \xi + \eta$      |
| 6 - Látice + AR1×AR1  | $\mu, r$                              | $g, b$                                  | $e = \xi$             |
| 7 - Látice + AR1×AR1 + $\eta$   | $\mu, r$                              | $g, b$                                  | $e = \xi + \eta$      |
| 8 - Látice + Linha + Coluna + AR1×AR1 + $\eta$                            | $\mu, r$                              | $g, b, l, c$                            | $e = \xi + \eta$      |
| 9 - DBC + Covariável <sup>#</sup>   | $\mu, r, \beta_{st}$                  | $g$                                     | $e$                   |
| 10 - Látice + Covariável <sup>#</sup>                                     | $\mu, r, \beta_{st}$                  | $g, b$                                  | $e$                   |
| 11 - DBC + Covariável <sup>#</sup> + AR1×AR1                              | $\mu, r, \beta_{st}$                  | $g$                                     | $e = \xi$             |
| 12 - DBC + Covariável <sup>#</sup> + AR1×AR1 + $\eta$                     | $\mu, r, \beta_{st}$                  | $g$                                     | $e = \xi + \eta$      |
| 13 - DBC + Covariável <sup>#</sup> + Linha + Coluna + AR1×AR1 + $\eta$    | $\mu, r, \beta_{st}$                  | $g, l, c$                               | $e = \xi + \eta$      |
| 14 - Látice + Covariável <sup>#</sup> + AR1×AR1                           | $\mu, r, \beta_{st}$                  | $g, b$                                  | $e = \xi$             |
| 15 - Látice + Covariável <sup>#</sup> + AR1×AR1 + $\eta$                  | $\mu, r, \beta_{st}$                  | $g, b$                                  | $e = \xi + \eta$      |
| 16 - Látice + Covariável <sup>#</sup> + Linha + Coluna + AR1×AR1 + $\eta$ | $\mu, r, \beta_{st}$                  | $g, b, l, c$                            | $e = \xi + \eta$      |

<sup>†</sup>  $\mu$ : média;  $r$ : efeito de repetição;  $\beta_{st}$ : efeito da covariável estande.

<sup>‡</sup>  $g$ : efeito de genótipos;  $b$ : efeito de blocos do látice;  $l$ : efeito de linhas;  $c$ : efeito de colunas.

<sup>§</sup>  $e$ : erros aleatórios;  $\xi$ : erros correlacionados;  $\eta$ : erros independentes.

<sup>¶</sup> DBC: Delineamento em Blocos Casualizados.

<sup>#</sup> Covariável: estande.

e) Modelo 13: modelo de blocos casualizados, incluindo estande como covariável, efeito de linhas, efeito de colunas e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );

f) Modelo 14: modelo de látice parcialmente balanceado, incluindo estande como covariável e considerando no vetor de resíduos ( $e$ ) apenas os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 ( $e = \xi$ );

g) Modelo 15: modelo de látice parcialmente balanceado, incluindo estande como covariável e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );

h) Modelo 16: modelo de látice parcialmente balanceado, incluindo estande como covariável, efeito de linhas, efeito de colunas e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ ).

Inicialmente, os modelos 1, 2, 3, 4, 5, 6, 7 e 8 foram ajustados para a variável estande e o teste da razão de verossimilhança usado para testar a significância do efeito de genótipos sobre estande em cada modelo. Segundo Cruz et al. (2014), o uso da covariável estande para correção da produtividade de grãos deve ocorrer unicamente quando o efeito de genótipos sobre as variações nos estandes for não significativo. Assim, os modelos de 9 a 16 foram ajustados para a característica produtividade de grãos apenas quando o efeito de genótipos para estande foi não significativo nos seus correspondentes modelos de 1 a 8.

Com base nos modelos ajustados foram obtidas as seguintes estimativas: componentes de variância genotípica ( $\hat{\sigma}_g^2$ ), variância de blocos ( $\hat{\sigma}_b^2$ ), variância de linhas ( $\hat{\sigma}_{linhas}^2$ ), variância de colunas ( $\hat{\sigma}_{colunas}^2$ ), variância residual ( $\hat{\sigma}_e^2$ ), variância dos efeitos aleatórios de tendência ( $\hat{\sigma}_\xi^2$ ), variância do erro independente ( $\hat{\sigma}_\eta^2$ ); coeficientes de

autocorrelação residual nas linhas ( $\hat{\rho}_r$ ) e nas colunas ( $\hat{\rho}_c$ ); valor-p para o efeito de genótipos pelo teste da razão de verossimilhança, herdabilidade no sentido amplo ( $\hat{h}^2$ ), acurácia seletiva ( $\hat{r}_{gg}$ ), variância do erro de predição (PEV), média de produtividade de grãos, coeficiente de variação experimental (CV) e logaritmo do máximo da função de verossimilhança (Log L).

As análises foram realizadas empregando-se o pacote estatístico ASReml-R (BUTLER et al., 2009), que usa as rotinas numéricas do programa ASReml (GILMOUR et al., 2002) no programa R (R CORE TEAM, 2018).

Dentro de cada grupo de modelos que possuem os mesmos efeitos fixos, a seleção do modelo mais adequado foi realizada por meio do critério de informação de Akaike (AIC) (AKAIKE, 1974). O AIC é dado por:  $AIC = -2\text{Log } L + 2p$ , em que  $p$  é o número de parâmetros estimados. Os menores valores de AIC refletem um melhor ajuste global (AKAIKE, 1974). Assim, os valores de AIC foram calculados para cada modelo candidato e as comparações entre os valores de AIC foram realizadas dentro de cada grupo de modelos (com e sem a inclusão da covariável estande). Como descreve Resende et al. (2014), dentro do grupo de modelos com mesma estrutura de efeitos fixos, o modelo com menor valor de AIC foi selecionado como o melhor modelo do grupo.

Além do AIC, dentro do grupo de modelos sem a inclusão da covariável estande, foi calculada para cada modelo a mudança do valor de Log L relativa ao Modelo 1. Dentro do grupo de modelos com inclusão da covariável estande, a mudança do valor de Log L foi calculada em relação ao Log L estimado com o Modelo 9 ou, quando o Modelo 9 não foi ajustado, em relação ao Log L de um modelo mais básico dentre os modelos ajustados. A significância na mudança relativa dos valores de Log L (Mud. Log L) foi verificada pelo teste da razão de verossimilhança.

Visando comparar os 16 modelos ajustados, foi estimada a eficiência de cada modelo em função da herdabilidade (Efic.  $\hat{h}^2$ ), dada pela razão entre a herdabilidade

estimada no modelo considerado e a herdabilidade estimada no modelo tradicional de blocos casualizados (Modelo 1).

Além dos parâmetros estimados e as estatísticas usadas para comparações entre modelos, também foram estimados coeficientes de correlação de Spearman entre os valores genotípicos preditos com os modelos em que o efeito de genótipos foi significativo sobre produtividade de grãos. Esses coeficientes foram estimados com auxílio do programa GENES (CRUZ, 2013). Além disso, estimou-se a frequência de híbridos comuns selecionados a partir dos valores genotípicos preditos nos diferentes modelos ajustados, considerando uma intensidade de seleção de 10% (aproximadamente quatro híbridos).

## **4. Resultados**

### **4.1. Efeito de genótipos sobre a variável estande (safras 2015/16, 2016/17 e 2017/18)**

Considerando os dados em nível de parcelas, os respectivos valores mínimo e máximo de estande (plantas ha<sup>-1</sup>) foram de: 27211 e 74830, na safra 2015/16; 40816 e 74830, na safra 2016/17; e 34014 e 74830, na safra 2017/18. Assim, observou-se que na safra 2015/16 houve maior amplitude nos valores observados para a variável estande.

O efeito de genótipos sobre a variável estande foi não significativo pelo teste da razão de verossimilhança nos oito modelos iniciais (modelos 1, 2, 3, 4, 5, 6, 7 e 8) ajustados para os dados das safras 2015/16 e 2016/17 (Tabela 2). Assim, nessas duas safras o estande foi incluído como covariável nos correspondentes modelos 9, 10, 11, 12, 13, 14, 15 e 16 (Tabela 1) para análise da produtividade de grãos. Na safra 2017/18, o efeito de genótipos sobre a variável estande foi não significativo somente nos modelos 3, 4, 5, 6 e 7 (Tabela 2), de modo que na análise da produtividade de grãos, o estande foi usado como covariável somente nos correspondentes modelos 11, 12, 13, 14 e 15 (Tabela 1).

**Tabela 2.** Estimativas de parâmetros para a variável estande dos ensaios de VCU conduzidos em condições de baixo teor de P (Baixo P) nas safras 2015/16, 2016/17 e 2017/18. Estimativas de componentes de variâncias genotípica ( $\hat{\sigma}_g^2$ ), blocos ( $\hat{\sigma}_b^2$ ), linhas ( $\hat{\sigma}_{linhas}^2$ ), colunas ( $\hat{\sigma}_{colunas}^2$ ), residual ( $\hat{\sigma}_e^2$ ), variância dos erros correlacionados ( $\hat{\sigma}_\xi^2$ ) e variância dos erros independentes ( $\hat{\sigma}_\eta^2$ ). Valor-p para o efeito de genótipos pelo teste da razão de verossimilhança (valor-p ( $\hat{\sigma}_g^2$ )); coeficientes de autocorrelação residual nas linhas ( $\hat{\rho}_r$ ) e nas colunas ( $\hat{\rho}_c$ )

| Parâmetros                           | Mod. 1                | Mod. 2                | Mod. 3                | Mod. 4                 | Mod. 5                 | Mod. 6                | Mod. 7                | Mod. 8                |
|--------------------------------------|-----------------------|-----------------------|-----------------------|------------------------|------------------------|-----------------------|-----------------------|-----------------------|
|                                      | $\mu, r$              | $\mu, r$              | $\mu, r$              | $\mu, r$               | $\mu, r$               | $\mu, r$              | $\mu, r$              | $\mu, r$              |
|                                      | $g$                   | $g, b$                | $g$                   | $g$                    | $g, l, c$              | $g, b$                | $g, b$                | $g, b, l, c$          |
|                                      | $e$                   | $e$                   | $\xi$                 | $\xi, \eta$            | $\xi, \eta$            | $\xi$                 | $\xi, \eta$           | $\xi, \eta$           |
| <b>VCU – Baixo P – safra 2015/16</b> |                       |                       |                       |                        |                        |                       |                       |                       |
| $\hat{\sigma}_g^2$                   | 8461211 <sup>ns</sup> | 9373250 <sup>ns</sup> | 5155065 <sup>ns</sup> | 6915400 <sup>ns</sup>  | 6971124 <sup>ns</sup>  | 6165254 <sup>ns</sup> | 7282273 <sup>ns</sup> | 7112781 <sup>ns</sup> |
| $\hat{\sigma}_b^2$                   | -                     | 4029853               | -                     | -                      | -                      | 6313933               | 5930685               | 5427122               |
| $\hat{\sigma}_{linhas}^2$            | -                     | -                     | -                     | -                      | 3,61                   | -                     | -                     | 4734494               |
| $\hat{\sigma}_{colunas}^2$           | -                     | -                     | -                     | -                      | 2941374                | -                     | -                     | 3081149               |
| $\hat{\sigma}_e^2$                   | 59113822              | 55033884              | -                     | -                      | -                      | -                     | -                     | -                     |
| $\hat{\sigma}_\xi^2$                 | -                     | -                     | 61091980              | 28842820               | 34590790               | 54525410              | 36372870              | 47664750              |
| $\hat{\sigma}_\eta^2$                | -                     | -                     | -                     | 31593910               | 24154970               | -                     | 17736350              | 41                    |
| $\hat{\rho}_r$                       | -                     | -                     | -0,17                 | -0,32                  | -0,33                  | -0,25                 | -0,34                 | -0,27                 |
| $\hat{\rho}_c$                       | -                     | -                     | 0,22                  | 0,53                   | 0,46                   | 0,26                  | 0,43                  | 0,19                  |
| valor-p ( $\hat{\sigma}_g^2$ )       | 8,95E-02              | 6,00E-02              | 2,76E-01              | 1,33E-01               | 1,30E-01               | 1,68E-01              | 1,14E-01              | 1,10E-01              |
| <b>VCU – Baixo P – safra 2016/17</b> |                       |                       |                       |                        |                        |                       |                       |                       |
| $\hat{\sigma}_g^2$                   | 25 <sup>ns</sup>      | 24 <sup>ns</sup>      | 27 <sup>ns</sup>      | 8,32 <sup>ns</sup>     | 21 <sup>ns</sup>       | 27 <sup>ns</sup>      | 2,66 <sup>ns</sup>    | 3,10 <sup>ns</sup>    |
| $\hat{\sigma}_b^2$                   | -                     | 7059505               | -                     | -                      | -                      | 30                    | 6,20                  | 5,97                  |
| $\hat{\sigma}_{linhas}^2$            | -                     | -                     | -                     | -                      | 736618                 | -                     | -                     | 736834                |
| $\hat{\sigma}_{colunas}^2$           | -                     | -                     | -                     | -                      | 5,72                   | -                     | -                     | 5,62                  |
| $\hat{\sigma}_e^2$                   | 55381570              | 49330570              | -                     | -                      | -                      | -                     | -                     | -                     |
| $\hat{\sigma}_\xi^2$                 | -                     | -                     | 56975900              | 51606530               | 52577400               | 56975860              | 51729050              | 52580330              |
| $\hat{\sigma}_\eta^2$                | -                     | -                     | -                     | 5219432                | 3637929                | -                     | 5390011               | 3637149               |
| $\hat{\rho}_r$                       | -                     | -                     | 0,28                  | 0,32                   | 0,31                   | 0,28                  | 0,32                  | 0,31                  |
| $\hat{\rho}_c$                       | -                     | -                     | 0,09                  | 0,11                   | 0,08                   | 0,09                  | 0,11                  | 0,08                  |
| valor-p ( $\hat{\sigma}_g^2$ )       | 1,00                  | 1,00                  | 1,00                  | 1,00                   | 9,98E-01               | 1,00                  | 1,00                  | 9,99E-01              |
| <b>VCU – Baixo P – safra 2017/18</b> |                       |                       |                       |                        |                        |                       |                       |                       |
| $\hat{\sigma}_g^2$                   | 11385207*             | 11745867*             | 9026435 <sup>ns</sup> | 10461540 <sup>ns</sup> | 10462580 <sup>ns</sup> | 9327135 <sup>ns</sup> | 9327119 <sup>ns</sup> | 9588275*              |
| $\hat{\sigma}_b^2$                   | -                     | 4664827               | -                     | -                      | -                      | 5361842               | 5361829               | 6436865               |
| $\hat{\sigma}_{linhas}^2$            | -                     | -                     | -                     | -                      | 7,80                   | -                     | -                     | 4914681               |
| $\hat{\sigma}_{colunas}^2$           | -                     | -                     | -                     | -                      | 1,44                   | -                     | -                     | 26                    |
| $\hat{\sigma}_e^2$                   | 60031338              | 55801536              | -                     | -                      | -                      | -                     | -                     | -                     |
| $\hat{\sigma}_\xi^2$                 | -                     | -                     | 62214300              | 15146660               | 15145060               | 57063180              | 57063010              | 51413570              |
| $\hat{\sigma}_\eta^2$                | -                     | -                     | -                     | 47453480               | 47461210               | -                     | 753                   | 171                   |
| $\hat{\rho}_r$                       | -                     | -                     | 0,00                  | 0,54                   | 0,54                   | -0,08                 | -0,08                 | -0,14                 |
| $\hat{\rho}_c$                       | -                     | -                     | 0,21                  | 0,65                   | 0,65                   | 0,21                  | 0,21                  | 0,14                  |
| valor-p ( $\hat{\sigma}_g^2$ )       | 3,28E-02              | 2,50E-02              | 6,49E-02              | 7,01E-02               | 7,73E-02               | 5,34E-02              | 5,34E-02              | 4,33E-02              |

\* Significativo ao nível de 5% de probabilidade; <sup>ns</sup> não significativo.

## **4.2. Seleção de modelos para análise da característica produtividade de grãos**

### **4.2.1. Produtividade de grãos – safra 2015/16**

As estimativas de parâmetros relacionados à variável produtividade de grãos da safra 2015/16 são apresentadas na Tabela 3. Verificou-se que a variância genotípica foi significativa em todos os modelos ajustados, sendo que o valor-p associado à variância genotípica variou de 3,27E-04 (modelos 14, 15 e 16) a 4,40E-02 (Modelo 1). O modelo tradicional em DBC (Modelo 1) e o modelo em DBC com inclusão do estande como covariável (Modelo 9) foram os únicos modelos que apresentaram estimativas de valor-p maiores que 0,01. Quanto ao coeficiente de variação experimental (CV), observou-se que as estimativas variaram de 17,77% (Modelo 10) a 24,09% (Modelo 1).

Entre os modelos que não incluem o estande como covariável, verificou-se que os modelos 2, 3, 4, 5, 6, 7 e 8 apresentaram melhor ajuste em relação ao modelo tradicional em DBC (Modelo 1), uma vez que as mudanças dos valores de Log L relativas ao Modelo 1 foram positivas e significativas pelo teste da razão de verossimilhança (Tabela 3). Dentre esses oito modelos, verificou-se que o Modelo 6 apresentou o menor valor de AIC (Tabela 3) e foi selecionado como o melhor modelo dentro desse grupo de modelos.

Entre os modelos que incluem o estande como covariável, os modelos 10, 11, 12, 13, 14, 15 e 16 apresentaram melhor ajuste em relação ao modelo em DBC com inclusão de covariável (Modelo 9), sendo que as mudanças em Log L relativas ao Modelo 9 foram positivas e significativas pelo teste da razão de verossimilhança (Tabela 3). Entre os oito modelos que incluem a covariável estande, o Modelo 14 apresentou a menor estimativa de AIC (Tabela 3) e foi selecionado como o melhor modelo dentro desse grupo.

**Tabela 3.** Estimativas de parâmetros genéticos e estatísticos do ensaio VCU – Baixo P, safra 2015/16, para a característica produtividade de grãos. Estimativas de componentes de variâncias genotípica ( $\hat{\sigma}_g^2$ ), blocos ( $\hat{\sigma}_b^2$ ), linhas ( $\hat{\sigma}_{linhas}^2$ ), colunas ( $\hat{\sigma}_{colunas}^2$ ), residual ( $\hat{\sigma}_e^2$ ), variância dos erros correlacionados ( $\hat{\sigma}_\xi^2$ ), variância dos erros independentes ( $\hat{\sigma}_\eta^2$ ) e soma dos componentes  $\hat{\sigma}_\xi^2$  e  $\hat{\sigma}_\eta^2$  ( $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ ). Coeficientes de autocorrelação residual nas linhas ( $\hat{\rho}_r$ ) e nas colunas ( $\hat{\rho}_c$ ). Valor-p para o efeito de genótipos, pelo teste da razão de verossimilhança (valor-p ( $\hat{\sigma}_g^2$ )). Herdabilidade no sentido amplo ( $\hat{h}^2$ ), acurácia seletiva ( $\hat{r}_{gg}$ ), variância do erro de predição (PEV), média de produtividade de grãos, coeficiente de variação experimental (CV), logaritmo do máximo da função de verossimilhança (Log L), critério de informação de Akaike (AIC), mudança do valor de Log L do modelo em relação ao seu respectivo modelo básico em blocos casualizados (Mud. Log L) e eficiência do modelo em função de herdabilidade (Efic.  $\hat{h}^2$ )

| Parâmetros                                 | Modelos estatísticos <sup>†</sup> e seus respectivos efeitos fixos <sup>‡</sup> , aleatórios <sup>§</sup> e resíduos <sup>¶</sup> |          |          |               |               |          |               |               |  |                      |                      |                      |                      |                      |                      |                      |
|--|---|----------|----------|---------------|---------------|----------|---------------|---------------|--|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
|  | Modelos sem inclusão da covariável estande  |          |          |               |               |          |               |               | Modelos com inclusão da covariável estande |                      |                      |                      |                      |                      |                      |                      |
|  | Mod. 1  | Mod. 2   | Mod. 3   | Mod. 4        | Mod. 5        | Mod. 6   | Mod. 7        | Mod. 8        | Mod. 9                                     | Mod. 10              | Mod. 11              | Mod. 12              | Mod. 13              | Mod. 14              | Mod. 15              | Mod. 16              |
|  | $\mu, r$  | $\mu, r$ | $\mu, r$ | $\mu, r$      | $\mu, r$      | $\mu, r$ | $\mu, r$      | $\mu, r$      | $\mu, r, \beta_{st}$                       | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ |
|  | $g$   | $g, b$   | $g$      | $g$           | $g, l, c$     | $g, b$   | $g, b$        | $g, b, l, c$  | $g$  | $g, b$               | $g$                  | $g$                  | $g, l, c$            | $g, b$               | $g, b$               | $g, b, l, c$         |
|  | $e$   | $e$      | $\zeta$  | $\zeta, \eta$ | $\zeta, \eta$ | $\zeta$  | $\zeta, \eta$ | $\zeta, \eta$ | $e$  | $e$                  | $\zeta$              | $\zeta, \eta$        | $\zeta, \eta$        | $\zeta$              | $\zeta, \eta$        | $\zeta, \eta$        |
| $\hat{\sigma}_g^2$                         | 306941*   | 399492** | 395393** | 395443**      | 395387**      | 412631** | 412685**      | 412697**      | 265035*                                    | 347185**             | 333792**             | 270183**             | 270111**             | 370883**             | 370877**             | 370870**             |
| $\hat{\sigma}_b^2$                         | -   | 442649   | -        | -             | -             | 289018   | 288981        | 288970        | -  | 449737               | -                    | -                    | -                    | 295113               | 295101               | 295103               |
| $\hat{\sigma}_{linhas}^2$                  | -   | -        | -        | -             | 0,25          | -        | -             | 0,21          | -  | -                    | -                    | -                    | 0,13                 | -                    | -                    | 0,06                 |
| $\hat{\sigma}_{colunas}^2$                 | -   | -        | -        | -             | 0,17          | -        | -             | 0,14          | -  | -                    | -                    | -                    | 0,05                 | -                    | -                    | 0,11                 |
| $\hat{\sigma}_e^2$                         | 1739987   | 1310079  | -        | -             | -             | -        | -             | -             | 1376964                                    | 947126               | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_\xi^2$                       | -   | -        | 1737118  | 1737143       | 1737125       | 1402276  | 1402463       | 1402535       | -  | -                    | 1362239              | 845214               | 845061               | 1059668              | 1059694              | 1059646              |
| $\hat{\sigma}_\eta^2$                      | -   | -        | -        | 1,11          | 1,87          | -        | 3,31          | 1,49          | -  | -                    | -                    | 635508               | 635580               | -                    | 0,32                 | 0,69                 |
| $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ | -   | -        | -        | 1737144       | 1737127       | -        | 1402466       | 1402536       | -  | -                    | -                    | 1480722              | 1480641              | -                    | 1059694              | 1059647              |
| $\hat{\rho}_r$                             | -   | -        | 0,22     | 0,22          | 0,22          | 0,07     | 0,07          | 0,07          | -  | -                    | 0,34                 | 0,65                 | 0,65                 | 0,23                 | 0,23                 | 0,23                 |
| $\hat{\rho}_c$                             | -   | -        | 0,41     | 0,41          | 0,41          | 0,39     | 0,39          | 0,39          | -  | -                    | 0,37                 | 0,68                 | 0,68                 | 0,38                 | 0,38                 | 0,38                 |
| valor-p ( $\hat{\sigma}_g^2$ )             | 4,40E-02  | 4,16E-03 | 3,68E-03 | 3,69E-03      | 3,76E-03      | 2,12E-03 | 2,12E-03      | 2,12E-03      | 3,08E-02                                   | 1,10E-03             | 1,21E-03             | 4,99E-03             | 5,00E-03             | 3,27E-04             | 3,27E-04             | 3,27E-04             |
| $\hat{h}^2$                                | 0,40  | 0,51     | 0,55     | 0,55          | 0,55          | 0,57     | 0,57          | 0,57          | 0,42                                       | 0,54                 | 0,58                 | 0,51                 | 0,51                 | 0,62                 | 0,62                 | 0,62                 |
| $\hat{r}_{gg}$                             | 0,63  | 0,71     | 0,74     | 0,74          | 0,74          | 0,75     | 0,75          | 0,75          | 0,65                                       | 0,74                 | 0,76                 | 0,71                 | 0,71                 | 0,79                 | 0,79                 | 0,79                 |
| PEV  | 183486  | 197341   | 177872   | 177903        | 177868        | 178488   | 178494        | 178492        | 153679                                     | 158672               | 141786               | 133431               | 133404               | 141411               | 141410               | 141413               |
| Média                                      | 5477  | 5477     | 5495     | 5495          | 5495          | 5488     | 5488          | 5488          | 5477                                       | 5477                 | 5457                 | 5422                 | 5422                 | 5462                 | 5462                 | 5462                 |
| CV (%)                                     | 24,09   | 20,90    | 23,98    | 23,98         | 23,98         | 21,58    | 21,58         | 21,58         | 21,43                                      | 17,77                | 21,39                | 22,44                | 22,44                | 18,85                | 18,85                | 18,85                |
| Log L                                      | -1092,37  | -1087,17 | -1081,69 | -1081,69      | -1081,69      | -1080,43 | -1080,43      | -1080,43      | -1080,47                                   | -1072,40             | -1066,99             | -1066,52             | -1066,52             | -1064,81             | -1064,81             | -1064,81             |
| AIC  | 2188,74   | 2180,35  | 2171,39  | 2173,39       | 2177,39       | 2170,85  | 2172,85       | 2176,85       | 2164,94                                    | 2150,79              | 2141,98              | 2143,03              | 2147,03              | 2139,62              | 2141,62              | 2145,62              |
|  | Comparações relativas ao Modelo 1   |          |          |               |               |          |               |               | Comparações relativas ao Modelo 9          |                      |                      |                      |                      |                      |                      |                      |
| Mud. Log L                                 | -   | 5,19**   | 10,67**  | 10,67**       | 10,67**       | 11,94**  | 11,94**       | 11,94**       | -  | 8,08**               | 13,48**              | 13,96**              | 13,96**              | 15,66**              | 15,66**              | 15,66**              |
|  | Comparações relativas ao Modelo 1   |          |          |               |               |          |               |               |  |                      |                      |                      |                      |                      |                      |                      |
| Efic. $\hat{h}^2$                          | -   | 1,26     | 1,37     | 1,37          | 1,37          | 1,41     | 1,41          | 1,41          | 1,04                                       | 1,35                 | 1,43                 | 1,26                 | 1,26                 | 1,54                 | 1,54                 | 1,54                 |

<sup>†</sup> Modelos estatísticos descritos na Tabela 1. <sup>‡</sup> Efeitos fixos:  $\mu$ : média;  $r$ : efeito de repetição;  $\beta_{st}$ : efeito da covariável estande. <sup>§</sup> Efeitos aleatórios:  $g$ : efeito de genótipos;  $b$ : efeito de blocos do látice;  $l$ : efeito de linhas;  $c$ : efeito de colunas. <sup>¶</sup> Resíduos:  $e$ : erros aleatórios;  $\xi$ : erros correlacionados;  $\eta$ : erros independentes. \* Significativo ao nível de 5% de probabilidade; \*\* Significativo ao nível de 1% de probabilidade.

O Modelo 14 difere do Modelo 6 apenas pela inclusão da covariável estande (Tabela 1). Comparando esses dois modelos, verificou-se que pelo Modelo 14 foi obtida maior estimativa de herdabilidade, maior acurácia seletiva e menor valor-p associado à variância genotípica (Tabela 3). Esses resultados evidenciam que o Modelo 14 é mais promissor que o Modelo 6 para a análise dos dados desta safra (2015/16). Assim, associar análise estatística espacial, informações do delineamento em látice e uso da covariável estande, tornaram o modelo estatístico mais adequado aos dados e, conseqüentemente, mais fidedignas as comparações entre os híbridos de milho avaliados em condições de baixo teor de P no solo, considerando esta safra de 2015/16.

Na Tabela 4, observou-se que os quatro híbridos identificados como superiores com base no Modelo 14 também foram selecionados usando os modelos 11, 15 e 16. No entanto, somente os modelos 15 e 16 garantiram a mesma classificação de todos os híbridos estabelecida no Modelo 14, uma vez que as estimativas de correlação de Spearman igual a um foram obtidas entre os valores genotípicos dos modelos 14 e 15 e dos modelos 14 e 16 (Tabela 4). Cabe ressaltar que o Modelo 14 apresenta um número menor de parâmetros em relação aos modelos 15 e 16, fato que reforça o uso Modelo 14 como o mais promissor para a análise estatística dos dados considerados.

**Tabela 4.** Correlações de Spearman e frequências de genótipos selecionados comuns, considerando o ensaio VCU – Baixo P, safra 2015/16. Acima da diagonal, correlações de Spearman entre os pares de modelos estatísticos considerando os valores genotípicos (u + g) preditos para produtividade de grãos. Abaixo da diagonal, frequências de genótipos selecionados comuns aos pares de modelos estatísticos, considerando a seleção dos quatro híbridos superiores quanto ao valor genotípico (u + g) de produtividade de grãos

|         | Mod. 1 | Mod. 2 | Mod. 3 | Mod. 4 | Mod. 5 | Mod. 6 | Mod. 7 | Mod. 8 | Mod. 9 | Mod. 10 | Mod. 11 | Mod. 12 | Mod. 13 | Mod. 14 | Mod. 15 | Mod. 16 |
|---------|--------|--------|--------|--------|--------|--------|--------|--------|--------|---------|---------|---------|---------|---------|---------|---------|
| Mod. 1  | -      | 0,955  | 0,930  | 0,930  | 0,930  | 0,937  | 0,937  | 0,937  | 0,891  | 0,866   | 0,858   | 0,856   | 0,856   | 0,858   | 0,858   | 0,858   |
| Mod. 2  | 0,500  | -      | 0,942  | 0,942  | 0,942  | 0,970  | 0,970  | 0,970  | 0,837  | 0,876   | 0,854   | 0,852   | 0,852   | 0,864   | 0,864   | 0,864   |
| Mod. 3  | 0,750  | 0,500  | -      | 1      | 1      | 0,981  | 0,981  | 0,981  | 0,800  | 0,840   | 0,876   | 0,869   | 0,869   | 0,871   | 0,871   | 0,871   |
| Mod. 4  | 0,750  | 0,500  | 1      | -      | 1      | 0,981  | 0,981  | 0,981  | 0,800  | 0,840   | 0,876   | 0,869   | 0,869   | 0,871   | 0,871   | 0,871   |
| Mod. 5  | 0,750  | 0,500  | 1      | 1      | -      | 0,981  | 0,981  | 0,981  | 0,800  | 0,840   | 0,876   | 0,869   | 0,869   | 0,871   | 0,871   | 0,871   |
| Mod. 6  | 0,750  | 0,500  | 1      | 1      | 1      | -      | 1      | 1      | 0,816  | 0,865   | 0,878   | 0,871   | 0,871   | 0,883   | 0,883   | 0,883   |
| Mod. 7  | 0,750  | 0,500  | 1      | 1      | 1      | 1      | -      | 1      | 0,816  | 0,865   | 0,878   | 0,871   | 0,871   | 0,883   | 0,883   | 0,883   |
| Mod. 8  | 0,750  | 0,500  | 1      | 1      | 1      | 1      | 1      | -      | 0,816  | 0,865   | 0,878   | 0,871   | 0,871   | 0,883   | 0,883   | 0,883   |
| Mod. 9  | 0,250  | 0,500  | 0,250  | 0,250  | 0,250  | 0,250  | 0,250  | 0,250  | -      | 0,951   | 0,909   | 0,926   | 0,926   | 0,917   | 0,917   | 0,917   |
| Mod. 10 | 0,250  | 0,750  | 0,250  | 0,250  | 0,250  | 0,250  | 0,250  | 0,250  | 0,750  | -       | 0,957   | 0,966   | 0,966   | 0,969   | 0,969   | 0,969   |
| Mod. 11 | 0,500  | 0,750  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,750  | 0,500   | -       | 0,984   | 0,984   | 0,995   | 0,995   | 0,995   |
| Mod. 12 | 0,500  | 0,750  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500   | 0,750   | -       | 1       | 0,982   | 0,982   | 0,982   |
| Mod. 13 | 0,500  | 0,750  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500   | 0,750   | 1       | -       | 0,982   | 0,982   | 0,982   |
| Mod. 14 | 0,500  | 0,750  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,750  | 0,500   | 1       | 0,750   | 0,750   | -       | 1       | 1       |
| Mod. 15 | 0,500  | 0,750  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,750  | 0,500   | 1       | 0,750   | 0,750   | 1       | -       | 1       |
| Mod. 16 | 0,500  | 0,750  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,500  | 0,750  | 0,500   | 1       | 0,750   | 0,750   | 1       | 1       | -       |

Na Tabela 5 são apresentados os valores genotípicos preditos para produtividade de grãos ( $\text{kg ha}^{-1}$ ) com base no Modelo 14 e nos modelos tradicionais de DBC (Modelo 1) e de látice parcialmente balanceado (Modelo 2). Considerando os quatro híbridos superiores com base em cada modelo, verificou-se que o híbrido 1M1804 (tratamento 30) teve o maior valor genotípico predito pelos três modelos. O híbrido 1N1975 (tratamento 12) teve o segundo maior valor genotípico predito pelo Modelo 14, no entanto esse híbrido apresentou o quarto maior valor predito pelo Modelo 2 e não foi selecionado pelo Modelo 1 (sétima posição pela classificação com base no Modelo 1). O terceiro maior valor genotípico predito pelo Modelo 14 (híbrido 1N1884 – tratamento 27) também foi selecionado com base nos modelos 1 e 2, assumindo o segundo maior valor nesses modelos. O híbrido 1N1962 (tratamento 16) foi o quarto maior valor genotípico predito pelo Modelo 14, sendo que esse híbrido não foi selecionado com base nos modelos 1 e 2, nos quais o híbrido foi classificado como o nono e o décimo primeiro valor genotípico, respectivamente. Esses resultados evidenciam que o uso de modelos estatísticos tradicionais (modelos 1 e 2) podem viesar as estimativas de valores genotípicos de híbridos de milho avaliados em condição de baixo teor de P no solo.

**Tabela 5.** Valores genotípicos (VG) preditos para produtividade de grãos (kg ha<sup>-1</sup>) dos híbridos de milho do ensaio VCU – Baixo P, na safra 2015/16. Valores genotípicos preditos pelos seguintes modelos: modelo tradicional de blocos casualizados (Modelo 1); modelo tradicional de látice quadrado parcialmente balanceado (Modelo 2); e modelo de látice parcialmente balanceado, incluindo estande como covariável e considerando no vetor de resíduos (*e*) apenas os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 (Modelo 14)

| Trat. | Híbrido    | Modelo 1 |         | Modelo 2 |         | Modelo 14 |         |
|-------|------------|----------|---------|----------|---------|-----------|---------|
|       |            | VG       | Ranking | VG       | Ranking | VG        | Ranking |
| 30    | 1M1804     | 6114     | 1       | 6356     | 1       | 6378      | 1       |
| 12    | 1N1975     | 5866     | 7       | 6049     | 4       | 6243      | 2       |
| 27    | 1N1884     | 6020     | 2       | 6317     | 2       | 6172      | 3       |
| 16    | 1N1962     | 5842     | 9       | 5794     | 11      | 6118      | 4       |
| 1     | 1M1752     | 5843     | 8       | 6076     | 3       | 6099      | 5       |
| 20    | 1N1925     | 5896     | 5       | 5971     | 6       | 6078      | 6       |
| 18    | AG8088 PRO | 5971     | 3       | 5887     | 9       | 5958      | 7       |
| 6     | 1M1718     | 5788     | 10      | 5853     | 10      | 5931      | 8       |
| 14    | 1M1819     | 5867     | 6       | 5893     | 8       | 5922      | 9       |
| 35    | 1L1421     | 5655     | 13      | 5657     | 13      | 5816      | 10      |
| 34    | 1M1764     | 5924     | 4       | 6040     | 5       | 5748      | 11      |
| 32    | 1M1760     | 5777     | 11      | 5911     | 7       | 5743      | 12      |
| 5     | 1M1807     | 5601     | 15      | 5658     | 12      | 5699      | 13      |
| 3     | 1L1411     | 5286     | 23      | 5273     | 23      | 5654      | 14      |
| 22    | BRS 1055   | 5611     | 14      | 5526     | 18      | 5616      | 15      |
| 8     | 1K1301     | 5432     | 20      | 5618     | 15      | 5614      | 16      |
| 29    | 1N1933     | 5500     | 16      | 5592     | 17      | 5477      | 17      |
| 25    | 1N1915     | 4811     | 35      | 4774     | 34      | 5477      | 18      |
| 9     | 1L1457     | 5464     | 18      | 5602     | 16      | 5420      | 19      |
| 19    | 1N1900     | 5262     | 24      | 5133     | 25      | 5381      | 20      |
| 31    | 1M1731     | 5466     | 17      | 5502     | 19      | 5310      | 21      |
| 11    | 1N1886     | 5390     | 21      | 5470     | 20      | 5262      | 22      |
| 15    | 1N1958     | 5249     | 27      | 5014     | 31      | 5224      | 23      |
| 4     | 1M1810     | 5257     | 25      | 5227     | 24      | 5218      | 24      |
| 28    | 1N1882     | 5113     | 32      | 5105     | 28      | 5214      | 25      |
| 17    | 1N1901     | 5357     | 22      | 5125     | 27      | 5120      | 26      |
| 13    | 1M1824     | 5457     | 19      | 5354     | 21      | 5046      | 27      |
| 33    | 2B587 PW   | 5176     | 29      | 5054     | 30      | 5039      | 28      |
| 21    | 1N1927     | 5687     | 12      | 5633     | 14      | 4964      | 29      |
| 24    | 1N1966     | 5255     | 26      | 4974     | 32      | 4935      | 30      |
| 10    | 2B707 PW   | 5114     | 31      | 5129     | 26      | 4923      | 31      |
| 7     | 1M1732     | 4754     | 36      | 4721     | 35      | 4855      | 32      |
| 2     | 1M1757     | 5244     | 28      | 5276     | 22      | 4852      | 33      |
| 26    | 1K1306     | 5052     | 33      | 5089     | 29      | 4821      | 34      |
| 36    | DKB390 PRO | 4882     | 34      | 4578     | 36      | 4666      | 35      |
| 23    | 1N1932     | 5176     | 30      | 4922     | 33      | 4645      | 36      |

#### 4.2.2. Produtividade de grãos – safra 2016/17

As estimativas de parâmetros relacionados à variável produtividade de grãos da safra 2016/17 são apresentadas na Tabela 6. Verificou-se que a variância genotípica foi significativa em todos os modelos ajustados, sendo que o valor-p associado à variância genotípica variou de 3,35E-06 (Modelo 4) a 2,08E-02 (Modelo 1). Somente o modelo tradicional em DBC (Modelo 1) e o modelo em DBC com inclusão do estande como covariável (Modelo 9) apresentaram estimativas de valor-p maiores que 0,01. Quanto ao coeficiente de variação experimental (CV), observou-se que as estimativas variaram de 18,29% (Modelo 16) a 35,68% (Modelo 4).

Entre os modelos que não incluem o estande como covariável, verificou-se que os modelos 2, 3, 4, 5, 6, 7 e 8 apresentaram melhor ajuste em relação ao modelo tradicional em DBC (Modelo 1), sendo que as mudanças nos valores de Log L relativas ao Modelo 1 foram positivas e significativas pelo teste da razão de verossimilhança (Tabela 6). Assim como aconteceu na safra anterior (2015/16), na safra 2016/17 o Modelo 6 também apresentou a menor estimativa de AIC dentre esses oito modelos (Tabela 6) e foi selecionado como o melhor modelo desse grupo.

Dentro do grupo de modelos que incluem a covariável estande, os modelos 10, 11, 12, 13, 14, 15 e 16 apresentaram melhor ajuste em relação ao modelo em DBC com inclusão da covariável estande (Modelo 9), sendo que as mudanças em Log L relativas ao Modelo 9 foram positivas e significativas pelo teste da razão de verossimilhança (Tabela 6). Entre os oito modelos que incluem a covariável estande, o Modelo 14 apresentou a menor estimativa de AIC (Tabela 6) e foi selecionado como o melhor modelo dentro desse grupo, assim como aconteceu na safra anterior (2015/16).

**Tabela 6.** Estimativas de parâmetros genéticos e estatísticos do ensaio VCU – Baixo P, safra 2016/17, considerando a característica produtividade de grãos. Estimativas de componentes de variâncias genotípica ( $\hat{\sigma}_g^2$ ), blocos ( $\hat{\sigma}_b^2$ ), linhas ( $\hat{\sigma}_{linhas}^2$ ), colunas ( $\hat{\sigma}_{colunas}^2$ ), residual ( $\hat{\sigma}_e^2$ ), variância dos erros correlacionados ( $\hat{\sigma}_\xi^2$ ), variância dos erros independentes ( $\hat{\sigma}_\eta^2$ ) e soma dos componentes  $\hat{\sigma}_\xi^2$  e  $\hat{\sigma}_\eta^2$  ( $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ ). Coeficientes de autocorrelação residual nas linhas ( $\hat{\rho}_r$ ) e nas colunas ( $\hat{\rho}_c$ ). Valor-p para o efeito de genótipos, pelo teste da razão de verossimilhança (valor-p ( $\hat{\sigma}_g^2$ )). Herdabilidade no sentido amplo ( $\hat{h}^2$ ), acurácia seletiva ( $\hat{r}_{gg}$ ), variância do erro de predição (PEV), média de produtividade de grãos, coeficiente de variação experimental (CV), logaritmo do máximo da função de verossimilhança (Log L), critério de informação de Akaike (AIC), mudança do valor de Log L do modelo em relação ao seu respectivo modelo básico em blocos casualizados (Mud. Log L) e eficiência do modelo em função de herdabilidade (Efic.  $\hat{h}^2$ )

| Parâmetros                                 | Modelos estatísticos <sup>†</sup> e seus respectivos efeitos fixos <sup>‡</sup> , aleatórios <sup>§</sup> e resíduos <sup>¶</sup> |          |               |               |          |               |               |                      |  |                      |                      |                      |                      |                      |                      |                      |
|--|---|----------|---------------|---------------|----------|---------------|---------------|----------------------|--|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
|  | Modelos sem inclusão da covariável estande  |          |               |               |          |               |               |                      | Modelos com inclusão da covariável estande |                      |                      |                      |                      |                      |                      |                      |
|  | Mod. 1  | Mod. 2   | Mod. 3        | Mod. 4        | Mod. 5   | Mod. 6        | Mod. 7        | Mod. 8               | Mod. 9                                     | Mod. 10              | Mod. 11              | Mod. 12              | Mod. 13              | Mod. 14              | Mod. 15              | Mod. 16              |
| $\mu, r$                                   | $\mu, r$  | $\mu, r$ | $\mu, r$      | $\mu, r$      | $\mu, r$ | $\mu, r$      | $\mu, r$      | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$                       | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ |
| $g$  | $g, b$  | $g$      | $g$           | $g, l, c$     | $g, b$   | $g, b$        | $g, b, l, c$  | $g$                  | $g, b$                                     | $g$                  | $g$                  | $g, l, c$            | $g, b$               | $g, b$               | $g, b, l, c$         | $g, b, l, c$         |
| $e$  | $e$   | $\zeta$  | $\zeta, \eta$ | $\zeta, \eta$ | $\zeta$  | $\zeta, \eta$ | $\zeta, \eta$ | $e$                  | $e$  | $\zeta$              | $\zeta, \eta$        | $\zeta, \eta$        | $\zeta$              | $\zeta, \eta$        | $\zeta, \eta$        | $\zeta, \eta$        |
| $\hat{\sigma}_g^2$                         | 213154*   | 310070** | 327965**      | 330019**      | 329031** | 240729**      | 240741**      | 261300**             | 221303*                                    | 328905**             | 364222**             | 329621**             | 329906**             | 269869**             | 274433**             | 267134**             |
| $\hat{\sigma}_b^2$                         | -   | 357848   | -             | -             | -        | 354195        | 354182        | 357067               | -  | 356327               | -                    | -                    | -                    | 339613               | 337959               | 327730               |
| $\hat{\sigma}_{linhas}^2$                  | -   | -        | -             | -             | 0,25     | -             | -             | 124041               | -  | -                    | -                    | -                    | 0,20                 | -                    | -                    | 100515               |
| $\hat{\sigma}_{colunas}^2$                 | -   | -        | -             | -             | 0,15     | -             | -             | 31880                | -  | -                    | -                    | -                    | 0,17                 | -                    | -                    | 52656                |
| $\hat{\sigma}_e^2$                         | 1015656   | 656184   | -             | -             | -        | -             | -             | -                    | 934344                                     | 570920               | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_\xi^2$                       | -   | -        | 975415        | 1050022       | 1048282  | 674553        | 674543        | 548422               | -  | -                    | 885202               | 962535               | 962994               | 583996               | 473664               | 483846               |
| $\hat{\sigma}_\eta^2$                      | -   | -        | -             | 506161        | 504758   | -             | 0,20          | 0,56                 | -  | -                    | -                    | 451082               | 451448               | -                    | 108156               | 2,84                 |
| $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ | -   | -        | -             | 1556183       | 1553040  | -             | 674543        | 548423               | -  | -                    | -                    | 1413617              | 1414442              | -                    | 581820               | 483849               |
| $\hat{\rho}_r$                             | -   | -        | 0,21          | 0,89          | 0,89     | -0,26         | -0,26         | -0,35                | -  | -                    | 0,26                 | 0,91                 | 0,91                 | -0,21                | -0,24                | -0,30                |
| $\hat{\rho}_c$                             | -   | -        | 0,34          | 0,78          | 0,78     | 0,35          | 0,35          | 0,24                 | -  | -                    | 0,36                 | 0,77                 | 0,77                 | 0,31                 | 0,39                 | 0,19                 |
| valor-p ( $\hat{\sigma}_g^2$ )             | 2,08E-02  | 1,25E-04 | 7,02E-04      | 3,35E-06      | 5,31E-05 | 1,33E-03      | 1,33E-03      | 6,75E-04             | 1,12E-02                                   | 1,49E-05             | 8,92E-05             | 8,28E-06             | 6,11E-06             | 2,22E-04             | 2,16E-04             | 1,92E-04             |
| $\hat{h}^2$                                | 0,44  | 0,60     | 0,62          | 0,64          | 0,64     | 0,59          | 0,59          | 0,62                 | 0,47                                       | 0,64                 | 0,67                 | 0,66                 | 0,66                 | 0,63                 | 0,63                 | 0,64                 |
| $\hat{r}_{gg}$                             | 0,67  | 0,78     | 0,79          | 0,80          | 0,80     | 0,77          | 0,77          | 0,79                 | 0,69                                       | 0,80                 | 0,82                 | 0,81                 | 0,81                 | 0,79                 | 0,80                 | 0,80                 |
| PEV  | 118580  | 122876   | 124981        | 118379        | 118378   | 99559         | 99569         | 99031                | 116994                                     | 116940               | 119921               | 111110               | 111112               | 99999                | 100585               | 96800                |
| Média                                      | 3795  | 3795     | 3749          | 3496          | 3496     | 3808          | 3808          | 3804                 | 3795                                       | 3795                 | 3744                 | 3497                 | 3497                 | 3805                 | 3806                 | 3803                 |
| CV (%)                                     | 26,55   | 21,34    | 26,34         | 35,68         | 35,64    | 21,57         | 21,57         | 19,47                | 25,47                                      | 19,91                | 25,13                | 34,00                | 34,01                | 20,08                | 20,04                | 18,29                |
| Log L                                      | -1056,01  | -1046,41 | -1048,32      | -1043,35      | -1043,35 | -1040,11      | -1040,11      | -1038,47             | -1055,12                                   | -1043,97             | -1046,03             | -1040,73             | -1040,73             | -1039,27             | -1039,25             | -1037,85             |
| AIC  | 2116,01   | 2098,83  | 2104,65       | 2096,71       | 2100,71  | 2090,21       | 2092,21       | 2092,95              | 2114,24                                    | 2093,94              | 2100,05              | 2091,45              | 2095,45              | 2088,54              | 2090,50              | 2091,70              |
|  | Comparações relativas ao Modelo 1   |          |               |               |          |               |               |                      | Comparações relativas ao Modelo 9          |                      |                      |                      |                      |                      |                      |                      |
| Mud. Log L                                 | -   | 9,59**   | 7,68**        | 12,65**       | 12,65**  | 15,90**       | 15,90**       | 17,53**              | -  | 11,15**              | 9,09**               | 14,40**              | 14,40**              | 15,85**              | 15,87**              | 17,27**              |
|  | Comparações relativas ao Modelo 1   |          |               |               |          |               |               |                      |  |                      |                      |                      |                      |                      |                      |                      |
| Efic. $\hat{h}^2$                          | -   | 1,36     | 1,39          | 1,45          | 1,44     | 1,32          | 1,32          | 1,40                 | 1,06                                       | 1,45                 | 1,51                 | 1,49                 | 1,49                 | 1,42                 | 1,43                 | 1,44                 |

<sup>†</sup> Modelos estatísticos descritos na Tabela 1. <sup>‡</sup> Efeitos fixos:  $\mu$ : média;  $r$ : efeito de repetição;  $\beta_{st}$ : efeito da covariável estande. <sup>§</sup> Efeitos aleatórios:  $g$ : efeito de genótipos;  $b$ : efeito de blocos do látice;  $l$ : efeito de linhas;  $c$ : efeito de colunas. <sup>¶</sup> Resíduos:  $e$ : erros aleatórios;  $\xi$ : erros correlacionados;  $\eta$ : erros independentes. \* Significativo ao nível de 5% de probabilidade; \*\* Significativo ao nível de 1% de probabilidade.

Comparando-se o Modelo 6 (selecionado dentre os modelos que não incluem a covariável estande) com o Modelo 14 (selecionado dentre os modelos que incluem a covariável estande), observou-se que maior herdabilidade, maior acurácia seletiva e menor valor-p foram estimados com base no Modelo 14 (Tabela 6). Esses resultados evidenciam que o Modelo 14 é mais promissor que o Modelo 6 para a análise dos dados desta safra (2016/17). Ressalta-se que os modelos 6 e 14 são correspondentes (Tabela 1), diferindo apenas pela inclusão da covariável estande no Modelo 14. Assim como verificado na safra anterior (2015/16), os resultados evidenciam que associar técnicas de análise espacial com estrutura autorregressiva para os erros, informações do delineamento em látice e uso da covariável estande, tornaram o modelo estatístico mais adequado aos dados e, conseqüentemente, mais fidedignas as comparações entre os híbridos de milho avaliados em condições de baixo teor de P no solo, considerando a safra 2016/17.

Considerando a frequência de híbridos comuns selecionados, observou-se que os quatro híbridos identificados como superiores com base no Modelo 14 também foram selecionados pelos modelos 2, 9, 10, 12, 13, 15 e 16 (Tabela 7). Porém, considerando os coeficientes de correlação de Spearman entre valores genotípicos preditos pelo Modelo 14 e os valores genotípicos preditos pelos demais modelos ajustados, nenhum dos modelos estatísticos garantiram a mesma classificação dos híbridos estabelecida pelo Modelo 14, uma vez que não houve coeficiente de correlação igual a um (Tabela 7). Os modelos 15 e 16 foram os que permitiram classificações dos híbridos mais próximas à classificação com base no Modelo 14, considerando que foram estimados coeficientes de correlação de Spearman maiores que 0,99 entre os modelos 14 e 15 e entre os modelos 14 e 16 (Tabela 7).

**Tabela 7.** Correlações de Spearman e frequências de genótipos selecionados comuns, considerando o ensaio VCU – Baixo P, safra 2016/17. Acima da diagonal, correlações de Spearman entre os pares de modelos estatísticos considerando os valores genotípicos (u + g) preditos para produtividade de grãos. Abaixo da diagonal, frequências de genótipos selecionados comuns aos pares de modelos estatísticos, considerando a seleção dos quatro híbridos superiores quanto ao valor genotípico (u + g) de produtividade de grãos

|         | Mod. 1 | Mod. 2 | Mod. 3 | Mod. 4 | Mod. 5 | Mod. 6 | Mod. 7 | Mod. 8 | Mod. 9 | Mod. 10 | Mod. 11 | Mod. 12 | Mod. 13 | Mod. 14 | Mod. 15 | Mod. 16 |
|---------|--------|--------|--------|--------|--------|--------|--------|--------|--------|---------|---------|---------|---------|---------|---------|---------|
| Mod. 1  | -      | 0,960  | 0,939  | 0,927  | 0,927  | 0,898  | 0,898  | 0,862  | 0,974  | 0,926   | 0,879   | 0,896   | 0,896   | 0,882   | 0,881   | 0,885   |
| Mod. 2  | 0,750  | -      | 0,949  | 0,971  | 0,971  | 0,949  | 0,949  | 0,928  | 0,954  | 0,974   | 0,915   | 0,954   | 0,954   | 0,947   | 0,944   | 0,953   |
| Mod. 3  | 1      | 0,750  | -      | 0,973  | 0,973  | 0,959  | 0,959  | 0,934  | 0,934  | 0,941   | 0,967   | 0,950   | 0,950   | 0,955   | 0,956   | 0,947   |
| Mod. 4  | 1      | 0,750  | 1      | -      | 1      | 0,959  | 0,959  | 0,949  | 0,920  | 0,966   | 0,959   | 0,980   | 0,980   | 0,965   | 0,965   | 0,966   |
| Mod. 5  | 1      | 0,750  | 1      | 1      | -      | 0,959  | 0,959  | 0,949  | 0,920  | 0,966   | 0,959   | 0,980   | 0,980   | 0,965   | 0,965   | 0,966   |
| Mod. 6  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | -      | 1      | 0,984  | 0,893  | 0,946   | 0,930   | 0,939   | 0,939   | 0,979   | 0,976   | 0,980   |
| Mod. 7  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | -      | 0,984  | 0,893  | 0,946   | 0,930   | 0,939   | 0,939   | 0,979   | 0,976   | 0,980   |
| Mod. 8  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | 1      | -      | 0,848  | 0,921   | 0,904   | 0,921   | 0,921   | 0,962   | 0,962   | 0,976   |
| Mod. 9  | 0,750  | 1      | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | -      | 0,957   | 0,912   | 0,927   | 0,927   | 0,903   | 0,903   | 0,901   |
| Mod. 10 | 0,750  | 1      | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | -       | 0,946   | 0,984   | 0,984   | 0,970   | 0,970   | 0,970   |
| Mod. 11 | 1      | 0,750  | 1      | 1      | 1      | 0,750  | 0,750  | 0,750  | 0,750  | 0,750   | -       | 0,972   | 0,972   | 0,961   | 0,965   | 0,947   |
| Mod. 12 | 0,750  | 1      | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | 1       | 0,750   | -       | 1       | 0,974   | 0,975   | 0,971   |
| Mod. 13 | 0,750  | 1      | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | 1       | 0,750   | 1       | -       | 0,974   | 0,975   | 0,971   |
| Mod. 14 | 0,750  | 1      | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | 1       | 0,750   | 1       | 1       | -       | 0,999   | 0,992   |
| Mod. 15 | 0,750  | 1      | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | 1       | 0,750   | 1       | 1       | 1       | -       | 0,991   |
| Mod. 16 | 0,750  | 1      | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | 1       | 0,750   | 1       | 1       | 1       | 1       | -       |

Na Tabela 8 são apresentados os valores genotípicos preditos para produtividade de grãos ( $\text{kg ha}^{-1}$ ) com base no Modelo 14 e nos modelos tradicionais de DBC (Modelo 1) e de látice parcialmente balanceado (Modelo 2). Considerando os quatro híbridos superiores preditos com base em cada modelo, observou-se que o híbrido 1O2109 (tratamento 27) apresentou o maior valor genotípico predito nos três modelos considerados (modelos 1, 2 e 14). O segundo maior valor genotípico predito pelo Modelo 14 foi para o híbrido 1O2010 (tratamento 16), que foi classificado como o terceiro maior valor genotípico predito pelos modelos 1 e 2. O híbrido 1L1421 (tratamento 7) foi o terceiro maior valor genotípico predito pelo Modelo 14, o quarto maior pelo Modelo 2 e o quinto maior pelo Modelo 1. Já o quarto maior valor genotípico predito pelo Modelo 14 (híbrido 1N1958 – tratamento 31) foi o segundo maior valor predito pelos modelos tradicionais 1 e 2. Esses resultados evidenciam que a classificação entre os híbridos selecionados com base no Modelo 14 difere das classificações com base nos modelos estatísticos tradicionais (modelos 1 e 2), o que evidencia que os modelos tradicionais podem viesar as estimativas de valores genotípicos de híbridos de milho avaliados em condições de baixo teor de P no solo.

#### **4.2.3. Produtividade de grãos – safra 2017/18**

As estimativas de parâmetros relacionados à variável produtividade de grãos da safra 2017/18 são apresentadas na Tabela 9. Verificou-se pelo teste da razão de verossimilhança que a variância genotípica foi significativa em todos os modelos estatísticos ajustados, de modo que o valor-p associado à variância genotípica variou de  $3,22\text{E}-06$  (Modelo 11) a  $7,11\text{E}-04$  (Modelo 2). Diferentemente das duas safras anteriores (2015/16 e 2016/17), na safra 2017/18 nenhum dos modelos ajustados apresentaram estimativas de valor-p maiores que 0,01. Quanto ao coeficiente de variação experimental

(CV), observou-se que as estimativas variaram de 21,15% (Modelo 2) a 23,76% (Modelo 4).

**Tabela 8.** Valores genotípicos (VG) preditos para produtividade de grãos (kg ha<sup>-1</sup>) dos híbridos de milho do ensaio VCU – Baixo P, na safra 2016/17. Valores genotípicos preditos pelos seguintes modelos: modelo tradicional de blocos casualizados (Modelo 1); modelo tradicional de látice quadrado parcialmente balanceado (Modelo 2); e modelo de látice parcialmente balanceado, incluindo estande como covariável e considerando no vetor de resíduos (*e*) apenas os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 (Modelo 14)

| Trat. | Híbrido      | Modelo 1 |         | Modelo 2 |         | Modelo 14 |         |
|-------|--------------|----------|---------|----------|---------|-----------|---------|
|       |              | VG       | Ranking | VG       | Ranking | VG        | Ranking |
| 27    | 1O2109       | 4454     | 1       | 4744     | 1       | 4758      | 1       |
| 16    | 1O2010       | 4355     | 3       | 4549     | 3       | 4545      | 2       |
| 7     | 1L1421       | 4147     | 5       | 4395     | 4       | 4409      | 3       |
| 31    | 1N1958       | 4378     | 2       | 4572     | 2       | 4393      | 4       |
| 23    | 1O2018       | 4205     | 4       | 4301     | 6       | 4296      | 5       |
| 35    | 1O2112       | 4139     | 6       | 4293     | 7       | 4290      | 6       |
| 4     | 1M1718       | 3890     | 14      | 4131     | 9       | 4228      | 7       |
| 34    | 1O2078       | 4106     | 7       | 4305     | 5       | 4192      | 8       |
| 12    | 1M1766       | 3962     | 11      | 4146     | 8       | 4187      | 9       |
| 5     | 1N1975       | 3829     | 16      | 3984     | 14      | 4040      | 10      |
| 29    | 1O2074       | 3822     | 17      | 3756     | 20      | 4031      | 11      |
| 28    | 1O2106       | 3999     | 10      | 4070     | 10      | 3953      | 12      |
| 21    | 1O2045       | 3798     | 18      | 3801     | 16      | 3925      | 13      |
| 3     | 1M1760       | 3617     | 25      | 3764     | 19      | 3925      | 14      |
| 26    | 1O2069       | 4035     | 9       | 3991     | 12      | 3914      | 15      |
| 15    | 1O2058       | 3946     | 12      | 3986     | 13      | 3882      | 16      |
| 10    | BRS1055      | 3626     | 23      | 3772     | 17      | 3844      | 17      |
| 30    | 1O2102       | 3900     | 13      | 3820     | 15      | 3833      | 18      |
| 18    | DKB310VTPRO2 | 4060     | 8       | 4018     | 11      | 3785      | 19      |
| 20    | 1O2007       | 3879     | 15      | 3764     | 18      | 3765      | 20      |
| 6     | 1L1411       | 3583     | 27      | 3584     | 25      | 3691      | 21      |
| 8     | 1M1824       | 3679     | 21      | 3718     | 21      | 3651      | 22      |
| 32    | 1O2080       | 3510     | 31      | 3322     | 31      | 3650      | 23      |
| 2     | 1M1764       | 3620     | 24      | 3615     | 24      | 3594      | 24      |
| 19    | 1O2048       | 3778     | 19      | 3625     | 23      | 3504      | 25      |
| 1     | 1M1752       | 3668     | 22      | 3690     | 22      | 3502      | 26      |
| 36    | 1O2073       | 3555     | 29      | 3407     | 27      | 3454      | 27      |
| 25    | 1O2088       | 3565     | 28      | 3324     | 30      | 3449      | 28      |
| 13    | 1O2012       | 3549     | 30      | 3270     | 32      | 3425      | 29      |
| 14    | 1O2034       | 3757     | 20      | 3563     | 26      | 3409      | 30      |
| 11    | 1O2054       | 3286     | 36      | 3225     | 33      | 3408      | 31      |
| 9     | 1M1731       | 3323     | 34      | 3361     | 29      | 3381      | 32      |
| 24    | 1O2008       | 3593     | 26      | 3375     | 28      | 3328      | 33      |
| 33    | DKB390PRO2   | 3309     | 35      | 3186     | 34      | 3136      | 34      |
| 17    | 1O2050       | 3369     | 32      | 3076     | 36      | 3127      | 35      |
| 22    | 2B587PW      | 3347     | 33      | 3131     | 35      | 3094      | 36      |

**Tabela 9.** Estimativas de parâmetros genéticos e estatísticos do ensaio VCU – Baixo P, safra 2017/18, considerando a característica produtividade de grãos. Estimativas de componentes de variâncias genotípica ( $\hat{\sigma}_g^2$ ), blocos ( $\hat{\sigma}_b^2$ ), linhas ( $\hat{\sigma}_{linhas}^2$ ), colunas ( $\hat{\sigma}_{colunas}^2$ ), residual ( $\hat{\sigma}_e^2$ ), variância dos erros correlacionados ( $\hat{\sigma}_\xi^2$ ), variância dos erros independentes ( $\hat{\sigma}_\eta^2$ ) e soma dos componentes  $\hat{\sigma}_\xi^2$  e  $\hat{\sigma}_\eta^2$  ( $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ ). Coeficientes de autocorrelação residual nas linhas ( $\hat{\rho}_r$ ) e nas colunas ( $\hat{\rho}_c$ ). Valor-p para o efeito de genótipos, pelo teste da razão de verossimilhança (valor-p ( $\hat{\sigma}_g^2$ )). Herdabilidade no sentido amplo ( $\hat{h}^2$ ), acurácia seletiva ( $\hat{r}_{gg}$ ), variância do erro de predição (PEV), média de produtividade de grãos, coeficiente de variação experimental (CV), logaritmo do máximo da função de verossimilhança (Log L), critério de informação de Akaike (AIC), mudança do valor de Log L do modelo em relação ao seu respectivo modelo básico em blocos casualizados (Mud. Log L) e eficiência do modelo em função de herdabilidade (Efic.  $\hat{h}^2$ )

| Parâmetros                                 | Modelos estatísticos <sup>†</sup> e seus respectivos efeitos fixos <sup>‡</sup> , aleatórios <sup>§</sup> e resíduos <sup>¶</sup> |          |          |             |             |          |             |              |  |                      |                      |                      |                      |                      |                      |                      |
|--|---|----------|----------|-------------|-------------|----------|-------------|--------------|--|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
|  | Modelos sem inclusão da covariável estande  |          |          |             |             |          |             |              | Modelos com inclusão da covariável estande |                      |                      |                      |                      |                      |                      |                      |
|  | Mod. 1  | Mod. 2   | Mod. 3   | Mod. 4      | Mod. 5      | Mod. 6   | Mod. 7      | Mod. 8       | Mod. 9                                     | Mod. 10              | Mod. 11              | Mod. 12              | Mod. 13              | Mod. 14              | Mod. 15              | Mod. 16              |
|  | $\mu, r$  | $\mu, r$ | $\mu, r$ | $\mu, r$    | $\mu, r$    | $\mu, r$ | $\mu, r$    | $\mu, r$     | $\mu, r, \beta_{st}$                       | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ |
|  | $g$   | $g, b$   | $g$      | $g$         | $g, l, c$   | $g, b$   | $g, b$      | $g, b, l, c$ | $g$  | $g, b$               | $g$                  | $g$                  | $g, l, c$            | $g, b$               | $g, b$               | $g, b, l, c$         |
|  | $e$   | $e$      | $\xi$    | $\xi, \eta$ | $\xi, \eta$ | $\xi$    | $\xi, \eta$ | $\xi, \eta$  | $e$  | $e$                  | $\xi$                | $\xi, \eta$          | $\xi, \eta$          | $\xi$                | $\xi, \eta$          | $\xi, \eta$          |
| $\hat{\sigma}_g^2$                         | 314429**  | 289923** | 335022** | 318309**    | 310191**    | 341131** | 341217**    | 320036**     | -  | -                    | 326493**             | 315342**             | 312605**             | 328184**             | 316417**             | -                    |
| $\hat{\sigma}_b^2$                         | -   | 169800   | -        | -           | -           | 39829    | 39785       | 21231        | -  | -                    | -                    | -                    | -                    | 6115                 | 0,11                 | -                    |
| $\hat{\sigma}_{linhas}^2$                  | -   | -        | -        | -           | 56055       | -        | -           | 53973        | -  | -                    | -                    | -                    | 52169                | -                    | -                    | -                    |
| $\hat{\sigma}_{colunas}^2$                 | -   | -        | -        | -           | 0,05        | -        | -           | 0,04         | -  | -                    | -                    | -                    | 0,07                 | -                    | -                    | -                    |
| $\hat{\sigma}_e^2$                         | 858204  | 722454   | -        | -           | -           | -        | -           | -            | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_\xi^2$                       | -   | -        | 870367   | 675014      | 589702      | 815971   | 816298      | 597812       | -  | -                    | 861289               | 748467               | 693880               | 851853               | 752729               | -                    |
| $\hat{\sigma}_\eta^2$                      | -   | -        | -        | 223917      | 273253      | -        | 0,28        | 227192       | -  | -                    | -                    | 126086               | 135810               | -                    | 122778               | -                    |
| $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ | -   | -        | -        | 898931      | 862955      | -        | 816299      | 825004       | -  | -                    | -                    | 874552               | 829690               | -                    | 875506               | -                    |
| $\hat{\rho}_r$                             | -   | -        | 0,18     | 0,33        | 0,42        | 0,14     | 0,14        | 0,35         | -  | -                    | 0,20                 | 0,27                 | 0,31                 | 0,19                 | 0,27                 | -                    |
| $\hat{\rho}_c$                             | -   | -        | 0,39     | 0,51        | 0,50        | 0,39     | 0,39        | 0,47         | -  | -                    | 0,44                 | 0,50                 | 0,47                 | 0,44                 | 0,50                 | -                    |
| valor-p ( $\hat{\sigma}_g^2$ )             | 4,99E-04  | 7,11E-04 | 6,39E-06 | 1,09E-04    | 1,01E-04    | 1,10E-05 | 9,66E-05    | 9,79E-05     | -  | -                    | 3,22E-06             | 8,24E-05             | 7,95E-05             | 3,83E-06             | 8,24E-05             | -                    |
| $\hat{h}^2$                                | 0,58  | 0,58     | 0,66     | 0,64        | 0,64        | 0,66     | 0,66        | 0,65         | -  | -                    | 0,67                 | 0,66                 | 0,66                 | 0,67                 | 0,66                 | -                    |
| $\hat{r}_{gg}$                             | 0,76  | 0,76     | 0,81     | 0,80        | 0,80        | 0,81     | 0,81        | 0,80         | -  | -                    | 0,82                 | 0,81                 | 0,81                 | 0,82                 | 0,81                 | -                    |
| PEV  | 132722  | 123045   | 114334   | 113524      | 112087      | 115014   | 115005      | 112919       | -  | -                    | 108625               | 108366               | 107667               | 108843               | 108394               | -                    |
| Média                                      | 4019  | 4019     | 3997     | 3991        | 3995        | 4005     | 4005        | 4000         | -  | -                    | 3995                 | 3991                 | 3996                 | 3996                 | 3991                 | -                    |
| CV (%)                                     | 23,05   | 21,15    | 23,34    | 23,76       | 23,25       | 22,56    | 22,56       | 22,70        | -  | -                    | 23,23                | 23,43                | 22,80                | 23,10                | 23,45                | -                    |
| Log L                                      | -1049,34  | -1046,06 | -1040,43 | -1040,38    | -1040,11    | -1040,26 | -1040,26    | -1040,08     | -  | -                    | -1041,34             | -1041,29             | -1041,10             | -1041,33             | -1041,29             | -                    |
| AIC  | 2102,68   | 2098,11  | 2088,86  | 2090,76     | 2094,22     | 2090,53  | 2092,53     | 2096,16      | -  | -                    | 2090,67              | 2092,59              | 2096,20              | 2092,66              | 2094,59              | -                    |
|  | Comparações relativas ao Modelo 1   |          |          |             |             |          |             |              | Comparações relativas ao Modelo 11         |                      |                      |                      |                      |                      |                      |                      |
| Mud. Log L                                 | -   | 3,29*    | 8,91**   | 8,96**      | 9,23**      | 9,08**   | 9,08**      | 9,26**       | -  | -                    | -                    | 0,04 <sup>ns</sup>   | 0,23 <sup>ns</sup>   | 0,005 <sup>ns</sup>  | 0,043 <sup>ns</sup>  | -                    |
|  | Comparações relativas ao Modelo 1   |          |          |             |             |          |             |              |  |                      |                      |                      |                      |                      |                      |                      |
| Efic. $\hat{h}^2$                          | -   | 1,00     | 1,14     | 1,11        | 1,11        | 1,15     | 1,15        | 1,12         | -  | -                    | 1,15                 | 1,14                 | 1,13                 | 1,16                 | 1,14                 | -                    |

<sup>†</sup> Modelos estatísticos descritos na Tabela 1. <sup>‡</sup> Efeitos fixos:  $\mu$ : média;  $r$ : efeito de repetição;  $\beta_{st}$ : efeito da covariável estande. <sup>§</sup> Efeitos aleatórios:  $g$ : efeito de genótipos;  $b$ : efeito de blocos do látice;  $l$ : efeito de linhas;  $c$ : efeito de colunas. <sup>¶</sup> Resíduos:  $e$ : erros aleatórios;  $\xi$ : erros correlacionados;  $\eta$ : erros independentes. \* Significativo ao nível de 5% de probabilidade; \*\* Significativo ao nível de 1% de probabilidade; <sup>ns</sup> não significativo.

Entre os modelos que não incluem o estande como covariável, os modelos 2, 3, 4, 5, 6, 7 e 8 apresentaram melhor ajuste em relação ao modelo tradicional em DBC (Modelo 1), o que pode ser verificado pelas mudanças nos valores de Log L relativas ao Modelo 1, que foram positivas e significativas pelo teste da razão de verossimilhança (Tabela 9). Dentre esses oito modelos, verificou-se que o Modelo 3 apresentou o menor valor de AIC (Tabela 9) e foi selecionado como melhor modelo dentro desse grupo.

Entre os modelos que incluem a covariável estande, o Modelo 11 foi tomado como base para estimação das mudanças relativas dos valores de Log L. Assim, comparando-se o Modelo 11 com os modelos 12, 13, 14 e 15, verificou-se que as mudanças de Log L relativas foram não significativas pelo teste da razão de verossimilhança (Tabela 9). Esses resultados evidenciam que nenhum dos modelos considerados apresentaram ajuste melhor que o Modelo 11. Além disso, verificou-se que o Modelo 11 apresentou o menor valor de AIC (Tabela 9), sendo selecionado como o melhor modelo dentro deste grupo de modelos que incluem a covariável estande.

Os modelos 3 e 11, selecionados dentro de cada grupo de modelos, são correspondentes e diferem apenas pela inclusão da covariável estande no Modelo 11 (Tabela 1). Comparando esses dois modelos, verificou-se que o Modelo 11 é ligeiramente mais promissor para a análise dos dados da safra 2017/18. Com base no Modelo 11 foram estimados menor valor-p associado a variância genotípica e maiores valores de acurácia seletiva e herdabilidade (Tabela 9). No entanto, as diferenças das estimativas de valor-p, acurácia e herdabilidade entre os modelos 3 e 11 foram de pequena magnitude (Tabela 9). Contudo, esses resultados evidenciam que a associação da análise espacial com o uso da covariável estande tornou o modelo estatístico mais adequado aos dados e, conseqüentemente, mais fidedignas as comparações entre os híbridos de milho avaliados em condições de baixo teor de P no solo, considerando a safra 2017/18. Diferentemente das duas safras anteriores (2015/16 e 2016/17), o modelo para análise estatística espacial

selecionado na safra 2017/18 não inclui informação do delineamento de látice parcialmente balanceado.

Considerando a frequência de híbridos comuns selecionados, observou-se que os quatro híbridos identificados como superiores com base no Modelo 11 também foram selecionados pelos modelos 3, 4, 5, 6, 7, 8, 12, 13, 14 e 15 (Tabela 10). No entanto, coeficiente de correlação de Spearman igual a um foi estimado somente entre os valores genotípicos preditos pelos modelos 11 e 14 (Tabela 10). Assim, somente o Modelo 14 garante classificação dos híbridos idêntica à estabelecida pelo Modelo 11.

Na Tabela 11 são apresentados os valores genotípicos preditos para produtividade de grãos ( $\text{kg ha}^{-1}$ ) com base no Modelo 11 e nos modelos tradicionais de DBC (Modelo 1) e de látice parcialmente balanceado (Modelo 2). Considerando os quatro híbridos superiores preditos em cada modelo, observou-se que os híbridos 1L1411 (tratamento 1) e 1N1958 (tratamento 6) apresentaram, respectivamente, o primeiro e segundo maiores valores genotípicos preditos pelos três modelos estatísticos (modelos 1, 2 e 11). O híbrido 1M1752 (tratamento 29) foi o terceiro maior valor genotípico predito pelos modelos 1 e 11 e o quarto maior valor pelo Modelo 2. O híbrido 1M1804 (tratamento 2) foi o quarto maior valor genotípico predito pelo Modelo 11, no entanto esse híbrido não foi selecionado pelos modelos tradicionais de DBC ou de látice parcialmente balanceado, sendo classificado como o nono e o sexto maior valor genotípico nos respectivos modelos (modelos 1 e 2). Assim como observado nas duas safras anteriores (2015/16 e 2016/17), verificou-se também na safra 2017/18 que o uso de modelos estatísticos tradicionais (modelos 1 e 2) podem viesar as estimativas de valores genotípicos de híbridos de milho avaliados em condição de baixo teor de P no solo.



**Tabela 11.** Valores genotípicos (VG) preditos para produtividade de grãos (kg ha<sup>-1</sup>) dos híbridos de milho do ensaio VCU – Baixo P, na safra 2017/18. Valores genotípicos preditos pelos seguintes modelos: modelo tradicional de blocos casualizados (Modelo 1); modelo tradicional de látice quadrado parcialmente balanceado (Modelo 2); e modelo de blocos casualizados, incluindo estande como covariável e considerando no vetor de resíduos (*e*) apenas os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 (Modelo 11)

| Trat. | Híbrido     | Modelo 1 |         | Modelo 2 |         | Modelo 11 |         |
|-------|-------------|----------|---------|----------|---------|-----------|---------|
|       |             | VG       | Ranking | VG       | Ranking | VG        | Ranking |
| 1     | 1L1411      | 4913     | 1       | 4887     | 1       | 5106      | 1       |
| 6     | 1N1958      | 4808     | 2       | 4804     | 2       | 4850      | 2       |
| 29    | 1M1752      | 4570     | 3       | 4467     | 4       | 4686      | 3       |
| 2     | 1M1804      | 4324     | 9       | 4425     | 6       | 4545      | 4       |
| 30    | 1P2255      | 4433     | 7       | 4374     | 9       | 4429      | 5       |
| 25    | 1P2214      | 4491     | 4       | 4408     | 7       | 4399      | 6       |
| 34    | 1P2231      | 4481     | 6       | 4501     | 3       | 4345      | 7       |
| 13    | 1O2018      | 4164     | 16      | 4177     | 13      | 4333      | 8       |
| 28    | 1P2273      | 4488     | 5       | 4462     | 5       | 4312      | 9       |
| 8     | 1O2106      | 4276     | 10      | 4396     | 8       | 4279      | 10      |
| 4     | 1M1807      | 4236     | 13      | 4242     | 12      | 4238      | 11      |
| 23    | 1P2184      | 4272     | 11      | 4311     | 11      | 4233      | 12      |
| 27    | 1P2212      | 4242     | 12      | 4131     | 16      | 4228      | 13      |
| 36    | 1P2215      | 4337     | 8       | 4322     | 10      | 4173      | 14      |
| 11    | 1O2073      | 4197     | 15      | 4142     | 15      | 4127      | 15      |
| 35    | 1P2267      | 4215     | 14      | 4146     | 14      | 4091      | 16      |
| 9     | 1O2112      | 4044     | 19      | 3987     | 20      | 4060      | 17      |
| 21    | 1P2203      | 3857     | 24      | 3884     | 23      | 4044      | 18      |
| 5     | 1M1782      | 3986     | 21      | 3902     | 22      | 4018      | 19      |
| 17    | 1P2216      | 4060     | 18      | 4046     | 19      | 4003      | 20      |
| 3     | 1M1810      | 4121     | 17      | 4046     | 18      | 3980      | 21      |
| 16    | 1N1906      | 3867     | 23      | 3926     | 21      | 3971      | 22      |
| 24    | 1P2175      | 4008     | 20      | 4087     | 17      | 3924      | 23      |
| 33    | 1F640       | 3930     | 22      | 3854     | 24      | 3879      | 24      |
| 32    | 1P2247      | 3764     | 27      | 3851     | 25      | 3719      | 25      |
| 10    | DKB310 PRO2 | 3801     | 26      | 3811     | 26      | 3676      | 26      |
| 31    | 1P2265      | 3849     | 25      | 3789     | 27      | 3626      | 27      |
| 12    | 1O2008      | 3506     | 31      | 3475     | 33      | 3534      | 28      |
| 26    | 1P2188      | 3571     | 29      | 3604     | 29      | 3531      | 29      |
| 22    | BRS 3042    | 3384     | 34      | 3471     | 34      | 3518      | 30      |
| 14    | 1P2224      | 3410     | 32      | 3544     | 32      | 3489      | 31      |
| 20    | 1P2237      | 3399     | 33      | 3579     | 31      | 3465      | 32      |
| 18    | DKB390 PRO2 | 3263     | 35      | 3269     | 35      | 3464      | 33      |
| 15    | 1P2227      | 3724     | 28      | 3702     | 28      | 3457      | 34      |
| 19    | 1P2193      | 3549     | 30      | 3585     | 30      | 3331      | 35      |
| 7     | 1O2034      | 3146     | 36      | 3075     | 36      | 2748      | 36      |

### **4.3. Produtividade de grãos – Importância dos delineamentos e de diferentes efeitos na análise espacial (safras 2015/16, 2016/17 e 2017/18)**

Para a análise estatística dos dados de produtividade de grãos dos híbridos de milho avaliados em condições de baixo teor de P no solo, na Embrapa Milho e Sorgo, os modelos selecionados como mais adequados foram o Modelo 14 (para as safras 2015/16 e 2016/17) e o Modelo 11 (para a safra 2017/18). O Modelo 11 é o modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ , sem o termo do erro independente ( $\eta$ ) e com inclusão do estande como covariável. O Modelo 14 é o modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ , sem o termo do erro independente ( $\eta$ ) e com inclusão do estande como covariável. Observa-se que tanto o Modelo 11 como o Modelo 14 são caracterizados por modelar a matriz de covariância residual por meio do processo autorregressivo separável de primeira ordem em duas dimensões ( $AR1 \times AR1$ ). Assim, esse fato evidencia que a técnica de análise espacial com estrutura autorregressiva para os erros é promissora para análise dos dados oriundos de experimentos de híbridos de milho avaliados em condições de baixo teor de P no solo.

Apesar de não ter sido selecionado como o melhor modelo na safra 2017/18, o Modelo 14 garantiu a mesma classificação e seleção dos híbridos superiores estabelecidas pelo Modelo 11 nessa safra (Tabela 10). Assim, o Modelo 14 apresenta potencial para ser adotado em análise de ensaios de VCU de híbridos de milho avaliados na Embrapa Milho e Sorgo sob condições de baixo teor de P no solo.

Na escolha do modelo mais adequado em cada safra, a decisão foi tomada considerando o melhor modelo do grupo sem inclusão da covariável estande (modelos de 1 a 8) e o melhor modelo do grupo com inclusão da covariável estande (modelos de 9 a 16). Em cada safra, observou-se que o modelo selecionado em um grupo foi correspondente quanto ao delineamento estatístico e à estrutura da matriz de covariância

residual do modelo selecionado no outro grupo (modelos 6 e 14, nas safras 2015/16 e 2016/17; e modelos 3 e 11, na safra 2017/18). Comparando os modelos correspondentes selecionados em cada safra, observou-se que o modelo com inclusão da covariável estande sempre proporcionou menor valor-p associado à variância genotípica e maiores estimativas de herdabilidade e acurácia (Tabelas 3, 6 e 9). Esse fato evidencia que o uso da covariável estande contribuiu para estimativas mais fidedignas dos valores genotípicos dos híbridos de milho avaliados nos ensaios de VCU de híbridos de milho da Embrapa Milho e Sorgo, conduzidos em áreas de baixo teor de P no solo.

Como os modelos selecionados (modelos 11 e 14) pertencem ao grupo de modelos que incluem o estande como covariável (Tabela 1), nas discussões subsequentes serão considerados somente os resultados desse grupo de modelos (modelos 9, 10, 11, 12, 13, 14, 15 e 16).

Considerando o modelo de blocos casualizados, com inclusão do estande como covariável, resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e sem o termo do erro independente ( $\eta$ ) (Modelo 11); e o modelo de blocos casualizados, com inclusão do estande como covariável, resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com o termo do erro independente ( $\eta$ ) (Modelo 12), verificou-se que em todas as safras a inclusão de  $\eta$  no Modelo 12 contribuiu para aumentar os valores estimados de autocorrelações de linhas ( $\hat{\rho}_r$ ) e de colunas ( $\hat{\rho}_c$ ) em relação ao Modelo 11 (Tabelas 3, 6 e 9). Com o Modelo 12, nas safras 2015/16 e 2016/17, foram estimados valores de autocorrelação maiores que 0,65 (Tabelas 3 e 6). Segundo Resende & Sturion (2003), valores de autocorrelação maiores que 0,60 são considerados de elevada magnitude e podem indicar padrões de resíduos espaciais ou variabilidade espacial em gradientes ou manchas.

O modelo de látice parcialmente balanceado, com inclusão do estande como covariável, resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com o termo do erro

independente ( $\eta$ ) (Modelo 15), possui um efeito a mais (efeito aleatório de blocos dentro de repetição) em relação ao Modelo 12. Nas safras 2015/16 e 2016/17 (Tabelas 3 e 6), comparando o Modelo 15 com o Modelo 12, observou-se que com o uso do Modelo 15 houve redução dos valores estimados para os coeficientes  $\hat{\rho}_r$  e  $\hat{\rho}_c$ , ou seja, redução na autocorrelação residual entre parcelas vizinhas. Além disso, com o Modelo 15 a estimativa de variância de blocos ( $\hat{\sigma}_b^2$ ) acomodou parte da variância total, reduzindo as variâncias residuais devido aos erros independentes ( $\hat{\sigma}_\eta^2$ ) e devido aos efeitos aleatórios de tendência ( $\hat{\sigma}_\xi^2$ ).

Na safra 2015/16, comparando o Modelo 15 com o Modelo 12, observou-se que a inclusão do efeito de blocos no Modelo 15 fez com que os componentes de variância de erros independentes ( $\hat{\sigma}_\eta^2$ ), variância genotípica ( $\hat{\sigma}_g^2$ ), variância de blocos ( $\hat{\sigma}_b^2$ ) e variância dos efeitos aleatórios de tendência ( $\hat{\sigma}_\xi^2$ ) fossem melhor estimados. Isso pode ser verificado na Tabela 3, onde  $\hat{\sigma}_\eta^2$  tendeu a zero no Modelo 15, além de que as estimativas  $\hat{\sigma}_g^2$  e  $\hat{\sigma}_\xi^2$  foram maiores nesse modelo. Apesar de  $\hat{\sigma}_\xi^2$  ser maior no Modelo 15, a soma dos componentes de variâncias residuais ( $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ ) foi menor no Modelo 15 em relação ao Modelo 12 (Tabela 3).

Na safra 2016/17, também observou-se que o efeito de blocos no Modelo 15 foi capaz de remover parte dos valores de  $\hat{\sigma}_\eta^2$  e  $\hat{\sigma}_\xi^2$  estimados com o Modelo 12 (Tabela 6). Nesta safra, a inclusão do efeito de blocos no Modelo 15 também influenciou na redução de  $\hat{\sigma}_g^2$ , evidenciando que no Modelo 12 parte da variação identificada como de natureza genética estava confundida com uma fração da variação de blocos.

Comparando-se os coeficientes de autocorrelação dos modelos 12 e 15 na safra 2016/17, verificou-se que o valor de  $\hat{\rho}_r = 0,91$  (de elevada magnitude e positiva) no Modelo 12, passou para  $\hat{\rho}_r = -0,24$  (de baixa magnitude e negativa) no Modelo 15 (Tabela 6). Esse resultado evidencia que o delineamento em látice parcialmente

balanceado foi capaz de remover os efeitos de tendência espacial entre linhas. Segundo Resende et al. (2014), a heterogeneidade espacial ambiental causa autocorrelações positivas, ao passo que os efeitos de competição entre plantas vizinhas causam autocorrelações negativas.

Esses resultados evidenciam que associar a informação do delineamento em látice parcialmente balanceado à análise espacial pode melhorar o controle da variação residual nos experimentos conduzidos em solos com baixo teor de P. Resende & Sturion (2003), considerando análise espacial pelo processo AR1 × AR1 e delineamentos em blocos casualizados (DBC), concluíram ser necessário preservar a informação do delineamento na análise espacial. Esses autores também verificaram que a análise espacial removeu toda a variação ambiental entre parcelas dentro de blocos, porém não removeu a variação entre blocos.

Apesar de constatadas as vantagens em considerar o delineamento de látice parcialmente balanceado juntamente com a análise espacial nas safras 2015/16 e 2016/17, verificou-se que na safra 2017/18 (comparando o Modelo 15 com o 12) a variância de blocos estimada pelo Modelo 15 foi próxima de zero e não contribuiu para reduzir  $\hat{\sigma}_\eta^2$ ,  $\hat{\sigma}_\xi^2$  e os coeficientes  $\hat{\rho}_r$  e  $\hat{\rho}_c$  (Tabela 9). Porém, os coeficientes de autocorrelação estimados pelo Modelo 12, na safra 2017/18, foram de menores magnitudes em relação às outras safras, evidenciando menor efeito de tendência espacial no ensaio conduzido em baixo teor de P nessa safra.

Considerando as comparações das estimativas dos coeficientes  $\hat{\rho}_r$  e  $\hat{\rho}_c$  dos modelos 12 e 15, nas três safras, observou-se que quando os efeitos de tendência local são elevados (safras 2015/16 e 2016/17), o delineamento em látice parcialmente balanceado é capaz de remover parte desses efeitos de tendência, reduzindo os coeficientes de autocorrelação residual. No entanto, se os efeitos de tendência local são pequenos ou moderados (safra 2017/18), considerar o delineamento em látice na análise

dos dados não permite reduções nos efeitos de tendência local. Assim, como relatam Resende et al. (2018), percebe-se que considerar somente o delineamento em blocos incompletos pode não permitir uma avaliação completa dos efeitos de tendência espacial sobre os dados, sendo necessário também considerar a análise estatística espacial.

Os efeitos de tendência global de linhas e de colunas foram não significativos considerando os modelos ajustados (5, 8, 13 e 16) que incluíam esses efeitos. Esses resultados indicam que os efeitos de tendência global de linhas e colunas não foram importantes na análise dos experimentos de VCU de híbridos de milho da Embrapa Milho e Sorgo, conduzidos em condições de baixo teor de P no solo, nas três safras consideradas.

## 5. Discussão

Em geral, os delineamentos experimentais usados em ensaios de competição de genótipos consideram os três princípios básicos da experimentação propostos por Fisher (1935): casualização, repetição e controle local. Assim, os modelos estatísticos tradicionais para análise de dados de ensaios desta natureza estimam os resíduos (erro experimental) com base nas repetições e assumem que os mesmos são independentes, dada a casualização dos genótipos (tratamentos) nas parcelas experimentais. É comum nesses ensaios que a área experimental apresente algum tipo de variação. O controle local utilizando a blocagem *a priori* (delineamentos em blocos casualizados, blocos incompletos, quadrado latino e outros) visa controlar variações que ocorrem na área experimental, com o princípio de que as condições dentro de cada bloco sejam homogêneas.

No delineamento em quadrado latino, o número de repetições é igual ao número de tratamentos. Isto associado à casualização dos tratamentos dentro de cada linha e de cada coluna, permite controlar variações em duas direções perpendiculares na área experimental (linhas, em uma direção, e colunas, na outra) (PIMENTEL-GOMES, 2009).

Essas variações são modeladas através de estrutura de médias e são definidas como variações de larga-escala ou de tendência global (GRONDONA et al., 1996). Entretanto, o delineamento em quadrado latino tem limitações em experimentação no melhoramento de plantas (RAMALHO et al., 2012a), pois nesses experimentos, em geral, se avalia um elevado número de genótipos (tratamentos). Pimentel-Gomes (2009) relata que em geral não se usam quadrados latinos para os casos em que o número de tratamentos é superior a oito, pois então o número de repetições seria exagerado.

Mesmo quando a variação espacial do solo for bem caracterizada e os experimentos delineados adequadamente, ainda há variações entre parcelas que não podem ser preditas *a priori* (COOPER et al., 2014), como, por exemplo, ocorrência de pragas e doenças, competição entre e dentro de parcelas, falhas de plantas na parcela, desuniformidade na distribuição de água na irrigação e pequenas manchas na fertilidade do solo (RAMALHO et al., 2012a), as quais podem comprometer a independência dos resíduos entre as parcelas. Estas variações, quando oriundas de uma estrutura de correlação espacial, são definidas por Grondona et al. (1996) como variações de pequena-escala ou de tendência local.

Em ensaios sob estresses abióticos, como exemplo, em condições de deficiência de nutrientes, as manchas de fertilidade no solo contribuem sobremaneira para aumentar as tendências locais, causando autocorrelação positiva entre parcelas vizinhas. Segundo Resende & Sturion (2003), autocorrelações altas e positivas indicam padrões de variabilidade espacial em gradientes ou em manchas. Nessa situação, os modelos espaciais têm se destacado (GRONDONA et al., 1996; GILMOUR et al., 1997; QIAO et al., 2000; RESENDE & STURION, 2003; LIU et al., 2015; BIAN et al., 2017; CHEN et al., 2018; FUKATSU et al., 2018). Em experimentos com a cultura do milho, além da heterogeneidade de fertilidade do solo, a desuniformidade de estande nas parcelas

experimentais é uma importante fonte que contribui para aumentar o erro experimental (RAMALHO et al., 2012a).

Neste trabalho foi observado elevada variação de estande (plantas ha<sup>-1</sup>) nas parcelas nas três safras avaliadas, com valores de amplitude de 47619, 34014 e 40816, nas respectivas safras de 2015/16, 2016/17 e 2017/18. Entretanto, o efeito de genótipos sobre a variável estande foi não significativo pelo teste da razão de verossimilhança para a maioria dos modelos ajustados nas três safras, indicando que a variação no estande (variação no número de plantas nas parcelas) foi predominantemente ao acaso, ou seja, não devida ao efeito de genótipos.

Na cultura do milho parece não haver uma proporcionalidade linear entre o número de plantas e a produtividade de grãos. Morais et al. (1986) relataram acréscimo de 24,5% e 32,5% na produção de plantas vizinhas às falhas devido à ausência de competição, considerando, respectivamente, os cultivares AG 7071 e AG 301. Esses mesmos autores também relataram variação na taxa de compensação para a cultivar de milho BR 200 em função de diferentes safras, com valores de 0,358 e 0,156 nos ensaios conduzidos nos anos agrícolas de 1982/83 e 1983/84, respectivamente. Vencovsky & Cruz (1991) afirmam que para uma correção mais precisa da produtividade em função do estande deve-se considerar tanto o decréscimo na produção, devido a presença de falhas, quanto o acréscimo obtido nas plantas vizinhas às falhas, em razão da ausência de competição. Assim, esses autores recomendam o uso do estande como covariável em modelos para correção da produtividade de grãos. Além disso, recomendam que a correção deve ser feita unicamente quando as variações nos estandes forem proporcionadas pelo acaso, de modo que não se deve proceder as correções quando as falhas nos estandes são inerentes aos próprios genótipos avaliados.

Cabe ressaltar que diferentemente dos métodos tradicionais de ANOVA, nos modelos ajustados via metodologias de modelos mistos, a correção da produtividade de

grãos considerando o estande como covariável é feita de forma simultânea com as estimativas dos componentes de variância e predição dos valores genotípicos (BLUPs). Neste trabalho, comparando-se os modelos correspondentes (com e sem inclusão da covariável), as estimativas de acurácia seletiva considerando os diferentes modelos ajustados para as três safras foram, em geral, superiores nos modelos em que o estande foi incluído como covariável (Tabelas 3, 6 e 9).

Neste trabalho foram utilizados os critérios AIC, herdabilidade, acurácia seletiva e valor-p para a escolha do melhor modelo, considerando o efeito de estande e análise espacial em dados de ensaios de VCU de híbridos de milho da Embrapa Milho e Sorgo, conduzidos em áreas de baixo teor de P no solo nas safras 2015/16, 2016/17 e 2017/18.

Segundo Resende et al. (2014), a partir de um conjunto de modelos candidatos que possuem a mesma estrutura de efeitos fixos, a seleção daquele modelo mais adequado pode ser realizada por meio de critérios como: o critério de informação de Akaike (AIC) (AKAIKE, 1974) e o critério de informação Bayesiano (BIC) (SCHWARZ, 1978). Segundo Burnham & Anderson (2004), BIC seria o melhor critério para a escolha de modelos, caso o verdadeiro modelo esteja entre aqueles sob consideração. No entanto, se esse não for o caso, o AIC deve ser preferido. Segundo Vrieze (2012), quando o modelo verdadeiro é complexo, envolvendo efeitos de elevada, moderada e baixa magnitude, e os modelos candidatos são simplificados em relação ao verdadeiro, o AIC deve ser preferido em relação ao BIC. De modo geral, espera-se que um modelo verdadeiro, que explique por completo os dados de experimentos conduzidos no campo, seja um modelo muito complexo.

Quando o objetivo é comparar modelos com diferentes efeitos fixos, alguns critérios de natureza genética, como herdabilidade e acurácia de seleção, podem ser usados. Esses critérios são mais pertinentes na escolha de modelos aplicados a dados oriundos de experimentação no melhoramento genético. Resende & Sturion (2003)

consideraram a eficiência de um dado modelo em função do incremento no valor da herdabilidade em relação a um modelo básico, ou seja, modelos que garantem maiores estimativas de herdabilidade devem ser preferidos. Assim como a herdabilidade, maiores valores de acurácia seletiva encontrados em análise de dados também indicam a superioridade de modelos estatísticos.

Na escolha do melhor modelo em cada uma das três safras, inicialmente foi observado o menor valor de AIC dentro de cada grupo de modelos ajustados (grupos com e sem a covariável estande). Para o grupo de modelos sem covariável estande, o Modelo 6 foi o de menor valor de AIC nas safras 2015/16 e 2016/17 e o Modelo 3 na safra 2017/18. Já para o grupo de modelos com a covariável estande, os modelos que se destacaram com menor AIC foram o Modelo 14 nas safras 2015/16 e 2016/17 e o Modelo 11 na safra 2017/18. Ressalta-se que a comparação entre modelos de grupos diferentes (modelo 6 vs. 14 e modelo 3 vs. 11) não pode ser feita pelo critério de AIC, uma vez que esses modelos a serem comparados não têm a mesma estrutura de efeitos fixos. Nesta situação, o modelo mais promissor foi identificado pelos maiores valores de herdabilidade e de acurácia seletiva e os menores valores de valor-p. Assim, o modelo escolhido foi o 14 nas safras 2015/16 e 2016/17 e o modelo 11 na safra 2017/18.

A análise estatística espacial em duas dimensões foi inicialmente proposta por Cullis & Gleeson (1991), sendo que os autores propuseram a modelagem dos resíduos por processo autorregressivo integrado de médias móveis em duas dimensões:  $ARIMA(p_1, d_1, q_1) \times ARIMA(p_2, d_2, q_2)$ . Estudando várias subclasses do modelo proposto por Cullis & Gleeson (1991), Grondona et al. (1996) identificaram que o modelo autorregressivo separável de primeira ordem em duas dimensões ( $AR1 \times AR1$ ) frequentemente apresentou melhor desempenho em relação a outras subclasses.

Com base nos resultados deste trabalho, percebe-se que em experimentos em condições de baixo P no solo é mais adequado considerar uma estrutura de erros

correlacionados ao invés de admitir independência entre resíduos. A modelagem da matriz de covariância residual pelo processo autorregressivo separável de primeira ordem em duas dimensões (AR1 × AR1) garantiram melhores resultados em relação aos modelos tradicionais que admitem resíduos independentes e modelam a matriz de covariância residual como uma matriz diagonal. A melhor adequabilidade dos modelos AR1 × AR1 em relação aos modelos tradicionais era esperada nos ensaios considerados neste trabalho, sendo que frequentemente ocorrem manchas de fertilidade do solo dentro de áreas experimentais com baixos teores de nutrientes (VIANA et al., 2009), o que leva a presença de autocorrelações positivas entre unidades experimentais (RESENDE et al., 2014). A eficácia de modelos AR1 × AR1 tem sido constatada na análise estatística de vários experimentos de campo em melhoramento de plantas (GRONDONA et al., 1996; GILMOUR et al., 1997; QIAO et al., 2000; RESENDE & STURION, 2003; LIU et al., 2015; BIAN et al., 2017; CHEN et al., 2018; FUKATSU et al., 2018).

Nos resultados apresentados neste trabalho, verificou-se que em modelos que consideram o delineamento em blocos casualizados, a inclusão de  $\eta$  contribui para aumentar as estimativas de autocorrelações de linhas ( $\hat{\rho}_r$ ) e colunas ( $\hat{\rho}_c$ ). Segundo Resende & Sturion (2003), com a inclusão de  $\eta$  no modelo a ser ajustado,  $\hat{\sigma}_\eta^2$  é estimado à parte e a estimativa da autocorrelação aumenta em magnitude em relação a autocorrelação estimada com base no modelo sem o ajuste de  $\eta$ . Consideremos um exemplo com nove unidades experimentais, distribuídas em três linhas e três colunas, como demonstrado no esquema a seguir (Quadro 1):

**Quadro 1.** Exemplo: croqui de uma área experimental com nove unidades experimentais (parcelas) distribuídas em três linhas e três colunas

|         | Coluna 1 | Coluna 2 | Coluna 3 |
|---------|----------|----------|----------|
| Linha 1 | 1        | 4        | 7        |
| Linha 2 | 2        | 5        | 8        |
| Linha 3 | 3        | 6        | 9        |

Nessa situação, a modelagem da matriz de covariância residual depende inicialmente das matrizes de autocorrelações em colunas ( $\Sigma_c(\rho_c)$ ) e em linhas ( $\Sigma_r(\rho_r)$ ):

$$\Sigma_c(\rho_c) = \begin{bmatrix} 1 & \rho_c & \rho_c^2 \\ \rho_c & 1 & \rho_c \\ \rho_c^2 & \rho_c & 1 \end{bmatrix} ; \quad \Sigma_r(\rho_r) = \begin{bmatrix} 1 & \rho_r & \rho_r^2 \\ \rho_r & 1 & \rho_r \\ \rho_r^2 & \rho_r & 1 \end{bmatrix}$$

Assim, a modelagem da matriz de covariância residual será dada por  $R = \Sigma = \sigma_\xi^2[\Sigma_c(\rho_c) \otimes \Sigma_r(\rho_r)] + I\sigma_\eta^2$ , de modo que teremos a seguinte matriz  $\Sigma_{(9 \times 9)}$ :

$$\Sigma = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \\ 7 \\ 8 \\ 9 \end{matrix} & \begin{bmatrix} \sigma_\xi^2 + \sigma_\eta^2 & \sigma_\xi^2 \rho_r & \sigma_\xi^2 \rho_r^2 & \sigma_\xi^2 \rho_c & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c \rho_r^2 & \sigma_\xi^2 \rho_c^2 & \sigma_\xi^2 \rho_c^2 \rho_r & \sigma_\xi^2 \rho_c^2 \rho_r^2 \\ \sigma_\xi^2 \rho_r & \sigma_\xi^2 + \sigma_\eta^2 & \sigma_\xi^2 \rho_r & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c^2 \rho_r & \sigma_\xi^2 \rho_c^2 & \sigma_\xi^2 \rho_c^2 \rho_r \\ \sigma_\xi^2 \rho_r^2 & \sigma_\xi^2 \rho_r & \sigma_\xi^2 + \sigma_\eta^2 & \sigma_\xi^2 \rho_c \rho_r^2 & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c & \sigma_\xi^2 \rho_c^2 \rho_r^2 & \sigma_\xi^2 \rho_c^2 \rho_r & \sigma_\xi^2 \rho_c^2 \\ \sigma_\xi^2 \rho_c & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c \rho_r^2 & \sigma_\xi^2 + \sigma_\eta^2 & \sigma_\xi^2 \rho_r & \sigma_\xi^2 \rho_r^2 & \sigma_\xi^2 \rho_c & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c \rho_r^2 \\ \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_r & \sigma_\xi^2 + \sigma_\eta^2 & \sigma_\xi^2 \rho_r & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c & \sigma_\xi^2 \rho_c \rho_r \\ \sigma_\xi^2 \rho_c \rho_r^2 & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c & \sigma_\xi^2 \rho_r^2 & \sigma_\xi^2 \rho_r & \sigma_\xi^2 + \sigma_\eta^2 & \sigma_\xi^2 \rho_c \rho_r^2 & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c \\ \sigma_\xi^2 \rho_c^2 & \sigma_\xi^2 \rho_c^2 \rho_r & \sigma_\xi^2 \rho_c^2 \rho_r^2 & \sigma_\xi^2 \rho_c & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c \rho_r^2 & \sigma_\xi^2 + \sigma_\eta^2 & \sigma_\xi^2 \rho_r & \sigma_\xi^2 \rho_r^2 \\ \sigma_\xi^2 \rho_c^2 \rho_r & \sigma_\xi^2 \rho_c^2 & \sigma_\xi^2 \rho_c^2 \rho_r & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_r & \sigma_\xi^2 + \sigma_\eta^2 & \sigma_\xi^2 \rho_r \\ \sigma_\xi^2 \rho_c^2 \rho_r^2 & \sigma_\xi^2 \rho_c^2 \rho_r & \sigma_\xi^2 \rho_c^2 & \sigma_\xi^2 \rho_c \rho_r^2 & \sigma_\xi^2 \rho_c \rho_r & \sigma_\xi^2 \rho_c & \sigma_\xi^2 \rho_r^2 & \sigma_\xi^2 \rho_r & \sigma_\xi^2 + \sigma_\eta^2 \end{bmatrix} \end{matrix}$$

Com base na matriz  $\Sigma$  apresentada, quando  $\hat{\sigma}_\eta^2$  é estimado à parte, as autocorrelações de linhas e de colunas podem ser encontradas considerando unidades experimentais vizinhas de primeira ordem em linhas e colunas, respectivamente. Assim, tomando como exemplo as unidades experimentais 1 e 2 (Quadro 1), vizinhas de primeira ordem no sentido de linhas, a autocorrelação entre linhas a partir de um modelo com o ajuste de  $\eta$  ( $\rho_r$  (com  $\eta$ )) pode ser encontrada pela razão entre a covariância residual das parcelas 1 e 2 ( $\sigma_\xi^2 \rho_r$ ) e a variância dos efeitos aleatórios de tendência associada a parcela

1 ( $\sigma_\xi^2$ ), de acordo com a expressão:  $\rho_r$  (com  $\eta$ ) =  $\frac{\sigma_\xi^2 \rho_r}{\sigma_\xi^2} = \rho_r$ . No entanto, em um modelo

sem o ajuste de  $\eta$ ,  $\hat{\sigma}_\eta^2$  é omitida do modelo e a variância correlacionada ( $\hat{\sigma}_\xi^2$ ) tem que acomodar toda a variância residual (RESENDE & STURION, 2003). Assim, de acordo com Resende & Sturion (2003), a autocorrelação entre linhas a partir de um modelo sem o ajuste de  $\eta$  ( $\rho_{r(sem\ \eta)}$ ) é dada por:  $\rho_{r(sem\ \eta)} = \frac{\sigma_\xi^2 \rho_r}{\sigma_\xi^2 + \sigma_\eta^2}$ . Desse modo, verifica-se que  $\rho_{r(com\ \eta)}$  é maior que  $\rho_{r(sem\ \eta)}$ , de modo que pode ser necessário incluir  $\eta$  no modelo quando  $\sigma_\eta^2$  apresentar alta magnitude (RESENDE & STURION, 2003). Situação semelhante também pode ser verificada para  $\rho_{c(com\ \eta)}$  e  $\rho_{c(sem\ \eta)}$  considerando unidades experimentais vizinhas de primeira ordem no sentido de colunas, como as parcelas 1 e 4 por exemplo.

Nos resultados apresentados neste trabalho, verificou-se que em situações que estão presentes autocorrelações entre linhas e entre colunas ( $\rho_r$  e  $\rho_c$ ) de elevada magnitude (safras 2015/16 e 2016/17), os modelos espaciais que consideram o delineamento de látice quadrado parcialmente balanceado (blocos incompletos) reduzem as estimativas dos coeficientes de autocorrelação. Além disso, utilizar a informação desse delineamento contribuiu para reduções das estimativas de variâncias residuais devido aos erros independentes ( $\hat{\sigma}_\eta^2$ ) e devido aos efeitos aleatórios de tendência ( $\hat{\sigma}_\xi^2$ ).

Os delineamentos de blocos incompletos, como o látice quadrado parcialmente balanceado, foram propostos para os casos em que há um grande número de tratamentos e a área experimental impossibilita delinear blocos completos uniformes em toda sua extensão (PIMENTEL-GOMES, 2009). Assim, a utilização de blocos menores (blocos incompletos) pelo delineamento de látice quadrado, por exemplo, favorece uma redução da heterogeneidade ambiental dentro de blocos (RAMALHO et al., 2012a), fato que contribui para reduções de variâncias residuais. Nos experimentos deste trabalho, conduzidos em condições de baixo teor de P no solo, percebe-se que a adoção do delineamento de látice quadrado parcialmente balanceado pode contribuir para redução

do efeito de manchas de fertilidade dentro de blocos. Assim, esse delineamento de blocos incompletos é capaz de remover parte do fator responsável pelas altas estimativas de autocorrelações ( $\hat{\rho}_r$  e  $\hat{\rho}_c$ ) e variâncias residuais ( $\hat{\sigma}_\eta^2$  e  $\hat{\sigma}_\xi^2$ ) presentes em modelos que consideram apenas o delineamento de blocos completos casualizados.

Segundo Borges et al. (2019), a heterogeneidade do campo experimental, associada ao tamanho do experimento, determina o desempenho do uso de delineamentos e de análise espacial, de modo que a maior variabilidade do campo experimental não controlada com algum delineamento experimental possivelmente induz maior viés na estimação de efeitos genotípicos. Assim como verificado nos resultados deste trabalho, alguns autores relatam que o desempenho de modelos estatísticos melhora quando se combina um delineamento experimental adequado com a modelagem espacial (GILMOUR et al., 1997; QIAO et al., 2000; WILLIAMS et al., 2006; BORGES et al., 2019). Desse modo, Borges et al. (2019) relatam que a modelagem espacial deve ser considerada como uma estratégia suplementar ao invés de uma alternativa aos delineamentos experimentais.

Em um programa de melhoramento de plantas, os ensaios de VCU fornecem a base para classificação dos genótipos, que é crucial para a recomendação de novos cultivares. Também nessa fase, a predição de valores genotípicos mais acurados garante a recomendação de novos cultivares de forma mais confiável. Neste trabalho, a análise espacial associada à inclusão da covariável estande apresentou resultados mais satisfatórios, uma vez que o melhor modelo selecionado em cada safra apresentou maiores estimativas de acurácia comparado aos modelos tradicionais de blocos casualizados e látice parcialmente balanceado (Tabelas 3, 6 e 9). Ainda cabe ressaltar que a partir dos valores genotípicos preditos com o modelo selecionado em cada safra, houve variações no ranqueamento dos híbridos avaliados em relação ao ranqueamento dos modelos

tradicionais, inclusive variações dos quatro híbridos de maior valor genotípico, o que compromete a recomendação de novos híbridos.

Nos experimentos utilizados neste trabalho, avaliados em condições de baixo P, a análise espacial via modelos  $AR1 \times AR1$ , associada ao delineamento de látice quadrado parcialmente balanceado e ao efeito da covariável estande, foi capaz de desinflacionar as estimativas de variâncias residuais e, em consequência, levou a obtenção de valores genotípicos mais acurados.

## **6. Conclusão**

Associar o delineamento de blocos incompletos (látice) e uso do estande como covariável ao modelo autorregressivo separável de primeira ordem em duas dimensões ( $AR1 \times AR1$ ), contribuiu para aumentar a acurácia seletiva em experimentos de híbridos de milho avaliados em condições de baixo teor de P no solo, visando a recomendação de novos cultivares.

## 7. Referências

- AKAIKE, H. A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, v. 19, p. 716-723, 1974.
- ALVAREZ V., V.H.; NOVAIS, R.F.; BARROS, N.F.; CANTARUTTI, R.B.; LOPES, A.S. Interpretação dos resultados das análises de solos. In: RIBEIRO, A.C.; GUIMARÃES, P.T.G.; ALVAREZ V., V.H. (eds). **Recomendação para uso de corretivos e fertilizantes em Minas Gerais – 5ª aproximação**. Viçosa, MG: Comissão de Fertilidade do Solo do Estado de Minas Gerais – CFSEMG, 359 p., 1999.
- ARAÚJO, A.P.; MACHADO, C.T.T. Fósforo. In: FERNANDES, M.S. (ed). **Nutrição mineral de plantas**. Sociedade Brasileira de Ciência do Solo, Viçosa, MG, 432p., 2006.
- BIAN, L.; ZHENG, R.; SU, S.; LIN, H.; XIAO, H.; WU, H.X.; SHI, J. Spatial analysis increases efficiency of progeny testing of Chinese fir. **Journal of Forestry Research**, v. 28, n. 3, p. 445-452, 2017.
- BORÉM, A.; RAMALHO, M.A.P. Estresses abióticos: desafios do melhoramento de plantas nas próximas décadas. In: FRITSCHÉ-NETO, R.; BORÉM, A. (eds). **Melhoramento de plantas para condições de estresses abióticos**. Editora Suprema, Visconde do Rio Branco, MG, 250p., 2011.
- BORGES, A.; GONZÁLEZ-REYMUÑDEZ, A.; ERNST O.; CADENAZZI, M.; TERRA, J.; GUTIÉRREZ, L. Can Spatial Modeling Substitute for Experimental Design in Agricultural Experiments?. **Crop Science**, v. 59, n. 1, p. 44-53, 2019.
- BURNHAM, K.P.; ANDERSON, D.R. Multimodel inference: understanding AIC and BIC in model selection. **Sociological methods & research**, v. 33, n. 2, p. 261-304, 2004.
- BUTLER, D.G.; CULLIS, B.R.; GILMOUR, A.R.; GOGEL, B.J. ASReml-R reference manual. **The State of Queensland, Department of Primary Industries and Fisheries, Brisbane**, 2009.
- CAVATTE, P.C.; MARTINS, S.C.V.; MORAIS, L.E.; SILVA, P.E.M.; SOUZA, L.T.; DAMATTA, F.M. A fisiologia dos estresses abióticos. In: FRITSCHÉ-NETO, R.; BORÉM, A. (eds). **Melhoramento de plantas para condições de estresses abióticos**. Editora Suprema, Visconde do Rio Branco, MG, 250p., 2011.
- CHEN, Z.; HELMERSSON, A.; WESTIN, J.; KARLSSON, B.; WU, H.X. Efficiency of using spatial analysis for Norway spruce progeny tests in Sweden. **Annals of forest science**, v. 75, n. 1, p. 2, 2018.
- COOPER, M.; MESSINA, C.D.; PODLICH, D.; TOTIR, L.R.; BAUMGARTEN, A.; HAUSMANN, N.J.; WRIGHT, D.; GRAHAM, G. Predicting the future of plant breeding: complementing empirical evaluation with genetic prediction. **Crop and Pasture Science**, v. 65, n. 4, p. 311-336, 2014.
- CRUZ, C.D.; CARNEIRO, P.C.S.; REGAZZI, A.J. **Modelos Biométricos Aplicados ao Melhoramento Genético**. 3 ed. Viçosa: Ed. UFV, v. 2, 668 p., 2014.

CRUZ, C.D. GENES - a software package for analysis in experimental statistics and quantitative genetics. **Acta Scientiarum**. v.35, n.3, p.271-276, 2013.

CULLIS, B. R.; GLEESON, A. C. Spatial analysis of field experiments-an extension to two dimensions. **Biometrics**, p. 1449-1460, 1991.

DECHEN, A.R.; NACHTIGALL, G.R. Elementos requeridos à nutrição de plantas. In: NOVAIS, R.F.; ALVAREZ V.,V.H.; BARROS, N. F.; FONTES, R.L.F.; CANTARUTTI, R.B.; NEVES, J.C.L. (eds). **Fertilidade do solo**. Sociedade Brasileira de Ciência do Solo, Viçosa, MG, 1017p., 2007.

EMBRAPA. **Sistema brasileiro de classificação de solos**. 2.ed. Rio de Janeiro: Embrapa Solos, 306 p., 2006.

FISHER, R.A. **The design of experiments**. Oliver and Boyd, Oxford, UK. 1935.

FUKATSU, E.; HIRAOKA, Y.; KURAMOTO, N.; YAMADA, H.; TAKAHASHI, M. Effectiveness of spatial analysis in *Cryptomeria japonica* D. Don (sugi) forward selection revealed by validation using progeny and clonal tests. **Annals of Forest Science**, v. 75, n. 4, p. 96, 2018.

GILMOUR, A.R.; CULLIS, B.R.; VERBYLA, A.P. Accounting for natural and extraneous variation in the analysis of field experiments. **J Agric Biol Environ Stat**, v. 2, n. 3, p. 269-293, 1997.

GILMOUR, A.R.; GOGEL, B.J.; CULLIS, B.R.; WELHAM, S.J.; THOMPSON, R. ASReml User Guide Release 1.0. VSN International, 5 The Waterhouse, Waterhouse St, Hemel Hempstead, HP1 1ES, UK, 2002.

GRONDONA, M.O.; CROSSA, J.; FOX, P.N.; PFEIFFER, W.H. Analysis of variety yield trials using two-dimensional separable ARIMA processes. **Biometrics**, p. 763-770, 1996.

HENDERSON, C.R. **Applications of linear models in animal breeding**. Guelph: University of Guelph, 1984.

LIU, S.M.; CONSTABLE, G.A.; CULLIS, B.R.; STILLER, W.N.; REID, P.E. Benefit of spatial analysis for furrow irrigated cotton breeding trials. **Euphytica**, v. 201, n. 2, p. 253-264, 2015.

MENDES, F.F.; GUIMARÃES, L.J.M.; SOUZA, J.C.; GUIMARÃES, P.E.O.; MAGALHÃES, J.V.; GARCIA, A.A.F.; PARENTONI, S.N.; GUIMARAES, C.T. Genetic architecture of phosphorus use efficiency in tropical maize cultivated in a low-P soil. **Crop Science**, v. 54, n. 4, p. 1530-1538, 2014.

MORAIS, A.R.; OLIVEIRA, A.C.; CRUZ, J.C. Correção de produções de grãos de milho em parcelas experimentais. **Relatório Técnico Anual do Centro Nacional de Pesquisa de Milho e Sorgo 1980-1984**. Sete Lagoas, MG: CNPMS, p. 130-132, 1986.

NOVAIS, R.F.; SMYTH, T.J.; NUNES, F.N. Fósforo. In: NOVAIS, R.F.; ALVAREZ V.V.H.; BARROS, N. F.; FONTES, R.L.F.; CANTARUTTI, R.B.; NEVES, J.C.L. (eds). **Fertilidade do solo**. Sociedade Brasileira de Ciência do Solo, Viçosa, MG, 1017 p., 2007.

PARENTONI, S.N.; SOUZA JÚNIOR, C.L. Phosphorus acquisition and internal utilization efficiency in tropical maize genotypes. **Pesquisa Agropecuária Brasileira**, v. 43, n. 7, p. 893-901, 2008.

PARENTONI, S.N.; MENDES, F.F.; GUIMARÃES, L.J.M. Melhoramento para eficiência no uso de fósforo. In: FRITSCHÉ-NETO, R.; BORÉM, A. (eds). **Melhoramento de plantas para condições de estresses abióticos**. Editora Suprema, Visconde do Rio Branco, MG, 250p., 2011.

PIMENTEL-GOMES, F. **Curso de estatística experimental**. 15. Ed. Piracicaba, SP: FEALQ, 2009. 451p.

QIAO, C.G.; BASFORD, K.E.; DELACY, I.H.; COOPER, M. Evaluation of experimental designs and spatial analyses in wheat breeding trials. **Theoretical and Applied Genetics**, v. 100, n. 1, p. 9-16, 2000.

R Core Team. **R: A language and environment for statistical computing**. R Found. Stat. Comput., Vienna. 2018.

RAMALHO, M.A.P.; FERREIRA, D.F.; OLIVEIRA, A.C. **Experimentação em Genética e Melhoramento de Plantas**. 3. Ed. Lavras, MG: Ed. UFLA, 2012a. 328p.

RESENDE, M.D.V.; STURION, J.A. Análise estatística espacial de experimentos via modelos mistos individuais com erros modelados por processos ARIMA em duas dimensões. **Rev. Mat. Estat.**, v. 21, n. 1, p. 7-33, 2003.

RESENDE, M.D.V.; SILVA, F.F.; AZEVEDO, C.F. **Estatística matemática, biométrica e computacional: modelos mistos, multivariados, categóricos e generalizados (REML/BLUP), inferência Bayesiana, regressão aleatória, seleção genômica, QTL-GWAS, estatística espacial e temporal, competição, sobrevivência**. Viçosa, MG: Suprema, 2014. 881p.

RESENDE, M.D.V.; VIANA, J.M.S.; AZEVEDO, C.F.; SILVA, F.F.; DELIMA, R.O. Modelos Mistos e Inferência Bayesiana. In: DELIMA, R.O.; BORÉM, A. (eds). **Melhoramento de milho**. Ed. UFV, Viçosa, MG, 396 p., 2018.

RESENDE, M.D.V; **Genética biométrica e estatística no melhoramento de plantas perenes**. 1. ed. Embrapa Informação Tecnológica, 2002. 975 p.

SCHWARZ, G. Estimating the dimension of a model. **The annals of statistics**, v. 6, n. 2, p. 461-464, 1978.

VENCOVSKY, R.; CRUZ, C.D. Comparação de métodos de correção do rendimento de parcelas com estandes variados. I. Dados simulados. **Pesquisa Agropecuária Brasileira**, v. 26, n. 5, p. 647-657, 1991.

VERGÜTZ, L.; NOVAIS, R.F. Recomendação corretivos e adubação. In: BORÉM, A.; GALVÃO, J.C.C.; PIMENTEL, M.A. (eds). **Milho: do plantio à colheita**. Ed. UFV, Viçosa, MG, 351 p., 2015.

VIANA, J.H.M.; RESENDE, A.V.; GUIMARÃES, C.T.; PARENTONI, S.N. Avaliação da variabilidade espacial do solo em experimentos de eficiência nutricional em milho, conduzidos em área com baixos teores de nutrientes: um estudo de caso. **Embrapa Milho e Sorgo-Boletim de Pesquisa e Desenvolvimento (INFOTECA-E)**. Sete Lagoas: Embrapa Milho e Sorgo, 2009.

VRIEZE, S.I. Model selection and psychological theory: a discussion of the differences between the Akaike information criterion (AIC) and the Bayesian information criterion (BIC). **Psychological methods**, v. 17, n. 2, p. 228-243, 2012.

WILLIAMS, E. R.; JOHN, J. A.; WHITAKER, David. Construction of resolvable spatial row-column designs. **Biometrics**, v. 62, n. 1, p. 103-108, 2006.

## 8. Material Suplementar

**Anexo I.** Exemplo de como montar o arquivo de dados para análise no ASReML-R. O arquivo contém os dados de produtividade de grãos (pg), dados de estande (st), informações de tratamentos (Trat), repetições (Rep), blocos incompletos do látice (Blocos), Linhas e Colunas. A codificação de linhas deve ser ordenada dentro de colunas, como demonstrado a seguir:

| Trat | Rep | Blocos | Colunas | Linhas | pg   | st    |
|------|-----|--------|---------|--------|------|-------|
| 1    | 1   | 1      | 1       | 1      | 6576 | 64626 |
| 2    | 1   | 1      | 1       | 2      | 3358 | 61224 |
| 3    | 1   | 1      | 1       | 3      | 4638 | 57823 |
| 4    | 1   | 1      | 1       | 4      | 2624 | 47619 |
| 5    | 1   | 1      | 1       | 5      | 4794 | 61224 |
| 6    | 1   | 1      | 1       | 6      | 3615 | 61224 |
| 7    | 1   | 2      | 1       | 7      | 3794 | 57823 |
| 8    | 1   | 2      | 1       | 8      | 4460 | 64626 |
| 9    | 1   | 2      | 1       | 9      | 6083 | 64626 |
| 10   | 1   | 2      | 1       | 10     | 4107 | 61224 |
| 11   | 1   | 2      | 1       | 11     | 4842 | 68027 |
| 12   | 1   | 2      | 1       | 12     | 5039 | 54422 |
| 13   | 1   | 3      | 1       | 13     | 6465 | 68027 |
| 14   | 1   | 3      | 1       | 14     | 8937 | 64626 |
| 15   | 1   | 3      | 1       | 15     | 5109 | 57823 |
| 16   | 1   | 3      | 1       | 16     | 7279 | 51020 |
| 32   | 1   | 6      | 2       | 1      | 5279 | 61224 |
| 31   | 1   | 6      | 2       | 2      | 4831 | 64626 |
| 30   | 1   | 5      | 2       | 3      | 5299 | 40816 |
| ⋮    | ⋮   | ⋮      | ⋮       | ⋮      | ⋮    | ⋮     |

**Anexo II.** Script com os modelos estatísticos propostos neste trabalho. Script para análise no ASReml-R (BUTLER et al., 2009).

```
#####
### Modelos para análise dos ensaios de VCU de híbridos de milho – Baixo Fósforo ###
#####

# Carregar ASReml:
library(asreml)

# Trilha de dados – indicar local do arquivo de dados:
setwd("C:\\Users\\USUARIO\\Desktop\\Baixo Fósforo")

# Função – carregar arquivo de dados (Ex.: dados da safra 2015/16):
dados <- asreml.read.table(file = " Baixo_P_2015-16.txt", h = T)

# Códigos usados para as variáveis e os fatores:
# pg = Produtividade de grãos;
# st = Estande;
# Trat = Tratamentos;
# Rep = Repetições;
# Blocos = Blocos incompletos do látice;
# Linhas;
# Colunas.

#####
##### Ajuste de modelos – Variável Estande #####
#####

##### Modelo 1 - Modelo de blocos casualizados:
m1 <- asreml(fixed = st ~ Rep,
             random = ~ Trat,
             rcov = ~ units,
             data = dados)

##### Modelo 2 - Modelo de látice parcialmente balanceado:
m2 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + Rep:Blocos,
             rcov = ~ units,
             data = dados)
```

##### Modelo 3 – Modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1:

```
m3 <- asreml(fixed = st ~ Rep,
             random = ~ Trat,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

##### Modelo 4 - Modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com a inclusão do termo do erro independente ( $\eta$ ):

```
m4 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

##### Modelo 5 - Modelo de blocos casualizados, com efeitos de linhas e colunas, resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com a inclusão do termo do erro independente ( $\eta$ ):

```
m5 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + Linhas + Colunas + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

##### Modelo 6 - Modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1:

```
m6 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + Rep:Blocos,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

##### Modelo 7 - Modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com a inclusão do termo do erro independente ( $\eta$ ):

```
m7 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + Rep:Blocos + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

##### Modelo 8 - Modelo de látice parcialmente balanceado, com efeitos de linhas e colunas, resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com a inclusão do termo do erro independente ( $\eta$ ):

```
m8 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + Rep:Blocos + Linhas + Colunas + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

```
#####
##### Ajuste de modelos – Produtividade de Grãos #####
#####
```

##### Modelo 1 - Modelo de blocos casualizados:

```
m1 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat,
             rcov = ~ units,
             data = dados)
```

##### Modelo 2 - Modelo de látice parcialmente balanceado:

```
m2 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + Rep:Blocos,
             rcov = ~ units,
             data = dados)
```

##### Modelo 3 – Modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ :

```
m3 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

##### Modelo 4 - Modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ):

```
m4 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

##### Modelo 5 - Modelo de blocos casualizados, com efeitos de linhas e colunas, resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ):

```
m5 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + Linhas + Colunas + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

##### Modelo 6 - Modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ :

```
m6 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + Rep:Blocos,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

##### Modelo 7 - Modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ):

```
m7 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + Rep:Blocos + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

##### Modelo 8 - Modelo de látice parcialmente balanceado, com efeitos de linhas e colunas, resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ):

```
m8 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + Rep:Blocos + Linhas + Colunas + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados)
```

##### Modelo 9 - Modelo de blocos casualizados, incluindo estande como covariável:

```
m9 <- asreml(fixed = pg ~ Rep + st,
             random = ~ Trat,
             rcov = ~ units,
             data = dados)
```

##### Modelo 10 - Modelo de látice parcialmente balanceado, incluindo estande como covariável:

```
m10 <- asreml(fixed = pg ~ Rep + st,
              random = ~ Trat + Rep:Blocos,
              rcov = ~ units,
              data = dados)
```

##### Modelo 11 - Modelo de blocos casualizados, incluindo estande como covariável e resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ :

```
m11 <- asreml(fixed = pg ~ Rep + st,
              random = ~ Trat,
              rcov = ~ ar1(Colunas):ar1(Linhas),
              data = dados)
```

##### Modelo 12 - Modelo de blocos casualizados, incluindo estande como covariável, resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com o termo do erro independente ( $\eta$ ):

```
m12 <- asreml(fixed = pg ~ Rep + st,
              random = ~ Trat + units,
              rcov = ~ ar1(Colunas):ar1(Linhas),
              data = dados)
```

##### Modelo 13 - Modelo de blocos casualizados, incluindo estande como covariável, efeito de linhas, efeito de colunas, resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com o termo do erro independente ( $\eta$ ):

```
m13 <- asreml(fixed = pg ~ Rep + st,
  random = ~ Trat + Linhas + Colunas + units,
  rcov = ~ ar1(Colunas):ar1(Linhas),
  data = dados)
```

##### Modelo 14 - Modelo de látice parcialmente balanceado, incluindo estande como covariável e resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1:

```
m14 <- asreml(fixed = pg ~ Rep + st,
  random = ~ Trat + Rep:Blocos,
  rcov = ~ ar1(Colunas):ar1(Linhas),
  data = dados)
```

##### Modelo 15 - Modelo de látice parcialmente balanceado, incluindo estande como covariável, resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com a inclusão do termo do erro independente ( $\eta$ ):

```
m15 <- asreml(fixed = pg ~ Rep + st,
  random = ~ Trat + Rep:Blocos + units,
  rcov = ~ ar1(Colunas):ar1(Linhas),
  data = dados)
```

##### Modelo 16 - Modelo de látice parcialmente balanceado, incluindo estande como covariável, efeito de linhas, efeito de colunas, resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com o termo do erro independente ( $\eta$ ):

```
m16 <- asreml(fixed = pg ~ Rep + st,
  random = ~ Trat + Rep:Blocos + Linhas + Colunas + units,
  rcov = ~ ar1(Colunas):ar1(Linhas),
  data = dados)
```

#### # Referência:

# BUTLER, D.G.; CULLIS, B.R.; GILMOUR, A.R.; GOGEL, B.J. ASReml-R reference manual. **The State of Queensland, Department of Primary Industries and Fisheries, Brisbane**, 2009.

## **CAPÍTULO II**

### **ANÁLISE ESTATÍSTICA ESPACIAL DE EXPERIMENTOS DE HÍBRIDOS DE MILHO EM CONDIÇÕES DE ALTA ADUBAÇÃO**

## 1. Resumo

A exploração de todo o potencial genético dos híbridos modernos de milho depende de aplicações de quantidades adequadas de fertilizantes no solo, sendo estas consideradas altas adubações. Assim, áreas experimentais sob altas adubações devem ser incluídas nos ensaios de valor de cultivo e uso (VCU) de híbridos de milho, visando representar as condições ideais de fertilidade do solo para a cultura. Nos ensaios de VCU de híbridos de milho, a competição intergenotípica entre parcelas, a variação espacial na fertilidade do solo e a variação espacial na distribuição da água de irrigação, podem causar dependência espacial entre unidades experimentais vizinhas, contribuindo para o aumento da variação residual e tornando os resíduos correlacionados. Nessa situação, uma medida para atenuar esses problemas é o uso da análise espacial pela flexibilização da matriz de covariância residual ( $R$ ), usando-se o modelo autorregressivo separável de primeira ordem em duas dimensões ( $AR1 \times AR1$ ). Assim, o objetivo deste estudo foi avaliar a eficiência de modelos estatísticos espaciais na análise da produtividade de grãos de ensaios de VCU de híbridos de milho conduzidos em áreas sob alta adubação. Neste estudo foram considerados três ensaios de VCU de híbridos de milho (safras 2015/16, 2016/17 e 2017/18) avaliados em condições de alta adubação. Na análise dos ensaios de VCU foram ajustados 16 modelos estatísticos diferentes. Dentre esses, os modelos tradicionais consideraram resíduos independentes (matriz  $R$  diagonal); e os modelos espaciais consideraram a modelagem da matriz  $R$  pelo processo  $AR1 \times AR1$ . Além disso, os modelos diferiram quanto ao delineamento experimental (blocos completos casualizados ou látice); quanto à inclusão de efeitos de tendência global de linhas e colunas; e quanto à inclusão da covariável estande. Nas safras 2015/16 e 2016/17, o ajuste de modelos que consideraram resíduos independentes foram suficientes para a análise da produtividade de grãos, ressaltando-se que na safra 2015/16 o melhor modelo também incluía o estande como covariável. No entanto, na safra 2017/18, o modelo selecionado foi o que considerou delineamento de blocos casualizados, com erros correlacionados modelados pelo processo  $AR1 \times AR1$  e com a inclusão dos erros independentes. Assim, para condições de alta adubação, os modelos espaciais ( $AR1 \times AR1$ ) devem ser testados entre os modelos candidatos às análises estatísticas da produtividade de grãos, de modo que na presença de dependência espacial esta possa ser identificada e tratada adequadamente.

**Palavras-chave:** *Zea mays* L. Tendência espacial. Erros correlacionados. Delineamentos experimentais. Melhoramento de plantas.

## 2. Introdução

Avanços contínuos no melhoramento de plantas, biotecnologia e práticas de manejo cultural têm resultado em elevadas produtividades de grãos na cultura do milho. No entanto, esse aumento de produtividade dos cultivares modernos não tem sido acompanhado pelo manejo correto da fertilidade do solo. Com isto as doses de nutrientes recomendadas nas atuais adubações são menores que o total de nutrientes exportados pela cultura, resultando em significativo decréscimo nos níveis de nutrientes nesses solos ao longo dos anos (BENDER et al., 2013). Segundo Vergütz & Novais (2015), as tabelas tradicionalmente usadas para recomendações de fertilizantes no Brasil (RIBEIRO et al., 1999; RAIJ et al., 1997; SOUZA & LOBATO, 2004; TEDESCO et al., 2004) foram desenvolvidas para materiais genéticos menos produtivos do que os cultivares atuais e, conseqüentemente, recomendam quantidades de fertilizantes menores do que as necessárias para alcançar o máximo de produtividade dos cultivares modernos de milho. Assim, segundo Vergütz & Novais (2015), a exploração de todo o potencial genético dos cultivares modernos de milho, almejando-se altas produtividades, dependerá de aplicações de quantidades adequadas de fertilizantes.

No melhoramento genético do milho, após identificado um genótipo superior (híbrido ou variedade), este só poderá ser produzido e comercializado legalmente no Brasil se estiver registrado no Registro Nacional de Cultivares – RNC (GUIMARÃES, 2018). Uma das exigências para inscrição de cultivares no RNC é a realização dos ensaios de Valor de Cultivo e Uso – VCU (BRASIL, 2019). As áreas experimentais destinadas aos ensaios de VCU devem representar as condições de cultivo do milho. Além disso, somente os ensaios de VCU com coeficiente de variação experimental de até 20% são válidos para a inscrição de cultivares no RNC (BRASIL, 2019). Como o objetivo do ensaio de VCU é caracterizar a superioridade dos genótipos, a precisão experimental e a

acurácia de seleção são fundamentais para garantir a identificação dos genótipos de maior valor genotípico entre os avaliados no ensaio.

Alguns fatores podem reduzir a precisão experimental e a acurácia de seleção nos ensaios de VCU. Segundo Ramalho et al. (2012a), a competição intergenotípica entre parcelas, o número reduzido de repetições, a ocorrência de falhas no estande de parcelas, a variação espacial na fertilidade do solo e na distribuição da água de irrigação, são fatores que contribuem para aumentar o erro experimental e, conseqüentemente, reduzir a precisão experimental e a acurácia de seleção.

Alguns desses fatores, como a competição intergenotípica entre parcelas e a variação espacial na fertilidade do solo e na distribuição da água de irrigação, podem causar dependência espacial entre unidades experimentais vizinhas, contribuindo para o aumento da variação residual e tornando os resíduos de parcelas vizinhas altamente correlacionados. Segundo Resende et al. (2014), a heterogeneidade espacial ambiental causa autocorrelações positivas, ao passo que os efeitos de competição entre parcelas vizinhas causam autocorrelações negativas. Nessa situação, técnicas de análise espacial, através da flexibilização da matriz de covariância residual, permitem contornar a questão e podem propiciar uma seleção mais acurada (RESENDE et al., 2014).

Dentre os vários métodos para modelagem da matriz de covariância residual, o modelo de séries temporais autorregressivo separável de primeira ordem em duas dimensões ( $AR1 \times AR1$ ) tem se destacado (GRONDONA et al., 1996, GILMOUR et al., 1997; RESENDE & STURION, 2003; RESENDE et al., 2018). O modelo  $AR1 \times AR1$  considera um efeito de tendência ( $\xi$ ) mais o erro aleatório independente ( $\eta$ ), de modo que o vetor de resíduos ( $e$ ) é particionado em:  $e = \xi + \eta$  (CULLIS & GLEESON, 1991; GILMOUR et al., 1997). De modo geral, o método de máxima verossimilhança restrita (REML) é usado para estimar os parâmetros do modelo  $AR1 \times AR1$  (RESENDE et al., 2018).

Em experimentos com a cultura do milho, outro fator importante que contribui para aumentar o erro experimental na avaliação de produtividade de grãos é a ocorrência de falhas no estande de parcelas (RAMALHO et al., 2012a). Mesmo adotando-se a técnica de semeadura em excesso, seguida de desbastes para o estande ideal, podem ocorrer fatores aleatórios que contribuem para a ocorrência de falhas nas parcelas (CRUZ et al., 2014). Assim, uma maneira de atenuar o problema de falhas no estande sobre as estimativas de produtividade de grãos, é considerar o efeito de estande nas análises estatísticas, incluindo-o como covariável nos modelos estatísticos (RAMALHO et al., 2012a; CRUZ et al., 2014).

Assim, o objetivo com este estudo foi avaliar a eficiência de modelos estatísticos espaciais na análise da produtividade de grãos de ensaios de VCU de híbridos de milho conduzidos em áreas sob alta adubação, além de avaliar o efeito de estande nesses modelos.

### **3. Material e métodos**

#### **3.1. Material genético e ensaios**

Neste trabalho foram avaliados híbridos de milho desenvolvidos pelo programa de melhoramento da Embrapa Milho e Sorgo (Centro Nacional de Pesquisa de Milho e Sorgo – CNPMS), na fase de ensaios de valor de cultivo e uso (VCU), considerando três safras consecutivas (2015/16, 2016/17 e 2017/18). Em cada safra, o ensaio de VCU foi constituído por 36 híbridos, sendo 32 híbridos experimentais em fase de pré-lançamento e quatro híbridos comerciais utilizados como testemunhas. Ressalta-se que a cada safra (VCU) novos híbridos experimentais foram incluídos e alguns excluídos ao longo dos ensaios de VCU.

Os ensaios foram conduzidos no campo experimental da Embrapa Milho e Sorgo, localizado no município de Sete Lagoas - MG (latitude de 19°26'52" S, longitude

de 44°10'01" W e altitude de 720 m) em Latossolos Vermelho distróficos (EMBRAPA, 2006). O delineamento experimental utilizado em todos os ensaios foi o látice quadrado simples parcialmente balanceado (RAMALHO et al., 2012a). Cada ensaio de VCU foi instalado com  $v = k^2 = 36$  tratamentos, sendo  $v$  o número de tratamentos e  $k$  o número de parcelas por bloco. As parcelas foram constituídas por duas linhas (dois sulcos) de 4,2 metros (m) de comprimento, com espaçamento de 0,70 m entre linhas (sulcos) e semeadura de 5 sementes  $m^{-1}$ . Em cada ensaio, a adubação na semeadura foi constituída de 40  $kg\ ha^{-1}$  de nitrogênio (N), 140  $kg\ ha^{-1}$  de fósforo ( $P_2O_5$ ) e 80  $kg\ ha^{-1}$  de potássio ( $K_2O$ ). A adubação de cobertura foi de 74  $kg\ ha^{-1}$  de N e 74  $kg\ ha^{-1}$  de potássio ( $K_2O$ ). A condição de alta adubação, nos ensaios de VCU desse trabalho, foi estabelecida pela aplicação de níveis adequados de fertilizantes NPK, conforme as recomendações para a cultura do milho (VERGÜTZ & NOVAIS, 2015).

As características avaliadas nos ensaios de VCU foram produção de grãos em quilogramas por parcela, umidade dos grãos em porcentagem, estande em número de plantas, número de plantas acamadas e/ou quebradas, altura de plantas em centímetros, altura de espigas em centímetros, número de dias da semeadura ao florescimento masculino e número de dias da semeadura ao florescimento feminino. A produção de grãos por parcela foi corrigida para 13% de umidade e convertida para produtividade de grãos em quilogramas por hectare ( $kg\ ha^{-1}$ ). O estande, em número de plantas por parcela, também foi convertido para número de plantas por hectare ( $plantas\ ha^{-1}$ ). Para os objetivos deste estudo, foram utilizadas as características produtividade de grãos e estande por hectare.

### 3.2. Modelos lineares mistos espaciais

Segundo Henderson (1984), um modelo linear misto geral é da forma  $y = X\tau + Zu + e$ , com as seguintes distribuições e estruturas de médias e variâncias:

$u \sim N(0, G)$ ;  $e \sim N(0, R)$ ;  $E(y) = X\tau$  e  $Var(y) = V = ZGZ' + R$ , em que:

$y$ : vetor de observações;

$\tau$ : vetor paramétrico dos efeitos fixos, com a matriz de incidência  $X$ ;

$u$ : vetor paramétrico dos efeitos aleatórios, com matriz de incidência  $Z$ ;

$e$ : vetor de erros aleatórios;

$G$ : matriz de covariâncias dos efeitos aleatórios;

$R$ : matriz de covariâncias dos erros aleatórios;

$0$ : vetor nulo.

Assim, conhecendo-se  $G$  e  $R$ , a simultânea estimação dos efeitos fixos e predição dos efeitos aleatórios pode ser obtida pelas equações de modelo misto, dadas por:

$$\begin{bmatrix} X'R^{-1}X & X'R^{-1}Z \\ Z'R^{-1}X & Z'R^{-1}Z + G^{-1} \end{bmatrix} \begin{bmatrix} \hat{\tau} \\ \hat{u} \end{bmatrix} = \begin{bmatrix} X'R^{-1}y \\ Z'R^{-1}y \end{bmatrix}$$

Os modelos espaciais, tais como os modelos autorregressivos de primeira ordem em duas dimensões (AR1  $\times$  AR1) ajustados pelo método de análise de séries temporais, consideram um vetor aleatório de erros correlacionados ( $\xi$ ) e um vetor aleatório de erros independentes ( $\eta$ ), de modo que o vetor de erros ( $e$ ) é modelado como:  $e = \xi + \eta$  (CULLIS & GLEESON, 1991; GILMOUR et al., 1997).

Assim, os modelos autorregressivos de primeira ordem em duas dimensões (AR1  $\times$  AR1) são da forma  $y = X\tau + Zu + \xi + \eta$ , sendo a variância dos resíduos dada por  $Var(e) = Var(\xi + \eta) = R = \Sigma = \sigma_{\xi}^2 [\Sigma_c(\rho_c) \otimes \Sigma_r(\rho_r)] + I\sigma_{\eta}^2$ , em que  $\sigma_{\xi}^2$  é a variância devida aos erros correlacionados e  $\sigma_{\eta}^2$  é a variância dos erros não correlacionados (RESENDE et al., 2014). As matrizes  $\Sigma_c(\rho_c)$  e  $\Sigma_r(\rho_r)$  referem-se a matrizes de correlação autorregressivas de primeira ordem, com parâmetros de

autocorrelação  $\rho_c$  e  $\rho_r$  e ordem igual ao número de colunas ( $c$ ) e número de linhas ( $r$ ), respectivamente (RESENDE et al., 2018). Assim, considerando as autocorrelações de primeira ordem no sentido de linhas ( $\rho_r$ ) e colunas ( $\rho_c$ ), as matrizes de correlação autorregressivas são da seguinte forma:

$$\sum_c^{(\rho_c)} = \begin{bmatrix} 1 & \rho_c^1 & \rho_c^2 & \rho_c^3 & \dots & \rho_c^{c-1} \\ \rho_c^1 & 1 & \rho_c^1 & \rho_c^2 & \dots & \rho_c^{c-2} \\ \rho_c^2 & \rho_c^1 & 1 & \rho_c^1 & \dots & \rho_c^{c-3} \\ \rho_c^3 & \rho_c^2 & \rho_c^1 & 1 & \dots & \rho_c^{c-4} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_c^{c-1} & \rho_c^{c-2} & \rho_c^{c-3} & \rho_c^{c-4} & \dots & 1 \end{bmatrix}$$

$$\sum_r^{(\rho_r)} = \begin{bmatrix} 1 & \rho_r^1 & \rho_r^2 & \rho_r^3 & \dots & \rho_r^{r-1} \\ \rho_r^1 & 1 & \rho_r^1 & \rho_r^2 & \dots & \rho_r^{r-2} \\ \rho_r^2 & \rho_r^1 & 1 & \rho_r^1 & \dots & \rho_r^{r-3} \\ \rho_r^3 & \rho_r^2 & \rho_r^1 & 1 & \dots & \rho_r^{r-4} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_r^{r-1} & \rho_r^{r-2} & \rho_r^{r-3} & \rho_r^{r-4} & \dots & 1 \end{bmatrix}$$

Neste trabalho foram ajustados 16 modelos estatísticos (Tabela 1) para cada safra. Os oito primeiros modelos foram ajustados tanto para a variável produtividade de grãos como para a variável estande e seguem a seguinte sequência:

- a) Modelo 1: modelo de blocos casualizados;
- b) Modelo 2: modelo de látice parcialmente balanceado;
- c) Modelo 3: modelo de blocos casualizados, considerando no vetor de resíduos ( $e$ ) apenas os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  ( $e = \xi$ );
- d) Modelo 4: modelo de blocos casualizados, considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );

e) Modelo 5: modelo de blocos casualizados, com efeito de linhas, efeito de colunas e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );

f) Modelo 6: modelo de látice parcialmente balanceado, considerando no vetor de resíduos ( $e$ ) apenas os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  ( $e = \xi$ );

g) Modelo 7: modelo de látice parcialmente balanceado, considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );

h) Modelo 8: modelo de látice parcialmente balanceado, com efeito de linhas, efeito de colunas e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ ).

Os próximos oito modelos (modelo 9 ao 16) foram ajustados para a característica produtividade de grãos. Os modelos 9, 10, 11, 12, 13, 14, 15 e 16 são correspondentes a sequência de modelos apresentados anteriormente (modelos 1, 2, 3, 4, 5, 6, 7 e 8), diferindo apenas pela inclusão da covariável estande nos respectivos modelos, como descrito a seguir:

a) Modelo 9: modelo de blocos casualizados, incluindo estande como covariável;

b) Modelo 10: modelo de látice parcialmente balanceado, incluindo estande como covariável;

c) Modelo 11: modelo de blocos casualizados, incluindo estande como covariável e considerando no vetor de resíduos ( $e$ ) apenas os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  ( $e = \xi$ );

d) Modelo 12: modelo de blocos casualizados, incluindo estande como covariável e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );

**Tabela 1.** Descrição dos modelos, com seus respectivos efeitos fixos ( $\tau$ ), aleatórios ( $u$ ) e resíduos. Do modelo 9 ao modelo 16 a covariável considerada foi estande

| Modelos   | Efeitos fixos ( $\tau$ ) <sup>†</sup> | Efeitos aleatórios ( $u$ ) <sup>‡</sup> | Resíduos <sup>§</sup> |
|---|---------------------------------------|---|-----------------------|
| 1 - DBC <sup>¶</sup>  | $\mu, r$                              | $g$                                     | $e$                   |
| 2 - Látice  | $\mu, r$                              | $g, b$                                  | $e$                   |
| 3 - DBC + AR1×AR1   | $\mu, r$                              | $g$                                     | $e = \xi$             |
| 4 - DBC + AR1×AR1 + $\eta$  | $\mu, r$                              | $g$                                     | $e = \xi + \eta$      |
| 5 - DBC + Linha + Coluna + AR1×AR1 + $\eta$                               | $\mu, r$                              | $g, l, c$                               | $e = \xi + \eta$      |
| 6 - Látice + AR1×AR1  | $\mu, r$                              | $g, b$                                  | $e = \xi$             |
| 7 - Látice + AR1×AR1 + $\eta$   | $\mu, r$                              | $g, b$                                  | $e = \xi + \eta$      |
| 8 - Látice + Linha + Coluna + AR1×AR1 + $\eta$                            | $\mu, r$                              | $g, b, l, c$                            | $e = \xi + \eta$      |
| 9 - DBC + Covariável <sup>#</sup>   | $\mu, r, \beta_{st}$                  | $g$                                     | $e$                   |
| 10 - Látice + Covariável <sup>#</sup>                                     | $\mu, r, \beta_{st}$                  | $g, b$                                  | $e$                   |
| 11 - DBC + Covariável <sup>#</sup> + AR1×AR1                              | $\mu, r, \beta_{st}$                  | $g$                                     | $e = \xi$             |
| 12 - DBC + Covariável <sup>#</sup> + AR1×AR1 + $\eta$                     | $\mu, r, \beta_{st}$                  | $g$                                     | $e = \xi + \eta$      |
| 13 - DBC + Covariável <sup>#</sup> + Linha + Coluna + AR1×AR1 + $\eta$    | $\mu, r, \beta_{st}$                  | $g, l, c$                               | $e = \xi + \eta$      |
| 14 - Látice + Covariável <sup>#</sup> + AR1×AR1                           | $\mu, r, \beta_{st}$                  | $g, b$                                  | $e = \xi$             |
| 15 - Látice + Covariável <sup>#</sup> + AR1×AR1 + $\eta$                  | $\mu, r, \beta_{st}$                  | $g, b$                                  | $e = \xi + \eta$      |
| 16 - Látice + Covariável <sup>#</sup> + Linha + Coluna + AR1×AR1 + $\eta$ | $\mu, r, \beta_{st}$                  | $g, b, l, c$                            | $e = \xi + \eta$      |

<sup>†</sup>  $\mu$ : média;  $r$ : efeito de repetição;  $\beta_{st}$ : efeito da covariável estande.

<sup>‡</sup>  $g$ : efeito de genótipos;  $b$ : efeito de blocos do látice;  $l$ : efeito de linhas;  $c$ : efeito de colunas.

<sup>§</sup>  $e$ : erros aleatórios;  $\xi$ : erros correlacionados;  $\eta$ : erros independentes.

<sup>¶</sup> DBC: Delineamento em Blocos Casualizados.

<sup>#</sup> Covariável: estande.

e) Modelo 13: modelo de blocos casualizados, incluindo estande como covariável, efeito de linhas, efeito de colunas e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );

f) Modelo 14: modelo de látice parcialmente balanceado, incluindo estande como covariável e considerando no vetor de resíduos ( $e$ ) apenas os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 ( $e = \xi$ );

g) Modelo 15: modelo de látice parcialmente balanceado, incluindo estande como covariável e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ );

h) Modelo 16: modelo de látice parcialmente balanceado, incluindo estande como covariável, efeito de linhas, efeito de colunas e considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e os erros independentes ( $\eta$ ) ( $e = \xi + \eta$ ).

Inicialmente, os modelos 1, 2, 3, 4, 5, 6, 7 e 8 foram ajustados para a característica estande e o teste da razão de verossimilhança usado para testar a significância do efeito de genótipos sobre estande em cada modelo. Segundo Cruz et al. (2014), o uso da covariável estande para correção da produtividade de grãos deve ocorrer unicamente quando o efeito de genótipos sobre as variações nos estandes for não significativo. Assim, os modelos de 9 a 16 foram ajustados para a característica produtividade de grãos apenas quando o efeito de genótipos para estande foi não significativo nos seus correspondentes modelos de 1 a 8.

Com base nos modelos ajustados foram obtidas as seguintes estimativas: componentes de variância genotípica ( $\hat{\sigma}_g^2$ ), variância de blocos ( $\hat{\sigma}_b^2$ ), variância de linhas ( $\hat{\sigma}_{linhas}^2$ ), variância de colunas ( $\hat{\sigma}_{colunas}^2$ ), variância residual ( $\hat{\sigma}_e^2$ ), variância dos efeitos aleatórios de tendência ( $\hat{\sigma}_\xi^2$ ), variância do erro independente ( $\hat{\sigma}_\eta^2$ ); coeficientes de

autocorrelação residual nas linhas ( $\hat{\rho}_r$ ) e nas colunas ( $\hat{\rho}_c$ ); valor-p para o efeito de genótipos pelo teste da razão de verossimilhança, herdabilidade no sentido amplo ( $\hat{h}^2$ ), acurácia seletiva ( $\hat{r}_{gg}$ ), variância do erro de predição (PEV), média de produtividade de grãos, coeficiente de variação experimental (CV) e logaritmo do máximo da função de verossimilhança (Log L).

As análises foram realizadas empregando-se o pacote estatístico ASReml-R (BUTLER et al., 2009), que usa as rotinas numéricas do programa ASReml (GILMOUR et al., 2002) no programa R (R CORE TEAM, 2018).

Dentro de cada grupo de modelos que possuem os mesmos efeitos fixos, a seleção do modelo mais adequado foi realizada por meio do critério de informação de Akaike (AIC) (AKAIKE, 1974). O AIC é dado por:  $AIC = -2\text{Log } L + 2p$ , em que  $p$  é o número de parâmetros estimados. Os menores valores de AIC refletem um melhor ajuste global (AKAIKE, 1974). Assim, os valores de AIC foram calculados para cada modelo candidato e as comparações entre os valores de AIC foram realizadas dentro de cada grupo de modelos (com e sem a inclusão da covariável estande). Como descreve Resende et al. (2014), dentro do grupo de modelos com mesma estrutura de efeitos fixos, o modelo com menor valor de AIC foi selecionado como o melhor modelo do grupo.

Além do AIC, dentro do grupo de modelos sem a inclusão da covariável estande, foi calculada para cada modelo a mudança do valor de Log L relativa ao Modelo 1. Dentro do grupo de modelos com inclusão da covariável estande, a mudança do valor de Log L foi calculada em relação ao Log L estimado no Modelo 9. A significância na mudança relativa dos valores de Log L (Mud. Log L) foi verificada pelo teste da razão de verossimilhança.

Visando comparar os 16 modelos ajustados, foi estimada a eficiência de cada modelo em função da herdabilidade (Efic.  $\hat{h}^2$ ), dada pela razão entre a herdabilidade estimada no modelo considerado e a herdabilidade estimada no modelo tradicional de

blocos casualizados (Modelo 1). Em ensaios que o componente de variância genotípica ( $\hat{\sigma}_g^2$ ) foi não significativo com o ajuste do Modelo 1, a herdabilidade não foi estimada com esse modelo e, conseqüentemente, não foi possível estimar a eficiência dos outros modelos em relação ao Modelo 1 quanto à herdabilidade (Efic.  $\hat{h}^2$ ).

Além dos parâmetros estimados e as estatísticas usadas para comparações entre modelos, também foram estimados coeficientes de correlação de Spearman entre os valores genotípicos preditos com os modelos em que o efeito de genótipos foi significativo sobre produtividade de grãos. Esses coeficientes foram estimados com auxílio do programa GENES (CRUZ, 2013). Além disso, considerando uma intensidade de seleção de 10% (aproximadamente quatro híbridos), estimou-se a frequência de híbridos comuns selecionados a partir dos valores genotípicos preditos nos diferentes modelos ajustados.

## **4. Resultados**

### **4.1. Efeito de genótipos sobre a variável estande (safras 2015/16, 2016/17 e 2017/18)**

Os respectivos valores, mínimo e máximo, de estande (plantas ha<sup>-1</sup>) foram de 39116 e 73129, na safra 2015/16; 49320 e 74830, na safra 2016/17; e 42517 e 74830, na safra 2017/18. A maior amplitude entre esses valores observados para a variável estande foi obtida na safra 2015/16.

Na safra 2015/16, o efeito de genótipo sobre a variável estande foi não significativo pelo teste da razão de verossimilhança nos modelos 1, 2, 3, 4, 6 e 7 (Tabela 12), de modo que o estande foi usado como covariável apenas nos correspondentes modelos 9, 10, 11, 12, 14 e 15 (Tabela 1) para a análise da produtividade de grãos nesta safra. Nos modelos 5 e 8 o efeito de genótipo sobre a variável estande foi significativo (Tabela 12), de modo que os modelos correspondentes 13 e 16 (Tabela 1) não foram ajustados para produtividade de grãos (Tabela 13).

**Tabela 12.** Estimativas de parâmetros para a variável estande dos ensaios de VCU conduzidos em condições de alta adubação nas safras 2015/16, 2016/17 e 2017/18. Estimativas de componentes de variâncias genotípica ( $\hat{\sigma}_g^2$ ), blocos ( $\hat{\sigma}_b^2$ ), linhas ( $\hat{\sigma}_{linhas}^2$ ), colunas ( $\hat{\sigma}_{colunas}^2$ ), residual ( $\hat{\sigma}_e^2$ ), variância dos erros correlacionados ( $\hat{\sigma}_\xi^2$ ) e variância dos erros independentes ( $\hat{\sigma}_\eta^2$ ). Valor-p para o efeito de genótipos pelo teste da razão de verossimilhança (valor-p ( $\hat{\sigma}_g^2$ )); estimativas de coeficientes de autocorrelação residual nas linhas ( $\hat{\rho}_r$ ) e nas colunas ( $\hat{\rho}_c$ )

| Parâmetros                                 | Mod. 1                 | Mod. 2                 | Mod. 3                 | Mod. 4                 | Mod. 5      | Mod. 6                 | Mod. 7                 | Mod. 8       |
|--|------------------------|------------------------|------------------------|------------------------|-------------|------------------------|------------------------|--------------|
|  | $\mu, r$               | $\mu, r$               | $\mu, r$               | $\mu, r$               | $\mu, r$    | $\mu, r$               | $\mu, r$               | $\mu, r$     |
|  | $g$                    | $g, b$                 | $g$                    | $g$                    | $g, l, c$   | $g, b$                 | $g, b$                 | $g, b, l, c$ |
|  | $e$                    | $e$                    | $\xi$                  | $\xi, \eta$            | $\xi, \eta$ | $\xi$                  | $\xi, \eta$            | $\xi, \eta$  |
| <b>VCU – Alta Adubação – safra 2015/16</b> |                        |                        |                        |                        |             |                        |                        |              |
| $\hat{\sigma}_g^2$                         | 10853150 <sup>ns</sup> | 11910508 <sup>ns</sup> | 12715360 <sup>ns</sup> | 12715350 <sup>ns</sup> | 18374880*   | 12715340 <sup>ns</sup> | 12715350 <sup>ns</sup> | 22868280*    |
| $\hat{\sigma}_b^2$                         | -                      | 3791653                | -                      | -                      | -           | 20                     | 1,26                   | 2394773      |
| $\hat{\sigma}_{linhas}^2$                  | -                      | -                      | -                      | -                      | 12383650    | -                      | -                      | 14053560     |
| $\hat{\sigma}_{colunas}^2$                 | -                      | -                      | -                      | -                      | 4,59        | -                      | -                      | 2,07         |
| $\hat{\sigma}_e^2$                         | 39001086               | 34964035               | -                      | -                      | -           | -                      | -                      | -            |
| $\hat{\sigma}_\xi^2$                       | -                      | -                      | 38507360               | 38507020               | 23729130    | 38506570               | 38507020               | 17865320     |
| $\hat{\sigma}_\eta^2$                      | -                      | -                      | -                      | 0,01                   | 45          | -                      | 0,01                   | 45           |
| $\hat{\rho}_r$                             | -                      | -                      | -0,15                  | -0,15                  | -0,25       | -0,15                  | -0,15                  | -0,31        |
| $\hat{\rho}_c$                             | -                      | -                      | 0,37                   | 0,37                   | 0,04        | 0,37                   | 0,37                   | -0,20        |
| valor-p ( $\hat{\sigma}_g^2$ )             | 1,92E-01               | 1,53E-01               | 9,45E-02               | 1,50E-01               | 3,63E-02    | 9,45E-02               | 1,50E-01               | 2,74E-02     |
| <b>VCU – Alta Adubação – safra 2016/17</b> |                        |                        |                        |                        |             |                        |                        |              |
| $\hat{\sigma}_g^2$                         | 9691878*               | 9691880*               | 7796832*               | 6257260*               | 7672778*    | 7795330*               | 10049860*              | 7672306*     |
| $\hat{\sigma}_b^2$                         | -                      | 1,55                   | -                      | -                      | -           | 1,66                   | 0,91                   | 1,48         |
| $\hat{\sigma}_{linhas}^2$                  | -                      | -                      | -                      | -                      | 1945264     | -                      | -                      | 1945152      |
| $\hat{\sigma}_{colunas}^2$                 | -                      | -                      | -                      | -                      | 1,48        | -                      | -                      | 1,48         |
| $\hat{\sigma}_e^2$                         | 15273923               | 15273920               | -                      | -                      | -           | -                      | -                      | -            |
| $\hat{\sigma}_\xi^2$                       | -                      | -                      | 16363140               | 7430052                | 14592920    | 16361800               | 9039930                | 14592710     |
| $\hat{\sigma}_\eta^2$                      | -                      | -                      | -                      | 5064960                | 13          | -                      | 11321780               | 11           |
| $\hat{\rho}_r$                             | -                      | -                      | -0,23                  | -0,31                  | -0,23       | -0,23                  | -0,47                  | -0,23        |
| $\hat{\rho}_c$                             | -                      | -                      | 0,08                   | 0,25                   | -0,06       | 0,08                   | 0,28                   | -0,06        |
| valor-p ( $\hat{\sigma}_g^2$ )             | 1,68E-02               | 1,68E-02               | 4,60E-02               | 4,31E-02               | 4,63E-02    | 4,60E-02               | 4,30E-02               | 4,63E-02     |
| <b>VCU – Alta Adubação – safra 2017/18</b> |                        |                        |                        |                        |             |                        |                        |              |
| $\hat{\sigma}_g^2$                         | 8683649 <sup>ns</sup>  | 10607494 <sup>ns</sup> | 17163420**             | 17164900**             | 17164060**  | 15646490*              | 15666150*              | 15680240*    |
| $\hat{\sigma}_b^2$                         | -                      | 6810249                | -                      | -                      | -           | 5153111                | 5167551                | 5174322      |
| $\hat{\sigma}_{linhas}^2$                  | -                      | -                      | -                      | -                      | 2,50        | -                      | -                      | 2,04         |
| $\hat{\sigma}_{colunas}^2$                 | -                      | -                      | -                      | -                      | 2,50        | -                      | -                      | 32           |
| $\hat{\sigma}_e^2$                         | 27499652               | 20397521               | -                      | -                      | -           | -                      | -                      | -            |
| $\hat{\sigma}_\xi^2$                       | -                      | -                      | 24702790               | 24701980               | 24701440    | 20177840               | 20195310               | 20207230     |
| $\hat{\sigma}_\eta^2$                      | -                      | -                      | -                      | 40                     | 40          | -                      | 32                     | 32           |
| $\hat{\rho}_r$                             | -                      | -                      | 0,50                   | 0,50                   | 0,50        | 0,39                   | 0,38                   | 0,38         |
| $\hat{\rho}_c$                             | -                      | -                      | 0,11                   | 0,11                   | 0,11        | 0,04                   | 0,04                   | 0,04         |
| valor-p ( $\hat{\sigma}_g^2$ )             | 1,50E-01               | 6,65E-02               | 7,98E-03               | 7,98E-03               | 7,98E-03    | 1,64E-02               | 1,64E-02               | 1,64E-02     |

\* Significativo ao nível de 5% de probabilidade; \*\* Significativo ao nível de 1% de probabilidade; <sup>ns</sup> não significativo.

Na safra 2016/17, o efeito de genótipos sobre a variável estande foi significativo nos oito modelos inicialmente ajustados (modelos 1, 2, 3, 4, 5, 6, 7 e 8) (Tabela 12). Assim, o estande não foi usado como covariável em nenhum modelo estatístico para análise da produtividade de grãos na safra 2016/17 (Tabela 16).

Na safra 2017/18, o efeito de genótipos sobre a variável estande foi não significativo somente nos modelos 1 e 2 (Tabela 12), de modo que na análise da produtividade de grãos, o estande foi usado como covariável somente nos correspondentes modelos 9 e 10 (Tabela 1) e os demais modelos 11, 12, 13, 14, 15 e 16 não foram ajustados (Tabela 19).

## **4.2. Seleção de modelos para análise da característica produtividade de grãos**

### **4.2.1. Produtividade de grãos – safra 2015/16**

As estimativas de parâmetros relacionados à característica produtividade de grãos da safra 2015/16 são apresentadas na Tabela 13. Verificou-se que a variância genotípica foi significativa em todos os modelos ajustados, sendo que o valor-p associado a variância genotípica variou de 8,42E-11 (Modelo 11) a 3,91E-10 (modelos 1 e 2). Os valores de coeficiente de variação experimental (CV) estimados variaram de 12,05% (modelos 9 e 10) a 14,10% (modelos 1 e 2).

Entre os modelos que não incluem o estande como covariável, verificou-se que as mudanças de Log L dos modelos 2, 3, 4, 5, 6, 7, e 8, relativas ao modelo tradicional em blocos casualizados (Modelo1), foram não significativas (Tabela 13). Assim, observou-se pelo teste da razão de verossimilhança que os ajustes dos modelos 2, 3, 4, 5, 6, 7 e 8 não diferiram do ajuste proporcionado pelo Modelo 1. Além disso, verificou-se que o Modelo 1 apresentou o menor valor de AIC (Tabela 13), sendo este modelo selecionado como o melhor dentre os modelos que não incluem o estande como covariável.

**Tabela 13.** Estimativas de parâmetros genéticos e estatísticos do ensaio VCU – Alta Aducação, safra 2015/16, para a característica produtividade de grãos. Estimativas de componentes de variâncias genotípica ( $\hat{\sigma}_g^2$ ), blocos ( $\hat{\sigma}_b^2$ ), linhas ( $\hat{\sigma}_{linhas}^2$ ), colunas ( $\hat{\sigma}_{colunas}^2$ ), residual ( $\hat{\sigma}_e^2$ ), variância dos erros correlacionados ( $\hat{\sigma}_\xi^2$ ), variância dos erros independentes ( $\hat{\sigma}_\eta^2$ ) e soma dos componentes  $\hat{\sigma}_\xi^2$  e  $\hat{\sigma}_\eta^2$  ( $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ ). Coeficientes de autocorrelação residual nas linhas ( $\hat{\rho}_r$ ) e nas colunas ( $\hat{\rho}_c$ ). Valor-p para o efeito de genótipos, pelo teste da razão de verossimilhança (valor-p ( $\hat{\sigma}_g^2$ )). Herdabilidade no sentido amplo ( $\hat{h}^2$ ), acurácia seletiva ( $\hat{r}_{gg}$ ), variância do erro de predição (PEV), média de produtividade de grãos, coeficiente de variação experimental (CV), logaritmo do máximo da função de verossimilhança (Log L), critério de informação de Akaike (AIC), mudança do valor de Log L do modelo em relação ao seu respectivo modelo básico em blocos casualizados (Mud. Log L) e eficiência do modelo em função de herdabilidade (Efic.  $\hat{h}^2$ )

| Parâmetros                                 | Modelos estatísticos <sup>†</sup> e seus respectivos efeitos fixos <sup>‡</sup> , aleatórios <sup>§</sup> e resíduos <sup>¶</sup> |                    |                    |                    |                    |                    |                    |                    |  |                      |                      |                      |                      |                      |                      |                      |
|--|---|--------------------|--------------------|--------------------|--------------------|--------------------|--------------------|--------------------|--|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
|  | Modelos sem inclusão da covariável estande  |                    |                    |                    |                    |                    |                    |                    | Modelos com inclusão da covariável estande |                      |                      |                      |                      |                      |                      |                      |
|  | Mod. 1  | Mod. 2             | Mod. 3             | Mod. 4             | Mod. 5             | Mod. 6             | Mod. 7             | Mod. 8             | Mod. 9                                     | Mod. 10              | Mod. 11              | Mod. 12              | Mod. 13              | Mod. 14              | Mod. 15              | Mod. 16              |
|  | $\mu, r$  | $\mu, r$           | $\mu, r$           | $\mu, r$           | $\mu, r$           | $\mu, r$           | $\mu, r$           | $\mu, r$           | $\mu, r, \beta_{st}$                       | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ |
|  | $g$   | $g, b$             | $g$                | $g$                | $g, l, c$          | $g, b$             | $g, b$             | $g, b, l, c$       | $g$  | $g, b$               | $g$                  | $g$                  | $g, l, c$            | $g, b$               | $g, b$               | $g, b, l, c$         |
|  | $e$   | $e$                | $\xi$              | $\xi, \eta$        | $\xi, \eta$        | $\xi$              | $\xi, \eta$        | $\xi, \eta$        | $e$  | $e$                  | $\xi$                | $\xi, \eta$          | $\xi, \eta$          | $\xi$                | $\xi, \eta$          | $\xi, \eta$          |
| $\hat{\sigma}_g^2$                         | 2585467**   | 2585467**          | 2551440**          | 2551667**          | 2551627**          | 2551590**          | 2551729**          | 2551625**          | 2200462**                                  | 2200461**            | 2078679**            | 2082985**            | -                    | 2082733**            | 2082497**            | -                    |
| $\hat{\sigma}_b^2$                         | -   | 0,21               | -                  | -                  | -                  | 0,06               | 0,26               | 0,06               | -  | 0,08                 | -                    | -                    | -                    | 0,06                 | 0,05                 | -                    |
| $\hat{\sigma}_{linhas}^2$                  | -   | -                  | -                  | -                  | 0,78               | -                  | -                  | 0,89               | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_{colunas}^2$                 | -   | -                  | -                  | -                  | 0,03               | -                  | -                  | 0,12               | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_e^2$                         | 565415  | 565415             | -                  | -                  | -                  | -                  | -                  | -                  | 412546                                     | 412546               | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_\xi^2$                       | -   | -                  | 563329             | 563330             | 562993             | 563372             | 561153             | 563333             | -  | -                    | 441659               | 442301               | -                    | 442272               | 442235               | -                    |
| $\hat{\sigma}_\eta^2$                      | -   | -                  | -                  | 56                 | 384                | -                  | 2232               | 45                 | -  | -                    | -                    | 0,90                 | -                    | -                    | 0,71                 | -                    |
| $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ | -   | -                  | -                  | 563387             | 563377             | -                  | 563385             | 563378             | -  | -                    | -                    | 442302               | -                    | -                    | 442236               | -                    |
| $\hat{\rho}_r$                             | -   | -                  | -0,20              | -0,20              | -0,20              | -0,20              | -0,20              | -0,20              | -  | -                    | 0,12                 | 0,11                 | -                    | 0,11                 | 0,11                 | -                    |
| $\hat{\rho}_c$                             | -   | -                  | 0,11               | 0,11               | 0,11               | 0,11               | 0,11               | 0,11               | -  | -                    | 0,31                 | 0,31                 | -                    | 0,31                 | 0,31                 | -                    |
| valor-p ( $\hat{\sigma}_g^2$ )             | 3,91E-10  | 3,91E-10           | 2,55E-10           | 2,61E-10           | 2,51E-10           | 2,55E-10           | 2,75E-10           | 2,72E-10           | 1,55E-10                                   | 3,29E-10             | 8,42E-11             | 3,58E-10             | -                    | 1,33E-10             | 3,58E-10             | -                    |
| $\hat{h}^2$                                | 0,88  | 0,88               | 0,88               | 0,88               | 0,88               | 0,88               | 0,88               | 0,88               | 0,89                                       | 0,89                 | 0,89                 | 0,89                 | -                    | 0,89                 | 0,89                 | -                    |
| $\hat{r}_{gg}$                             | 0,94  | 0,94               | 0,94               | 0,94               | 0,94               | 0,94               | 0,94               | 0,94               | 0,94                                       | 0,94                 | 0,94                 | 0,94                 | -                    | 0,94                 | 0,94                 | -                    |
| PEV  | 319581  | 319581             | 307265             | 307206             | 307216             | 307221             | 307224             | 307212             | 251057                                     | 251057               | 236389               | 236126               | -                    | 236145               | 236156               | -                    |
| Média                                      | 5331  | 5331               | 5333               | 5333               | 5333               | 5333               | 5333               | 5333               | 5331                                       | 5331                 | 5332                 | 5332                 | -                    | 5332                 | 5332                 | -                    |
| CV (%)                                     | 14,10   | 14,10              | 14,07              | 14,08              | 14,08              | 14,08              | 14,08              | 14,08              | 12,05                                      | 12,05                | 12,46                | 12,47                | -                    | 12,47                | 12,47                | -                    |
| Log L                                      | -542,72   | -542,72            | -542,06            | -542,06            | -542,06            | -542,06            | -542,06            | -542,06            | -537,75                                    | -537,75              | -536,85              | -536,85              | -                    | -536,85              | -536,85              | -                    |
| AIC  | 1089,44   | 1091,44            | 1092,11            | 1094,11            | 1098,11            | 1094,11            | 1096,11            | 1100,11            | 1079,49                                    | 1081,49              | 1081,70              | 1083,70              | -                    | 1083,70              | 1085,70              | -                    |
|  | Comparações relativas ao Modelo 1   |                    |                    |                    |                    |                    |                    |                    | Comparações relativas ao Modelo 9          |                      |                      |                      |                      |                      |                      |                      |
| Mud. Log L                                 | -   | 0,00 <sup>ns</sup> | 0,66 <sup>ns</sup> | 0,66 <sup>ns</sup> | 0,66 <sup>ns</sup> | 0,66 <sup>ns</sup> | 0,66 <sup>ns</sup> | 0,66 <sup>ns</sup> | -  | 0,00 <sup>ns</sup>   | 0,90 <sup>ns</sup>   | 0,90 <sup>ns</sup>   | -                    | 0,90 <sup>ns</sup>   | 0,90 <sup>ns</sup>   | -                    |
|  | Comparações relativas ao Modelo 1   |                    |                    |                    |                    |                    |                    |                    | Comparações relativas ao Modelo 1          |                      |                      |                      |                      |                      |                      |                      |
| Efic. $\hat{h}^2$                          | -   | 1,00               | 1,00               | 1,00               | 1,00               | 1,00               | 1,00               | 1,00               | 1,01                                       | 1,01                 | 1,01                 | 1,01                 | -                    | 1,01                 | 1,01                 | -                    |

<sup>†</sup> Modelos estatísticos descritos na Tabela 1. <sup>‡</sup> Efeitos fixos:  $\mu$ : média;  $r$ : efeito de repetição;  $\beta_{st}$ : efeito da covariável estande. <sup>§</sup> Efeitos aleatórios:  $g$ : efeito de genótipos;  $b$ : efeito de blocos do látice;  $l$ : efeito de linhas;  $c$ : efeito de colunas. <sup>¶</sup> Resíduos:  $e$ : erros aleatórios;  $\xi$ : erros correlacionados;  $\eta$ : erros independentes. \*\* Significativo ao nível de 1% de probabilidade. <sup>ns</sup> não significativo.

Entre os modelos que incluem o estande como covariável, verificou-se que as mudanças de Log L dos modelos 10, 11, 12, 14 e 15, relativas ao modelo em blocos casualizados com inclusão de covariável (Modelo 9), também foram não significativas (Tabela 13). Esse fato evidencia que os ajustes dos modelos 10, 11, 12, 14 e 15 não diferiram estatisticamente do ajuste do Modelo 9. Dentro do grupo de modelos que incluem o estande como covariável, o Modelo 9 apresentou o menor valor de AIC (Tabela 13) e foi selecionado como o melhor modelo desse grupo.

Os modelos 1 e 9 são correspondentes, de modo que o Modelo 9 difere apenas pela inclusão da covariável estande (Tabela 1). Comparando-se esses dois modelos, verificou-se que foram estimados menor valor-p associado a variância genotípica e maior herdabilidade com o Modelo 9 (Tabela 13). Os dois modelos apresentaram estimativas de acurácias seletivas altas e com valores aproximadamente iguais (Tabela 13). Com base na superioridade do Modelo 9 quanto às estimativas de valor-p e herdabilidade, esse modelo foi selecionado como o mais promissor para a análise da produtividade de grãos dos híbridos avaliados em condições de alta adubação na safra 2015/16, fato que evidencia a importância da inclusão do estande como covariável nesta safra.

Na Tabela 14, observou-se que os quatro híbridos identificados como superiores pelo Modelo 9 também foram selecionados usando-se os modelos 10, 11, 12, 14 e 15. No entanto, somente o Modelo 10 garantiu a mesma classificação geral dos híbridos estabelecida pelo Modelo 9, uma vez que o valor do coeficiente de correlação de Spearman igual a um foi estimado entre os valores genotípicos preditos pelos modelos 9 e 10 (Tabela 14).

**Tabela 14.** Correlações de Spearman e frequências de genótipos selecionados comuns, considerando o ensaio VCU – Alta Adubação, safra 2015/16. Acima da diagonal, correlações de Spearman entre os pares de modelos estatísticos considerando os valores genotípicos (u + g) preditos para produtividade de grãos. Abaixo da diagonal, frequências de genótipos selecionados comuns aos pares de modelos estatísticos, considerando a seleção dos quatro híbridos superiores quanto ao valor genotípico (u + g) de produtividade de grãos

|         | Mod. 1 | Mod. 2 | Mod. 3 | Mod. 4 | Mod. 5 | Mod. 6 | Mod. 7 | Mod. 8 | Mod. 9 | Mod. 10 | Mod. 11 | Mod. 12 | Mod. 14 | Mod. 15 |
|---------|--------|--------|--------|--------|--------|--------|--------|--------|--------|---------|---------|---------|---------|---------|
| Mod. 1  | -      | 1      | 0,996  | 0,996  | 0,996  | 0,996  | 0,996  | 0,996  | 0,958  | 0,958   | 0,950   | 0,950   | 0,950   | 0,950   |
| Mod. 2  | 1      | -      | 0,996  | 0,996  | 0,996  | 0,996  | 0,996  | 0,996  | 0,958  | 0,958   | 0,950   | 0,950   | 0,950   | 0,950   |
| Mod. 3  | 0,750  | 0,750  | -      | 1      | 1      | 1      | 1      | 1      | 0,956  | 0,956   | 0,952   | 0,952   | 0,952   | 0,952   |
| Mod. 4  | 0,750  | 0,750  | 1      | -      | 1      | 1      | 1      | 1      | 0,956  | 0,956   | 0,952   | 0,952   | 0,952   | 0,952   |
| Mod. 5  | 0,750  | 0,750  | 1      | 1      | -      | 1      | 1      | 1      | 0,956  | 0,956   | 0,952   | 0,952   | 0,952   | 0,952   |
| Mod. 6  | 0,750  | 0,750  | 1      | 1      | 1      | -      | 1      | 1      | 0,956  | 0,956   | 0,952   | 0,952   | 0,952   | 0,952   |
| Mod. 7  | 0,750  | 0,750  | 1      | 1      | 1      | 1      | -      | 1      | 0,956  | 0,956   | 0,952   | 0,952   | 0,952   | 0,952   |
| Mod. 8  | 0,750  | 0,750  | 1      | 1      | 1      | 1      | 1      | -      | 0,956  | 0,956   | 0,952   | 0,952   | 0,952   | 0,952   |
| Mod. 9  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | -      | 1       | 0,993   | 0,993   | 0,993   | 0,993   |
| Mod. 10 | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | -       | 0,993   | 0,993   | 0,993   | 0,993   |
| Mod. 11 | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | 1       | -       | 1       | 1       | 1       |
| Mod. 12 | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | 1       | 1       | -       | 1       | 1       |
| Mod. 14 | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | 1       | 1       | 1       | -       | 1       |
| Mod. 15 | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 0,750  | 1      | 1       | 1       | 1       | 1       | -       |

Na Tabela 15 são apresentados os valores genotípicos preditos para produtividade de grãos ( $\text{kg ha}^{-1}$ ) com base no Modelo 9 e nos modelos tradicionais de blocos casualizados (Modelo 1) e de látice parcialmente balanceado (Modelo 2). Observou-se que os híbridos AG8088 PRO (tratamento 18) e 1N1884 (tratamento 27), respectivamente, foram classificados como primeiro e segundo maior valor genotípico predito pelos três modelos considerados. O híbrido 1M1819 (tratamento 14) foi o terceiro maior valor genotípico predito com o Modelo 9, no entanto foi classificado como o quinto maior valor com os modelos 1 e 2. O híbrido 2B707 PW (tratamento 10) foi o quarto maior valor genotípico predito com os três modelos considerados. Ressalta-se que entre os quatro híbridos selecionados com o Modelo 9, os híbridos AG8088 PRO e 2B707 PW são híbridos comerciais (testemunhas) e os híbridos 1N1884 e 1M1819 são híbridos experimentais desenvolvidos pela Embrapa Milho e Sorgo.

**Tabela 15.** Valores genotípicos (VG) preditos para produtividade de grãos (kg ha<sup>-1</sup>) dos híbridos de milho do ensaio VCU – Alta Adubação, na safra 2015/16. Valores genotípicos preditos pelos seguintes modelos: modelo tradicional de blocos casualizados (Modelo 1); modelo tradicional de látice quadrado parcialmente balanceado (Modelo 2); e modelo de blocos casualizados com inclusão de estande como covariável (Modelo 9)

| Trat. | Híbrido    | Modelo 1 |         | Modelo 2 |         | Modelo 9 |         |
|-------|------------|----------|---------|----------|---------|----------|---------|
|       |            | VG       | Ranking | VG       | Ranking | VG       | Ranking |
| 18    | AG8088 PRO | 8245     | 1       | 8245     | 1       | 7924     | 1       |
| 27    | 1N1884     | 7792     | 2       | 7792     | 2       | 7406     | 2       |
| 14    | 1M1819     | 7033     | 5       | 7033     | 5       | 6983     | 3       |
| 10    | 2B707 PW   | 7144     | 4       | 7144     | 4       | 6980     | 4       |
| 30    | 1M1804     | 7153     | 3       | 7153     | 3       | 6875     | 5       |
| 36    | DKB390 PRO | 6354     | 9       | 6354     | 9       | 6756     | 6       |
| 15    | 1N1958     | 5955     | 16      | 5955     | 16      | 6756     | 7       |
| 35    | 1L1421     | 6731     | 7       | 6731     | 7       | 6504     | 8       |
| 1     | 1M1752     | 6844     | 6       | 6844     | 6       | 6503     | 9       |
| 3     | 1L1411     | 6022     | 15      | 6022     | 15      | 6362     | 10      |
| 5     | 1M1807     | 6318     | 10      | 6318     | 10      | 6316     | 11      |
| 12    | 1N1975     | 5662     | 17      | 5662     | 17      | 6228     | 12      |
| 17    | 1N1901     | 6486     | 8       | 6486     | 8       | 6082     | 13      |
| 20    | 1N1925     | 6222     | 11      | 6222     | 11      | 6046     | 14      |
| 33    | 2B587 PW   | 6036     | 14      | 6036     | 14      | 6030     | 15      |
| 32    | 1M1760     | 6167     | 12      | 6167     | 12      | 5874     | 16      |
| 26    | 1K1306     | 6156     | 13      | 6156     | 13      | 5632     | 17      |
| 25    | 1N1915     | 4880     | 24      | 4880     | 24      | 5551     | 18      |
| 19    | 1N1900     | 5510     | 18      | 5510     | 18      | 5497     | 19      |
| 13    | 1M1824     | 5199     | 22      | 5199     | 22      | 5469     | 20      |
| 6     | 1M1718     | 5165     | 23      | 5165     | 23      | 5262     | 21      |
| 28    | 1N1882     | 5349     | 19      | 5349     | 19      | 5102     | 22      |
| 21    | 1N1927     | 5222     | 21      | 5222     | 21      | 5031     | 23      |
| 34    | 1M1764     | 5287     | 20      | 5287     | 20      | 4751     | 24      |
| 8     | 1K1301     | 4456     | 27      | 4456     | 27      | 4543     | 25      |
| 7     | 1M1732     | 4842     | 26      | 4842     | 26      | 4530     | 26      |
| 24    | 1N1966     | 3648     | 30      | 3648     | 30      | 4359     | 27      |
| 4     | 1M1810     | 4865     | 25      | 4865     | 25      | 4323     | 28      |
| 31    | 1M1731     | 4025     | 29      | 4025     | 29      | 4048     | 29      |
| 29    | 1N1933     | 4166     | 28      | 4166     | 28      | 4018     | 30      |
| 23    | 1N1932     | 3310     | 32      | 3310     | 32      | 3554     | 31      |
| 22    | BRS 1055   | 3479     | 31      | 3479     | 31      | 3494     | 32      |
| 2     | 1M1757     | 3085     | 33      | 3085     | 33      | 2921     | 33      |
| 16    | 1N1962     | 2499     | 34      | 2499     | 34      | 2847     | 34      |
| 11    | 1N1886     | 2485     | 35      | 2485     | 35      | 2833     | 35      |
| 9     | 1L1457     | 2140     | 36      | 2140     | 36      | 2540     | 36      |

#### 4.2.2. Produtividade de grãos – safra 2016/17

As estimativas de parâmetros relacionados à característica produtividade de grãos da safra 2016/17 são apresentadas na Tabela 16. Verificou-se pelo teste da razão de verossimilhança que a variância genotípica foi significativa em todos os modelos ajustados, de modo que o valor-p associado à variância genotípica variou de 5,56E-11 (modelos 3, 4, 6 e 7) a 9,42E-11 (modelos 5 e 8). Os valores de coeficiente de variação experimental (CV) estimados variaram de 11,94% (modelos 5 e 8) a 12,93% (modelos 3, 4, 6 e 7).

Na safra 2016/17, os modelos ajustados foram somente os que pertencem ao grupo de modelos que não incluem o estande como covariável. Observou-se pela mudança nos valores de Log L que os ajustes dos modelos 2, 3, 4, 5, 6, 7 e 8 não diferiram do ajuste do modelo tradicional de blocos casualizados (Modelo 1) (Tabela 16). Além disso, o Modelo 1 apresentou a menor estimativa de AIC (Tabela 16), sendo selecionado como o modelo mais adequado para a análise estatística da produtividade de grãos na safra 2016/17.

Considerando a frequência de híbridos comuns selecionados, observou-se que todos os modelos selecionaram os mesmos quatro híbridos identificados como superiores pelo Modelo 1. No entanto, somente o modelo tradicional de látice parcialmente balanceado (Modelo 2) garante classificação geral dos híbridos idêntica à classificação estabelecida pelo Modelo 1, uma vez que o valor do coeficiente de correlação de Spearman igual a um foi estimado entre os valores genotípicos preditos pelos modelos 1 e 2 (Tabela 17).

**Tabela 16.** Estimativas de parâmetros genéticos e estatísticos do ensaio VCU – Alta Adubação, safra 2016/17, para a característica produtividade de grãos. Estimativas de componentes de variâncias genotípica ( $\hat{\sigma}_g^2$ ), blocos ( $\hat{\sigma}_b^2$ ), linhas ( $\hat{\sigma}_{linhas}^2$ ), colunas ( $\hat{\sigma}_{colunas}^2$ ), residual ( $\hat{\sigma}_e^2$ ), variância dos erros correlacionados ( $\hat{\sigma}_\xi^2$ ), variância do erro independente ( $\hat{\sigma}_\eta^2$ ) e soma dos componentes  $\hat{\sigma}_\xi^2$  e  $\hat{\sigma}_\eta^2$  ( $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ ). Coeficientes de autocorrelação residual nas linhas ( $\hat{\rho}_r$ ) e nas colunas ( $\hat{\rho}_c$ ). Valor-p para o efeito de genótipos, pelo teste da razão de verossimilhança (valor-p ( $\hat{\sigma}_g^2$ )). Herdabilidade no sentido amplo ( $\hat{h}^2$ ), acurácia seletiva ( $\hat{r}_{gg}$ ), variância do erro de predição (PEV), média de produtividade de grãos, coeficiente de variação experimental (CV), logaritmo do máximo da função de verossimilhança (Log L), critério de informação de Akaike (AIC), mudança do valor de Log L do modelo em relação ao seu respectivo modelo básico em blocos casualizados (Mud. Log L) e eficiência do modelo em função de herdabilidade (Efic.  $\hat{h}^2$ )

| Parâmetros                                 | Modelos estatísticos <sup>†</sup> e seus respectivos efeitos fixos <sup>‡</sup> , aleatórios <sup>§</sup> e resíduos <sup>¶</sup> |                    |                    |                    |                    |                    |                    |                    |  |                      |                      |                      |                      |                      |                      |                      |
|--|---|--------------------|--------------------|--------------------|--------------------|--------------------|--------------------|--------------------|--|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
|  | Modelos sem inclusão da covariável estande  |                    |                    |                    |                    |                    |                    |                    | Modelos com inclusão da covariável estande |                      |                      |                      |                      |                      |                      |                      |
|  | Mod. 1  | Mod. 2             | Mod. 3             | Mod. 4             | Mod. 5             | Mod. 6             | Mod. 7             | Mod. 8             | Mod. 9                                     | Mod. 10              | Mod. 11              | Mod. 12              | Mod. 13              | Mod. 14              | Mod. 15              | Mod. 16              |
|  | $\mu, r$  | $\mu, r$           | $\mu, r$           | $\mu, r$           | $\mu, r$           | $\mu, r$           | $\mu, r$           | $\mu, r$           | $\mu, r, \beta_{st}$                       | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ |
|  | $g$   | $g, b$             | $g$                | $g$                | $g, l, c$          | $g, b$             | $g, b$             | $g, b, l, c$       | $g$  | $g, b$               | $g$                  | $g$                  | $g, l, c$            | $g, b$               | $g, b$               | $g, b, l, c$         |
|  | $e$   | $e$                | $\zeta$            | $\zeta, \eta$      | $\zeta, \eta$      | $\zeta$            | $\zeta, \eta$      | $\zeta, \eta$      | $e$  | $e$                  | $\zeta$              | $\zeta, \eta$        | $\zeta, \eta$        | $\zeta$              | $\zeta, \eta$        | $\zeta, \eta$        |
| $\hat{\sigma}_g^2$                         | 2264845**   | 2264845**          | 2245207**          | 2245458**          | 2114179**          | 2245462**          | 2245455**          | 2111530**          | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_b^2$                         | -   | 0,33               | -                  | -                  | -                  | 0,04               | 0,08               | 0,59               | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_{linhas}^2$                  | -   | -                  | -                  | -                  | 57981              | -                  | -                  | 58283              | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_{colunas}^2$                 | -   | -                  | -                  | -                  | 44304              | -                  | -                  | 44599              | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_e^2$                         | 431021  | 431021             | -                  | -                  | -                  | -                  | -                  | -                  | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_\xi^2$                       | -   | -                  | 432530             | 432558             | 369608             | 432561             | 432560             | 369125             | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_\eta^2$                      | -   | -                  | -                  | 2,48               | 0,58               | -                  | 0,11               | 3,69E-04           | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ | -   | -                  | -                  | 432560             | 369609             | -                  | 432560             | 369125             | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\rho}_r$                             | -   | -                  | -0,08              | -0,08              | -0,15              | -0,08              | -0,08              | -0,15              | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\rho}_c$                             | -   | -                  | 0,05               | 0,05               | -0,14              | 0,05               | 0,05               | -0,14              | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| valor-p ( $\hat{\sigma}_g^2$ )             | 6,00E-11  | 6,00E-11           | 5,56E-11           | 5,56E-11           | 9,42E-11           | 5,56E-11           | 5,56E-11           | 9,42E-11           | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{h}^2$                                | 0,89  | 0,89               | 0,89               | 0,89               | 0,88               | 0,89               | 0,89               | 0,88               | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{r}_{gg}$                             | 0,94  | 0,94               | 0,94               | 0,94               | 0,94               | 0,94               | 0,94               | 0,94               | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| PEV  | 254232  | 254232             | 253061             | 253065             | 247073             | 253066             | 253065             | 246959             | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| Média                                      | 5087  | 5087               | 5085               | 5085               | 5090               | 5085               | 5085               | 5090               | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| CV (%)                                     | 12,91   | 12,91              | 12,93              | 12,93              | 11,94              | 12,93              | 12,93              | 11,94              | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| Log L                                      | -535,43   | -535,43            | -535,32            | -535,32            | -535,08            | -535,32            | -535,32            | -535,08            | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| AIC  | 1074,85   | 1076,85            | 1078,65            | 1080,65            | 1084,17            | 1080,65            | 1082,65            | 1086,17            | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
|  | Comparações relativas ao Modelo 1   |                    |                    |                    |                    |                    |                    |                    | Comparações relativas ao Modelo 9          |                      |                      |                      |                      |                      |                      |                      |
| Mud. Log L                                 | -   | 0,00 <sup>ns</sup> | 0,10 <sup>ns</sup> | 0,10 <sup>ns</sup> | 0,34 <sup>ns</sup> | 0,10 <sup>ns</sup> | 0,10 <sup>ns</sup> | 0,34 <sup>ns</sup> | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
|  | Comparações relativas ao Modelo 1   |                    |                    |                    |                    |                    |                    |                    | Comparações relativas ao Modelo 9          |                      |                      |                      |                      |                      |                      |                      |
| Efic. $\hat{h}^2$                          | -   | 1,00               | 1,00               | 1,00               | 0,99               | 1,00               | 1,00               | 0,99               | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |

<sup>†</sup> Modelos estatísticos descritos na Tabela 1. <sup>‡</sup> Efeitos fixos:  $\mu$ : média;  $r$ : efeito de repetição;  $\beta_{st}$ : efeito da covariável estande. <sup>§</sup> Efeitos aleatórios:  $g$ : efeito de genótipos;  $b$ : efeito de blocos do látice;  $l$ : efeito de linhas;  $c$ : efeito de colunas. <sup>¶</sup> Resíduos:  $e$ : erros aleatórios;  $\xi$ : erros correlacionados;  $\eta$ : erros independentes. \*\* Significativo ao nível de 1% de probabilidade. <sup>ns</sup> não significativo.

**Tabela 17.** Correlações de Spearman e frequências de genótipos selecionados comuns, considerando o ensaio VCU – Alta Adubação, safra 2016/17. Acima da diagonal, correlações de Spearman entre os pares de modelos estatísticos considerando os valores genotípicos (u + g) preditos para produtividade de grãos. Abaixo da diagonal, frequências de genótipos selecionados comuns aos pares de modelos estatísticos, considerando a seleção dos quatro híbridos superiores quanto ao valor genotípico (u + g) de produtividade de grãos

|        | Mod. 1 | Mod. 2 | Mod. 3 | Mod. 4 | Mod. 5 | Mod. 6 | Mod. 7 | Mod. 8 |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| Mod. 1 | -      | 1      | 0,999  | 0,999  | 0,985  | 0,999  | 0,999  | 0,985  |
| Mod. 2 | 1      | -      | 0,999  | 0,999  | 0,985  | 0,999  | 0,999  | 0,985  |
| Mod. 3 | 1      | 1      | -      | 1      | 0,983  | 1      | 1      | 0,983  |
| Mod. 4 | 1      | 1      | 1      | -      | 0,983  | 1      | 1      | 0,983  |
| Mod. 5 | 1      | 1      | 1      | 1      | -      | 0,983  | 0,983  | 1      |
| Mod. 6 | 1      | 1      | 1      | 1      | 1      | -      | 1      | 0,983  |
| Mod. 7 | 1      | 1      | 1      | 1      | 1      | 1      | -      | 0,983  |
| Mod. 8 | 1      | 1      | 1      | 1      | 1      | 1      | 1      | -      |

Na Tabela 18 são apresentados os valores genotípicos preditos para produtividade de grãos ( $\text{kg ha}^{-1}$ ) com base nos modelos tradicionais de blocos casualizados (Modelo 1) e de látice parcialmente balanceado (Modelo 2). Observou-se que foram preditos os mesmos valores genotípicos para cada tratamento com os modelos 1 e 2, de modo que a classificação dos híbridos foi a mesma (Tabela 18), como já verificado anteriormente pelo coeficiente de correlação de Spearman apresentado na Tabela 17. Os híbridos 1N1958 (tratamento 31), 1O2109 (tratamento 27), 1O2106 (tratamento 28) e 1O2088 (tratamento 25) foram classificados, respectivamente, como primeiro, segundo, terceiro e quarto maior valor genotípico predito pelos modelos 1 e 2 na safra 2016/17 (Tabela 18), sendo que todos esses quatro híbridos selecionados são híbridos experimentais desenvolvidos pela Embrapa Milho e Sorgo.

Com base nas estimativas de Log L, AIC e nas classificações dos valores genotípicos preditos com os modelos tradicionais de blocos casualizados (Modelo 1) e de látice parcialmente balanceado (Modelo 2), ressalta-se que o delineamento de látice parcialmente balanceado não foi eficiente na análise estatística da produtividade de grãos da safra 2016/17. Além disso, pode-se inferir que a área experimental usada nesta safra

de 2016/17 é homogênea o suficiente para garantir o estabelecimento de blocos completos homogêneos.

**Tabela 18.** Valores genotípicos preditos para produtividade de grãos (kg ha<sup>-1</sup>) dos híbridos de milho do ensaio VCU – Alta Adubação, na safra 2016/17. Valores genotípicos preditos pelos seguintes modelos: modelo tradicional de blocos casualizados (Modelo 1); modelo tradicional de látice quadrado parcialmente balanceado (Modelo 2)

| Trat. | Híbrido      | Modelo 1 |         | Modelo 2 |         |
|-------|--------------|----------|---------|----------|---------|
|       |              | VG       | Ranking | VG       | Ranking |
| 31    | 1N1958       | 8067     | 1       | 8067     | 1       |
| 27    | 1O2109       | 7717     | 2       | 7717     | 2       |
| 28    | 1O2106       | 7477     | 3       | 7477     | 3       |
| 25    | 1O2088       | 6669     | 4       | 6669     | 4       |
| 33    | DKB390PRO2   | 6403     | 5       | 6403     | 5       |
| 19    | 1O2048       | 6317     | 6       | 6317     | 6       |
| 18    | DKB310VTPRO2 | 6193     | 7       | 6193     | 7       |
| 14    | 1O2034       | 6081     | 8       | 6081     | 8       |
| 23    | 1O2018       | 5965     | 9       | 5965     | 9       |
| 7     | 1L1421       | 5902     | 10      | 5902     | 10      |
| 21    | 1O2045       | 5898     | 11      | 5898     | 11      |
| 11    | 1O2054       | 5779     | 12      | 5779     | 12      |
| 5     | 1N1975       | 5759     | 13      | 5759     | 13      |
| 16    | 1O2010       | 5731     | 14      | 5731     | 14      |
| 24    | 1O2008       | 5679     | 15      | 5679     | 15      |
| 26    | 1O2069       | 5653     | 16      | 5653     | 16      |
| 15    | 1O2058       | 5211     | 17      | 5211     | 17      |
| 3     | 1M1760       | 4987     | 18      | 4987     | 18      |
| 6     | 1L1411       | 4938     | 19      | 4938     | 19      |
| 1     | 1M1752       | 4899     | 20      | 4899     | 20      |
| 35    | 1O2112       | 4892     | 21      | 4892     | 21      |
| 36    | 1O2073       | 4884     | 22      | 4884     | 22      |
| 12    | 1M1766       | 4811     | 23      | 4811     | 23      |
| 13    | 1O2012       | 4733     | 24      | 4733     | 24      |
| 2     | 1M1764       | 4716     | 25      | 4716     | 25      |
| 17    | 1O2050       | 4447     | 26      | 4447     | 26      |
| 34    | 1O2078       | 4408     | 27      | 4408     | 27      |
| 8     | 1M1824       | 4391     | 28      | 4391     | 28      |
| 22    | 2B587PW      | 3928     | 29      | 3928     | 29      |
| 20    | 1O2007       | 3815     | 30      | 3815     | 30      |
| 4     | 1M1718       | 3590     | 31      | 3590     | 31      |
| 32    | 1O2080       | 3341     | 32      | 3341     | 32      |
| 29    | 1O2074       | 3319     | 33      | 3319     | 33      |
| 10    | BRS1055      | 2386     | 34      | 2386     | 34      |
| 9     | 1M1731       | 2114     | 35      | 2114     | 35      |
| 30    | 1O2102       | 2016     | 36      | 2016     | 36      |

### 4.2.3. Produtividade de grãos – safra 2017/18

As estimativas de parâmetros relacionados à característica produtividade de grãos da safra 2017/18 são apresentadas na Tabela 19. Verificou-se pelo teste da razão de verossimilhança que a variância genotípica foi significativa somente com os ajustes dos modelos 3, 4, 6 e 7. A variância genotípica foi não significativa com os ajustes dos modelos 1, 2, 5, 8, 9 e 10. Os valores-p dos modelos ajustados variaram de 1,04E-03 (modelos 4 e 7) a 1,00 (modelos 5 e 8). Quanto as estimativas de coeficiente de variação experimental (CV), observou-se que as estimativas variaram de 12,68% (Modelo 8) a 16,32% (Modelo 7).

Entre os modelos que não incluem o estande como covariável, observou-se que apenas os modelos 4, 5 e 7 apresentaram melhores ajustes em relação ao ajuste alcançado pelo modelo tradicional de blocos casualizados (Modelo 1), uma vez que as mudanças nos valores de Log L relativas ao Modelo 1 foram significativas apenas com os modelos 4, 5 e 7 (Tabela 19). Dentro do grupo de modelos que não incluem o estande como covariável, o Modelo 4 apresentou o menor valor de AIC (Tabela 19) e foi selecionado como o melhor modelo desse grupo.

No grupo de modelos que incluem o estande como covariável foram ajustados somente os modelos 9 e 10. Observou-se que esses dois modelos não diferiram quanto ao ajuste, apresentando o mesmo valor de Log L e, conseqüentemente, mudança do valor de Log L do Modelo 10 em relação ao Modelo 9 igual a zero e não significativa (Tabela 19). O Modelo 9 apresentou menor valor de AIC (Tabela 19).

**Tabela 19.** Estimativas de parâmetros genéticos e estatísticos do ensaio VCU – Alta Adubação, safra 2017/18, para a característica produtividade de grãos. Estimativas de componentes de variâncias genotípica ( $\hat{\sigma}_g^2$ ), blocos ( $\hat{\sigma}_b^2$ ), linhas ( $\hat{\sigma}_{linhas}^2$ ), colunas ( $\hat{\sigma}_{colunas}^2$ ), residual ( $\hat{\sigma}_e^2$ ), variância dos erros correlacionados ( $\hat{\sigma}_\xi^2$ ), variância dos erros independentes ( $\hat{\sigma}_\eta^2$ ) e soma dos componentes  $\hat{\sigma}_\xi^2$  e  $\hat{\sigma}_\eta^2$  ( $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ ). Coeficientes de autocorrelação residual nas linhas ( $\hat{\rho}_r$ ) e nas colunas ( $\hat{\rho}_c$ ). Valor-p para o efeito de genótipos, pelo teste da razão de verossimilhança (valor-p ( $\hat{\sigma}_g^2$ )). Herdabilidade no sentido amplo ( $\hat{h}^2$ ), acurácia seletiva ( $\hat{r}_{gg}$ ), variância do erro de predição (PEV), média de produtividade de grãos, coeficiente de variação experimental (CV), logaritmo do máximo da função de verossimilhança (Log L), critério de informação de Akaike (AIC), mudança do valor de Log L do modelo em relação ao seu respectivo modelo básico em blocos casualizados (Mud. Log L) e eficiência do modelo em função de herdabilidade (Efic.  $\hat{h}^2$ )

| Parâmetros                                 | Modelos estatísticos <sup>†</sup> e seus respectivos efeitos fixos <sup>‡</sup> , aleatórios <sup>§</sup> e resíduos <sup>¶</sup> |                      |                    |               |                    |                    |               |                    |  |                      |                      |                      |                      |                      |                      |                      |
|--|---|----------------------|--------------------|---------------|--------------------|--------------------|---------------|--------------------|--|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
|  | Modelos sem inclusão da covariável estande  |                      |                    |               |                    |                    |               |                    | Modelos com inclusão da covariável estande |                      |                      |                      |                      |                      |                      |                      |
|  | Mod. 1  | Mod. 2               | Mod. 3             | Mod. 4        | Mod. 5             | Mod. 6             | Mod. 7        | Mod. 8             | Mod. 9                                     | Mod. 10              | Mod. 11              | Mod. 12              | Mod. 13              | Mod. 14              | Mod. 15              | Mod. 16              |
|  | $\mu, r$  | $\mu, r$             | $\mu, r$           | $\mu, r$      | $\mu, r$           | $\mu, r$           | $\mu, r$      | $\mu, r$           | $\mu, r, \beta_{st}$                       | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ | $\mu, r, \beta_{st}$ |
|  | $g$   | $g, b$               | $g$                | $g$           | $g, l, c$          | $g, b$             | $g, b$        | $g, b, l, c$       | $g$  | $g, b$               | $g$                  | $g$                  | $g, l, c$            | $g, b$               | $g, b$               | $g, b, l, c$         |
|  | $e$   | $e$                  | $\zeta$            | $\zeta, \eta$ | $\zeta, \eta$      | $\zeta$            | $\zeta, \eta$ | $\zeta, \eta$      | $e$  | $e$                  | $\zeta$              | $\zeta, \eta$        | $\zeta, \eta$        | $\zeta$              | $\zeta, \eta$        | $\zeta, \eta$        |
| $\hat{\sigma}_g^2$                         | 358039 <sup>ns</sup>  | 358039 <sup>ns</sup> | 1725640*           | 932451**      | 0,50 <sup>ns</sup> | 1725768*           | 954160**      | 0,38 <sup>ns</sup> | 268736 <sup>ns</sup>                       | 268736 <sup>ns</sup> | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_b^2$                         | -   | 0,46                 | -                  | -             | -                  | 1,22               | 0,33          | 41841              | -  | 0,07                 | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_{linhas}^2$                  | -   | -                    | -                  | -             | 474863             | -                  | -             | 478539             | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_{colunas}^2$                 | -   | -                    | -                  | -             | 0,88               | -                  | -             | 0,38               | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_e^2$                         | 1693766   | 1693766              | -                  | -             | -                  | -                  | -             | -                  | 1700021                                    | 1700021              | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_\xi^2$                       | -   | -                    | 1902731            | 2259299       | 1664944            | 1902928            | 2288022       | 1621337            | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_\eta^2$                      | -   | -                    | -                  | 693423        | 0,99               | -                  | 709732        | 6,24               | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ | -   | -                    | -                  | 2952722       | 1664945            | -                  | 2997754       | 1621343            | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\rho}_r$                             | -   | -                    | 0,64               | 0,88          | -0,27              | 0,64               | 0,88          | -0,29              | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{\rho}_c$                             | -   | -                    | 0,72               | 0,96          | -0,41              | 0,72               | 0,96          | -0,43              | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| valor-p ( $\hat{\sigma}_g^2$ )             | 2,98E-01  | 2,99E-01             | 2,45E-02           | 1,04E-03      | 1,00               | 2,71E-02           | 1,04E-03      | 1,00               | 4,20E-01                                   | 4,20E-01             | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{h}^2$                                | -   | -                    | 0,85               | 0,65          | -                  | 0,85               | 0,66          | -                  | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |
| $\hat{r}_{gg}$                             | 0,54  | 0,54                 | 0,92               | 0,81          | 0,001              | 0,92               | 0,81          | 0,001              | 0,48                                       | 0,48                 | -                    | -                    | -                    | -                    | -                    | -                    |
| PEV  | 254604  | 254604               | 257674             | 323338        | 0,50               | 257661             | 323376        | 0,38               | 206968                                     | 206968               | -                    | -                    | -                    | -                    | -                    | -                    |
| Média                                      | 10081   | 10081                | 10297              | 10602         | 10043              | 10297              | 10606         | 10043              | 10081                                      | 10081                | -                    | -                    | -                    | -                    | -                    | -                    |
| CV (%)                                     | 12,91   | 12,91                | 13,40              | 16,21         | 12,85              | 13,40              | 16,32         | 12,68              | 12,93                                      | 12,93                | -                    | -                    | -                    | -                    | -                    | -                    |
| Log L                                      | -546,74   | -546,74              | -544,40            | -541,56       | -540,79            | -544,40            | -541,56       | -540,60            | -548,58                                    | -548,58              | -                    | -                    | -                    | -                    | -                    | -                    |
| AIC  | 1097,48   | 1099,48              | 1096,81            | 1093,12       | 1095,58            | 1098,81            | 1095,12       | 1097,21            | 1101,16                                    | 1103,16              | -                    | -                    | -                    | -                    | -                    | -                    |
|  | Comparações relativas ao Modelo 1   |                      |                    |               |                    |                    |               |                    | Comparações relativas ao Modelo 9          |                      |                      |                      |                      |                      |                      |                      |
| Mud. Log L                                 | -   | 0,00 <sup>ns</sup>   | 2,34 <sup>ns</sup> | 5,18*         | 5,95*              | 2,34 <sup>ns</sup> | 5,18*         | 6,14 <sup>ns</sup> | -  | 0,00 <sup>ns</sup>   | -                    | -                    | -                    | -                    | -                    | -                    |
|  | Comparações relativas ao Modelo 1   |                      |                    |               |                    |                    |               |                    |  |                      |                      |                      |                      |                      |                      |                      |
| Efic. $\hat{h}^2$                          | -   | -                    | -                  | -             | -                  | -                  | -             | -                  | -  | -                    | -                    | -                    | -                    | -                    | -                    | -                    |

<sup>†</sup> Modelos estatísticos descritos na Tabela 1. <sup>‡</sup> Efeitos fixos:  $\mu$ : média;  $r$ : efeito de repetição;  $\beta_{st}$ : efeito da covariável estande. <sup>§</sup> Efeitos aleatórios:  $g$ : efeito de genótipos;  $b$ : efeito de blocos do látice;  $l$ : efeito de linhas;  $c$ : efeito de colunas. <sup>¶</sup> Resíduos:  $e$ : erros aleatórios;  $\xi$ : erros correlacionados;  $\eta$ : erros independentes. \* Significativo ao nível de 5% de probabilidade. \*\* Significativo ao nível de 1% de probabilidade. <sup>ns</sup> não significativo.

Comparando os dois modelos (4 e 9) selecionados dentro de cada grupo verificou-se que foram estimados menor valor-p associado à variância genotípica e maiores valores de herdabilidade e acurácia com base no Modelo 4 (Tabela 19). Além disso o componente de variância genotípica foi significativo apenas com o Modelo 4. Assim, o Modelo 4 foi selecionado como o mais promissor para a análise da produtividade de grãos dos híbridos avaliados em condições de alta adubação na safra de 2017/18, fato que evidencia a importância da análise espacial.

Considerando-se os valores genotípicos preditos com os modelos que apresentaram variâncias genotípicas significativas (modelos 3, 4, 6 e 7), foram estimados os coeficientes de correlação de Spearman e as frequências de híbridos comuns selecionados. Esses resultados são apresentados na Tabela 20. Observou-se que os quatro híbridos identificados como superiores pelo Modelo 4 também foram selecionados com os modelos 3, 6 e 7 (Tabela 20). No entanto, somente o Modelo 7 garantiu a mesma classificação geral dos híbridos estabelecida com o Modelo 4, uma vez que o coeficiente de correlação de Spearman igual ao valor um foi estimado entre os valores genotípicos preditos pelos modelos 4 e 7 (Tabela 20).

Na Tabela 21 são apresentados os valores genotípicos preditos para produtividade de grãos ( $\text{kg ha}^{-1}$ ) com base no Modelo 4 e nos modelos tradicionais de blocos casualizados (Modelo 1) e de látice parcialmente balanceado (Modelo 2). Como os componentes de variância genotípica estimados pelos modelos 1 e 2 foram não significativos (Tabela 19), a classificação dos valores genotípicos preditos com os modelos 1 e 2 (Tabela 21) não apresentam interpretação confiável do ponto de vista estatístico. Como mencionado anteriormente, com o Modelo 4 foram estimados componente de variância genotípica significativa e alto valor de acurácia seletiva (Tabela 19). Assim, considerando os valores genotípicos preditos com o Modelo 4, verificou-se que os híbridos 1N1958 (tratamento 6), 1P2214 (tratamento 25), 1P2267 (tratamento 35)

e DKB310 PRO2 (tratamento 10) foram classificados como primeiro, segundo, terceiro e quarto maior valor genotípico, respectivamente (Tabela 21). Dentre esses quatro híbridos superiores, verificou-se que somente o DKB310 PRO2 é um híbrido comercial usado como testemunha, sendo que os outros três híbridos (1N1958, 1P2214 e 1P2267) são híbridos experimentais desenvolvidos pela Embrapa Milho e Sorgo.

**Tabela 20.** Correlações de Spearman e frequências de genótipos selecionados comuns, considerando o ensaio VCU – Alta Adubação, safra 2017/18. Acima da diagonal, correlações de Spearman entre os pares de modelos estatísticos considerando os valores genotípicos (u + g) preditos para produtividade de grãos. Abaixo da diagonal, frequências de genótipos selecionados comuns aos pares de modelos estatísticos, considerando a seleção dos quatro híbridos superiores quanto ao valor genotípico (u + g) de produtividade de grãos

|        | Mod. 3 | Mod. 4 | Mod. 6 | Mod. 7 |
|--------|--------|--------|--------|--------|
| Mod. 3 | -      | 0,957  | 1      | 0,957  |
| Mod. 4 | 1      | -      | 0,957  | 1      |
| Mod. 6 | 1      | 1      | -      | 0,957  |
| Mod. 7 | 1      | 1      | 1      | -      |

**Tabela 21.** Valores genotípicos (VG) preditos para produtividade de grãos (kg ha<sup>-1</sup>) dos híbridos de milho do ensaio VCU – Alta Adubação, na safra 2017/18. Valores genotípicos preditos pelos seguintes modelos: modelo tradicional de blocos casualizados (Modelo 1); modelo tradicional de látice quadrado parcialmente balanceado (Modelo 2); e modelo de blocos casualizados, considerando no vetor de resíduos ( $e$ ) os erros correlacionados ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e os erros independentes ( $\eta$ ) (Modelo 4)

| Trat. | Híbrido     | Modelo 1 |         | Modelo 2 |         | Modelo 4 |         |
|-------|-------------|----------|---------|----------|---------|----------|---------|
|       |             | VG       | Ranking | VG       | Ranking | VG       | Ranking |
| 6     | 1N1958      | 10537    | 4       | 10537    | 4       | 12185    | 1       |
| 25    | 1P2214      | 10732    | 1       | 10732    | 1       | 11881    | 2       |
| 35    | 1P2267      | 10392    | 5       | 10392    | 5       | 11764    | 3       |
| 10    | DKB310 PRO2 | 10332    | 7       | 10332    | 7       | 11687    | 4       |
| 2     | 1M1804      | 10677    | 3       | 10677    | 3       | 11602    | 5       |
| 27    | 1P2212      | 10246    | 11      | 10246    | 11      | 11525    | 6       |
| 21    | 1P2203      | 10708    | 2       | 10708    | 2       | 11425    | 7       |
| 14    | 1P2224      | 10188    | 13      | 10188    | 13      | 11415    | 8       |
| 11    | 1O2073      | 10315    | 9       | 10315    | 9       | 11021    | 9       |
| 8     | 1O2106      | 10018    | 21      | 10018    | 21      | 10983    | 10      |
| 5     | 1M1782      | 10293    | 10      | 10293    | 10      | 10973    | 11      |
| 30    | 1P2255      | 10353    | 6       | 10353    | 6       | 10900    | 12      |
| 20    | 1P2237      | 10330    | 8       | 10330    | 8       | 10890    | 13      |
| 23    | 1P2184      | 10224    | 12      | 10224    | 12      | 10859    | 14      |
| 33    | 1F640       | 9965     | 22      | 9965     | 22      | 10845    | 15      |
| 17    | 1P2216      | 10177    | 14      | 10177    | 14      | 10793    | 16      |
| 9     | 1O2112      | 10119    | 20      | 10119    | 20      | 10714    | 17      |
| 36    | 1P2215      | 10153    | 16      | 10153    | 16      | 10617    | 18      |
| 24    | 1P2175      | 10121    | 19      | 10121    | 19      | 10570    | 19      |
| 29    | 1M1752      | 9964     | 23      | 9964     | 23      | 10530    | 20      |
| 1     | 1L1411      | 10172    | 15      | 10172    | 15      | 10489    | 21      |
| 3     | 1M1810      | 10136    | 17      | 10136    | 17      | 10470    | 22      |
| 26    | 1P2188      | 9849     | 28      | 9849     | 28      | 10431    | 23      |
| 32    | 1P2247      | 9927     | 25      | 9927     | 25      | 10386    | 24      |
| 4     | 1M1807      | 9796     | 29      | 9796     | 29      | 10316    | 25      |
| 15    | 1P2227      | 9870     | 27      | 9870     | 27      | 10228    | 26      |
| 22    | BRS 3042    | 10132    | 18      | 10132    | 18      | 10221    | 27      |
| 28    | 1P2273      | 9871     | 26      | 9871     | 26      | 10123    | 28      |
| 31    | 1P2265      | 9953     | 24      | 9953     | 24      | 9903     | 29      |
| 13    | 1O2018      | 9712     | 32      | 9712     | 32      | 9831     | 30      |
| 12    | 1O2008      | 9625     | 33      | 9625     | 33      | 9745     | 31      |
| 16    | 1N1906      | 9443     | 36      | 9443     | 36      | 9489     | 32      |
| 18    | DKB390 PRO2 | 9765     | 30      | 9765     | 30      | 9413     | 33      |
| 7     | 1O2034      | 9450     | 35      | 9450     | 35      | 9206     | 34      |
| 34    | 1P2231      | 9619     | 34      | 9619     | 34      | 9190     | 35      |
| 19    | 1P2193      | 9764     | 31      | 9764     | 31      | 9060     | 36      |

### **4.3. Produtividade de grãos – Importância dos delineamentos e de diferentes efeitos nos modelos ajustados (safras 2015/16, 2016/17 e 2017/18)**

Para a análise estatística dos dados de produtividade de grãos dos híbridos de milho avaliados em condições de alta adubação, na Embrapa Milho e Sorgo, os modelos selecionados como mais adequados foram: Modelo 9 (safra 2015/16), Modelo 1 (safra 2016/17) e Modelo 4 (safra 2017/18). O Modelo 9 é o modelo que considera delineamento de blocos casualizados, inclusão de estande como covariável e resíduos ( $e$ ) independentes. O Modelo 1 é o modelo tradicional de blocos casualizados, que considera resíduos ( $e$ ) independentes. O Modelo 4 é o modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ). Observou-se que entre os modelos selecionados nas três safras, todos consideram o delineamento de blocos casualizados, porém não houve um padrão quanto à modelagem da matriz de covariância residual e ao uso da covariável estande.

O fator que limitou ajustar todos os modelos que incluem o estande como covariável foi a ocorrência de efeito significativo de genótipos sobre a variável estande em vários modelos inicialmente ajustados para esta variável (Tabela 12). Assim, principalmente nas safras 2016/17 e 2017/18, as comparações entre modelos ajustados para a característica produtividade de grãos ficaram, predominantemente, limitadas aos oito modelos iniciais que não incluem o estande como covariável (modelos 1, 2, 3, 4, 5, 6, 7, e 8). No entanto, com a utilização do Modelo 9 na safra 2015/16, observou-se ligeira melhora das estimativas de herdabilidade e valor-p no ensaio de VCU conduzido em área experimental sob alta adubação nesta safra. Além disso, na safra 2015/16 observou-se que foram estimados menores valores de coeficiente de variação experimental com o ajuste dos modelos que incluem o estande como covariável (Tabela 13).

De modo geral, com os ajustes dos modelos que consideram o delineamento de látice parcialmente balanceado (modelos 2, 6, 7, 8, 10, 14, 15 e 16), observou-se que os

componentes de variância devido aos blocos incompletos ( $\hat{\sigma}_b^2$ ) foram de pequenas magnitudes e, praticamente, não contribuíram para aumentar as estimativas de Log L dos modelos quando comparados com seus respectivos modelos que consideram o delineamento de blocos completos casualizados (modelos 1, 3, 4, 5, 9, 11, 12, 13) (Tabelas 13, 16 e 19). Além disso, considerando os valores genotípicos preditos com os modelos tradicionais de blocos casualizados (Modelo 1) e de látice parcialmente balanceado (Modelo 2) nas três safras (Tabelas 15, 18 e 21), observou-se que os modelos 1 e 2 predizem exatamente o mesmo valor genotípico para cada híbrido de milho avaliado. Com base nessas informações, verificou-se que o uso do delineamento de látice parcialmente balanceado não foi eficiente nos ensaios de VCU conduzidos em condições de alta adubação na Embrapa Milho e Sorgo nas três safras avaliadas.

Considerando os efeitos de tendências globais de linhas e colunas, incluídos simultaneamente nos modelos, verificou-se que nas três safras esses efeitos não contribuíram para aumentar significativamente os valores de Log L. Comparando-se, por exemplo, os modelos 4 e 5 é possível inferir sobre os efeitos de tendências globais de linhas e colunas, uma vez que o Modelo 5 difere do Modelo 4 apenas pela inclusão dos efeitos aleatórios de linhas e colunas. Assim, comparando-se os valores de Log L estimados com os modelos 4 e 5, nas três safras (Tabelas 13, 16 e 19), verificou-se mudanças nos valores de Log L do Modelo 5 em relação ao Modelo 4 foi de: 0 (safra 2015/16), 0,24 (safra 2016/17) e 0,77 (safra 2017/18). Como o Modelo 5 difere do Modelo 4 em dois efeitos aleatórios (linhas e colunas), com base no teste da razão de verossimilhança, com dois graus de liberdade, verificou-se que as mudanças nos valores de Log L relatadas acima foram não significativas. Fato semelhante pode ser verificado comparando-se os valores de Log L dos modelos 7 e 8 (Tabelas 13, 16 e 19), cujas mudanças de Log L de 0 (safra 2015/16), 0,24 (safra 2016/17) e 0,96 (safra 2017/18) também foram não significativas.

Nas safras 2015/16 e 2016/17, verificou-se que os modelos espaciais que consideram a modelagem da matriz de covariância residual pelo processo autorregressivo separável de primeira ordem em duas dimensões ( $AR1 \times AR1$ ), não contribuíram para melhorar as estimativas de acurácia seletiva, sendo que as estimativas de acurácia seletiva foram iguais e de alta magnitude (0,94) com todos os modelos ajustados nestas duas safras (Tabelas 13 e 16). Nessas duas safras (2015/16 e 2016/17), observou-se predomínio de autocorrelações de baixa magnitude, sendo estimados valores negativos para autocorrelações entre linhas.

Diferentemente das safras 2015/16 e 2016/17, na safra 2017/18 alguns modelos espaciais ajustados (modelos 3, 4, 6 e 7) estimaram elevados valores de autocorrelações de linhas (0,64 e 0,88) e de colunas (0,72 e 0,96) (Tabela 19), fatos que indicam algum tipo de heterogeneidade espacial na área experimental levando a fortes efeitos de tendência local. Nesta safra de 2017/18, considerando as comparações do Modelo 3 com o 4 e do Modelo 6 com o 7 (Tabela 19), observou-se que a inclusão do termo do erro independente ( $\eta$ ) contribuiu para aumentar as estimativas de autocorrelações de linhas ( $\hat{\rho}_r$ ) e de colunas ( $\hat{\rho}_c$ ).

Na safra 2017/18, considerando as comparações do Modelo 4 com o 5 e do Modelo 7 com o 8, verificou-se que a inclusão dos efeitos de tendência global de linhas e colunas tornou negativas as estimativas de autocorrelações de linhas e colunas (efeitos de tendência local) (Tabela 19). Além disso, nos modelos 5 e 8, observou-se que a variância de linhas ( $\hat{\sigma}_{linhas}^2$ ) absorveu toda a variância genotípica ( $\hat{\sigma}_g^2$ ) e parte das variâncias residuais devido aos erros independentes ( $\hat{\sigma}_\eta^2$ ) e devido aos efeitos aleatórios de tendência ( $\hat{\sigma}_\xi^2$ ) (Tabela 19). Ressalta-se que o ensaio de VCU considerado envolve 36 tratamentos e duas repetições, totalizando 72 unidades experimentais distribuídas em 10 linhas e 8 colunas (Quadro 2). Percebe-se que nessa situação há um número relativamente pequeno de unidades experimentais, com poucas linhas e colunas. Desse modo, mesmo

as parcelas mais distantes podem não ter sido separadas por uma distância mínima o suficiente para tornar seus resíduos independentes nas condições experimentais do ensaio.

Além dos aspectos referentes ao pequeno número de unidades experimentais, a elevada estimativa de variância de linhas ( $\hat{\sigma}_{linhas}^2$ ), em detrimento da variância genotípica ( $\hat{\sigma}_g^2$ ), pode estar relacionada com a necessidade de incluir algum outro tipo de efeito de tendência global de linhas que não foi adequadamente considerado nos modelos ajustados na Tabela 19. Assim, buscando-se visualizar algum tipo de comportamento sistemático entre linhas, os dados de produtividade de grãos da safra 2017/18 foram plotados em um croqui do ensaio de VCU instalado nesta safra (Quadro 2).

Com base na distribuição espacial dos dados de produtividade de grãos e das médias de linhas (Quadro 2), observou-se uma tendência entre as linhas, de modo que as linhas mais próximas das laterais da área experimental apresentaram maiores médias de produtividade de grãos; e as linhas mais próximas do centro da área experimental apresentaram médias menores. Nesse caso, considerar o efeito aleatório de *spline* em linhas pode explicar melhor a variação sistemática nas médias das linhas. Assim, para verificar a existência de efeito de tendência global de *spline* de linhas, os seguintes modelos foram ajustados: um modelo de blocos casualizados, com *spline* de linhas, resíduos correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ) (Modelo 17); e outro modelo de látice parcialmente balanceado, com *spline* de linhas, resíduos correlacionados ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ) (Modelo 18).

**Quadro 2.** Croqui do ensaio de VCU de híbridos de milho conduzido sob alta adubação na safra 2017/18. Distribuição espacial dos 36 tratamentos (2 repetições) às unidades experimentais e os respectivos valores de produtividades de grãos ( $\text{kg ha}^{-1}$ ) observados. Representação de repetições como blocos completos no Delineamento de Blocos Casualizados. Representação de blocos incompletos no delineamento de Látice quadrado parcialmente balanceado. Representação de produtividades de grãos ( $\text{kg ha}^{-1}$ ) nas unidades experimentais, com médias de produtividade de linhas definindo o agrupamento de unidades experimentais no processo de blocagem *a posteriori*

### Delineamento de Blocos Casualizados – Códigos de tratamentos

|          | Coluna 1 | Coluna 2 | Coluna 3 | Coluna 4 | Coluna 5 | Coluna 6 | Coluna 7 | Coluna 8 |
|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| Linha 1  | 1        | 20       | 21       | 19       | 25       | 34       | 5        | -        |
| Linha 2  | 2        | 19       | 22       | 13       | 31       | 28       | 11       | -        |
| Linha 3  | 3        | 18       | 23       | 7        | 2        | 22       | 17       | -        |
| Linha 4  | 4        | 17       | 24       | 1        | 8        | 16       | 23       | -        |
| Linha 5  | 5        | 16       | 25       | 36       | 14       | 10       | 29       | -        |
| Linha 6  | 6        | 15       | 26       | 35       | 20       | 4        | 35       | -        |
| Linha 7  | 7        | 14       | 27       | 34       | 26       | 33       | 6        | -        |
| Linha 8  | 8        | 13       | 28       | 33       | 32       | 27       | 12       | -        |
| Linha 9  | 9        | 12       | 29       | 32       | 3        | 21       | 18       | 36       |
| Linha 10 | 10       | 11       | 30       | 31       | 9        | 15       | 24       | 30       |

**Legenda:** ■ Repetição 1 – Bloco completo 1  
■ Repetição 2 – Bloco completo 2

### Látice quadrado parcialmente balanceado – Códigos de tratamentos

|          | Coluna 1 | Coluna 2 | Coluna 3 | Coluna 4 | Coluna 5 | Coluna 6 | Coluna 7 | Coluna 8 |
|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| Linha 1  | 1        | 20       | 21       | 19       | 25       | 34       | 5        | -        |
| Linha 2  | 2        | 19       | 22       | 13       | 31       | 28       | 11       | -        |
| Linha 3  | 3        | 18       | 23       | 7        | 2        | 22       | 17       | -        |
| Linha 4  | 4        | 17       | 24       | 1        | 8        | 16       | 23       | -        |
| Linha 5  | 5        | 16       | 25       | 36       | 14       | 10       | 29       | -        |
| Linha 6  | 6        | 15       | 26       | 35       | 20       | 4        | 35       | -        |
| Linha 7  | 7        | 14       | 27       | 34       | 26       | 33       | 6        | -        |
| Linha 8  | 8        | 13       | 28       | 33       | 32       | 27       | 12       | -        |
| Linha 9  | 9        | 12       | 29       | 32       | 3        | 21       | 18       | 36       |
| Linha 10 | 10       | 11       | 30       | 31       | 9        | 15       | 24       | 30       |

**Legenda:** Blocos incompletos dentro de repetições:  
■ Bloco 1; ■ Bloco 4;  
■ Bloco 2; ■ Bloco 5;  
■ Bloco 3; ■ Bloco 6.

### Blocagem *a posteriori* vs. Blocagem *a priori* (Látice)

#### Produtividades de grãos ( $\text{kg ha}^{-1}$ )

|               | Coluna 1    | Coluna 2    | Coluna 3     | Coluna 4    | Coluna 5     | Coluna 6    | Coluna 7     | Coluna 8     | Médias             |
|---------------|-------------|-------------|--------------|-------------|--------------|-------------|--------------|--------------|--------------------|
| Linha 1       | 11113       | 12789       | 13041        | 9424        | 13798        | 9185        | 11803        | -            | 11593 <sup>†</sup> |
| Linha 2       | 11322       | 8600        | 10284        | 9829        | 10076        | 10807       | 11989        | -            | 10415 <sup>†</sup> |
| Linha 3       | 10090       | 9120        | 11821        | 9115        | 12848        | 10218       | 10417        | -            | 10518 <sup>†</sup> |
| Linha 4       | 9484        | 10392       | 9115         | 9660        | 10517        | 8287        | 9300         | -            | 9536 <sup>‡</sup>  |
| Linha 5       | 9787        | 7582        | 10742        | 7909        | 10732        | 11521       | 8478         | -            | 9536 <sup>‡</sup>  |
| Linha 6       | 11372       | 9128        | 9367         | 11983       | 9047         | 8756        | 10272        | -            | 9989 <sup>‡</sup>  |
| Linha 7       | 6796        | 10149       | 11459        | 7865        | 9233         | 9129        | 11857        | -            | 9498 <sup>‡</sup>  |
| Linha 8       | 9219        | 7845        | 7937         | 10253       | 8579         | 9815        | 8077         | -            | 8818 <sup>‡</sup>  |
| Linha 9       | 9756        | 9014        | 10894        | 10544       | 10444        | 11337       | 8915         | 12735        | 10455 <sup>†</sup> |
| Linha 10      | 10329       | 9746        | 9801         | 9223        | 10661        | 9615        | 11314        | 12190        | 10360 <sup>†</sup> |
| <b>Médias</b> | <b>9927</b> | <b>9437</b> | <b>10446</b> | <b>9580</b> | <b>10594</b> | <b>9867</b> | <b>10242</b> | <b>12462</b> |                    |

**Legenda:** ■ Bloco 1 – *post-block* 1;  
■ Bloco 2 – *post-block* 2.

<sup>†</sup> Linhas marcadas de azul: linhas com médias de produtividade de grãos superiores a  $10000 \text{ kg ha}^{-1}$ ;

<sup>‡</sup> Linhas marcadas de amarelo: linhas com médias de produtividade de grãos inferiores a  $10000 \text{ kg ha}^{-1}$ .

Na Tabela 22 são apresentadas as estimativas de parâmetros com os modelos 17 e 18, juntamente com os parâmetros estimados com os modelos 4, 5 e 8 (que foram apresentados previamente na Tabela 19). Observou-se que com a inclusão do efeito aleatório de *spline* de linhas, os modelos 17 e 18 foram capazes de captar variância genotípica significativa (Tabela 22). Pelas estimativas de AIC, verificou-se que o Modelo 17 foi mais adequado que os modelos 5 e 8 (Tabela 22). No entanto, o Modelo 4 selecionado previamente, teve estimativa de AIC menor que o Modelo 17 (Tabela 22). Além disso, a mudança de Log L do Modelo 17 em relação ao Modelo 4 foi não significativa (Tabela 22), evidenciando que o efeito de *spline* de linhas não contribuiu para melhorar o ajuste do modelo. Assim, percebe-se que o uso do Modelo 4, que considera apenas efeitos de tendência local, é mais adequado que o Modelo 17 que também considera o efeito de tendência global em *spline* de linhas.

Na safra 2017/18, comparando-se o Modelo 4 com o 7 (Tabela 19) e o Modelo 17 com o 18 (Tabela 22), verificou-se que a inclusão do efeito aleatório de blocos do látice não contribuiu para redução das autocorrelações de linhas e de colunas. O delineamento de látice quadrado parcialmente balanceado é capaz de remover parte das autocorrelações entre parcelas vizinhas quando as autocorrelações são causadas por heterogeneidade em manchas na área experimental. No caso do ensaio de VCU da safra 2017/18 a variação ocorreu entre linhas, de modo que os blocos incompletos foram compostos por linhas heterogêneas, o que comprometeu o pré-requisito de homogeneidade dentro de blocos.

**Tabela 22.** Estimativas de parâmetros genéticos e estatísticos do ensaio VCU – Alta Adubação, safra 2017/18, para a característica produtividade de grãos. Estimativas de componentes de variâncias genotípica ( $\hat{\sigma}_g^2$ ), blocos ( $\hat{\sigma}_b^2$ ), linhas ( $\hat{\sigma}_{linhas}^2$ ), colunas ( $\hat{\sigma}_{colunas}^2$ ), variância dos erros correlacionados ( $\hat{\sigma}_\xi^2$ ), variância dos erros independentes ( $\hat{\sigma}_\eta^2$ ) e soma dos componentes  $\hat{\sigma}_\xi^2$  e  $\hat{\sigma}_\eta^2$  ( $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$ ). Coeficientes de autocorrelação residual nas linhas ( $\hat{\rho}_r$ ) e nas colunas ( $\hat{\rho}_c$ ). Valor-p para o efeito de genótipos, pelo teste da razão de verossimilhança (valor-p ( $\hat{\sigma}_g^2$ )). Herdabilidade no sentido amplo ( $\hat{h}^2$ ), acurácia seletiva ( $\hat{r}_{gg}$ ), variância do erro de previsão (PEV), logaritmo do máximo da função de verossimilhança (Log L), critério de informação de Akaike (AIC) e mudança do valor de Log L dos modelos em relação ao Modelo 4 selecionado previamente (Mud. Log L)

| Modelos estatísticos e seus respectivos efeitos fixos <sup>†</sup> , aleatórios <sup>‡</sup> e resíduos <sup>§</sup> |             |                      |                      |                     |                      |
|--|-------------|----------------------|----------------------|---------------------|----------------------|
|  | Mod. 4      | Mod.5                | Mod. 8               | Mod. 17             | Mod. 18              |
|  | $\mu, r$    | $\mu, r$             | $\mu, r$             | $\mu, r$            | $\mu, r$             |
|  | $g$         | $g, l, c$            | $g, b, l, c$         | $g, spl (linhas)$   | $g, b, spl (linhas)$ |
| Parâmetros   | $\xi, \eta$ | $\xi, \eta$          | $\xi, \eta$          | $\xi, \eta$         | $\xi, \eta$          |
| $\hat{\sigma}_g^2$   | 932451**    | 0,50 <sup>ns</sup>   | 0,38 <sup>ns</sup>   | 829317*             | 825808*              |
| $\hat{\sigma}_b^2$   | -           | -                    | 41841 <sup>ns</sup>  | -                   | 0,16 <sup>ns</sup>   |
| $\hat{\sigma}_{linhas}^2$  | -           | 474863 <sup>ns</sup> | 478539 <sup>ns</sup> | -                   | -                    |
| $\hat{\sigma}_{colunas}^2$   | -           | 0,88 <sup>ns</sup>   | 0,38 <sup>ns</sup>   | -                   | -                    |
| $\hat{\sigma}_{spline(linhas)}^2$  | -           | -                    | -                    | 85232 <sup>ns</sup> | 84664 <sup>ns</sup>  |
| $\hat{\sigma}_\xi^2$   | 2259299     | 1664944              | 1621337              | 1036166             | 1058784              |
| $\hat{\sigma}_\eta^2$  | 693423      | 0,99                 | 6,24                 | 870586              | 863480               |
| $\hat{\sigma}_\xi^2 + \hat{\sigma}_\eta^2$   | 2952722     | 1664945              | 1621343              | 1906752             | 1922264              |
| $\hat{\rho}_r$   | 0,88        | -0,27                | -0,29                | 0,91                | 0,91                 |
| $\hat{\rho}_c$   | 0,96        | -0,41                | -0,43                | 0,95                | 0,95                 |
| valor-p ( $\hat{\sigma}_g^2$ )   | 1,04E-03    | 1,00                 | 1,00                 | 4,05E-02            | 4,05E-02             |
| $\hat{h}^2$  | 0,65        | -                    | -                    | 0,61                | 0,61                 |
| $\hat{r}_{gg}$   | 0,81        | 0,001                | 0,001                | 0,78                | 0,78                 |
| PEV  | 323338      | 0,50                 | 0,38                 | 325548              | 325166               |
| Log L  | -541,56     | -540,79              | -540,60              | -541,10             | -541,10              |
| AIC  | 1093,12     | 1095,58              | 1097,21              | 1094,21             | 1096,20              |
| Comparações relativas ao Modelo 4  |             |                      |                      |                     |                      |
| Mud. Log L   | -           | 0,77 <sup>ns</sup>   | 0,96 <sup>ns</sup>   | 0,46 <sup>ns</sup>  | 0,46 <sup>ns</sup>   |

<sup>†</sup> Efeitos fixos:  $\mu$ : média;  $r$ : efeito de repetição.

<sup>‡</sup> Efeitos aleatórios:  $g$ : efeito de genótipos;  $b$ : efeito de blocos do látice;  $l$ : efeito de linhas;  $c$ : efeito de colunas;  $spl (linhas)$ : efeito de splines em linhas.

<sup>§</sup> Resíduos:  $\xi$ : erro correlacionado;  $\eta$ : erro independente.

\* Significativo ao nível de 5% de probabilidade; \*\* Significativo ao nível de 1% de probabilidade; <sup>ns</sup> não significativo.

Com base no croqui apresentado do ensaio de VCU da safra 2017/18 (Quadro 2), outra técnica de análise espacial que pode ser sugerida para os dados desta safra é a blocagem *a posteriori*. O objetivo desta técnica é estabelecer blocos homogêneos com base nas informações dos dados obtidos do experimento, agrupando-se unidades experimentais de regiões homogêneas dentro da área experimental (GILMOUR, 2000). A blocagem *a posteriori* não preconiza a modelagem da matriz de covariância residual,

mas essa técnica permite que uma causa para as variações extrínsecas identificada pelo experimentador possa ser incluída no modelo estatístico (GILMOUR, 2000).

Desconsiderando os blocos delineados *a priori* (blocos incompletos do Látice) no ensaio de VCU da safra 2017/18 (Quadro 2), observou-se no croqui (Quadro 2) que as linhas com médias de produtividade de grãos superiores a 10000 kg ha<sup>-1</sup> (linhas marcadas em azul – Quadro 2) podem compor um bloco mais homogêneo (bloco *a posteriori*); e as linhas com médias inferiores a 10000 kg ha<sup>-1</sup> (linhas marcadas em amarelo – Quadro 2) podem compor outro bloco homogêneo. Desse modo, os blocos delineados *a posteriori* foram compostos pelo agrupamento das seguintes linhas: Bloco 1: linhas 1, 2, 3, 9 e 10; Bloco 2: linhas 4, 5, 6, 7 e 8. Com base nesses blocos delineados *a posteriori*, o seguinte modelo foi ajustado: modelo com inclusão de blocos *a posteriori* (efeitos fixos) e resíduos independentes (Modelo 19).

Na Tabela 23 são apresentados os resultados obtidos com o ajuste do Modelo 19 aos dados do ensaio de VCU da safra 2017/18. Observou-se na Tabela 23 que o uso da blocagem *a posteriori* também permitiu estimar variância genotípica significativa na safra de 2017/18, com estimativas de herdabilidade, acurácia seletiva e valor-p próximos aos valores estimados pelo Modelo 4 selecionado anteriormente na Tabela 19. Esse resultado reforça a ideia de que houve um efeito ambiental beneficiando as linhas próximas as laterais, de modo que esse efeito foi considerado em dois níveis nos blocos delineados *a posteriori*. Ressalta-se que, com a blocagem *a posteriori*, o valor de CV estimado no ensaio de VCU da safra 2017/18 reduziu para 9,38%.

**Tabela 23.** Estimativas de parâmetros genéticos e estatísticos do ensaio VCU – Alta Adubação, safra 2017/18, para a característica produtividade de grãos, considerando a blocagem a *posteriori*. Estimativas de componentes de variâncias genotípica ( $\hat{\sigma}_g^2$ ) e residual ( $\hat{\sigma}_e^2$ ). Valor-p para o efeito de genótipos, pelo teste da razão de verossimilhança (valor-p ( $\hat{\sigma}_g^2$ )). Média de produtividade de grãos, coeficiente de variação experimental (CV), herdabilidade no sentido amplo ( $\hat{h}^2$ ), acurácia seletiva ( $\hat{r}_{gg}$ ), variância do erro de predição (PEV) e logaritmo do máximo da função de verossimilhança (Log L)

| <b>Modelo 19 - efeitos fixos<sup>†</sup> e aleatórios<sup>‡</sup></b> |          |
|---|----------|
| <b>Modelo 19</b>  |          |
| <b>Parâmetros</b>   | $\mu, p$ |
|   | $g, e$   |
| $\hat{\sigma}_g^2$  | 884862** |
| $\hat{\sigma}_e^2$  | 891061   |
| valor-p ( $\hat{\sigma}_g^2$ )  | 3,08E-03 |
| $\hat{h}^2$   | 0,64     |
| $\hat{r}_{gg}$  | 0,80     |
| PEV   | 317122   |
| Média   | 10060    |
| CV (%)  | 9,38     |
| Log L   | -537,02  |

<sup>†</sup> Efeitos fixos:  $\mu$ : média;  $p$ : efeito de blocos delineados a *posteriori* (*post-block*).

<sup>‡</sup> Efeitos aleatórios:  $g$ : efeito de genótipos;  $e$ : resíduos considerados independentes.

\*\* Significativo ao nível de 1% de probabilidade.

## 5. Discussão

Para os experimentos de híbridos de milho em condições de alta adubação (VCU safras 2015/16, 2016/17 e 2017/18) foram ajustados os modelos tradicionais de blocos completos casualizados e de látice quadrado parcialmente balanceado, ambos considerando independência entre resíduos. Além desses modelos também foram ajustados os modelos espaciais AR1  $\times$  AR1 que combinaram correção espacial com esses delineamentos. Nas safras 2015/16 e 2016/17 os modelos 9 (DBC + covariável estande) e 1 (DBC), respectivamente, foram os modelos mais adequados para a análise dos dados, enquanto que na safra 2017/18 foi o Modelo 4 (DBC + AR1  $\times$  AR1 +  $\eta$ ). Ressalta-se que nesta condição de alta adubação os modelos que incluíam o delineamento de blocos casualizados foram mais adequados que aqueles com o delineamento de látice. Além disso, apenas na safra 2017/18 o modelo espacial foi mais adequado que os modelos tradicionais de blocos casualizados.

Segundo Ramalho et al. (2012a), o uso de maiores níveis de fertilizantes (altas adubações) em experimentos possibilita que as pequenas diferenças de fertilidade que existam sejam encobertas pela adubação usada. No entanto, a uniformidade na fertilidade do solo não é garantia de homogeneidade ambiental. A desuniformidade de distribuição de água na irrigação é um importante fator que contribui para aumento da heterogeneidade ambiental (RAMALHO et al., 2012b). Segundo esses mesmos autores, mesmo tomando cuidados na irrigação, como aplicação em baixa intensidade para evitar o escoamento superficial, a maioria das irrigações são realizadas por aspersores rotativos que cobrem áreas circulares, de modo que a aplicação bem uniforme não é possível.

Em áreas que apresentam uniformidade na fertilidade do solo, além da desuniformidade na distribuição da água de irrigação, a variação no estande devido a falhas, competição entre plantas da mesma parcela ou de parcelas vizinhas e a ocorrência de pragas e doenças, também são fatores que podem causar heterogeneidade ambiental dentro das áreas experimentais, afetando o resíduo e comprometendo a precisão experimental (RAMALHO et al., 2012a; 2012b). Além desses fatores, a variação na textura do solo e a presença de manchas de solos compactados também podem contribuir com heterogeneidade ambiental.

Para atenuar os efeitos da variação de estande sobre a produtividade de grãos, uma metodologia que se destaca é o uso do estande como covariável na análise estatística da produtividade de grãos (VENCOVSKY & CRUZ, 1991; RAMALHO et al., 2012a; CRUZ et al., 2014). Segundo Cruz et al. (2014), o uso do estande como covariável na análise da característica produtividade de grãos contribui para redução da variação residual e, conseqüentemente, redução do coeficiente de variação experimental. No entanto, Vencovsky & Cruz (1991) e Cruz et al. (2014) recomendam que o uso do estande como covariável deve ser feito unicamente quando as variações nos estandes forem proporcionadas por fatores aleatórios, de modo que não se deve proceder a análise com a

covariável estande quando as falhas nos estandes são inerentes aos próprios genótipos avaliados.

Nos resultados obtidos neste trabalho, verificou-se que houve efeito significativo de genótipos sobre a variável estande na maioria dos modelos ajustados nas safras 2016/17 e 2017/18 para a variável estande (Tabela 12). Na safra 2015/16, apenas dois modelos (modelos 5 e 8) ajustados para a variável estande identificaram variância genotípica significativa (Tabela 12). Desse modo, foi somente na safra 2015/16 que a maioria dos modelos que incluem o estande como covariável puderam ser ajustados para a característica produtividade de grãos. Mesmo com a prática de semeadura em excesso seguida de desbaste para estande desejado, a ocorrência de pragas e doenças pode ocasionar variação no estande. Em ensaios que os genótipos avaliados apresentarem diferentes genes de resistência a pragas e doenças, a variação no estande pode ocorrer em função do efeito de genótipos.

Com base nos resultados referentes a safra 2015/16, verificou-se que o uso de estande como covariável foi efetivo para reduzir as estimativas de CV na análise da produtividade de grãos do ensaio de VCU conduzido em condição de alta adubação (Tabela 13). Além de contribuir para redução do CV, o uso de estande como covariável em ensaios de VCU tornam mais justas as comparações de produtividade de grãos entre genótipos que apresentam diferenças no estande (CRUZ et al., 2014).

Em áreas experimentais que apresentam algum tipo de heterogeneidade, o uso do princípio do controle local (FISHER, 1935) visa estabelecer homogeneidade ambiental dentro de um conjunto de unidades experimentais através da blocagem *a priori*. Juntamente com os princípios básicos da repetição e casualização (FISHER, 1935), o controle local contribui para reduzir o erro experimental e garantir a independência entre resíduos. No entanto, mesmo com o uso adequado do princípio do controle local, através de uma escolha criteriosa do delineamento experimental, variações ambientais podem

ocorrer entre unidades experimentais dentro de blocos (GRONDONA et al., 1996), comprometendo a independência entre resíduos de parcelas vizinhas. Nessa situação, a análise espacial usando modelos  $AR1 \times AR1$  é capaz de considerar as autocorrelações residuais entre parcelas vizinhas, através da modelagem da matriz de covariância residual (CULLIS & GLEESON, 1991, GRONDONA et al., 1996; GILMOUR et al., 1997). Assim, alguns autores (GILMOUR et al., 1997; QIAO et al., 2000; WILLIAMS et al., 2006; BORGES et al., 2019) relatam que o desempenho de modelos estatísticos melhora quando se combina um delineamento experimental adequado e uma correção espacial.

Os modelos estatísticos mais adequados para análise da produtividade de grãos das safras 2015/16 e 2016/17 foram, respectivamente, os modelos 9 e 1. Esses dois modelos consideraram o delineamento de blocos completos casualizados e resíduos independentes. Nestas duas safras foi constatada alta homogeneidade ambiental nas áreas utilizadas, uma vez que nenhum outro modelo estatístico ajustado, que considerou o delineamento de látice e/ou a modelagem dos resíduos pelo processo  $AR1 \times AR1$ , foi capaz de apresentar melhor ajuste, dado que não houve mudanças significativas nos valores de Log L (Tabelas 13 e 16). Além disso, os valores próximos de zero estimados para variância de blocos incompletos do látice ( $\hat{\sigma}_b^2$ ) também evidenciam uma uniformidade entre blocos na área experimental. Além dos pequenos valores estimados para  $\hat{\sigma}_b^2$ , as estimativas de autocorrelações de linhas e de colunas foram de pequenas magnitudes e, na maioria dos casos, negativas, também evidenciando ausência de heterogeneidade ambiental na área experimental. Segundo Resende et al. (2014), autocorrelações positivas e de elevada magnitude se devem à heterogeneidade espacial ambiental. Cabe ressaltar que para as safras 2015/16 e 2016/17, em que foram observadas condições ambientais homogêneas, o delineamento de blocos completos casualizados e resíduos independentes foi suficiente para a análise dos dados de produtividade de grãos.

Os modelos em blocos completos casualizados e com resíduos independentes, ajustados para as safras 2015/16 e 2016/17, proporcionaram elevadas estimativas de acurácia de mesma magnitude que os outros modelos mais parametrizados ajustados (Tabelas 13 e 16). Nos experimentos de campo é desejável um alto grau de precisão experimental e uma alta acurácia na inferência sobre as médias genotípicas (RESENDE & DUARTE, 2007). Nos experimentos de VCU o parâmetro estatístico que tem sido utilizado para a avaliação da precisão experimental é o coeficiente de variação experimental (CV), de modo que na cultura do milho os ensaios de VCU utilizados no processo de recomendação de cultivares devem apresentar valores de CV inferiores a 20% (BRASIL, 2019). No entanto, Resende & Duarte (2007) sugerem que os ensaios de avaliação de cultivares devem ser abordados do ponto de vista genético e estatístico, de modo que um dos parâmetros mais relevantes para a avaliação da qualidade de um experimento é a acurácia seletiva. Segundo esses autores, a acurácia seletiva tem a propriedade de informar o correto ordenamento das cultivares para fins de seleção e informar sobre a eficácia da inferência acerca do valor genotípico.

Nas safras 2015/16 e 2016/17, os altos valores de acurácia seletiva estimados em todos os modelos ajustados nestas safras evidenciam alta qualidade dos dados experimentais, de modo que os experimentos destas duas safras apresentam precisão muito alta, de acordo com classificação estabelecida por Resende & Duarte (2007). Nessas duas safras, além das elevadas estimativas de acurácia seletiva, os valores de CV estimados com todos os modelos ajustados foram inferiores ao limite máximo estabelecido pelo Ministério da Agricultura para ensaios de VCU com a cultura do milho, que é de 20% (BRASIL, 2019). Os baixos valores de CV e os altos valores de acurácia seletiva estimados com todos os modelos ajustados são reflexos da homogeneidade ambiental das áreas experimentais usadas nas safras 2015/16 e 2016/17.

No entanto, na safra de 2017/18, mesmo com experimento em condição de alta adubação, as condições ambientais não foram homogêneas. Nessa safra, o modelo mais adequado para a análise dos dados de produtividade de grãos foi o modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com a inclusão do termo do erro independente ( $\eta$ ) (Modelo 4). Os altos valores de autocorrelações de linhas ( $\hat{\rho}_r = 0,88$ ) e de colunas ( $\hat{\rho}_c = 0,96$ ) estimados com o Modelo 4 evidenciam forte heterogeneidade ambiental no ensaio de VCU desta safra. Segundo Resende et al. (2014), a heterogeneidade espacial ambiental causa autocorrelações positivas e de elevada magnitude entre parcelas vizinhas. Resende & Sturion (2003) relatam que coeficientes de autocorrelação maiores que 0,60 indicam padrões de resíduos espaciais ou variabilidade espacial em gradientes ou em manchas.

Na safra 2017/18, com os ajustes de modelos que consideram resíduos independentes (modelos 1, 2, 9 e 10), os efeitos de genótipos sobre a produtividade de grãos foram não significativos (Tabela 19), o que inviabilizaria o uso do ensaio de VCU desta safra no processo de recomendação de novos híbridos de milho. Segundo Resende & Sturion (2001), a análise tradicional de experimentos de campo parte do princípio de que todas as observações tomadas em posições adjacentes são não correlacionadas. No entanto, os autores relatam que a presença de manchas ou gradientes ambientais dentro dos experimentos, quando não considerados adequadamente pelos delineamentos experimentais, causam dependência espacial entre as observações e, conseqüentemente, autocorrelação espacial. Assim, na presença da elevada heterogeneidade ambiental do ensaio de VCU da safra 2017/18, a modelagem da matriz de covariância residual como uma matriz diagonal (resíduos independentes) inflaciona o componente de variância residual em relação ao componente de variância genotípica, prejudicando a identificação de variância genotípica significativa. Além disso, a variância residual inflacionada é um dos fatores que levam a redução nas estimativas de acurácia seletiva (RESENDE &

DUARTE, 2007), comprometendo as inferências dos valores genotípicos dos híbridos de milho avaliados no ensaio de VCU da safra considerada.

Na safra 2017/18, as acurácias seletivas de 0,48 (modelos 9 e 10) e 0,54 (modelos 1 e 2), estimadas com modelos que consideravam resíduos independentes, foram relativamente baixas quando comparadas às acurácias de 0,81 (modelos 4 e 7) e 0,92 (modelos 3 e 6), estimadas com modelos que consideravam a modelagem da matriz de covariância residual pelo processo autorregressivo separável de primeira ordem em duas dimensões ( $AR1 \times AR1$ ). Assim, verificou-se que os modelos espaciais que combinaram informações de delineamentos (blocos casualizados ou látice) e a modelagem da matriz de covariância residual pelo processo  $AR1 \times AR1$  (modelos 3, 4, 6 e 7), foram mais eficazes em melhorar as estimativas de acurácia seletiva. Segundo Resende & Duarte (2007), a acurácia seletiva tem a propriedade de informar sobre o correto ordenamento dos genótipos para fins de seleção e, também, sobre a eficácia da inferência acerca do valor genotípico, de modo que os autores recomendam que nos processos de seleção em melhoramento de plantas devem ser buscados valores de acurácia superiores a 0,70. Assim, percebe-se o que uso da análise espacial, considerando os efeitos de tendência local por meio de modelos  $AR1 \times AR1$ , é promissor na análise de dados de ensaios de VCU de híbridos de milho quando ocorre heterogeneidade na área experimental.

Segundo Gilmour (2000), a análise estatística eficiente de um experimento de campo é alcançada pelo uso de um modelo que considere a estrutura de variância presente nos resíduos. Na presença de dependência espacial, a estrutura de variância residual é sempre adequadamente modelada como uma estrutura autorregressiva separável ( $AR1 \times AR1$ ) (GILMOUR et al., 1997). Esses modelos podem incluir efeitos de linhas e colunas, efeitos de blocos, regressão aleatória e *splines* cúbicas (GILMOUR et al., 1997). Assim, Gilmour (2000) relata que esses efeitos extrínsecos devem ser ajustados como aleatórios para que façam parte da estrutura de covariância de resíduos, para recuperação

de informações de tratamentos e para que seja fornecida alguma proteção contra o ajuste excessivo, uma vez que efeitos aleatórios são regredidos para zero com o grau de *shrinkage* dependendo de suas variâncias.

Na safra 2017/18, os efeitos aleatórios de linhas e colunas incluídos nos modelos com estrutura AR1 × AR1 de resíduos (modelos 5 e 8), comprometeram as estimativas de variância genotípica (Tabela 19). No entanto, o efeito aleatório de *splines* de linhas incluído nos modelos com estrutura AR1 × AR1 de resíduos (modelos 17 e 18), não consumiu a variância genotípica nesses modelos, de modo que as variâncias genotípicas foram significativas com os ajustes dos modelos 17 e 18 (Tabela 22). Entretanto, comparando o modelo 17 com o modelo 4 observou-se que o efeito de *spline* de linhas não foi efetivo para melhorar o ajuste do modelo (Tabela 22). Este resultado indica que houve predomínio de efeitos de tendência local na área experimental da safra 2017/18.

Segundo Resende & Sturion (2001), além da flexibilização da matriz de covariância residual, a blocagem a *posteriori* é também uma alternativa para análise espacial quando ocorre efeitos de tendência local ou global na área de experimentação. Segundo Gilmour (2000), a blocagem a *posteriori* pode ser usada sempre que o experimentador identificar uma causa para as variações extrínsecas. Neste trabalho, a variação nas médias das linhas para produtividade de grãos (Quadro 2) está relacionada à distribuição da água de irrigação, de modo que as linhas mais próximas às laterais recebem mais água do que as linhas mais próximas ao centro do experimento. Nesse sentido, a partir da variação das médias das linhas (Quadro 2) foi possível determinar os *post-blocks*. A blocagem a *posteriori* (modelo 19) mostrou-se adequada para a análise dos dados da safra 2017/18. Esse modelo foi superior aos modelos tradicionais de DBC (Modelo 1) e látice (Modelo 2), que consideram blocagem a *priori* (Tabelas 19 e 23). Nessa comparação, observa-se que o efeito significativo de genótipos foi obtido apenas com o Modelo 19. Assim, pode-se concluir que a blocagem a *priori* não foi adequada

para contornar as variações de linhas, o que resultou em heterogeneidade ambiental dentro de blocos incompletos (látice) e dentro de repetições (DBC) (Quadro 2). Gilmour (2000) relata que blocagem a *posteriori* baseada puramente em significância estatística de contrastes arbitrários, sem nenhuma plausível explicação, não é justificável.

No entanto, comparando o Modelo 19 (blocagem a *posteriori*) com o Modelo 4 (blocagem a *priori*:  $DBC + AR1 \times AR1 + \eta$ ), observa-se que este último foi ligeiramente superior quanto às estimativas de acurácia, herdabilidade e valor-p. Este resultado corrobora o predomínio de efeitos de tendência local na área experimental da safra 2017/18 e que a análise espacial com modelos autorregressivos separável de primeira ordem com inclusão de erros independentes ( $AR1 \times AR1 + \eta$ ) foi eficiente na modelagem desses efeitos de tendência. Vários autores relatam que o modelo autorregressivo separável de primeira ordem em duas dimensões ( $AR1 \times AR1$ ) tem-se mostrado superior para a modelagem da matriz de covariância residual na análise espacial (GRONDONA et al., 1996; GILMOUR et al., 1997; QIAO et al., 2000; RESENDE & STURION, 2003; LIU et al., 2015; BIAN et al., 2017; CHEN et al., 2018; FUKATSU et al., 2018). Além disso, Resende & Sturion (2003) ressaltam a necessidade de considerar o termo do erro independente ( $\eta$ ) na modelagem da matriz de covariância residual quando  $\sigma_{\eta}^2$  apresentar alta magnitude, uma vez que a inclusão de  $\eta$  contribui para melhorar as estimativas dos coeficientes de autocorrelação de linhas e colunas.

## 6. Conclusão

Mesmo em condições de alta adubação, ocorrem situações em que a estatística espacial é eficiente na análise de experimentos de campo, de modo que as análises estatísticas de ensaios de VCU de híbridos de milho avaliados em condições de alta adubação devem considerar a análise espacial entre os modelos candidatos para a análise dos dados.

## 7. Referências

- AKAIKE, H. A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, v. 19, p. 716-723, 1974.
- BENDER, R.R.; HAEGELE, J.W.; RUFFO, M.L.; BELOW, F.E. Nutrient uptake, partitioning, and remobilization in modern, transgenic insect-protected maize hybrids. *Agronomy Journal*, v. 105, n. 1, p. 161-170, 2013.
- BIAN, L.; ZHENG, R.; SU, S.; LIN, H.; XIAO, H.; WU, H.X.; SHI, J. Spatial analysis increases efficiency of progeny testing of Chinese fir. *Journal of Forestry Research*, v. 28, n. 3, p. 445-452, 2017.
- BORGES, A.; GONZÁLEZ-REYMUUNDEZ, A.; ERNST O.; CADENAZZI, M.; TERRA, J.; GUTIÉRREZ, L. Can Spatial Modeling Substitute for Experimental Design in Agricultural Experiments?. *Crop Science*, v. 59, n. 1, p. 44-53, 2019.
- BRASIL. MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO – MAPA. Brasília, 2019. **Formulários para Registro de Cultivares**. Disponível em: <<http://www.agricultura.gov.br/assuntos/insumos-agropecuarios/insumos-agricolas/sementes-e-mudas/registro-nacional-de-cultivares-2013-rnc-1/formularios-para-registro-de-cultivares>>. Acesso em: 15 out. 2019.
- BUTLER, D.G.; CULLIS, B.R.; GILMOUR, A.R.; GOGEL, B.J. ASReml-R reference manual. **The State of Queensland, Department of Primary Industries and Fisheries, Brisbane**, 2009.
- CHEN, Z.; HELMERSSON, A.; WESTIN, J.; KARLSSON, B.; WU, H.X. Efficiency of using spatial analysis for Norway spruce progeny tests in Sweden. *Annals of forest science*, v. 75, n. 1, p. 2, 2018.
- CRUZ, C.D.; CARNEIRO, P.C.S.; REGAZZI, A.J. **Modelos Biométricos Aplicados ao Melhoramento Genético**. 3 ed. Viçosa: Ed. UFV, v. 2, 668 p., 2014.
- CRUZ, C.D. GENES - a software package for analysis in experimental statistics and quantitative genetics. *Acta Scientiarum*. v.35, n.3, p.271-276, 2013.
- CULLIS, B. R.; GLEESON, A. C. Spatial analysis of field experiments-an extension to two dimensions. *Biometrics*, p. 1449-1460, 1991.
- EMBRAPA. **Sistema brasileiro de classificação de solos**. 2.ed. Rio de Janeiro: Embrapa Solos, 2006. 306p.
- FISHER, R.A. **The design of experiments**. Oliver and Boyd, Oxford, UK. 1935.
- FUKATSU, E.; HIRAOKA, Y.; KURAMOTO, N.; YAMADA, H.; TAKAHASHI, M. Effectiveness of spatial analysis in *Cryptomeria japonica* D. Don (sugi) forward selection revealed by validation using progeny and clonal tests. *Annals of Forest Science*, v. 75, n. 4, p. 96, 2018.
- GILMOUR, A.R. Post blocking gone too far! Recovery of information and spatial analysis in field experiments. *Biometrics*, v. 56, n. 3, p. 944-945, 2000.

GILMOUR, A.R.; CULLIS, B.R.; VERBYLA, A.P. Accounting for natural and extraneous variation in the analysis of field experiments. **J Agric Biol Environ Stat**, v. 2, n. 3, p. 269-293, 1997.

Gilmour, A.R.; Gogel, B.J.; Cullis, B.R.; Welham, S.J.; Thompson, R. ASReml User Guide Release 1.0. VSN International, 5 The Waterhouse, Waterhouse St, Hemel Hempstead, HP1 1ES, UK, 2002.

GRONDONA, M.O.; CROSSA, J.; FOX, P.N.; PFEIFFER, W.H. Analysis of variety yield trials using two-dimensional separable ARIMA processes. **Biometrics**, p. 763-770, 1996.

GUIMARÃES, P.E.O. Registro e Proteção de Cultivares. In: DELIMA, R.O.; BORÉM, A. (eds). **Melhoramento de milho**. Ed. UFV, Viçosa, MG, 396 p., 2018.

HENDERSON, C.R. **Applications of linear models in animal breeding**. Guelph: University of Guelph, 1984.

LIU, S.M.; CONSTABLE, G.A.; CULLIS, B.R.; STILLER, W.N.; REID, P.E. Benefit of spatial analysis for furrow irrigated cotton breeding trials. **Euphytica**, v. 201, n. 2, p. 253-264, 2015.

QIAO, C.G.; BASFORD, K.E.; DELACY, I.H.; COOPER, M. Evaluation of experimental designs and spatial analyses in wheat breeding trials. **Theoretical and Applied Genetics**, v. 100, n. 1, p. 9-16, 2000.

R Core Team. **R: A language and environment for statistical computing**. R Found. Stat. Comput., Vienna. 2018.

RAIJ, B.V.; CANTARELLA, H.; QUAGGIO, J.A.; FURLANI, A.M.C. **Recomendações de adubação e calagem para o Estado de São Paulo**. 2 ed. Campinas: Instituto Agrônomo/Fundação IAC, 285 p., 1997.

RAMALHO, M.A.P.; FERREIRA, D.F.; OLIVEIRA, A.C. **Experimentação em Genética e Melhoramento de Plantas**. 3. ed. Lavras, MG: Ed. UFLA, 2012a. 328p.

RAMALHO, M.A.P.; ABREU, A.F.B.; SANTOS, J.B.; NUNES, J.A.R. **Aplicações da Genética Quantitativa no Melhoramento de Plantas Autógamas**. 1. ed. Lavras: Ed. UFLA, 2012b. 522 p.

RESENDE, M.D.V.; DUARTE, J. B. Precisão e controle de qualidade em experimentos de avaliação de cultivares. **Pesquisa Agropecuária Tropical**. v.37, p.182-194, 2007.

RESENDE, M.D.V.; STURION, J.A. Análise genética de dados com dependência espacial e temporal no melhoramento de plantas perenes via modelos geoestatísticos e de séries temporais empregando REML/BLUP ao nível individual. **Embrapa Florestas- Documentos (INFOTECA-E)**, 2001.

RESENDE, M.D.V.; STURION, J.A. Análise estatística espacial de experimentos via modelos mistos individuais com erros modelados por processos ARIMA em duas dimensões. **Rev. Mat. Estat.**, v. 21, n. 1, p. 7-33, 2003.

RESENDE, M.D.V.; SILVA, F.F.; AZEVEDO, C.F. **Estatística matemática, biométrica e computacional: modelos mistos, multivariados, categóricos e generalizados (REML/BLUP), inferência Bayesiana, regressão aleatória, seleção genômica, QTL-GWAS, estatística espacial e temporal, competição, sobrevivência.** Viçosa, MG: Suprema, 2014. 881p.

RESENDE, M.D.V.; VIANA, J.M.S.; AZEVEDO, C.F.; SILVA, F.F.; DELIMA, R.O. Modelos Mistos e Inferência Bayesiana. In: DELIMA, R.O.; BORÉM, A. (eds). **Melhoramento de milho.** Ed. UFV, Viçosa, MG, 396 p., 2018.

RIBEIRO, A.C.; GUIMARÃES, P.T.G.; ALVAREZ V., V.H. **Recomendação para uso de corretivos e fertilizantes em Minas Gerais – 5ª aproximação.** Viçosa, MG: Comissão de Fertilidade do Solo do Estado de Minas Gerais – CFSEMG, 359 p., 1999.

SOUSA, D.M.G.; LOBATO, E. **Cerrado: correção do solo e adubação.** 2 ed. Planaltina, DF: Embrapa Cerrados, 416 p., 2004.

TEDESCO, M.J.; GIANELLO, C.; ANGHINONI, I.; BISSANI, C.A.; CAMARGO, F.A.O.; WIETHÖLTER, S. **Manual de adubação e calagem para os Estados do Rio Grande do Sul e de Santa Catarina.** 10 ed. Porto Alegre, RS: Comissão de Química e Fertilidade do Solo/Sociedade Brasileira de Ciência do Solo, 400 p., 2004.

VENCOVSKY, R.; CRUZ, C.D. Comparação de métodos de correção do rendimento de parcelas com estandes variados. I. Dados simulados. **Pesquisa Agropecuária Brasileira**, v. 26, n. 5, p. 647-657, 1991.

VERGÜTZ, L.; NOVAIS, R.F. Recomendação corretivos e adubação. In: BORÉM, A.; GALVÃO, J.C.C.; PIMENTEL, M.A. (eds). **Milho: do plantio à colheita.** Ed. UFV, Viçosa, MG, 351 p., 2015.

WILLIAMS, E. R.; JOHN, J. A.; WHITAKER, David. Construction of resolvable spatial row-column designs. **Biometrics**, v. 62, n. 1, p. 103-108, 2006.

## 8. Material Suplementar

**Anexo I.** Exemplo de como montar o arquivo de dados para análise no ASReml-R. O arquivo contém os dados de produtividade de grãos (pg), dados de estande (st), informações de tratamentos (Trat), repetições (Rep), blocos incompletos do látice (Blocos), Linhas e Colunas. A codificação de linhas deve ser ordenada dentro de colunas, como demonstrado a seguir:

| Trat | Rep      | Blocos   | Colunas | Linhas | pg    | st    |
|------|----------|----------|---------|--------|-------|-------|
| 1    | 1        | 1        | 1       | 1      | 11113 | 57823 |
| 2    | 1        | 1        | 1       | 2      | 11322 | 59524 |
| 3    | 1        | 1        | 1       | 3      | 10090 | 68027 |
| 4    | 1        | 1        | 1       | 4      | 9484  | 59524 |
| 5    | 1        | 1        | 1       | 5      | 9787  | 52721 |
| 6    | 1        | 1        | 1       | 6      | 11372 | 54422 |
| 7    | 1        | 2        | 1       | 7      | 6796  | 57823 |
| 8    | 1        | 2        | 1       | 8      | 9219  | 56122 |
| 9    | 1        | 2        | 1       | 9      | 9756  | 56122 |
| 10   | 1        | 2        | 1       | 10     | 10329 | 64626 |
| 20   | 1        | 4        | 2       | 1      | 12789 | 62925 |
| 19   | 1        | 4        | 2       | 2      | 8600  | 56122 |
| 18   | 1        | 3        | 2       | 3      | 9120  | 49320 |
| 17   | 1        | 3        | 2       | 4      | 10392 | 57823 |
| 16   | 1        | 3        | 2       | 5      | 7582  | 61224 |
| 15   | 1        | 3        | 2       | 6      | 9128  | 52721 |
| 14   | 1        | 3        | 2       | 7      | 10149 | 57823 |
| 13   | 1        | 3        | 2       | 8      | 7845  | 56122 |
| 12   | <b>1</b> | <b>2</b> | 2       | 9      | 9014  | 49320 |
| 11   | 1        | 2        | 2       | 10     | 9746  | 64626 |
| ⋮    | ⋮        | ⋮        | ⋮       | ⋮      | ⋮     | ⋮     |

**Anexo II.** Script com os modelos estatísticos propostos neste trabalho. Script para análise no ASReml-R (BUTLER et al., 2009).

```
#####
### Modelos para análise dos ensaios de VCU de híbridos de milho – Alta Adubação ##
#####

# Carregar ASReml:
library(asreml)

# Trilha de dados – indicar local do arquivo de dados:
setwd("C:\\Users\\USUARIO\\Desktop\\Alta Adubação")

# Função – carregar arquivo de dados (Ex.: dados da safra 2017/18):
dados <- asreml.read.table(file = "Alta_Adubação_2017-18.txt", h = T)

# Códigos usados para as variáveis e os fatores:
  # pg = Produtividade de grãos;
  # st = Estande;
  # Trat = Tratamentos;
  # Rep = Repetições;
  # Blocos = Blocos incompletos do látice;
  # Linhas;
  # Colunas.

#####
##### Ajuste de modelos – Variável Estande #####
#####

##### Modelo 1 - Modelo de blocos casualizados:
m1 <- asreml(fixed = st ~ Rep,
             random = ~ Trat,
             rcov = ~ units,
             data = dados,
             na.method.Y = "include")

##### Modelo 2 - Modelo de látice parcialmente balanceado:
m2 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + Rep:Blocos,
             rcov = ~ units,
             data = dados,
```

```
na.method.Y = "include")
```

##### Modelo 3 – Modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ :

```
m3 <- asreml(fixed = st ~ Rep,
             random = ~ Trat,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 4 - Modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ):

```
m4 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 5 - Modelo de blocos casualizados, com efeitos de linhas e colunas, resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ):

```
m5 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + Linhas + Colunas + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 6 - Modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ :

```
m6 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + Rep:Blocos,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 7 - Modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ):

```
m7 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + Rep:Blocos + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 8 - Modelo de látice parcialmente balanceado, com efeitos de linhas e colunas, resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ):

```
m8 <- asreml(fixed = st ~ Rep,
             random = ~ Trat + Rep:Blocos + Linhas + Colunas + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

```
#####
##### Ajuste de modelos – Produtividade de Grãos #####
#####
```

##### Modelo 1 - Modelo de blocos casualizados:

```
m1 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat,
             rcov = ~ units,
             data = dados,
             na.method.Y = "include")
```

##### Modelo 2 - Modelo de látice parcialmente balanceado:

```
m2 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + Rep:Blocos,
             rcov = ~ units,
             data = dados,
             na.method.Y = "include")
```

##### Modelo 3 – Modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$ :

```
m3 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 4 - Modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ):

```
m4 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 5 - Modelo de blocos casualizados, com efeitos de linhas e colunas, resíduos ( $\xi$ ) modelados pelo processo  $AR1 \times AR1$  e com a inclusão do termo do erro independente ( $\eta$ ):

```
m5 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + Linhas + Colunas + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 6 - Modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1:

```
m6 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + Rep:Blocos,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 7 - Modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com a inclusão do termo do erro independente ( $\eta$ ):

```
m7 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + Rep:Blocos + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 8 - Modelo de látice parcialmente balanceado, com efeitos de linhas e colunas, resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com a inclusão do termo do erro independente ( $\eta$ ):

```
m8 <- asreml(fixed = pg ~ Rep,
             random = ~ Trat + Rep:Blocos + Linhas + Colunas + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 9 - Modelo de blocos casualizados, incluindo estande como covariável:

```
m9 <- asreml(fixed = pg ~ Rep + st,
             random = ~ Trat,
             rcov = ~ units,
             data = dados,
             na.method.Y = "include")
```

##### Modelo 10 - Modelo de látice parcialmente balanceado, incluindo estande como covariável:

```
m10 <- asreml(fixed = pg ~ Rep + st,
             random = ~ Trat + Rep:Blocos,
             rcov = ~ units,
             data = dados,
             na.method.Y = "include")
```

##### Modelo 11 - Modelo de blocos casualizados, incluindo estande como covariável e resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1:

```
m11 <- asreml(fixed = pg ~ Rep + st,
             random = ~ Trat,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 12 - Modelo de blocos casualizados, incluindo estande como covariável, resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com o termo do erro independente ( $\eta$ ):

```
m12 <- asreml(fixed = pg ~ Rep + st,
             random = ~ Trat + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 13 - Modelo de blocos casualizados, incluindo estande como covariável, efeito de linhas, efeito de colunas, resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com o termo do erro independente ( $\eta$ ):

```
m13 <- asreml(fixed = pg ~ Rep + st,
             random = ~ Trat + Linhas + Colunas + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 14 - Modelo de látice parcialmente balanceado, incluindo estande como covariável e resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1:

```
m14 <- asreml(fixed = pg ~ Rep + st,
             random = ~ Trat + Rep:Blocos,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 15 - Modelo de látice parcialmente balanceado, incluindo estande como covariável, resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com a inclusão do termo do erro independente ( $\eta$ ):

```
m15 <- asreml(fixed = pg ~ Rep + st,
             random = ~ Trat + Rep:Blocos + units,
             rcov = ~ ar1(Colunas):ar1(Linhas),
             data = dados,
             na.method.Y = "include")
```

##### Modelo 16 - Modelo de látice parcialmente balanceado, incluindo estande como covariável, efeito de linhas, efeito de colunas, resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com o termo do erro independente ( $\eta$ ):

```
m16 <- asreml(fixed = pg ~ Rep + st,
```

```
random = ~ Trat + Rep:Blocos + Linhas + Colunas + units,  
rcov = ~ ar1(Colunas):ar1(Linhas),  
data = dados,  
na.method.Y = "include")
```

**# Referência:**

# BUTLER, D.G.; CULLIS, B.R.; GILMOUR, A.R.; GOGEL, B.J. ASReml-R reference manual. **The State of Queensland, Department of Primary Industries and Fisheries, Brisbane, 2009.**

## CONSIDERAÇÕES GERAIS

A análise estatística espacial, via flexibilização da matriz de covariância residual pelo processo autorregressivo separável de primeira ordem em duas dimensões (AR1  $\times$  AR1), pode contribuir para a melhoria no ajuste de modelos na análise da produtividade de grãos de experimentos de híbridos de milho conduzidos tanto em condições de baixo P como em condições de alta adubação.

Nos resultados obtidos neste trabalho, verificou-se que os modelos selecionados para as análises estatísticas dos experimentos de híbridos de milho conduzidos em baixo P foram: (a) safras 2015/16 e 2016/17: o modelo de látice parcialmente balanceado, com resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1, sem o termo do erro independente ( $\eta$ ) e com inclusão do estande como covariável; (b) safra 2017/18: o modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1, sem o termo do erro independente ( $\eta$ ) e com inclusão do estande como covariável.

Para as análises estatísticas dos experimentos de híbridos de milho conduzidos em condições de alta adubação, os modelos selecionados foram: (a) safra 2015/16: o modelo de blocos casualizados, com inclusão de estande como covariável e resíduos ( $e$ ) independentes; (b) safra 2016/17: o modelo de blocos casualizados, com resíduos ( $e$ ) independentes; (c) safra 2017/18: o modelo de blocos casualizados, com resíduos ( $\xi$ ) modelados pelo processo AR1  $\times$  AR1 e com a inclusão do termo do erro independente ( $\eta$ ).

Com base nos modelos selecionados em cada uma das condições contrastantes de P no solo (baixo P e alta adubação), percebe-se que na condição de baixo P há predominância de heterogeneidade ambiental em manchas dentro das áreas experimentais, uma vez que foi mais frequente a seleção do modelo estatístico que associou o delineamento de látice e a modelagem da matriz de covariância residual pelo processo AR1  $\times$  AR1. Na condição de alta adubação, percebe-se maior homogeneidade

ambiental dentro das áreas experimentais, uma vez que predominou entre os modelos selecionados o delineamento de blocos completos casualizados e resíduos independentes. No entanto, mesmo em condição de alta adubação, alguns fatores podem ocorrer nas áreas experimentais e causar variabilidade espacial nas condições ambientais, como por exemplo, a desuniformidade na distribuição de água na irrigação. Assim, esses fatores podem provocar dependência espacial entre parcelas. Essa situação foi verificada na safra 2017/18, onde um modelo estatístico espacial foi selecionado para a análise da produtividade de grãos do experimento conduzido em condição de alta adubação.

Com base nos resultados obtidos neste trabalho, percebe-se que tanto em análises de experimentos conduzidos em baixo P como em experimentos conduzidos em alta adubação, os modelos estatísticos espaciais devem ser testados entre os modelos candidatos às análises dos dados de produtividade de grãos. Desse modo, em situações que houver dependência espacial entre parcelas, esta é identificada e tratada adequadamente segundo um modelo espacial.

O uso de análise estatística espacial é promissor na análise de experimentos de campo conduzidos nos programas de melhoramento de plantas. Na presença de heterogeneidade ambiental em manchas ou gradientes dentro da área experimental, os modelos estatísticos espaciais são capazes de prever os efeitos de tendência espacial, contribuindo para melhorar as estimativas de acurácia seletiva. Além disso, a análise espacial não exige que sejam adquiridos novos insumos ou equipamentos. Como se trata de um procedimento estatístico, o uso da análise espacial não onera os custos dos experimentos de um programa de melhoramento.

De modo geral, o melhorista interessado em usar a análise espacial deve tomar alguns cuidados nos processos de instalação dos experimentos e obtenção dos dados. O principal cuidado a ser tomado na instalação do experimento é garantir que todo o experimento seja instalado numa faixa contínua, de modo que as parcelas possam ser

posicionadas segundo as coordenadas de linhas e colunas do experimento. Na obtenção e armazenamento dos dados experimentais, o principal cuidado a ser tomado é manter registrado as informações de posicionamento das parcelas no campo, o que pode ser feito por meio de um croqui da área experimental ou por meio das coordenadas de linhas e colunas associadas a cada parcela no experimento. Tomando-se esses cuidados básicos, a análise estatística espacial pode ser aplicada a experimentos de campo conduzidos em todas as fases de um programa de melhoramento de plantas.