



**EDMUNDO DO ROSÁRIO RODRIGUES CAETANO**

**ANÁLISE DE VARIÂNCIA UTILIZANDO  
MODELOS AUTORREGRESSIVOS EM  
EXPERIMENTOS COM DEPENDÊNCIA  
ESPACIAL**

**LAVRAS – MG**

**2013**

**EDMUNDO DO ROSÁRIO RODRIGUES CAETANO**

**ANÁLISE DE VARIÂNCIA UTILIZANDO MODELOS  
AUTORREGRESSIVOS EM EXPERIMENTOS COM DEPENDÊNCIA  
ESPACIAL**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Estatística e Experimentação Agropecuária, área de concentração em Estatística e Experimentação Agropecuária, para a obtenção do título de Mestre.

Orientador  
Prof. Dr. Renato Ribeiro de Lima

**LAVRAS – MG**

**2013**

**Ficha Catalográfica Elaborada pela Divisão de Processos Técnicos da  
Biblioteca da UFLA**

Caetano, Edmundo do Rosário Rodrigues.

Análise de variância utilizando modelos autorregressivos em experimentos com dependência espacial / Edmundo do Rosário Rodrigues Caetano. – Lavras : UFLA, 2013.

115 p. : il.

Dissertação (mestrado) – Universidade Federal de Lavras, 2013.

Orientador: Renato Ribeiro de Lima.

Bibliografia.

1. Autocorrelação espacial. 2. SAR. 3. CAR. 4. ANOVA. I. Universidade Federal de Lavras. II. Título.

CDD – 519.538

**EDMUNDO DO ROSÁRIO RODRIGUES CAETANO**

**ANÁLISE DE VARIÂNCIA UTILIZANDO MODELOS  
AUTORREGRESSIVOS EM EXPERIMENTOS COM DEPENDÊNCIA  
ESPACIAL**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Estatística e Experimentação Agropecuária, área de concentração em Estatística e Experimentação Agropecuária, para a obtenção do título de Mestre.

APROVADA em 29 de janeiro de 2013.

Prof. Dr. José Márcio de Mello UFLA

Prof. Dr. João Domingos Scalon UFLA

  
Prof. Dr. Renato Ribeiro de Lima  
Orientador

**LAVRAS – MG**

**2013**

*Aos meus filhos Kelvyn Caetano e Melissa Caetano  
que ficaram dois anos sem o carinho e amor do pai;  
A minha esposa Jamila Aboobacar; pela paciência,  
coragem, pelo carinho e amor incondicional  
que foram fundamentais nesta conquista;  
Aos meus pais; José Geraldo de Brito R. Caetano e  
Amélia Esmeralda José Rodrigues Gêmo,  
pelos ensinamentos e pela força.  
Aos meus queridos irmãos, Arquimedes, Celso, Edgar,  
Isidro, Leonel e Marivete, que sempre  
mostraram muito carinho e amor ;  
Aos meus sobrinhos, Ivandro, Káká e Ivan  
que serviram de fonte de inspiração.*

**DEDICO**

## AGRADECIMENTOS

À Universidade Federal de Lavras (UFLA) e ao Departamento de Ciências Exatas (DEX), pela oportunidade concedida para a realização do Mestrado;

Ao Professor Renato Ribeiro de Lima, pela orientação, a amizade, ensinamentos e crédito ao meu trabalho;

Ao Professor João Domingos Scalon, pela sua disposição pela força dada para que se realizasse o mestrado e pelos seus ensinamentos;

Aos Professores; José Márcio de Mello, Carlos Rogério de Mello e Marcelo da Silva Oliveira, por suas contribuições para a melhoria do trabalho;

Aos professores do Departamento de Ciências Exatas, pelos conhecimentos transmitidos durante esta caminhada;

Ao meu amigo e colega, Diogo Francisco Rossoni, pelas contribuições, disposição que teve para ensinar e ajudar-me nas simulações dos experimentos, pela amizade e convivência;

Aos colegas e amigos do DEX, Lourenço Manuel, Marcelo Ribeiro, Ben Deivide, Gilberto Liska, Guido Humada, Rossi Rangel, Mariana Figueira, Gláucia Amorim, Juliano Bortolini, Manuel Veloso, Jair Prado, Jair Wzykowski, Marcília, Silvio, Cristina, Tadeu, Tales, Leandro, Maíra, Deyse, Micheli, Adriele, Mariele, Camila dentre outros, pela amizade e convivência que tivemos;

Aos meus amigos e colegas, Ângela Manjichi, José Chambo e José Monteiro, pela amizade, força e carinho, que mesmo distante, souberam transmitir;

Aos amigos, Marques Donça, Munguambe, Ludmila, Dovel, Nelson Mesquita, Denilson, Joel, Joaquim, Mateus, Chadreque, Tangune, Moses

Otameh, Nair, Suluza Gafur, Marla e outros aqui não citados, pela amizade e convivência;

Ao Instituto Superior Politécnico de Manica (ISPM), pelo apoio e pela homologação da licença para a formação em nível de Mestrado;

A todos colegas da Pós-Graduação em Estatística e Experimentação Agropecuária e aos funcionários do Departamento de Ciências Exatas da UFLA;

A CAPES/CNPq – IEL Nacional – Brasil, pela concessão da bolsa de estudos, essencial para esta conquista;

A todos que de forma direta ou indiretamente contribuíram para realização deste novo desafio em minha vida agradeço.

## RESUMO

Com o objetivo de comparar o desempenho dos modelos autorregressivos, nomeadamente o modelo “*Simultaneous Autoregressive Model ou Spatial Autoregressive*”-SAR e “*Conditional Autoregressive Model*”-CAR na análise de variância de experimentos com dependência espacial, estudou-se as suas estruturas e os parâmetros envolvidos. O estudo foi feito considerando experimentos em delineamento de blocos casualizados e delineamento em quadrados latinos, com 3 configurações diferentes. Os dados, os erros com características aleatórias e os padrões de proximidade de primeira, segunda e terceira ordem, foram gerados por simulação. Os parâmetros dos modelos foram estimados pelo método da máxima verossimilhança e a comparação dos modelos feita utilizando critério de Akaike. Os resultados obtidos mostraram que os modelos autorregressivos SAR apresentam melhor ajuste e precisão quando comparados com os modelos CAR.

Palavras-chave: SAR. CAR. ANOVA. Autocorrelação espacial.

## **ABSTRACT**

In this study, we compare the performance of autoregressive models, including the Simultaneous Autoregressive Model or Spatial Autoregressive (SAR) and the Conditional Autoregressive Model (CAR) in the analysis of variance of experiments with spatial dependence. The structure and the parameters involved in these models were studying. This study considered a randomized complete block and Latin square design, each one in 3 different settings. The data, the errors with random characteristics and first, second and third order proximity patterns, were generated by simulation. The parameters of the models were estimate by maximum likelihood method. The models were compare by the AIC criteria. The SAR models fit better than the CAR models and the analysis, which considered independent errors.

Keywords: SAR. CAR. ANOVA. Spatial autocorrelation.

## LISTA DE FIGURAS

Figura 1	Representação de um gride regular com 9 observações de um experimento .....	25
Figura 2	Padrões de proximidade apresentados por Gumpertz, Graham e Ristaino (1997).....	27

## LISTA DE GRÁFICOS

Gráfico 1	Histograma do valor p da estatística do teste de Wald para os experimentos usando blocos casualizados provenientes de 1000 simulações .....	61
Gráfico 2	Histogramas da $\hat{\sigma}^2$ da configuração <i>Gaus(0,05-1-2)</i> para experimento <i>i</i> e <i>ii</i> provenientes de 1000 simulações .....	62
Gráfico 3	Intervalo de credibilidade das médias da $\hat{\sigma}^2$ dos experimentos <i>i</i> e <i>ii</i> na configuração <i>Gaus(0,05-1-2)</i> provenientes de 1000 simulações .....	63
Gráfico 4	Histograma do valor-p da estatística do teste de Wald dos experimentos <i>iii</i> e <i>iv</i> , de 1000 simulações .....	66
Gráfico 5	Histogramas da $\hat{\sigma}^2$ da configuração <i>Gaus(0,05-1-2)</i> para experimento <i>iii</i> e <i>iv</i> provenientes de 1000 simulações .....	67
Gráfico 6	Intervalo de credibilidade das médias da variância estimada $\hat{\sigma}^2$ dos experimentos <i>iii</i> e <i>vi</i> na configuração <i>Gaus(0,05-1-2)</i> proveniente de 1000 simulações .....	68
Gráfico 7	Intervalo de credibilidade de $\sigma^2$ estimada de todos experimentos em blocos casualizados proveniente de 1000 simulações.....	71
Gráfico 8	Intervalo de credibilidade de médias da $\sigma^2$ estimada de todos experimentos em quadrado latino proveniente de 1000 simulações .....	73

## LISTA DE TABELAS

Tabela 1	Análise de variância para um delineamento inteiramente casualizado.....	19
Tabela 2	Análise de variância para um delineamento em blocos casualizado... 20	
Tabela 3	Análise de variância para um delineamento em quadrado latino.....	22
Tabela 4	Padrões de proximidade em função do raio da circunferência .....	28
Tabela 5	Análise de variância do modelo autorregressivo SAR.....	33
Tabela 6	Efeitos fixos dos parâmetros utilizados na simulação dos experimentos .....	52
Tabela 7	Parâmetros do semivariograma para simulação do erro experimental.....	55
Tabela 8	Valores médios dos parâmetros estimados de $\sigma^2$ e $\Phi_t$ para o experimento i e ii na configuração <i>Gaus(0,05-1-2)</i> .....	64
Tabela 9	Valores médios dos parâmetros estimados de $\sigma^2$ e $\Phi_t$ para o experimento iii e iv na configuração <i>Gaus (0,05-1-2)</i> .....	69
Tabela 10	Intervalo de credibilidade para o AIC de todas as configurações do experimento i, com 95% de probabilidade.....	75
Tabela 11	Intervalo de credibilidade para o AIC de todas as configurações do experimento ii, com 95% de probabilidade.....	76
Tabela 12	Intervalo de credibilidade para o AIC de todas as configurações do experimento iii, com 95% de probabilidade.....	77
Tabela 13	Tabela Intervalo de credibilidade para o AIC de todas as configurações do experimento iv, com 95% de probabilidade .....	78

## APÊNDICES

Tabela 14 Intervalo de credibilidade das estimativas de $\rho$ e $\lambda$ de todas as configurações dos experimentos com os respectivos padrões de proximidades.....	84
Tabela 15 Intervalo de credibilidade da abordagem autorregressiva para todas as configurações de alcance 2 e 4 do experimento i, com 95% de probabilidade.....	86
Tabela 16 Intervalo de credibilidade da abordagem autorregressiva para todas as configurações de alcance 2 e 4 do experimento ii com 95% de probabilidade.....	89
Tabela 17 Intervalo de credibilidade da abordagem autorregressiva para todas as configurações de alcance 2 e 4 do experimento iii com 95% de probabilidade.....	92
Tabela 18 Intervalo de credibilidade da abordagem autorregressiva para todas as configurações de alcance 2 e 4 do experimento iv com 95% de probabilidade.....	95

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	13
<b>2</b>	<b>REFERENCIAL TEÓRICO</b> .....	16
<b>2.1</b>	<b>Princípios da experimentação</b> .....	16
<b>2.2</b>	<b>Análise de variância (ANOVA)</b> .....	17
<b>2.2.1</b>	<b>Delineamento inteiramente casualizado (DIC)</b> .....	18
<b>2.2.2</b>	<b>Delineamento em blocos casualizados (DBC)</b> .....	19
<b>2.2.3</b>	<b>Delineamento em quadrado latino (DQL)</b> .....	21
<b>2.3</b>	<b>Modelos autorregressivos</b> .....	22
<b>2.3.1</b>	<b>Matriz de vizinhança espacial</b> .....	23
<b>2.3.2</b>	<b>Modelo espacial autorregressivo - SAR</b> .....	29
<b>2.3.2.1</b>	<b>Estimação dos parâmetros do modelo SAR</b> .....	30
<b>2.3.2.2</b>	<b>Análise de variância usando o modelo autorregressivo SAR</b> .....	32
<b>2.3.3</b>	<b>Modelo condicional autorregressivos - CAR</b> .....	35
<b>2.3.3.1</b>	<b>Estimação dos parâmetros do modelo CAR</b> .....	36
<b>2.3.3.2</b>	<b>Análise de variância usando o modelo autorregressivo CAR</b> .....	40
<b>2.3.4</b>	<b>Avaliação da dependência espacial</b> .....	42
<b>2.3.4.1</b>	<b>Índice de Moran</b> .....	42
<b>2.3.4.2</b>	<b>Teste de Wald</b> .....	46
<b>2.3.4.3</b>	<b>Teste de razão de verossimilhança</b> .....	47
<b>3</b>	<b>MATERIAL E MÉTODOS</b> .....	50
<b>3.1</b>	<b>Simulação dos experimentos</b> .....	50
<b>3.1.1</b>	<b>Delineamentos experimentais e configurações simuladas</b> .....	50
<b>3.1.2</b>	<b>Simulação dos dados</b> .....	53
<b>3.2</b>	<b>Estimação dos parâmetros e análise de variância</b> .....	56
<b>3.2.1</b>	<b>Análise de variância</b> .....	56
<b>3.2.2</b>	<b>Critérios de comparação das abordagens ANOVA, SAR e CAR</b> .....	57
<b>3.2.3</b>	<b>Critérios de comparação de modelos</b> .....	59
<b>4</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	60
<b>4.1</b>	<b>Exemplo de delineamento em blocos casualizados</b> .....	60
<b>4.2</b>	<b>Exemplo de delineamento em quadrado latino</b> .....	65
<b>4.3</b>	<b>Estudo de outros experimentos com diferentes configurações</b> .....	70
<b>5</b>	<b>CONCLUSÕES</b> .....	79
	<b>REFERÊNCIAS</b> .....	80
	<b>APÊNDICES</b> .....	84

## 1 INTRODUÇÃO

Os delineamentos experimentais clássicos são baseados em três princípios básicos: repetição, casualização e controle local. A repetição permite adicionar precisão à estimação dos parâmetros, além de permitir a estimação do erro experimental. O uso do controle local é outro princípio, de uso muito frequente, mas não obrigatório. Este, deve ser utilizado para que a variação devido ao acaso não seja estimada de uma forma tendenciosa.

A casualização, outro princípio importante, visa conferir à modelagem estatística, um contexto conceitual de independência dos erros e o caráter aleatório da amostra, minimizando assim, os efeitos da correlação espacial, possivelmente existente na área utilizada no experimento, permitindo então a utilização da inferência clássica na análise de dados de experimentos. Contudo, em muitos ramos da experimentação, existe uma influência decisiva do local sobre os efeitos dos tratamentos, isto é, em experimentos que utilizam grandes extensões de campo, a casualização pode ter a sua eficiência reduzida e modelagens adicionais e mais refinadas podem ser introduzidas de modo a melhorar sua eficiência.

A análise tradicional ou clássica de experimentos de campo assume que todas as observações tomadas em posições adjacentes, tais como em plantas ou parcelas vizinhas, são não correlacionadas. Assim, a matriz de covariância residual é modelada como uma matriz diagonal, ou seja os erros são assumidos como independentes e a dependência espacial existente entre as diferentes parcelas não é considerada.

Em muitas situações práticas existem problemas estritamente espaciais, tornando impossível a aplicação dos procedimentos exigidos à uma análise de variância tradicional (ou clássica).

A suposição de independência dos erros facilita a teoria da estatística matemática, contudo os modelos que envolvem a dependência espacial são frequentemente mais realísticos. Cressie (1993) mostra os efeitos da dependência espacial em experimentos clássicos e assegura que a detecção da estrutura de autocorrelação e o uso da informação espacial na análise estatística, garantem estimativas mais eficientes dos contrastes entre as médias dos tratamentos.

O uso de metodologias que englobam informação espacial, especialmente o uso de modelos autorregressivos na análise de variância, torna-se importante uma vez que poderá contribuir para a aprimoramento das técnicas de análise de experimentos, tendo em vista que, em condições reais, pode existir dependência espacial, o que contribui para o aumento da variação residual e, conseqüentemente, uma diminuição da precisão do experimento.

Com o desenvolvimento de tecnologias computacionais, várias alternativas tornaram-se disponíveis aos pesquisadores, podendo em certas ocasiões, proporcionar melhores resultados. Esses métodos são baseados na análise de vizinhança, isto é, nas parcelas vizinhas ou modelando a dependência espacial em função das distâncias entre as parcelas, com o objetivo de controlar a heterogeneidade espacial.

A adoção desses métodos de análise de experimentos, que utilizam informação espacial das parcelas envolvidas são alternativas para aumentar a eficiência das análises efetuadas.

As formas de análise que utilizam a modelagem espacial são mais adequadas para experimentos em que é verificada a dependência espacial entre os erros experimentais, pois a eficiência dos estimadores dos contrastes dos tratamentos não só dependerão apenas da variação residual, mas também das posições das parcelas. Assim, a análise de variância usando modelos autorregressivos, como o “*Simultaneous Autoregressive model ou Spatial*

*autoregressive*” - SAR e “*Conditional autoregressive model*” - CAR, pode constituir uma vantagem para a análise de experimentos quando comparados com a análise de variância clássica (ANOVA).

Com o presente trabalho objetivo-se avaliar principalmente o desempenho dos modelos autorregressivos, nomeadamente o modelo espacial autorregressivo (SAR- *Spatial autoregressive*) e o modelo de erro espacial (CAR – *Conditional autoregressive model*) na análise de dados provenientes de experimentos com dependência espacial. O trabalho teve como objetivo específico o seguinte:

- a) Comparar a eficiência dos modelos espaciais SAR e CAR em experimentos instalados segundo o delineamento em blocos casualizados e delineamento em quadrados latinos.

## **2 REFERENCIAL TEÓRICO**

Este capítulo aborda três temas principais, nomeadamente, os princípios da experimentação, análise de variância e os modelos autorregressivos.

### **2.1 Princípios da experimentação**

Os três princípios fundamentais da experimentação utilizados em delineamentos experimentais controlados foram propostos por Fisher (1935), nomeadamente, a casualização, a repetição e o controle local.

A casualização consiste em atribuir a todos os tratamentos a mesma probabilidade de serem designados a qualquer das unidades experimentais e tem como finalidade proporcionar uma estimativa válida para o erro. A repetição que consiste na reprodução do experimento básico tem como finalidade proporcionar a obtenção de uma estimativa de erro experimental para o experimento (BANZATTO; KRONKA, 2006; PLANT, 2012).

Segundo Banzatto e Kronka (2006), o princípio de controle local é frequentemente utilizado, mas não é de uso obrigatório, uma vez que podemos realizar experimentos sem utilizá-lo. O controle local consiste em dividir um ambiente heterogêneo em subambientes homogêneos com a finalidade de tornar o delineamento experimental mais eficiente pela redução do erro experimental. Segundo Plant (2012), a incorporação no experimento do controle local em forma de blocos é um reconhecimento da existência de autocorrelação espacial entre as unidades experimentais. O propósito do controle local é reduzir o efeito da autocorrelação espacial sobre os efeitos dos tratamentos pela introdução de blocos homogêneos.

Definidos os três princípios fundamentais utilizados em delineamentos experimentais, na sequência será abordada a metodologia da análise de variância.

## **2.2 Análise de variância (ANOVA)**

A análise de variância é um procedimento que visa, fundamentalmente, verificar se existe diferença significativa entre as médias dos tratamentos e se os fatores exercem influência em alguma variável dependente. Fatores esses que podem ser de origem quantitativa ou qualitativa, mas a variável dependente deverá ser necessariamente contínua, permitindo que vários grupos sejam comparados ao mesmo tempo (MONTGOMERY, 2008).

Métodos de análise de dados de experimentos, como a análise de variância (ANOVA), são amplamente utilizados na avaliação de resultados experimentais. Na ANOVA separaram-se e estimam-se as diferentes causas de variabilidade, afim de verificar se a diferença entre suas magnitudes é significativa.

Em experimentos, toda a variabilidade que não pode ser controlada é atribuída ao erro experimental, ou seja, ao acaso. Assim sendo, para que o erro seja reduzido, várias técnicas e procedimentos são utilizados, tais como: a escolha do material experimental homogêneo, aumento de repetições, escolha de técnicas refinadas, seleção adequada das unidades experimentais e dos tratamentos e a escolha do delineamento a ser utilizado.

Os principais delineamentos experimentais são: o delineamento inteiramente ao acaso, em blocos casualizados e em quadrado latino, sendo o delineamento em blocos casualizados o mais utilizado em experimentos de campo (BANZATTO; KRONKA, 2006; MONTGOMERY, 2008; PIMENTEL-GOMES, 2009; RESENDE, 2007).

A seguir serão apresentados os delineamentos inteiramente casualizado, em blocos casualizados e em quadrado latino, os seus modelos estatísticos e a suas estruturas de análise de variância para dados balanceados utilizando modelos de efeitos fixos.

### 2.2.1 Delineamento inteiramente casualizado (DIC)

O delineamento inteiramente casualizado é o mais simples de todos os delineamentos. Considera apenas os princípios da repetição e da casualização. Para a instalação desses experimentos em campo, é necessário ter a certeza da homogeneidade das condições ambientais e do material experimental (BANZATTO; KRONKA, 2006).

Este é um delineamento frequentemente utilizado em experimentos de laboratório e nos ensaios realizados em casas de vegetação, nos quais as condições são homogêneas e bem controladas.

Para o delineamento inteiramente casualizado o modelo estatístico é dado por:

$$y_{ij} = \mu + t_i + e_{ij}, \quad (1)$$

em que:

$y_{ij}$  é a observação do  $i$ -ésimo tratamento na  $j$ -ésima repetição, com  $i=1,2,\dots,a$  e  $j=1,2,\dots,r$ ,

$\mu$  é uma constante inerente a cada observação, (média)

$t_i$  é o efeito do  $i$ -ésimo tratamento,

$e_{ij}$  é o erro associado a cada observação, sendo  $e_{ij} \stackrel{iid}{\sim} N(0, \sigma^2)$ .

A estrutura da análise de variância para um delineamento inteiramente casualizado balanceado com efeitos fixos é apresentada na Tabela 1.

Tabela 1 Análise de variância para um delineamento inteiramente casualizado

<i>FV</i>	<i>GL</i>	<i>SQ</i>	<i>QM</i>	<i>Valor de F</i>
<i>Tratamentos</i>	$a-1$	$SQT_{rat}$	$QMT_{rat}$	$QMT_{rat}/QME_{erro}$
<i>Resíduo</i>	$a(r-1)$	$SQE_{erro}$	$QME_{erro}$	
<i>Total</i>	$ar-1$	$SQT$		

Segundo Banzatto e Kronka (2006) e Montgomery (2008), em experimentos utilizando o delineamento inteiramente casualizado tem-se o interesse em comparar os efeitos dos tratamentos.

### 2.2.2 Delineamento em blocos casualizados (DBC)

No delineamento em blocos casualizados utiliza-se o princípio de controle local, com o objetivo de eliminar o efeito da autocorrelação entre as unidades experimentais (PASCUAL, 2000).

Segundo Pimentel-Gomes (2009), o delineamento em blocos casualizados, constitui o tipo mais importante de delineamento, onde o controle local é representado pelos blocos, cada um dos quais incluindo todos os tratamentos, devendo cada bloco ser tão uniforme quanto possível, para que o experimento seja eficiente. Contudo, entre os blocos pode haver diferença e esta não afeta o efeito dos tratamentos.

O modelo estatístico do delineamento em blocos casualizados é dado por:

$$y_{ij} = \mu + t_i + b_j + e_{ij}, \quad (2)$$

em que:

$y_{ij}$  é a observação do  $i$ -ésimo tratamento no  $j$ -ésimo bloco, com  $i = 1, 2, \dots, a$  e  $j = 1, 2, \dots, b$ ,

$\mu$  é uma constante inerente a cada observação,

$t_i$  é o efeito do  $i$ -ésimo tratamento,

$b_j$  é o efeito do  $j$ -ésimo bloco,

$e_{ij}$  é o erro associado a cada observação, sendo  $e_{ij} \stackrel{iid}{\sim} N(0, \sigma^2)$ .

A estrutura da tabela de análise de variância para o delineamento de blocos casualizados balanceado é apresentada pela Tabela 2.

Tabela 2 Análise de variância para um delineamento em blocos casualizado

<b><i>FV</i></b>	<b><i>GL</i></b>	<b><i>SQ</i></b>	<b><i>QM</i></b>	<b><i>Valor de F</i></b>
<i>Blocos</i>	$b-1$	$SQB_{locos}$	$QMB_{locos}$	$QMB_{locos}/QME_{erro}$
<i>Tratamentos</i>	$a-1$	$SQT_{rat}$	$QMT_{rat}$	$QMT_{rat}/QME_{erro}$
<i>Resíduo</i>	$(a-1)(b-1)$	$SQE_{erro}$	$QME_{erro}$	
<i>Total</i>	$ab-1$	$SQT$		

O objetivo principal quando se utiliza o delineamento em blocos casualizados é comparar os efeitos dos tratamentos. Porém, podem ser comparados os efeitos que os blocos causam em um determinado experimento.

### 2.2.3 Delineamento em quadrado latino (DQL)

Segundo Pimentel-Gomes (2009), nos quadrados latinos, os blocos são organizados de duas maneiras diferentes, uns constituindo linhas e outros colunas. Esse tipo de delineamento, também é usado para eliminar a heterogeneidade do solo em duas direções perpendiculares, e tem-se em conta a localização topográfica das parcelas.

Os quadrados latinos constituem um bom tipo de delineamento, mas a sua flexibilidade é muito menor do que a dos blocos casualizados e o inteiramente casualizado, pois o número de repetições deve ser igual ao número de tratamentos.

O modelo estatístico desse delineamento é dado por:

$$y_{ijk} = \mu + t_i + l_j + c_k + e_{ijk}, \quad (3)$$

em que:

$y_{ijk}$  é a observação do  $i$ -ésimo tratamento dentro da  $j$ -ésima linha e  $k$ -ésima coluna, com  $i = 1, 2, \dots, a$ ;  $j = 1, 2, \dots, b$  e  $k = 1, 2, \dots, c$ , sendo  $a=b=c$ ;

$\mu$  é uma constante inerente a cada observação;

$t_i$  é o efeito do  $i$ -ésimo tratamento;

$l_j$  é o efeito da  $j$ -ésima linha;

$c_k$  é o efeito da  $k$ -ésima coluna,

$e_{ijk}$  é o erro associado a cada observação, sendo  $e_{ijk} \stackrel{iid}{\sim} N(0, \sigma^2)$ .

O interesse quando se utiliza o delineamento em quadrados latinos é comparar principalmente os efeitos dos tratamentos. Porém, pode-se também comparar os efeitos das linhas e das colunas num determinado experimento.

Na Tabela 3 tem-se a estrutura da análise de variância para um experimento em delineamento em quadrados latinos.

Tabela 3 Análise de variância para um delineamento em quadrado latino

<i>FV</i>	<i>GL</i>	<i>SQ</i>	<i>QM</i>	<i>Valor de F</i>
<i>Linhas</i>	$a-1$	$SQ_{Linhas}$	$QM_{Linhas}$	$QM_{Linhas}/QME_{erro}$
<i>Colunas</i>	$a-1$	$SQ_{Colunas}$	$QM_{Colunas}$	$QM_{Colunas}/QME_{erro}$
<i>Tratamentos</i>	$a-1$	$SQ_{rat}$	$QM_{rat}$	$QM_{rat}/QME_{erro}$
<i>Resíduo</i>	$(a-1)(a-2)$	$SQ_{erro}$	$QME_{erro}$	
<i>Total</i>	$a^2-1$	$SQ_T$		

O delineamento em quadrados latinos permite controlar as variações relacionadas à duas variáveis, isto é, permite fazer o controle local em duas direções. Na prática não são utilizados quadrados latinos com mais de 8 tratamentos, uma vez que o número de repetições é igual ao número de tratamentos, pois tornaria o experimento bastante caro e com repetições exageradas (PIMENTEL-GOMES, 2009).

Os quadrados latinos de 3x3 e 4x4 são recomendados se o experimento incluir vários quadrados latinos. Os quadrados latinos mais utilizados são os de 5x5 a 8x8 (PIMENTEL-GOMES, 2009).

### 2.3 Modelos autorregressivos

Segundo Cressie (1993), os modelos autorregressivos assumem que a resposta de cada lugar  $Y_i$  é uma função não só da variável explicativa nesse local, mas também dos valores das respostas dos vizinhos, isto é, a estrutura autorregressiva dos modelos requer uma definição de dados de vizinhança.

Duas das abordagens utilizadas para modelar dados de experimentos com dependência espacial, são: *Simultaneous Autoregressive Model* (SAR) e *Conditional Autoregressive Model* (CAR). Ambas as abordagens relacionam os dados de um determinado local com uma combinação linear de valores vizinhos, que representam a estrutura autorregressiva (COLLINS; BABYAK; MOLONEY, 2006).

Na abordagem de modelos SAR, os termos autorregressivos são baseados no valor médio de todos os locais vizinhos. Os valores em determinados locais são especificados como sendo um conjunto de valores de todos os outros locais, indicando que a autoregressão ocorreu simultaneamente para cada região. Na abordagem de modelos CAR, o valor de uma dada localização é especificamente condicional às regiões vizinhas. Assim, os valores das regiões vizinhas podem ser assumidos e modelados por uma variável com uma distribuição condicional (ANSELIN, 2002).

### 2.3.1 Matriz de vizinhança espacial

A matriz  $W$  é um dos componentes presentes nos modelos espaciais. Esta é conhecida como sendo a matriz da vizinhança ou de proximidade, sendo definida de várias formas.

Segundo Assunção (2001), Câmara et al. (2004) e Collins, Babyak e Moloney (2006), dado um conjunto de  $n$  áreas  $\{A_1, \dots, A_n\}$ , constrói-se a matriz  $W$  ( $n \times n$ ), onde cada um dos elementos  $w_{ij}$  representa uma medida de proximidade entre  $A_i$  e  $A_j$ .

De acordo com Assunção (2001), Câmara et al. (2004) e Collins, Babyak e Moloney (2006), a matriz  $W$  pode ser obtida a partir de um dos seguintes critérios:

- a)  $w_{ij} = 1$ , se a área  $A_i$  compartilha de mesma fronteira com a área  $A_j$  ( $i \neq j$ ),  $w_{ij} = 0$  caso contrário;
- b)  $w_{ij} = 1$ , se o centroide de  $A_j$  está a uma determinada distância do centroide de  $A_i$  e  $w_{ij} = 0$ , caso contrário;
- c)  $w_{ij} = l_{ij}/l_i$ , onde  $l_{ij}$  é o comprimento da fronteira entre  $A_i$  e  $A_j$  e  $l_i$  é o perímetro de  $A_i$ .

Uma das formas mais comumente empregadas para a definição da matriz  $\mathbf{W}$  consiste na identificação do vizinho de primeira ordem. Considera-se que cada observação no vetor  $\mathbf{Y}$  esteja associada a um polígono, no caso da experimentação a uma parcela e a um sistema referenciado (YWATA; ALBUQUERQUE, 2011).

Segundo Ywata e Albuquerque (2011), por definição, a diagonal principal da matriz  $\mathbf{W}$  possui todos os elementos iguais a zero. O elemento  $w_{i,j}$  da matriz assume o valor  $w_{i,j} = 1$ , caso os polígonos  $i$  e  $j$  sejam vizinhos ou seja apresentam a mesma fronteira e  $w_{i,j} = 0$ , caso  $i$  e  $j$  não partilhem a mesma fronteira, isto é, não são vizinhos.

A matriz  $\mathbf{W}$ , com elementos 0 e 1, é conhecida como matriz de vizinhança não normalizada. A matriz  $\mathbf{W}^*$ , designada de matriz normalizada, e é construída a partir da matriz  $\mathbf{W}$  original, dividindo-se todos os elementos de cada linha de  $\mathbf{W}$  pela soma da linha. Portanto, a matriz  $\mathbf{W}^*$  possui todas as linhas com a soma igual a 1. Por sua vez, a matriz  $\mathbf{W}$  original é simétrica, o que não acontece para a matriz  $\mathbf{W}^*$  (YWATA; ALBUQUERQUE, 2011).

A matriz  $\mathbf{W}$  também pode ser obtida através da multiplicação de duas outras matrizes  $\mathbf{D}$  e  $\mathbf{C}$  ( $\mathbf{W}=\mathbf{D}*\mathbf{C}$ ). A matriz  $\mathbf{C}$  de dimensões  $n \times n$  é uma matriz binária, e descreve a vizinhança das parcelas experimentais e a matriz  $\mathbf{D}$  é uma matriz diagonal contendo a parcela dividida pelo número de vizinhos.

Por exemplo, considerando um experimento com 9 observações com um gride regular apresentado na Figura 1.

1	2	3
4	5	6
7	8	9

Figura 1 Representação de um gride regular com 9 observações de um experimento

Seja a parcela 2 a parcela de referência. Considerando um padrão de proximidade de primeira ordem, tem-se que as parcelas 1, 5 e 3 seriam consideradas vizinhas. Logo na matriz  $C$  os elementos  $c_{21}$ ,  $c_{25}$  e  $c_{23}$ , receberiam o valor 1 e os demais  $c_{2i} = 0$ . Considerando a parcela 5 como referência, têm-se  $c_{52} = c_{54} = c_{56} = c_{58} = 1$  e  $c_{5i} = 0$  para  $i = 1, 3, 7$  e  $9$ .

A matriz de vizinhança  $C$  considerando o padrão de proximidade de primeira ordem, considerando o exemplo da figura 1, será dada por:

$$\mathbf{C} = \begin{pmatrix} 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 \end{pmatrix} .$$

A matriz de vizinhança  $\mathbf{D}$  é uma matriz diagonal com os elementos  $1/k_i$ , em que  $k_i$  é a soma dos valores da linha  $i$  da matriz  $\mathbf{C}$ . Logo tem-se que:

$$\mathbf{D} = \begin{pmatrix} 1/2 & & & & & & & & \\ & 1/3 & & & & & & & \\ & & 1/2 & & & & & & \\ & & & 1/3 & & & & & \\ & & & & 1/4 & & & & \\ & & & & & 1/3 & & & \\ & & & & & & 1/2 & & \\ & & & & & & & 1/3 & \\ & & & & & & & & 1/2 \end{pmatrix} .$$

Assim a matriz  $\mathbf{W}$  será dada pela multiplicação das matrizes  $\mathbf{C}$  e  $\mathbf{D}$ , cujo resultado é:



$u.m$ ), logo, os centroides de cada parcela também distam  $1 u.m$  dos outros centroides adjacentes. Pode-se então definir a vizinhança como as parcelas que são abrangidas pela circunferência de raio  $r$ , partindo da parcela de origem. Assim sendo, pode-se reescrever os padrões de proximidade em função dos raios, centrado na parcela de referência, conforme descrito na Tabela 4.

Tabela 4 Padrões de proximidade em função do raio da circunferência

<b>Padrão de proximidade</b>	<b>Raio da circunferência</b>
Primeira ordem	$1 u.m$
Segunda ordem	$1\sqrt{2} u.m$
Terceira ordem	$2 u.m$
Quarta ordem	$2\sqrt{2} u.m$
:	:
.	.
n-ésima ordem impar	$n u.m$
n-ésima ordem par	$n\sqrt{2} u.m$

Fonte: Rossoni (2011)

Assim, cada elemento  $c_{ij}$  da matriz  $C$  pode ser definido por:

$$c_{ij} = \begin{cases} 1 & \text{para parcelas contidas na} \\ & \text{circunferência de raio } r, \text{ centrada em } c_{ij} \\ 0 & \text{caso contrário.} \end{cases} \quad (4)$$

### 2.3.2 Modelo espacial autorregressivo - SAR

Segundo Ywata e Albuquerque (2011), um dos modelos mais utilizados para a modelagem de autocorrelação espacial é o modelo autorregressivo (*Spatial Autoregressive ou Spatial Lag Model*), ou simplesmente designado de modelo SAR. De forma análoga aos modelos autorregressivos de séries temporais, nos modelos SAR incorpora-se um parâmetro  $\rho$  aos modelos lineares. Na forma matricial mais simples, o modelo SAR pode ser representado por:

$$\mathbf{Y} = \rho \mathbf{WY} + \boldsymbol{\varepsilon} , \quad (5)$$

em que  $\mathbf{Y}$  é um vetor coluna, contendo  $n$  observações na amostra para a resposta  $Y$ , o coeficiente escalar  $\rho$  corresponde ao parâmetro autorregressivo, parâmetro esse cuja interpretação é o efeito médio da variável dependente relativo à vizinhança espacial do local ou região em causa, o termo  $\boldsymbol{\varepsilon}$  corresponde a um vetor coluna contendo os erros  $\boldsymbol{\varepsilon}$ .

O modelo SAR descrito na equação (4) pode ser estendido, para incorporar variáveis explicativas no lado direito da equação, obtendo-se

$$\mathbf{Y} = \rho \mathbf{WY} + \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} , \quad (6)$$

em que

$\mathbf{Y}$  é m vetor  $n \times 1$  de valores observados;

$\rho$  é um parâmetro autorregressivos;

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

$\mathbf{X}$  é uma matriz  $n \times p$  da incidência das variáveis explicativas;

$\boldsymbol{\beta}$  é um vetor  $p \times 1$  dos parâmetros e

$\varepsilon$  é um vetor  $n \times 1$  dos erros inerentes a cada observação, onde  $\varepsilon \sim N(\phi, I\sigma^2)$ .

A ideia básica no modelo (5) é incorporar a autocorrelação espacial como componente do modelo. Caso se observe a ausência de autocorrelação espacial ( $\rho=0$ ), isto é, o modelo espacial autorregressivo (equação 5) é o próprio modelo de Guass-Markov geral.

### 2.3.2.1 Estimação dos parâmetros do modelo SAR

A estimação dos parâmetros no modelo SAR pode ser efetuada pelo método da máxima verossimilhança, uma vez que usando o método de mínimos quadrados ordinários, este produz estimativas inconsistentes (YWATA; ALBUQUERQUE, 2011).

A partir da equação (5) tem-se que:

$$Y - \rho WY = X\beta + \varepsilon, \quad (7)$$

Resolvendo a a equação (7) em função da variável  $Y$  tem-se que:

$$Y(I - \rho W) = X\beta + \varepsilon, \quad (8)$$

A partir da equação (8) encontra-se uma das parametrizações do modelo SAR, apresentada por Anselin (1999), dada por:

$$Y = (I - \rho W)^{-1} X\beta + (I - \rho W)^{-1} \varepsilon. \quad (9)$$

No modelo (9), a variável  $Y$  é uma combinação linear de variáveis aleatórias normais, sendo assim,  $Y$  segue uma distribuição normal cuja média é dada por:

$$E[Y] = (I - \rho W)^{-1} X\beta, \quad (10)$$

e uma matriz de variâncias e covariâncias definida por:

$$Var[Y] = \sum_Y = \sigma^2 (I - \rho W)^{-1} (I - \rho W')^{-1}, \quad (11)$$

Assim sendo,  $Y \sim N\left((I - \rho W)^{-1} X\beta; \sum_Y\right)$  em que os elementos fora da diagonal principal da matriz  $\sum_Y$  representa a autocorrelação espacial na variável  $Y$ .

Segundo Anselin (1999), Militino, Ugarte e Reinaldos (2004) e Plant (2012), para o caso do modelo SAR representado pela equação (9), o logaritmo da função de máxima verossimilhança é definido como:

$$\begin{aligned} \ln(L(\beta, \sigma, \rho | Y, X)) = & -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) + \ln(I - \rho W) \\ & - \frac{1}{2\sigma^2} (Y - \rho WY - X\beta)' (Y - \rho WY - X\beta) \end{aligned} \quad (12)$$

Para estimar os parâmetros do modelos SAR, pelo método de máxima verossimilhança, deriva-se a função log de verossimilhança representada pela equação (12) em relação aos parâmetros e iguala-se a zero, resolvendo o sistema de equações resultantes.

Inicialmente proposto por Ord (1975), a estimação por máxima verossimilhança de um modelo espacial autorregressivo consiste em explorar a decomposição do Jacobiano  $|I - \rho W|$ , em termos de autovalores  $\omega_i$  da matriz  $W$ . Assim tem-se que:

$$\ln|I - \rho W| = \ln \left[ \prod_{i=1}^n (1 - \rho \omega_i) \right], \quad (13)$$

em que  $\omega_i$  são os autovalores da matriz  $W$ . A partir da equação (13) obtém-se um polinômio que não possui solução única. Assim sendo, o parâmetro  $\rho$  na equação é estimado por métodos iterativos, usando métodos de aproximação numérica como o algoritmo de Newton-Raphson ou de Gauss-Newton.

### 2.3.2.2 Análise de variância usando o modelo autorregressivo SAR

A análise de variância usando o modelo autorregressivo, foi descrita por Long (1996) e detalhada por Rossoni (2011), cuja ideia básica consiste em transformar observações autocorrelacionadas em observações não-correlacionadas. Logo, após a estimação do parâmetro  $\hat{\rho}$ , deve-se proceder ao ajuste dos dados observados a partir de

$$Y_{adj} = Y - (\hat{\rho} W Y - \hat{\rho} \beta_0), \quad (14)$$

em que

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

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

$\hat{\rho}$  é o estimador do parâmetro espacial autorregressivo;

$W$  é a matriz  $n \times n$  com atribuições de pesos da vizinhança espacial;

$\beta_0$  é a média dos valores observados.

Com os valores de  $Y_{adj}$  obtém-se uma nova tabela de análise de variância a ser utilizada como base para a construção da análise de variância para o modelo autorregressivo.

O valor da Soma dos Quadrados do parâmetro  $\rho$  ( $SQ\rho$ ) é obtida pela diferença entre a Soma dos Quadrados Total ( $SQT$ ) da análise de variância dos dados não ajustados e a Soma dos Quadrados Total ( $SQT_{adj}$ ) da análise de variância dos dados ajustados pela equação (14). Assim, tem-se

$$SQ\rho = SQT - SQT_{adj}. \quad (15)$$

Na tabela 5 apresenta-se o esquema da análise de variância para o modelo autorregressivo SAR.

Tabela 5 Análise de variância do modelo autorregressivo SAR

<i>FV</i>	<i>GL</i>	<i>SQ</i>	<i>QM</i>	<i>F</i>
<i>Fator de correção (<math>\rho</math>)</i>	<i>1</i>	<i>SQ\rho</i>	_____	_____
<i>Parâmetros</i>	<i>P</i>	<i>SQP<sub>adj</sub></i>	<i>QMP<sub>adj</sub></i>	<i>QMP<sub>adj</sub>/QME<sub>adj</sub></i>
<i>Resíduo</i>	<i>n-p-2</i>	<i>SQE<sub>adj</sub></i>	<i>QME<sub>adj</sub></i>	
<i>Total</i>	<i>n-1</i>	<i>SQT</i>		

Na Tabela 5 tem-se que:

$$QMP_{adj} = \frac{SQP_{adj}}{p}, \quad (16)$$

O Quadrado Médio do Erro deve ser calculado de acordo com a seguinte expressão:

$$QME_{adj} = \frac{SQE_{adj}}{n - p - 2}. \quad (17)$$

em que:

$n$  é o número de observações;

$p$  é o número de parâmetros.

A análise de variância usando a abordagem autorregressiva foi aplicada por Long (1996) para estudar experimentos de campo, onde utilizou dados de um experimento realizado no Centro de Investigação Agrícola da Universidade de Montana com a cultura de trigo. O experimento consistia em avaliar 34 cultivares num delineamento de blocos completos casualizados.

Os resultados das análises feitas por Long (1996) mostraram-se satisfatórios indicando uma eficiência relativa quando se utilizam esses modelos autorregressivos em experimentos que apresentam dependência espacial, quando comparados com análise de variância clássica. No experimento verificou-se uma redução significativa do erro experimental e do efeito dos blocos sobre as cultivares em estudo. Contudo, para Long (1996) o uso da estatística espacial deve ser um complemento para o uso do controlo local.

Estudo feito por Rossoni (2011) usando a simulação de experimentos em blocos completos casualizados em diferentes situações mostra que os experimentos que consideram informação espacial tornam-se mais precisos em relação aos que não consideram esta informação. Contudo, mostrou também que nem sempre os valores do fator  $\rho$  são positivos, isto é, os valores de  $SQ\rho$  por vezes são negativos. Verificou também que com o uso da abordagem autorregressiva na análise de variância usando modelo SAR houve uma redução do erro experimental e do fator bloco quando comparado com a análise de variância clássica. Esses resultados são semelhantes aos encontrados por Long (1996).

### 2.3.3 Modelo condicional autorregressivos - CAR

Outra classe de modelos espaciais é composta pelos modelos de erros espaciais CAR (*Spatial Error Model* ou *Conditional Autoregressive*). Os modelos CAR possuem a seguinte especificação:

$$Y = X\beta + u, \quad (18)$$

em que

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

$X$  é uma matriz  $n \times p$  da incidência das variáveis explicativas;

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

$u$  é um vetor  $n \times 1$  de erros espacialmente dependentes.

Neste estudo, os erros da equação (18) possuem uma estrutura autorregressiva da forma

$$\mathbf{u} = \lambda \mathbf{W}\mathbf{u} + \boldsymbol{\varepsilon}. \quad (19)$$

em que

$\mathbf{u}$  é um vetor  $n \times 1$  do erro espacialmente dependente;

$\lambda$  é um parâmetro espacial autorregressivo;

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

$\boldsymbol{\varepsilon}$  é um vetor  $n \times 1$  dos erros inerentes a cada observação.

O vetor de erros  $\boldsymbol{\varepsilon}$  possui uma distribuição normal multivariada, com média nula e matriz de covariância  $\sigma^2 I$ . O coeficiente escalar  $\lambda$  indica a intensidade da autocorrelação espacial entre os erros da equação (19), isto é, o parâmetro  $\lambda$  mensura o efeito médio dos erros dos vizinhos sobre o erro da região em questão.

A diferença básica entre modelos SAR e CAR é que neste último a variável resposta não se apresenta como função direta dos seus vizinhos. A autocorrelação espacial nos modelos CAR aparece nos termos de erro.

### 2.3.3.1 Estimação dos parâmetros do modelo CAR

Segundo Ywata e Albuquerque (2011), nos modelos CAR, os coeficientes no vetor  $\boldsymbol{\beta}$  podem ser estimados de uma forma consistente utilizando mínimos quadrados ordinários, obtendo-se  $\hat{\boldsymbol{\beta}}_{ols}$ . Porém, a matriz de covariância dos estimadores de  $\hat{\boldsymbol{\beta}}_{ols}$  não será mais dada por  $\sigma^2 [XX]^{-1}$ . Devido aos erros correlacionados, a matriz de covariância de  $\hat{\boldsymbol{\beta}}_{ols}$  é dada pela seguinte expressão:

$$Var[\hat{\beta}_{ols}] = \mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{\Omega}^{-1}\mathbf{X})^{-1}\mathbf{X}'\mathbf{X} , \quad (20)$$

em que  $\mathbf{\Omega} = Var[u] = \sigma^2 (\mathbf{I} - \lambda\mathbf{W})^{-1} [(\mathbf{I} - \lambda\mathbf{W})^{-1}]^T$ . A matriz  $\mathbf{\Omega}$  depende do coeficiente  $\lambda$  e da variância  $\sigma^2$ , sendo que as suas estimativas podem ser obtidas de uma forma consistente a partir da estimação de um modelo SAR utilizando o método de máxima verossimilhança, sendo os resíduos  $\hat{\mathbf{u}} = \mathbf{Y} - \mathbf{X}\hat{\beta}_{ols}$ . Uma vez estimados os escalares  $\lambda$  e  $\sigma^2$ , pode-se obter uma estimativa para a matriz de covariância de  $\hat{\beta}_{ols}$ , a partir de

$$\hat{Var}[\hat{\beta}_{ols}] = \mathbf{X}'\mathbf{X}(\mathbf{X}'\hat{\mathbf{\Omega}}^{-1}\mathbf{X})^{-1}\mathbf{X}'\mathbf{X} , \quad (21)$$

$$\text{em que } \hat{\mathbf{\Omega}} = \hat{\sigma}^2 (\mathbf{I} - \hat{\lambda}\mathbf{W})^{-1} [(\mathbf{I} - \hat{\lambda}\mathbf{W})^{-1}]^T .$$

No caso de modelos CAR que possuem variáveis exógenas, com resíduos correlacionados, o estimador de mínimos quadrados ordinários é consistente, mas não é eficiente, havendo outros estimadores lineares que produzem variâncias menores (YWATA; ALBUQUERQUE, 2011).

Para o modelo CAR, o estimador linear que apresenta a mínima variância é o estimador de mínimos quadrados generalizados (GLS), dado por:

$$\hat{\beta}_{gls} = (\mathbf{X}'\mathbf{\Omega}^{-1}\mathbf{X})^{-1}\mathbf{X}'\mathbf{\Omega}^{-1}\mathbf{Y} , \quad (22)$$

$$\text{em que } \mathbf{\Omega} = \hat{Var}[\hat{\mathbf{u}}] = \sigma^2 (\mathbf{I} - \lambda\mathbf{W})^{-1} [(\mathbf{I} - \lambda\mathbf{W})^{-1}]^T .$$

Na realidade, não se conhece a matriz  $\Omega$ , uma vez que ela depende dos parâmetros desconhecidos  $\lambda$  e  $\sigma^2$ . Assim sendo, utiliza-se o estimador de mínimos quadrados generalizados (YWATA; ALBUQUERQUE, 2011), dado por

$$\hat{\beta}_{gls} = (X' \hat{\Omega}^{-1} X)^{-1} X' \hat{\Omega}^{-1} Y, \quad (23)$$

em que  $\hat{\Omega} = \hat{\sigma}^2 (I - \hat{\lambda} W)^{-1} \left[ (I - \hat{\lambda} W)^{-1} \right]^T$ , com  $\hat{\lambda}$  e  $\hat{\sigma}^2$  estimados usando o método de máxima verossimilhança do modelo SAR simples, a partir dos resíduos  $\hat{u} = Y - X \hat{\beta}_{ols}$ .

Segundo Ywata e Albuquerque (2011), uma outra alternativa para a estimação dos parâmetros do modelo CAR é dada pelos seguintes procedimentos:

- a) Obter a estimativa de mínimos quadrados ordinários

$$\hat{\beta}_{ols} = (X'X)^{-1} X'Y;$$

- b) Calcular os resíduos  $\hat{u} = Y - X \hat{\beta}_{ols}$ ;

- c) Estimar os parâmetros  $\hat{\lambda}$  e  $\hat{\sigma}^2$ , pelo método de máxima verossimilhança, para o modelo SAR em  $\hat{u}$ ,  $\hat{u} = \lambda W \hat{u} + \varepsilon$ , em que

$$\varepsilon \stackrel{iid}{\sim} N(\phi, I\sigma^2)$$

- d) Estimar  $\Omega$  a estimativa  $\hat{\Omega} = \hat{\sigma}^2 (I - \hat{\lambda} W)^{-1} \left[ (I - \hat{\lambda} W)^{-1} \right]^T$ ;

- e) obter a estimativa  $\hat{\beta}_{gls} = (X' \hat{\Omega}^{-1} X)^{-1} X' \hat{\Omega}^{-1} Y$ ;

f) Obter as estimativas para a matriz de covariâncias de  $\hat{\beta}_{gls}$ ,

$$\hat{Var}[\hat{\beta}_{gls}] = (\mathbf{X}'\hat{\Omega}^{-1}\mathbf{X})^{-1}.$$

A estimativa para os coeficientes em  $\beta$  pode ser obtida a partir da matriz  $(\mathbf{X}'\hat{\Omega}^{-1}\mathbf{X})^{-1}$ , por um processo iterativo. Isto é, a estimativa final do vetor  $\beta$  pode ser obtida a partir de uma estimativa de  $\hat{\beta}_{gls}$ , bastando para o efeito obter um novo vetor  $\hat{\mathbf{u}} = \mathbf{Y} - \mathbf{X}\hat{\beta}_{gls}$ . Para este novo vetor  $\hat{\mathbf{u}}$ , estimam-se novamente os parâmetros  $\hat{\lambda}$  e  $\hat{\sigma}^2$  repetindo-se os procedimentos (iv) e (v). Este processo deve ser efetuado repetidamente até que os valores de  $\hat{\beta}_{gls}$  atinjam a convergência. Finalizam-se então as estimações com o procedimento (vi) (YWATA; ALBUQUERQUE, 2011).

A estimação dos parâmetros do modelo CAR, também pode ser efetuada via máxima verossimilhança. Anselin (1999), Plant (2012) e Ywata e Albuquerque (2011) mostram que uma das parametrizações do modelo CAR, é definida combinando-se as equações (18) e (19), obtendo-se

$$\mathbf{Y} = \mathbf{X}\beta + (1 - \lambda\mathbf{W})^{-1}\boldsymbol{\varepsilon}, \quad (24)$$

em que  $\boldsymbol{\varepsilon} \sim N(0, \sigma^2\mathbf{I})$

Nesse caso, o vetor de variável resposta  $\mathbf{Y}$  possui uma distribuição normal multivariada com média condicional dada pela seguinte expressão:

$$E[Y|X] = X\beta, \quad (25)$$

e matriz de variância condicional

$$\sum_{Y|X} = \sigma^2 (I - \lambda W)^{-1} [(I - \lambda W)^{-1}]^T. \quad (26)$$

A partir da distribuição de  $Y$ , obtém-se a função de log-verossimilhança condicional, que é expressa da seguinte forma:

$$\begin{aligned} \ln(L(\beta, \sigma, \lambda | Y, X)) = & -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) + \ln(I - \lambda W) \\ & - \frac{1}{2\sigma^2} (Y - X\beta)' (I - \lambda W)' (I - \lambda W) (Y - X\beta), \end{aligned} \quad (27)$$

A estimação dos parâmetros do modelos CAR pode ser feita pelo método de máxima verossimilhança. Este método consiste em maximizar a função de log-verossimilhança em relação aos parâmetros do modelo, encontrando as estimativas para os coeficientes e para a variância dos resíduos. Para encontrar os estimadores de máxima verossimilhança do modelo, deriva-se a equação (27) em relação aos parâmetros e iguala-se a zero. Porém, deste processo resulta um sistema de equações resultantes que envolvem matrizes muito esparsas e que não retornam a uma solução única, exigindo a utilização de métodos iterativos, como é o caso de método de Gauss-Newton ou o algoritmo de Newton-Raphson.

### 2.3.3.2 Análise de variância usando o modelo autorregressivo CAR

Segundo Griffith (1978), com a adaptação e o uso da teoria da estatística clássica em análises envolvendo experimentos com dependência espacial

descobriu-se um problema geral relacionado com a estimação de parâmetros em modelos envolvendo os termos dos erros espacialmente correlacionados e consequências atribuídas a este problema foram documentadas especialmente em modelos de regressão linear.

A regressão linear, assim como, os delineamentos de experimentos são ambos casos particulares do modelo linear geral. Na regressão linear, o modelo pressupõe uma relação entre a variável resposta e as variáveis explicativas. Nos delineamentos experimentais as variáveis explicativas, ou tratamentos, e em alguns casos o modelo não assume um relacionamento especial de dependência entre os tratamentos e a variável resposta (PLANT, 2012).

O ajuste de modelos com autocorrelação espacial dentro do contexto do modelo linear geral tem sido estudado bastante, considerando os modelos autorregressivos. Uma aproximação usando a decomposição do Jacobiano foi proposto e desenvolvido por Cliff e Ord em 1975 para a estimação dos parâmetros dos modelos autorregressivos incluindo o modelo CAR (GRIFFITH, 1992).

Griffith (1978) descreve como a análise de variância pode ser aplicada considerando-se modelos lineares em situações em que os dados apresentam dependência espacial, tendo explorado o modelo de regressão na forma de análise de variância.

Estudos realizados por Griffith (1992), que consistiram em analisar dados referentes à distribuição geográfica de oito variáveis agrícolas, as quais foram obtidas a partir do Censo Agrícola dos Estados Unidos, foi utilizado tendo em conta o modelo linear geral. A ideia básica consistia em três procedimentos, nomeadamente:

- a) Estimar o valor do parâmetro espacial autorregressivo;
- b) Ajustar a variável dependente com o parâmetro autorregressivo;

- c) Submeter a variável dependente ao procedimento de análise de variância.

#### **2.3.4 Avaliação da dependência espacial**

Um aspecto importante da análise exploratória espacial é a caracterização da dependência espacial, de modo a verificar como os valores se encontram correlacionados no espaço. Neste contexto, para contabilizar a presença de dependência espacial podem ser utilizados índices, como é o caso do índice de Moran, assim como, testes para a detecção da presença espacial, tais como teste de Wald, teste de razão de verossimilhança e teste de multiplicadores de Lagrange.

##### **2.3.4.1 Índice de Moran**

Segundo Long (1996) e Plant (2012), Moran foi o primeiro a propor, em 1948, uma medida para avaliar a natureza e o grau de auto-correlação de variáveis geo-referenciadas.

O coeficiente de Moran, ou índice de Moran como é conhecido, pode ser utilizado para a avaliação da auto-correlação espacial em experimentos agronômicos de campo com dados referenciados e com um arranjo regular nas parcelas (LONG, 1996).

O índice de Moran é calculado comparando-se os pares adjacentes das observações com o seu desvio em relação a média de todas as observações, utilizando-se a seguinte fórmula:

$$I = \frac{n}{\sum_i \sum_j w_{ij}} \times \frac{\sum_i \sum_j w_{ij} (Y_j - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2}, \quad (28)$$

em que  $I$  é o coeficiente de Moran ou índice de Moran,  $n$  é o número de parcelas,  $w_{ij}$  é a  $ij$ -ésima entrada binária na matriz de proximidade espacial (1 ou 0),  $Y_i$  é a  $i$ -ésima observação e  $Y_j$  é a  $j$  éxima observação e  $\bar{Y}$  é a média dos valores observados. Os valores de coeficiente de Moran podem ser positivos, assim como, negativos, podendo assumir qualquer valor no conjunto dos números reais (WALLER; GOTWAY, 2004). Porém, na maior parte dos casos encontra-se no intervalo  $[-1,1]$ . Caso o valor esteja entre 0 e +1, indica uma correlação direta e se estiver entre 0 e -1, correlação inversa. Segundo Plant (2012), quando existe homogeneidade entre as parcelas próximas, o  $I$  tende a ser positivo, enquanto que se as parcelas próximas forem dissimilares, o coeficiente tende a ser negativo.

Uma vez calculado o índice de Moran, é necessário estabelecer a sua validade, isto é, se os valores encontrados representam correlação espacial significativa ou não. O índice de Moran presta-se a um teste cuja hipótese de nulidade é a existência de independência espacial, ou seja, caso o valor do índice seja igual a zero não existe dependência espacial (GRIFFITH, 2010).

Segundo Cliff e Ord (1981), para estimar a significância do índice de Moran, é preciso associar a este uma distribuição estatística, sendo comum à distribuição normal, que é assintótica sob a suposição de normalidade à medida que  $n$  aumenta, com a média e variância dadas pelas seguintes expressões:

$$E[\hat{I}] = \frac{-1}{n-1}, \quad (29)$$

$$Var[\hat{I}] = \frac{\frac{1}{2}n^2 \sum_{i=1}^n \sum_{j=1}^n (w_{ij} + w_{ji})^2 - n \sum_{i=1}^n \sum_{j=1}^n (w_{i+} + w_{+j})^2 + 3 \left( \sum_{i=1}^n \sum_{j=1}^n w_{ij} \right)^2}{(n-1)(n+1) \left( \sum_{i=1}^n \sum_{j=1}^n w_{ij} \right)^2} - \left( \frac{1}{n-1} \right)^2, \quad (30)$$

ou

$$Var[\hat{I}] = \frac{n^2 S_1 - n S_2 + 3 S_0^2}{(n-1)(n+1) S_0^2} - \left( \frac{1}{n-1} \right)^2, \quad (31)$$

Segundo Anselin (2005), em análise de dados de áreas, uma forma de escolha para ajuste de um modelo espacial, é avaliar a presença da dependência espacial dos resíduos no modelo Gauss-Markov ordinário, pois se o coeficiente espacial autorregressivo nos modelos espaciais for nulo ( $\rho = 0$ ), estes modelos transformam-se num modelo geral de Gauss-Markov.

Segundo Lichstein et al. (2002), Waller e Gotway (2004) e Ywata e Alburquerque (2011), a presença da dependência espacial, pode ser analisada calculando a estatística de Moran dos resíduos, conforme a equação seguinte:

$$\hat{I}_{res} = \frac{n}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \frac{\mathbf{u}' \mathbf{W} \mathbf{u}}{\mathbf{u}' \mathbf{u}}, \quad (32)$$

em que  $\mathbf{u}$  representa o vetor de resíduos observados,  $\mathbf{W}$  é a matriz de vizinhança,  $w_{ij}$  são os elementos da matriz de vizinhança e  $n$  é o número de áreas ou parcelas para o caso de experimentação.

O índice de Moran dos resíduos segue uma distribuição normal assintótica com média e variância dadas pelas equações (33) e (34), respectivamente (CLIFF; ORD, 1981).

$$E[\hat{I}_{res}] = \frac{n}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \frac{tr(MW)}{n-p}, \quad (33)$$

em que  $p$  é o número de parâmetros e  $tr(\cdot)$  é o traço da matriz, e

$$Var[\hat{I}_{res}] = \left( \frac{n}{\sum_{i=1}^n \sum_{j=1}^n (w_{ij})} \right)^2 \frac{tr(MWMW') + tr(MW)^2 + [tr(MW)]^2}{(n-p)(n-p+2)} - [E(I_{res})]^2, \quad (34)$$

em que  $M = I - X(X'X)^{-1}X'$ , matriz de projeção, com  $I_n$  sendo a matriz identidade.

$p$  é o número de parâmetros,

$tr$  é o traço da matriz.

A partir da estatística de Moran pode-se construir um teste para a hipótese nula de independência espacial. Segundo Ywata e Albuquerque (2011), a distribuição associada à estatística de Moran foi derivada por Cliff e Ord em 1972. A rejeição da hipótese nula implica evidências da existência de dependência espacial no modelo. A estatística de Moran é assintoticamente distribuída, e é, representada pela equação (35):

$$Z = \frac{I_{res} - E[\hat{I}_{res}]}{\sqrt{Var[\hat{I}_{res}]}} , \quad (35)$$

O valor de  $z$  obtido na equação (35), corresponde a um quantil da distribuição normal padronizada, que está associado a um valor-p. O índice de Moran será considerado significativo se o valor-p for inferior ao valor nominal de significância pré-definido.

Alternativamente ao índice de Moran, pode-se avaliar a existência da dependência espacial utilizando o teste de Wald e o teste de razão de verossimilhança (ANSELIN, 2005; MILITINO; UGARTE; REINALDOS, 2004; YWATA; ALBURQUERQUE, 2011).

#### 2.3.4.2 Teste de Wald

Segundo Ywata e Albuquerque (2011), o teste de Wald é um teste baseado nas propriedades dos estimadores de máxima verossimilhança, podendo ser utilizado em diferentes contextos.

O teste de Wald ao contrário do índice de Moran, é estruturado de forma específica, tendo a hipótese nula e alternativa sobre os parâmetros autorregressivos do modelo. A hipótese nula é formulada sobre a existência de independência espacial, ou seja o parâmetro autorregressivo do modelo SAR ( $\rho=0$ ) ou CAR ( $\lambda=0$ ) são iguais a zero (YWATA; ALBUQUERQUE, 2011).

A estatística do teste de Wald para o modelo CAR foi descrita e apresentado por Lesage (1998), sendo  $H_0: \lambda=0$ , sendo a hipótese alternativa o modelo CAR representado pelas equações (18) e (19). A expressão para esse modelo espacial é:

$$Wald = \hat{\lambda}^2 \left[ t_2 + t_3 - \frac{(t_1)^2}{n} \right] \sim \chi_1^2, \quad (36)$$

em que  $t_1 = tr(W)\hat{B}^{-1}$ ,

$$t_2 = tr\left[\left(W\hat{B}^{-1}\right)\right]^2,$$

$$t_3 = tr\left[\left(W\hat{B}^{-1}\right)'\left(W\hat{B}^{-1}\right)\right] \text{ e } \hat{B} = (I - \hat{\lambda}W).$$

Onde  $tr$  é o traço da matriz e  $I$  é a matriz identidade.

A estatística de Wald também segue uma distribuição assintótica  $\chi^2$  com um grau de liberdade, sendo feita a inferência a partir desta distribuição.

#### 2.3.4.3 Teste de razão de verossimilhança

Segundo Militino, Ugarte e Reinaldos (2004), o teste de razão de verossimilhança pode ser aplicado quando os modelos são ajustados via máxima verossimilhança. A hipótese nula estabelecida para o parâmetro de dependência espacial, denotado por  $\rho$  ou  $\lambda$ , é igual a zero. A estatística do teste compara as diferenças entre a log-verossimilhança do modelo não restrito (modelo linear espacial) e o modelo restrito sobre a hipótese nula (modelo linear, com  $\rho = 0$  ou  $\lambda = 0$ ).

Tyszler (2006) apresentou e descreveu o teste de razão de verossimilhança para os modelos autorregressivos, no qual, afirma que o teste de razão de verossimilhanças para presença de dependência espacial no erro parte da função se baseia no cálculo da diferença entre as equações (37) e (38) utilizando os parâmetros obtidos de um modelo CAR por máxima verossimilhança em (37) e mínimos quadrados ordinários em (38)

$$\ln(L(\beta, \sigma, \lambda | Y, X)) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) + \ln(I - \lambda W) - \frac{1}{2\sigma^2} (Y - X\beta)' (I - \lambda W)' (I - \lambda W) (Y - X\beta), \quad (37)$$

Sob  $H_0: \lambda=0$ , a equação (37) pode ser reescrita como:

$$\ln(L(\beta, \sigma, \lambda | Y, X)) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} (Y - X\beta)' (Y - X\beta), \quad (38)$$

A variância estimada,  $S_1^2$  seria:

$$\frac{\varepsilon' \varepsilon}{n} = \frac{u' (I - \lambda W)' (I - \lambda W) u}{n}, \quad (39)$$

Dessa forma, a equação (37) avaliada com os parâmetros estimados por máxima verossimilhança com  $S_1^2$  no lugar de  $\sigma^2$ , se torna

$$\ln(L(\beta, \sigma, \lambda | Y, X)) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln S_1^2 + \ln(I - \lambda W) - \frac{n}{2}, \quad (40)$$

Por transformação semelhante da variância estimada por mínimos quadrados ordinários, chamando-a de  $S_0^2$ , é possível reescrever a equação (38)

$$\ln(L(\beta, \sigma, \lambda | Y, X)) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln S_0^2 - \frac{n}{2}, \quad (41)$$

Dessa forma, fazendo a duas vezes diferença de (40) e (41), e ajustando os termos, temos a estatística de razão de verossimilhança expressa por

$$LR = -n (\ln S_0^2 - \ln S_1^2) + 2 \ln |I - \lambda W| \sim \chi_1^2 \quad (42)$$

Em geral, a estatística do teste de razão é assintoticamente distribuída como uma  $\chi^2$  com  $r$  graus de liberdade. Nesse caso particular, a distribuição correspondente a estatística da razão de verossimilhança é a distribuição  $\chi^2$  com um grau de liberdade (MILITINO; UGARTE; REINALDOS, 2004).

### **3 MATERIAL E MÉTODOS**

No presente trabalho, foram utilizados dados gerados a partir de simulação computacional. As simulações bem como as análises foram efetuadas no *software* R (R DEVELOPMENT CORE TEAM, 2012). Foi efetuada uma análise comparativa da análise de variância utilizando modelo autorregressivo SAR e análise de variância usando modelo autorregressivo CAR.

#### **3.1 Simulação dos experimentos**

A simulação dos experimentos envolveu a escolha dos delineamentos experimentais, as configurações simuladas e a simulação dos dados com dependência espacial.

##### **3.1.1 Delineamentos experimentais e configurações simuladas**

Foram utilizados dois tipos de delineamentos para a simular os dados dos experimentos, nomeadamente o delineamento em blocos casualizados (DBC) e o delineamento em quadrado latino (DQL). Para a casualização dos tratamentos dentro das parcelas envolvidas nos experimentos durante a geração dos dados foi utilizado o pacote *Agricolae* (MENDIBURI, 2012). A escolha desses dois delineamentos foi por estes utilizarem o controle local.

No trabalho foram utilizadas 4 configurações diferentes, 2 para o delineamento em blocos casualizados, propostas por Rossoni (2011), e 2 para o delineamento em quadrado latino, considerando configurações mais utilizadas no campo. As configurações utilizadas para a simulação dos dados foram as seguintes:

**Experimento i** - um experimento em blocos casualizados com 5 tratamentos e 4 blocos.

**Experimento ii** - um experimento em blocos casualizados com 18 tratamentos e 6 blocos.

**Experimento iii** - um experimento em quadrado latino com 5 tratamentos.

**Experimento iv** - um experimento em quadrado latino com 10 tratamentos.

Os experimentos foram construídos considerando-se um gride regular de forma quadrangular com tamanho das parcelas definido em  $1 \text{ u.m}^2$ . Os parâmetros iniciais foram fixados, sendo que a parte aleatória foi atribuída ao erro. Os efeitos fixos foram estabelecidos de modo que as diferenças entre os tratamentos sejam pequenas, com o objetivo de verificar se os modelos autorregressivos conseguem captar as diferenças entre os tratamentos. Na tabela 6 são apresentados os valores dos efeitos fixos considerados nas simulações.

Tabela 6 Efeitos fixos dos parâmetros utilizados na simulação dos experimentos

DBC				DQL			
<i>Experimento i</i>		<i>Experimento ii</i>		<i>Experimento iii</i>		<i>Experimento iv</i>	
<i>Parâmetro</i>	<i>Valor</i>	<i>Parâmetro</i>	<i>Valor</i>	<i>Parâmetro</i>	<i>Valor</i>	<i>Parâmetro</i>	<i>Valor</i>
$\mu$	275	$\mu$	375	$\mu$	335	$\mu$	335
$t_1$	105	$t_1$	104	$t_1$	105	$t_1$	105
$t_2$	110	$t_2$	109	$t_2$	110	$t_2$	107
$t_3$	120	$t_3$	111	$t_3$	120	$t_3$	109
$t_4$	125	$t_4$	119	$t_4$	125	$t_4$	111
$t_5$	130	$t_5$	124	$t_5$	130	$t_5$	113
$b_1$	108	$t_6$	129	$l_1$	106	$t_6$	115
$b_2$	113	$t_7$	134	$l_2$	111	$t_7$	117
$b_3$	118	$t_8$	139	$l_3$	116	$t_8$	119
$b_4$	123	$t_9$	144	$l_4$	121	$t_9$	121
		$t_{10}$	149	$l_5$	126	$t_{10}$	123
		$t_{11}$	154	$c_1$	98	$l_1$	106
		$t_{12}$	159	$c_2$	103	$l_2$	108
		$t_{13}$	164	$c_3$	108	$l_3$	110
		$t_{15}$	174	$c_5$	118	$l_5$	114
		$t_{14}$	169	$c_4$	113	$l_4$	112
		$t_{16}$	179			$l_6$	116
		$t_{17}$	184			$l_7$	118
		$t_{18}$	189			$l_8$	120
		$b_1$	108			$l_9$	124
		$b_2$	113			$l_{10}$	126
		$b_3$	118			$c_1$	98
		$b_4$	123			$c_2$	100
		$b_5$	128			$c_3$	102
		$b_6$	133			$c_4$	104
						$c_5$	106
						$c_6$	108
						$c_7$	110
						$c_8$	102
						$c_9$	104
						$c_{10}$	106

### 3.1.2 Simulação dos dados

Para os experimentos, os erros foram gerados utilizando o modelo gaussiano, dado pela seguinte expressão:

$$\gamma(h) = \begin{cases} 0 & , |h| = 0 \\ C_0 + C_1 \left[ 1 - \exp\left(\frac{-|h|}{a}\right)^2 \right] & , |h| \neq 0 \end{cases} \quad (43)$$

em que:

- a) Alcance ( $a$ ) é a distância dentro da qual as amostras se encontram espacialmente correlacionadas;
- b) Efeito pepita ( $C_0$ ) é o efeito que representa a descontinuidade do semivariograma na sua origem. Segundo Isaaks e Srivastava (1989), à medida que  $h$  tende para zero,  $\gamma(h)$  se aproxima de um valor designado de efeito pepita, que revela a descontinuidade do semivariograma para distâncias menores que a distância entre as amostras. Parte dessa descontinuidade pode ser também devido a erros de medição ou da variabilidade de pequena escala não captada durante a amostragem;
- c) O patamar  $C$  é o valor da semivariância correspondente ao valor do alcance ( $a$ ), isto é,  $\gamma(a) = C$ . O patamar é o ponto a partir do qual, que se considera não existir dependência espacial entre as amostras, uma vez que a variância da diferença entre os pares de amostras torna-se invariante com a distância;
- d) O  $\gamma(h)$  é a semivariância, que é a medida do grau de dependência espacial entre duas amostras;

- e) A contribuição ( $C_I$ ) é a diferença entre o patamar ( $C$ ) e o efeito pepita ( $C_0$ ).

Foi utilizado o modelo gaussiano pois, segundo Clark (1979), nos experimentos de campos que apresentam dependência espacial é mais comum se encontrarem erros que podem ser modelados por este.

No presente estudo os erros dependentes foram gerados usando o pacote *RandomFields* (SCHLATHER et al., 2012). Além da incorporação dos erros dependentes, foram gerados vários conjuntos de dados de acordo com padrões de proximidade de primeira, segunda e terceira ordem.

Sob a hipótese de nulidade, isto é, de não existência de dependência espacial para os modelos SAR ( $\rho=0$ ) e para o CAR ( $\lambda=0$ ) foi feita a verificação da existência de dependência espacial nos diferentes conjuntos de dados baseando-se no teste de Wald.

Para os experimentos foram considerados dois alcances: 2 e 4. O patamar considerado em todas as configurações apresentadas foi de 1. Para o efeito pepita foram consideradas três configurações (0,05; 0,25 e 0,75) com o intuito de gerar um erro no qual a explicação por parte do modelo apresenta-se um grau de dependência espacial forte, moderada e fraca dependência. O grau de dependência espacial foi considerado de acordo com a classificação apresentada por Cambardela et al. (1994), que estabelece uma proporção do efeito pepita, em relação ao patamar conforme a relação abaixo:

- a) **Dependência forte** se efeito pepita for menor que 25% do patamar;
- b) **Dependência moderada** se o efeito pepita estiver entre 25% e 75% do patamar;
- c) **Dependência fraca** se o efeito pepita for igual ou superior à 75% do patamar;

Foram considerados três padrões de proximidade, nomeadamente primeira ordem, segunda ordem e terceira ordem, para o modelo SAR (SAR1, SAR2 e SAR3) e para o modelo CAR (CAR1, CAR2 e CAR3). As ordens foram definidas segundo o critério apresentado na Tabela 4.

Seis configurações de erros dependentes com o intuito de verificar o desempenho e a eficácia dos modelos autorregressivos SAR e CAR foram geradas, as quais estão apresentadas na Tabela 7.

Tabela 7 Parâmetros do semivariograma para simulação do erro experimental

	<i>Configuração</i>	<i>Efeito pepita</i>	<i>Patamar</i>	<i>Alcance</i>
<i>Experimento i</i>	<i>Gaus (0,05-1-2)</i>	0,05	1	2
	<i>Gaus (0,25-1-2)</i>	0,25	1	2
	<i>Gaus (0,75-1-2)</i>	0,75	1	2
	<i>Gaus (0,05-1-4)</i>	0,05	1	4
	<i>Gaus (0,25-1-4)</i>	0,25	1	4
	<i>Gaus (0,75-1-4)</i>	0,75	1	4
<i>Experimento ii</i>	<i>Gaus (0,05-1-2)</i>	0,05	1	2
	<i>Gaus (0,25-1-2)</i>	0,25	1	2
	<i>Gaus (0,75-1-2)</i>	0,75	1	2
	<i>Gaus (0,05-1-4)</i>	0,05	1	4
	<i>Gaus (0,25-1-4)</i>	0,25	1	4
	<i>Gaus (0,75-1-4)</i>	0,75	1	4
<i>Experimento iii</i>	<i>Gaus (0,05-1-2)</i>	0,05	1	2
	<i>Gaus (0,25-1-2)</i>	0,25	1	2
	<i>Gaus (0,75-1-2)</i>	0,75	1	2
	<i>Gaus (0,05-1-4)</i>	0,05	1	4
	<i>Gaus (0,25-1-4)</i>	0,25	1	4
	<i>Gaus (0,75-1-4)</i>	0,75	1	4
<i>Experimento iv</i>	<i>Gaus (0,05-1-2)</i>	0,05	1	2
	<i>Gaus (0,25-1-2)</i>	0,25	1	2
	<i>Gaus (0,75-1-2)</i>	0,75	1	2
	<i>Gaus (0,05-1-4)</i>	0,05	1	4
	<i>Gaus (0,25-1-4)</i>	0,25	1	4
	<i>Gaus (0,75-1-4)</i>	0,75	1	4

Um total de 1000 simulações foram feitas para cada configuração apresentada na Tabela 7, perfazendo um total de 24000 conjuntos de dados analisados considerando-se cada modelo autorregressivo.

### 3.2 Estimação dos parâmetros e análise de variância

A estimação dos parâmetros dos modelos foi efetuada usando o pacote *spdep* (BIVAND et al., 2012), tendo em conta as equações (12) e (27) para o modelo SAR e CAR, respectivamente. A avaliação da existência de dependência espacial nos modelos foi feita com base no teste de Wald. Uma vez confirmada a existência de dependência espacial foi efetuada a estimação dos parâmetros dos modelos autorregressivos SAR e CAR utilizando o método de máxima verossimilhança.

#### 3.2.1 Análise de variância

Para a análise de variância utilizando o modelo autorregressivos SAR foi utilizada a metodologia descrita por Long (1996) e detalhada por Rossoni (2011), que consiste em transformar observações autocorrelacionadas em observações não-correlacionadas. Assim, tem-se as seguintes etapas:

- a) Definição do padrão de proximidade a ser adotado;
- b) Construção da matriz  $C$  e conseqüentemente as matrizes  $D$  e  $W$ ;
- c) Cálculo dos autovalores da matriz  $W$ ;
- d) Estimação do parâmetro  $\hat{\rho}$  utilizando a equação (13);
- e) Uma vez obtido o  $\hat{\rho}$ , ajusta-se as observações autocorrelacionadas utilizando-se a equação (14);

- f) Com a obtenção do vetor dos valores ajustados ( $Y_{adj}$ ) procede-se a construção do modelo autorregressivos conforme definido na Tabela 5.

De forma similar ao modelo SAR, para o caso do modelo CAR têm-se as seguintes etapas:

- a) Definição do padrão de proximidade a ser adotado;
- b) Construção da matriz  $C$  e conseqüentemente as matrizes  $D$  e  $W$ ;
- c) Cálculo dos autovalores da matriz  $W$ ;
- d) Estimação do parâmetro  $\hat{\lambda}$  utilizando a equação (27);
- e) Uma vez estimado o parâmetro  $\hat{\lambda}$ , ajustam-se os erros autocorrelacionados, tendo em conta uma distribuição normal multivariada com média zero e variância igual à um (Vide APÊNDICE C);
- f) Após ajustar os erros autocorrelacionados, ajusta-se o modelo para obter os valores de  $Y$  e a posterior análise de variância.

### 3.2.2 Critérios de comparação das abordagens ANOVA, SAR e CAR

Para a comparação das abordagens utilizando a análise clássica ANOVA e modelos autorregressivos SAR e CAR, foram utilizados os intervalos de credibilidade.

Segundo Migon e Gamerman (1999), os intervalos de credibilidade constituem uma forma mais adequada de avaliar informação disponível a respeito de parâmetros desconhecidos por meio da distribuição a posteriori. Assim, ao resumir a informação da distribuição a posteriori em um único valor,

não se tem uma medida da precisão da estimativa obtida. Uma alternativa para contornar esta situação é a obtenção de intervalos de credibilidade.

Um intervalo de credibilidade é definido da seguinte maneira:

Seja  $\theta$  uma quantidade desconhecida definida em  $\Theta$ . Uma região  $C \subset \Theta$  é um intervalo de credibilidade  $100(1 - \alpha)\%$  para  $\theta$  se  $p(\theta \in C | x) = 1 - \alpha$ .

Neste caso,  $(1 - \alpha)$  é chamado de nível de credibilidade, e o intervalo de credibilidade bayesiano com este nível é denotado por  $IC(1 - \alpha)\%$ .

No presente estudo foram obtidos e avaliados os intervalos de credibilidade para os parâmetros em estudo, nomeadamente a variância residual ( $\sigma^2$ ), a função quadrática dos efeitos dos tratamentos ( $\Phi_T$ ),  $\rho$ ,  $\lambda$  e o valor de  $AIC$ , com 95% de probabilidade de conter o verdadeiro parâmetro. Os quantis utilizados para determinação do intervalo de credibilidade foram (0,025 e 0,975).

Os modelos utilizados para análise foram modelos de efeitos fixos, assim sendo, teremos que a variância residual estimada ( $\hat{\sigma}^2$ ) é igual ao quadrado médio do erro (QME) e que  $\hat{\Phi}_t$  estimado será dado pela equação seguinte:

$$\hat{\Phi}_t = \frac{QM_{Trat} - QME}{J}, \quad (44)$$

em que  $QM_{Trat}$  é a soma dos quadrados dos tratamentos

$QME$  é a soma dos quadrados do erro

$J$  é o número de repetições

O  $\Phi_t$  observado é dado pela seguinte expressão:

$$\Phi_t = \frac{1}{I-1} \sum_{i=1}^n \tau_i^2 \quad (45)$$

em que  $\tau_i$  é o efeito de tratamentos

$I$  é o número de tratamentos

### 3.2.3 Critérios de comparação de modelos

Para a comparação de resultados das análises de variância consideranso-se os modelos SAR e CAR, foi utilizado o critério de informação de Akaike (AIC). Esse critério, em geral tem sido utilizado para a comparação de modelos para verificar qual dos modelos apresenta melhor desempenho em termos de ajuste. O AIC é baseado na teoria de decisão e é definido como a quantidade:

$$AIC = -2\ln + 2p \quad , \quad (46)$$

em que  $\ln$  é o logaritmo neperiano do máximo da função de verossimilhança e  $p$  é o número de parâmetros do modelo considerado. De acordo com esse critério, o melhor modelo é aquele que apresenta o menor valor de AIC.

## 4 RESULTADOS E DISCUSSÃO

Os resultados das análises efetuadas estão apresentados a seguir. Para uma melhor compreensão, este estudo apresentará, inicialmente, um caso particular de cada delineamento experimental.

### 4.1 Exemplo de delineamento em blocos casualizados

Para exemplificar a abordagem autorregressiva usando o delineamento em blocos casualizados foram escolhidas duas configurações *Gaus* (0,05-1-2) do experimento *i* e *ii*, isto é, os experimentos apresentam um erro com configuração gaussiana, com efeito pepita 5%, patamar um e alcance dois. Inicialmente, foi avaliada a presença da autocorrelação espacial utilizando-se o teste de Wald.

Os histogramas apresentados no Gráfico 1 mostram existência de assimetria positiva, evidenciando uma maior concentração de valores de  $p$  da estatística do teste Wald próximo de zero, o que sugere que foi possível incorporar a dependência espacial nos experimentos em blocos casualizados em estudo. Porém, vale ressaltar que, apesar da incorporação da dependência espacial em alguns experimentos, os resultados das estimativas dos parâmetros  $\rho$  do modelo SAR para as quais foram testadas pelo teste de Wald, apresentados em intervalos de credibilidade na Tabela 14, no apêndice A, mostram, que em alguns casos esta dependência espacial não existe, o que pode ser visualmente observado no Gráfico 1, resultados esses que podem estar associados a dificuldades encontradas nos pacotes para a simulação de erros.

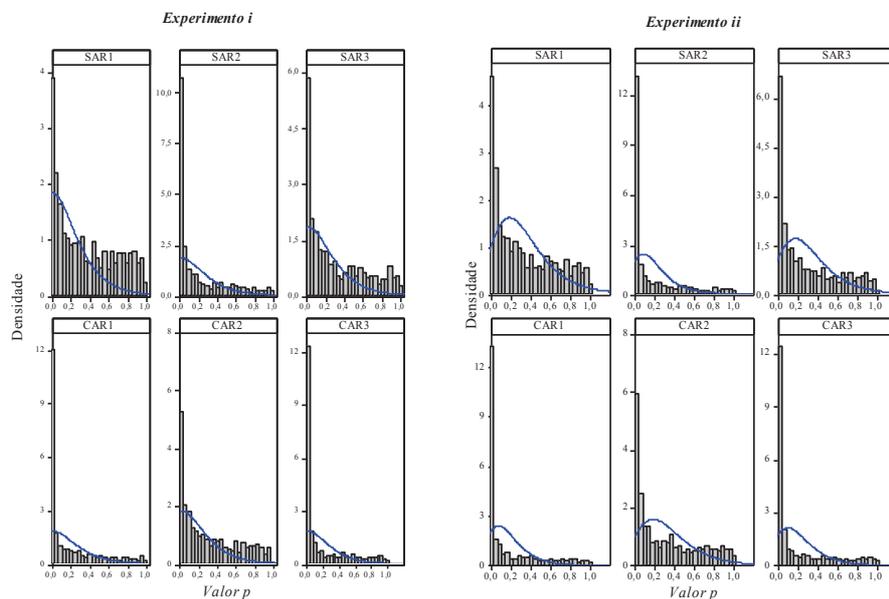


Gráfico 1 Histograma do valor p da estatística do teste de Wald para os experimentos usando blocos casualizados provenientes de 1000 simulações

No Gráfico 2 têm-se histogramas da variância estimada ( $\hat{\sigma}^2$ ). No gráfico pode-se observar um aumento da  $\hat{\sigma}^2$  para os modelos autorregressivos (CAR1, CAR2, e CAR3) quando comparados com os modelos SAR1, SAR2, SAR3 e ANOVA, indicando que a abordagem autorregressiva CAR para análise de variância não melhorou a precisão do experimento. Quando comparados os modelos autorregressivos SAR entre si e com a abordagem clássica ANOVA constata-se que não existem diferenças significativas na  $\hat{\sigma}^2$  e o seu valor é muito pequeno.

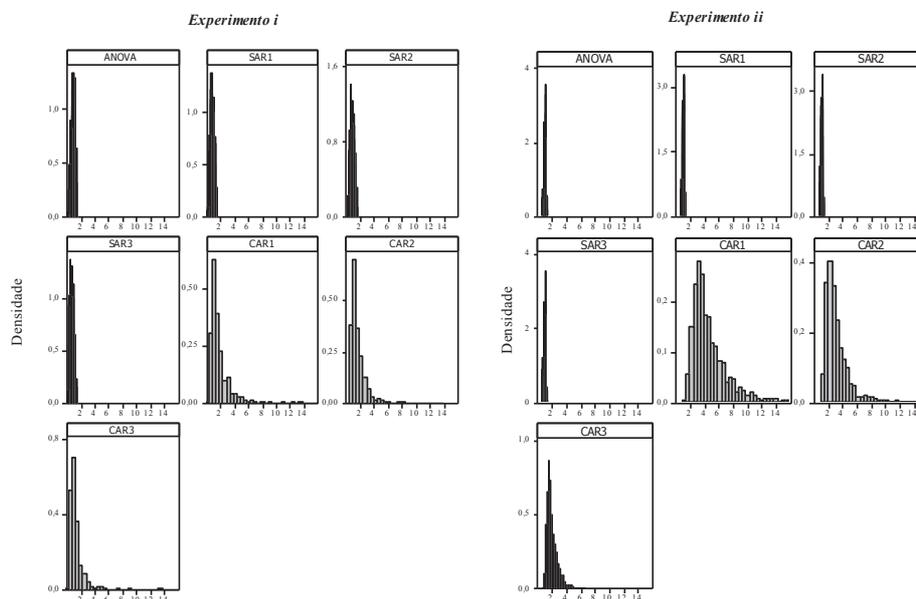


Gráfico 2 Histogramas da  $\hat{\sigma}^2$  da configuração *Gaus* (0,05-1-2) para experimento *i* e *ii* provenientes de 1000 simulações

Os intervalos de credibilidade das médias da  $\hat{\sigma}^2$  nos experimentos *i* e *ii* estão apresentados no Gráfico 3. No experimento *i* pode-se observar que não existem diferenças significativas entre os modelos autorregressivos SAR, quando comparados entre si. Contudo, quando comparados com os modelos autorregressivos CAR e a abordagem clássica ANOVA estes apresentam diferenças significativas, sendo que os modelos SAR apresentaram uma melhor na precisão do experimento em relação a abordagem autorregressiva CAR e a abordagem clássica ANOVA.

Para o caso do experimento *ii*, constata-se que não existem diferenças entre as abordagens autorregressivas SAR e ANOVA, o que pode ser explicado pelo elevado número de tratamentos envolvidos nos experimentos. Mas quando

se compara a abordagem autorregressiva SAR com a autorregressiva CAR, contata-se claramente uma diferença significativa, tendo os modelos CAR apresentado um valor maior da  $\hat{\sigma}^2$  quando comparados entre si. Assim, os modelos SAR e a análise clássica ANOVA mostraram um melhor desempenho tanto no experimento *i* quanto no *ii* ou seja, experimentos com delineamento em blocos casualizados, no que se refere a variabilidade e na redução da variância do erro experimental. No gráfico observa-se também que nos experimentos *i* e *ii* os modelos SAR de um modo geral não apresentam diferenças significativas quando comparados entre si e com a análise clássica ANOVA.

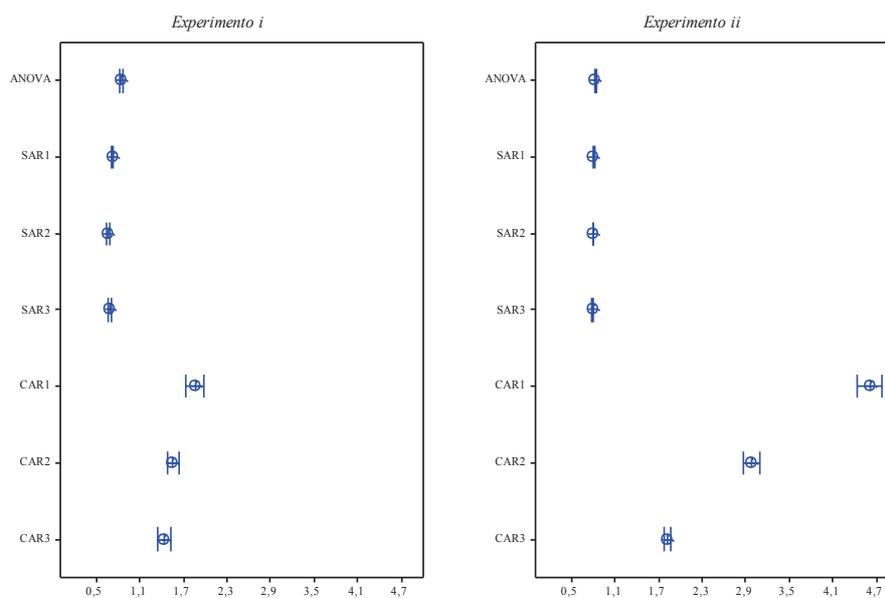


Gráfico 3 Intervalo de credibilidade das médias da  $\hat{\sigma}^2$  dos experimentos *i* e *ii* na configuração  $Gaus(0,05-1-2)$  provenientes de 1000 simulações

A abordagem utilizando modelos autorregressivos SAR possuiu uma maior precisão em relação aos restantes modelos, uma vez que os valores de  $\hat{\sigma}^2$

estimado é muito menor. Além disso, as estimativas estão mais próximas da variância utilizada na simulação ( $\hat{\sigma}^2 = 0,05$ ), indicando maior acurácia. Em relação aos valores da função quadrática  $\hat{\Phi}_t$ , estimada nada pode ser afirmado, visto que, as diferenças encontradas entre os modelos usando tanto abordagem autorregressiva, assim como, análise clássica, não mostra evidências de existência de diferenças significativas (Tabela 8 e Tabela 15).

Tabela 8 Valores médios dos parâmetros estimados de  $\sigma^2$  e  $\Phi_t$  para o experimento i e ii na configuração *Gaus(0,05-1-2)*

	Experimento i		Experimento ii	
	$\hat{\sigma}^2$	$\hat{\Phi}_t$	$\hat{\sigma}^2$	$\hat{\Phi}_t$
ANOVA	0,84	107,66	0,83	724,39
SAR1	0,72	107,93	0,81	724,51
SAR2	0,67	108,11	0,79	724,63
SAR3	0,68	108,25	0,79	724,62
CAR1	1,86	107,66	4,61	724,44
CAR2	1,56	107,58	2,98	724,75
CAR3	1,43	107,55	1,82	724,48

Os resultados encontrados para  $\hat{\sigma}^2$  nos experimentos *i* e *ii* com a configuração *Gaus(0,05-1-2)* usando modelos autorregressivos SAR, confirmam o que Duarte (2000) e Silva, Guimarães e Pedrosa (2004) verificaram quando modelaram a dependência espacial na análise dos seus experimentos, isto é, com a incorporação da dependência espacial na análise, o erro experimental tende a reduzir. O mesmo não foi verificado quando se utilizam os modelos autorregressivos CAR, o que pode estar associado à forma como foi especificado o modelo, isto é, a forma como foi determinada a matriz de proximidade e as

distâncias entre as parcelas vizinhas e também ao número de tratamentos associados ao experimento.

Os efeitos dos tratamentos de todos os modelos estudados nos experimentos *i* e *ii*. Pode-se verificar que para todos os modelos avaliados os valores-p foram estatisticamente significativos ( $p < 0,01$ ).

#### **4.2 Exemplo de delineamento em quadrado latino**

Para exemplificar a abordagem autorregressiva usando o delineamento em quadrado latino foram escolhidas duas configurações *Gaus(0,05-1-2)* do experimento *iii* e *iv*. Foi avaliada inicialmente a incorporação da dependência espacial nos modelos.

No Gráfico 4 pode-se observar que os histogramas apresentam um comportamento similar ao observado no experimento em blocos casualizados, isto é, os valores-p da estatística do teste de Wald possuem uma assimetria a direita e concentram um maior número de observações próximas do zero, sugerindo a existência de dependência espacial nos experimentos. Pode-se verificar que as o comportamento dos modelos em relação ao teste de Wald são diferentes, o que pode estar associado ao fato dos erros serem estimados de modelos diferentes.

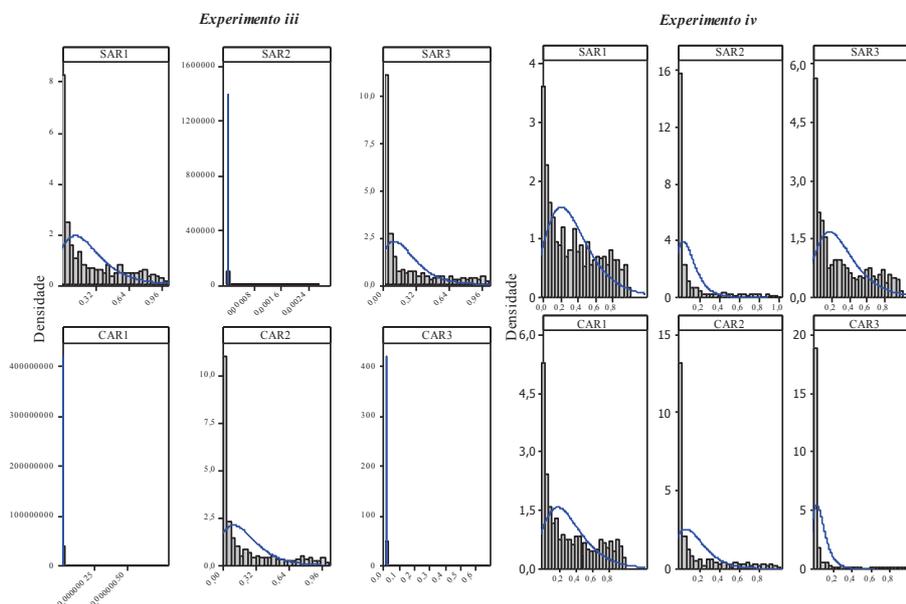


Gráfico 4 Histograma do valor-p da estatística do teste de Wald dos experimentos *iii* e *iv*, de 1000 simulações

No Gráfico 5 pode-se verificar um comportamento da variância residual estimada  $\hat{\sigma}^2$  semelhante no experimento *iii* e *iv*. Nos dois casos a análise de variância usando a abordagem clássica ANOVA e a abordagem autorregressiva SAR apresentaram melhores resultados quando comparados com a abordagem autorregressiva CAR. Este resultado pode ser observado a partir dos pequenos valores existentes da variância residual  $\hat{\sigma}^2$  estimada dos modelos ANOVA, SAR1, SAR2 e SAR3 quando comparada com os modelos CAR1, CAR2 e CAR3.

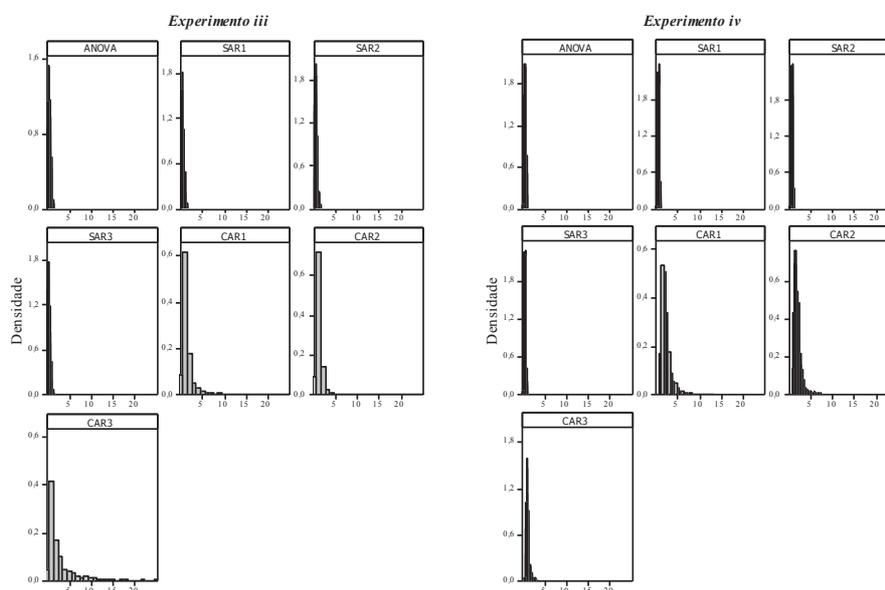


Gráfico 5 Histogramas da  $\hat{\sigma}^2$  da configuração *Gaus* (0,05-1-2) para experimento *iii* e *iv* provenientes de 1000 simulações

Os resultados observados no Gráfico 5 estão melhor ilustrados no gráfico de intervalos de credibilidade das médias de  $\hat{\sigma}^2$  (Gráfico 6). Neste Gráfico pode-se verificar que os valores de  $\hat{\sigma}^2$  para os modelos autorregressivos SAR e a ANOVA foram bem menores e apresentaram menor variabilidade que os obtidos utilizando-se os modelos autorregressivos CAR. Observa-se principalmente no experimento *iii* esse aumento na variabilidade nos modelos CAR, podendo este fato estar associado ao reduzido número de tratamentos envolvidos no experimento. Para o caso do experimento *iv*, tanto nos modelos autorregressivos SAR assim como nos modelos CAR e ANOVA, o valor da variância estimada  $\hat{\sigma}^2$  é pequeno. Contudo, apesar da variabilidade reduzida observada nos modelos CAR, esses modelos apresentam uma  $\hat{\sigma}^2$  estimada

maior quando comparados com a  $\hat{\sigma}^2$  dos modelos SAR e ANOVA, indicando menor accurácia.

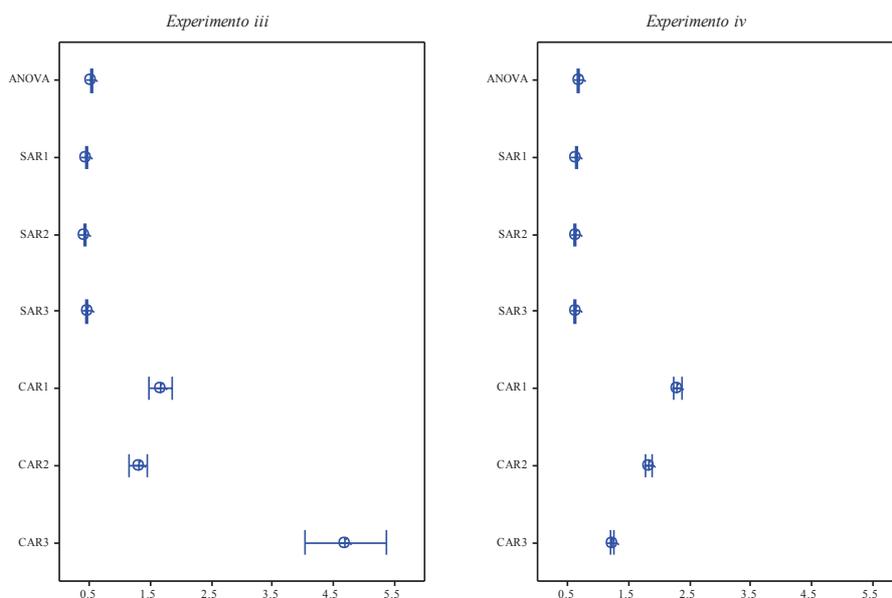


Gráfico 6 Intervalo de credibilidade das médias da variância estimada  $\hat{\sigma}^2$  dos experimentos *iii* e *iv* na configuração  $Gaus(0,05-1-2)$  proveniente de 1000 simulações

Nos experimentos *iii* e *iv*, pode-se constar também que a abordagem utilizando os modelos SAR (SAR1, SAR2 e SAR3) apresentaram valores médios da variância estimada  $\hat{\sigma}^2$  inferior aos restantes modelos utilizados, indicando desse modo maior acurácia do modelo SAR em relação as abordagens usando os modelos CAR e a análise clássica ANOVA. Em relação ao  $\hat{\Phi}_t$  foram encontrados resultados semelhantes, isto é que não apresentam diferenças significativas no que refere ao valor de  $\Phi_t$  estimado e o observado, com exceção do modelo CAR1 tanto no experimento *iii*, assim como, no experimento *iv*. O

que sugere que o modelo CAR1 não se ajustou muito bem em relação aos tratamentos.

Tabela 9 Valores médios dos parâmetros estimados de  $\sigma^2$  e  $\Phi_t$  para o experimento iii e iv na configuração *Gaus (0,05-1-2)*

	<i>Experimento iii</i>		<i>Experimento iv</i>	
	$\hat{\sigma}^2$	$\hat{\Phi}_t$	$\hat{\sigma}^2$	$\hat{\Phi}_t$
ANOVA	0,53	107,67	0,67	36,61
SAR1	0,45	108,05	0,63	36,68
SAR2	0,42	108,03	0,62	36,39
SAR3	0,45	107,86	0,62	36,98
CAR1	1,68	62,92	2,30	12,79
CAR2	1,30	108,07	1,83	36,91
CAR3	1,70	107,42	1,23	36,92

Os resultados indicam haver evidências de diferenças significativas entre as abordagens usando os modelos SAR e CAR, quando comparadas entre si. Observando o experimento *iii*, o modelo que teve um maior valor da variância estimada  $\hat{\sigma}^2$ , foi o modelo CAR da terceira ordem (CAR3). Esta grande variabilidade pode estar associada ao padrão de proximidade e ao reduzido número de tratamentos envolvidos no experimento. Apesar de existir um pequeno valor da  $\hat{\sigma}^2$  estimada nos modelos CAR, estes modelos apresentaram um desempenho relativamente baixo em relação aos modelos SAR e a ANOVA, no que diz respeito a redução do erro experimental. Portanto, as abordagens usando modelos autorregressivos SAR mostraram-se mais precisas quando comparadas com a abordagem usando modelos CAR.

De forma semelhante ao experimento utilizando o delineamento em blocos casualizados, os efeitos dos tratamentos, mostram evidências de

existência de diferenças significativas nos tratamentos para os dois experimentos apresentados ( $p < 0,05$ ). Estes corroboram os resultados de Long (1996), o qual afirma que na presença de dependência espacial pode-se inflacionar a soma dos quadrados dos tratamentos, fazendo com que pequenas diferenças existentes entre os tratamentos sejam detetadas.

#### 4.3 Estudo de outros experimentos com diferentes configurações

Procedeu-se a análise dos diferentes experimentos em blocos casualizados com diferentes configurações. Fixando o alcance em 2 e 4, e o patamar em 1, e trabalhando com valores de efeito pepita diferentes (0,05; 0,25; 0,75), obtendo-se resultados semelhantes ao já descritos nos exemplos anteriores.

No Gráfico 7 tem-se o comportamento da  $\sigma^2$  estimada nos experimentos *i* e *ii* para as diferentes configurações estudadas. Os resultados obtidos demonstram que existe uma diferença significativa na análise de variância utilizando as abordagens autorregressivas com modelos SAR e CAR. Esta diferença é mais bem ilustrada no experimento *ii* no modelo autorregressivo da primeira ordem (CAR1) nas configurações *Gaus*(0,05-1-2) e *Gaus*(0,05-1-4), o que pode ser devido à proximidade das parcelas dos experimentos, número de tratamentos e o tipo de delineamento envolvidos.

Para o caso do experimento *i*, também se pode constatar que existem diferenças entre as abordagens autorregressivas SAR e CAR, tendo a análise de variância usando modelos CAR obtido um maior valor de  $\hat{\sigma}^2$  quando comparada com a abordagem usando modelos SAR e análise de variância clássica ANOVA. Os modelos que apresentaram valores maiores de  $\hat{\sigma}^2$  foram os modelos CAR da terceira ordem (CAR3), o que pode ser devido ao fato de possuírem padrões de proximidade muito elevados (Tabela 14, Apêndice A) e

um menor número de tratamentos, uma vez que esse fato não foi constatado quando se utilizam experimentos com maior número de tratamentos, isto é, a valor de  $\hat{\sigma}^2$  é pequeno quando é envolvido um número maior de tratamentos no experimento.

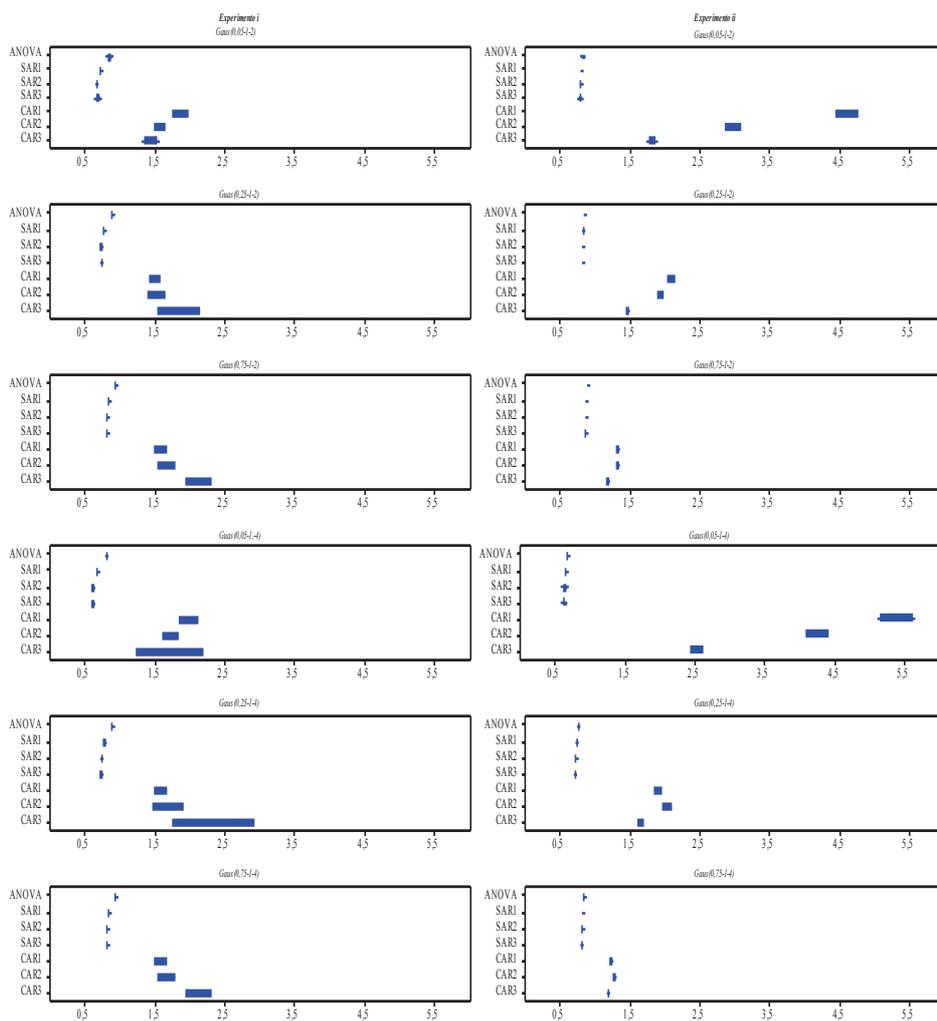


Gráfico 7 Intervalo de credibilidade de  $\sigma^2$  estimada de todos experimentos em blocos casualizados proveniente de 1000 simulações

Procedeu-se com análise dos experimentos em quadrado latino (experimento *iii* e *iv*) com as diferentes configurações, isto, é com erro de configuração gaussiana, com efeito, pepita (0,05; 0,25 e 0,75), patamar um e alcance dois e quatro.

Os resultados apresentados no Gráfico 8 mostram que existem diferenças entre as abordagens usando a análise clássica ANOVA, modelos autorregressivos SAR e CAR, tanto no experimento *iii*, assim como no experimento *iv*. Nas abordagens usando análise clássica e modelos autorregressivos SAR pode-se verificar que  $\hat{\sigma}^2$  é bastante pequena quando comparada com a abordagem usando modelos autorregressivos SAR.

No experimento *iii* comparando os modelos CAR entre si pode-se verificar que existem diferenças significativas entre os modelos das diferentes ordens, tendo se destacado o modelo CAR3 que se difere dos restantes modelos CAR, uma vez que apresentou a maior variância estimada  $\hat{\sigma}^2$ , o que pode estar associado ao fato do experimento ter um menor número de tratamentos e grau de proximidade entre elas ser elevado. Para o caso das configurações *Gaus(0,05-1-2)*, *Gaus(0,25-1-4)* e *Gaus(0,75-1-4)* os modelos CAR1 e CAR2 apresentam diferenças significativas entre si e para as restantes configurações estes dois modelos não apresentam diferenças.

Para o caso do experimento *iv* observa-se que a variância estimada  $\hat{\sigma}^2$  tanto da análise de variância usando modelos autorregressivos SAR assim como modelos autorregressivos CAR é bastante pequena, exceto na configuração *Gaus(0,05-1-2)* e *Gaus(0,05-1-4)* em que se mostram ligeiramente superiores quando comparados com os restantes modelos. Esse fato pode estar relacionado ao grau de proximidade e ao número elevado de tratamentos existentes no experimento.

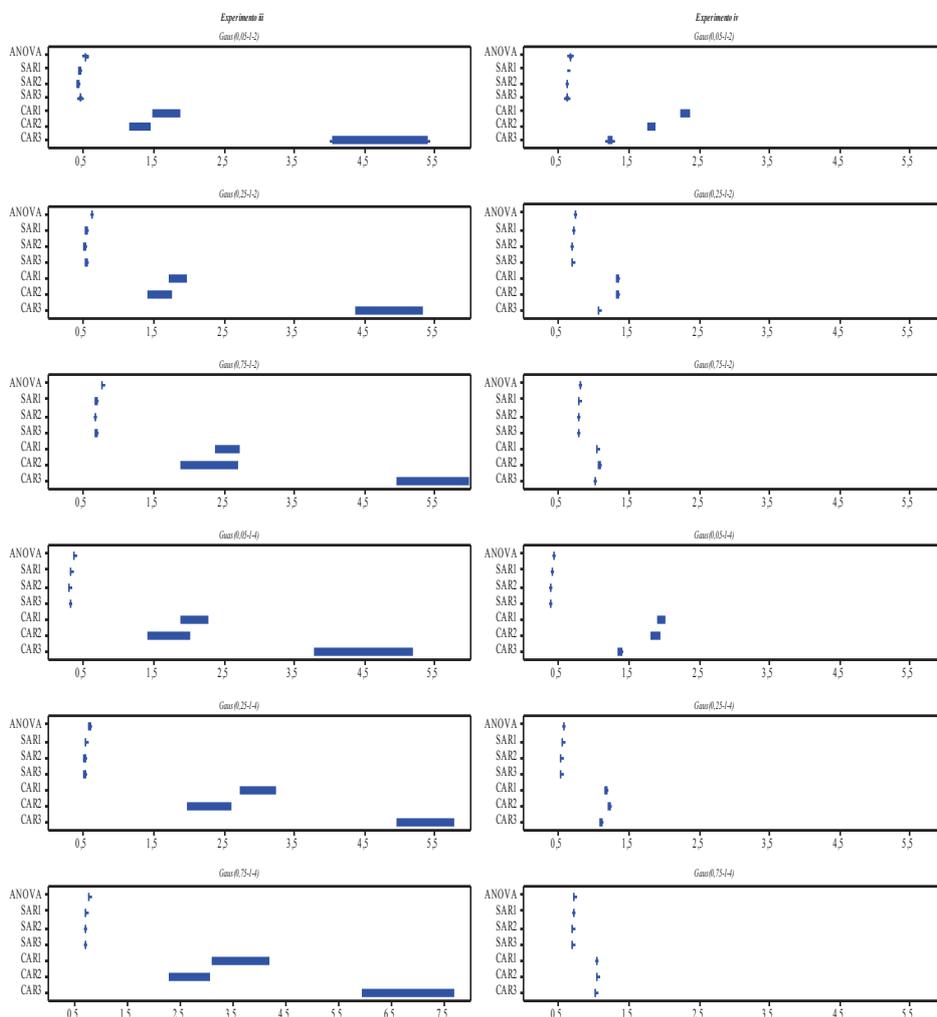


Gráfico 8 Intervalo de credibilidade de médias da  $\sigma^2$  estimada de todos experimentos em quadrado latino proveniente de 1000 simulações

Os resultados apresentados nos Gráfico 7 e Gráfico 8, mostram que a análise de variância utilizando modelos autorregressivos SAR apresentou melhores resultados em relação aos modelos autorregressivos CAR. Contudo, para Kissling e Carl (2008), o desempenho dos modelos autorregressivos SAR e CAR depende das especificações do modelo, isto é, depende de como é definido

a matriz de proximidade espacial e a distância entre as parcelas vizinhas. Verificou-se também que na maior parte das configurações apresentadas nos experimentos em análise que a abordagem autorregressiva SAR e análise clássica ANOVA não apresentam diferenças significativas, o que corrobora com Kissling e Carl (2008), que afirmam nem sempre as estimativas encontradas nos modelos autorregressivos SAR e CAR são mais precisas que as encontradas utilizando a análise clássica ANOVA.

Os resultados apresentados na Tabela 10 ilustram os intervalos de credibilidade obtidos para os valores de Akaike para o experimento *i*. Pelo critério de seleção de modelos AIC verifica-se que os resultados para as abordagens autorregressivas SAR e CAR, assim como, para análise clássica ANOVA não apresentaram melhores resultados, isto é, tanto os limites inferiores do intervalo de credibilidade, quanto os superiores, para os modelos em estudo, apresentam valores equivalentes, indiferente da configuração do erro utilizada. Este resultado também foi verificado por Rossoni (2011), quando avaliou o intervalo de credibilidade para o critério de informação do Akaike em experimentos em blocos, o que significa que devem ser considerados outros métodos para a seleção dos modelos autorregressivos.

Tabela 10 Intervalo de credibilidade para o AIC de todas as configurações do experimento i, com 95% de probabilidade

	<b><i>Gaus(0,05-1-2)</i></b>		<b><i>Gaus(0,25-1-2)</i></b>		<b><i>Gaus(0,75-1-2)</i></b>	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	42,83	72,28	45,09	72,58	49,71	72,40
SAR1	35,49	71,80	40,88	71,45	46,37	71,76
SAR2	31,17	70,62	39,39	71,54	44,95	70,88
SAR3	34,65	71,74	39,91	71,66	43,77	70,39
CAR1	44,97	99,19	45,48	93,37	43,03	90,55
CAR2	48,32	93,90	44,50	92,80	43,85	94,24
CAR3	42,92	94,79	43,83	96,98	46,52	100,36

	<b><i>Gaus(0,05-1-4)</i></b>		<b><i>Gaus(0,25-1-4)</i></b>		<b><i>Gaus(0,75-1-4)</i></b>	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	35,58	72,84	44,72	72,36	50,57	71,75
SAR1	30,22	70,92	41,76	71,59	46,91	71,46
SAR2	28,74	70,96	38,25	70,36	46,74	71,15
SAR3	27,82	70,91	39,01	71,26	45,69	71,21
CAR1	45,02	100,06	44,71	94,21	41,81	92,23
CAR2	48,98	97,65	43,44	93,92	44,38	99,76
CAR3	43,73	94,58	45,54	105,51	46,91	102,98

Os valores dos intervalos para o AIC no experimento *ii* nas configurações que possuem o alcance 2 e 4 os modelos autorregressivos não apresentaram diferenças significativas, pois pode-se observar que os intervalos de credibilidade se sobrepõe, com exceção dos modelos CAR1 e CAR2 nas configurações *Gaus(0,05-1-2)* e *Gaus(0,05-1-4)*, onde os intervalos de credibilidade não coincidem com os outros modelos autorregressivos analisados,

sugerindo que em alguns casos os modelos SAR e análise clássica ANOVA apresentaram um melhor ajuste quando comparados com os modelos CAR (Tabela 11).

Tabela 11 Intervalo de credibilidade para o AIC de todas as configurações do experimento ii, com 95% de probabilidade

	<i>Gaus(0,05-1-2)</i>		<i>Gaus(0,25-1-2)</i>		<i>Gaus(0,75-1-2)</i>	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	265,48	337,10	277,65	337,32	288,79	338,08
SAR1	264,68	337,25	275,59	337,87	285,64	335,86
SAR2	259,56	335,14	274,09	337,35	283,22	334,33
SAR3	260,85	336,83	273,03	336,09	285,95	337,25
CAR1	386,86	588,84	328,98	472,21	304,87	410,28
CAR2	344,48	545,94	319,40	475,19	302,60	410,30
CAR3	314,92	462,00	303,79	430,81	296,42	394,55

	<i>Gaus(0,05-1-4)</i>		<i>Gaus(0,25-1-4)</i>		<i>Gaus(0,75-1-4)</i>	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	198,37	334,93	229,94	339,56	265,16	339,22
SAR1	192,93	331,78	228,89	339,04	263,34	338,82
SAR2	192,05	331,73	225,91	338,45	259,35	335,68
SAR3	190,59	331,52	224,71	336,31	259,55	336,14
CAR1	377,11	627,01	310,46	477,36	301,80	403,63
CAR2	364,69	589,71	304,57	483,37	303,27	417,82
CAR3	329,18	521,73	302,37	456,61	295,20	400,17

Para os experimentos em quadrado latino foram encontrados resultados semelhantes aos resultados encontrados nos experimentos em blocos casualizados para o AIC em todas as configurações (Tabela 12 e Tabela 13).

Tabela 12 Intervalo de credibilidade para o AIC de todas as configurações do experimento iii, com 95% de probabilidade

	<b><i>Gaus(0,05-1-2)</i></b>		<b><i>Gaus(0,25-1-2)</i></b>		<b><i>Gaus(0,75-1-2)</i></b>	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	28,77	90,38	39,86	90,40	50,07	89,44
SAR1	19,74	85,22	30,82	84,79	45,73	86,82
SAR2	18,91	84,23	32,62	86,73	44,71	86,52
SAR3	21,45	84,35	34,21	88,67	46,24	88,17
CAR1	54,17	117,78	51,96	122,45	58,01	136,66
CAR2	52,64	108,44	50,98	115,83	52,36	128,88
CAR3	57,38	158,38	62,54	154,99	63,77	156,17
	<b><i>Gaus(0,05-1-4)</i></b>		<b><i>Gaus(0,25-1-4)</i></b>		<b><i>Gaus(0,75-1-4)</i></b>	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	9,78	83,37	38,21	88,84	51,18	89,85
SAR1	4,13	79,76	32,67	84,93	47,19	89,36
SAR2	4,12	78,45	33,01	84,12	47,03	88,41
SAR3	5,00	79,20	34,53	84,39	46,93	88,76
CAR1	53,82	130,25	57,59	137,61	60,67	140,42
CAR2	54,70	115,85	54,69	126,64	55,13	133,09
CAR3	56,90	153,79	62,70	157,76	64,82	162,48

Tabela 13 Tabela Intervalo de credibilidade para o AIC de todas as configurações do experimento iv, com 95% de probabilidade

	<b><i>Gaus(0,05-1-2)</i></b>		<b><i>Gaus(0,25-1-2)</i></b>		<b><i>Gaus(0,75-1-2)</i></b>	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	206,82	312,93	229,90	314,09	254,06	319,85
SAR1	201,36	309,22	224,45	310,28	248,55	314,95
SAR2	198,27	308,83	220,45	309,32	249,18	316,39
SAR3	198,29	309,99	223,07	310,67	247,17	314,44
CAR1	308,41	466,78	282,13	388,76	274,04	351,95
CAR2	290,98	436,04	278,24	390,57	279,81	356,05
CAR3	274,79	388,79	272,57	358,13	268,40	342,34

	<b><i>Gaus(0,05-1-4)</i></b>		<b><i>Gaus(0,25-1-4)</i></b>		<b><i>Gaus(0,75-1-4)</i></b>	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	101,45	304,36	171,47	315,25	222,60	315,81
SAR1	94,30	295,69	166,00	310,79	222,34	315,99
SAR2	94,01	294,49	158,42	303,90	217,74	311,26
SAR3	94,70	296,31	158,59	303,16	217,33	311,42
CAR1	296,46	461,98	268,01	369,63	271,86	351,32
CAR2	290,58	450,66	272,18	375,22	273,37	350,50
CAR3	272,12	408,56	268,56	361,51	268,79	346,15

Pode-se constatar analisando as tabelas dos intervalos de credibilidade para o AIC que os resultados encontrados não são conclusivos no que refere ao melhor ajuste dos modelos autorregressivos, isto é, os limites do intervalo de credibilidade, sugerem não existir diferenças significativas nos intervalos. Sendo assim, outros critérios como mínima autocorrelação residual e coeficiente de determinação ( $R^2$ ) devem ser utilizados para a seleção dos modelos.

## 5 CONCLUSÕES

Os resultados obtidos nesta dissertação, mostraram que o uso de modelos autorregressivos na análise de dados de experimentos com dependência espacial, torna a análise mais precisa principalmente em experimentos pequenos, uma vez que pode-se verificar que há uma diminuição da variância estimada  $\hat{\sigma}^2$  nos experimentos avaliados. Os modelos autorregressivos SAR apresentaram maior precisão e acurácia em relação aos modelos autorregressivos CAR.

Em todos os experimentos observou-se que as abordagens autorregressivas SAR e a análise clássica apresentaram um menor valor da variância estimada  $\hat{\sigma}^2$  quando comparada com a abordagem autorregressiva CAR.

A abordagem autorregressiva SAR e a análise clássica de experimentos mostraram-se ser mais precisas em relação a abordagem autorregressiva CAR, tanto em delineamento em blocos casualizados como em quadrados latinos.

A abordagem usando o modelo autorregressivo SAR mostrou ser apropriada na análise de experimentos com dependência espacial, tanto em delineamento de blocos casualizados como delineamento em quadrado latino. Porém, mais estudos precisam ser realizados, tendo em conta o tipo da estrutura espacial, isto é, a forma como as matrizes de dependência espacial é determinadas, as distâncias entre as parcelas vizinhas e o tipo de modelo a ser utilizado, uma vez que estes fatores podem influenciar no desempenho dos modelos autorregressivos.

## REFERÊNCIAS

ANSELIN, L. **Exploring spatial data with GeoDa™**: a workbook. Urbana: University of Illinois, 2005. 245 p.

\_\_\_\_\_. **Spatial econometrics**. Dallas: University of Texas, 1999. 50 p.

\_\_\_\_\_. Under the hood: issues in the specification and interpretation of spatial regression models. **Agricultural Economics**, Amsterdam, v. 27, n. 3, p. 247-267, Nov. 2002.

ASSUNÇÃO, R. M. **Estatística espacial com aplicações em epidemiologia, economia e sociologia**. São Carlos: UFSCar, 2001. 136 p.

BANZATTO, D. A.; KRONKA, S. N. **Experimentação agrícola**. 4. ed. Jaboticabal: FUNEP, 2006. 237 p.

BIVAHIND, R. et al. **Spdep**: spatial dependence: weighting schemes, statistics and models. Version 0.5-45. Madison, 2012. Software.

CÂMARA, G. et al. Análise espacial de áreas. In: DRUCK, S. et al. (Ed.). **Análise espacial de dados geográficos**. Brasília: EMBRAPA, 2004. Disponível em: <<http://www.dpi.inpe.br/gilberto/livro/analise/cap1-intro.pdf>>. Acesso em: 10 jan. 2012.

CAMBARDELLA, C. A. et al. Field-scale variability of soil properties in Central Iowa Soils. **Soil Science Society American Journal**, Madison, v. 58, n. 5, p. 1501-1511, 1994.

CLARK, I. **Practical geostatistics**. London: Applied Science, 1979. 129 p.

CLIFF, A. A. D.; ORD, J. K. **Spatial processes: models & applications**. London: Pion, 1981. 263 p.

COLLINS, K.; BABYAK, C.; MOLONEY, J. Treatment of spatial autocorrelation in Geocoded crime data. In: \_\_\_\_\_. **American Statistical Association, section on survey research methods**. Ottawa: Statistics Canada, 2006. p. 2864-2871.

CRESSIE, N. **Statistics for spatial data**. 2<sup>nd</sup> ed. New York: J. Wiley, 1993. 900 p.

DUARTE, J. B. **Sobre o emprego e a análise estatística do delineamento em blocos aumentados no melhoramento genético vegetal**. 2000. 293 p. Tese (Doutoramento em Genética e Melhoramento de Plantas) - Escola Superior de Agricultura "Luiz de Queiroz", Piracicaba, 2000.

FISHER, R. A. **The design of experiments**. London: Oliver & Boyd, 1935. 41 p.

GRIFFITH, D. A. Moran coefficient for non-normal data. **Journal of Statistical Planning and Inference**, Amsterdam, v. 140, n. 11, p. 2980-2990, Nov. 2010.

\_\_\_\_\_. Spatially adjusted ANOVA model. **Geographical Analysis**, Columbus, v. 13, p. 296-301, July 1978.

\_\_\_\_\_. Spatially adjusted N-way ANOVA model. **Regional Science and Urban Economics**, Amsterdam, v. 22, p. 347-369, Jan. 1992.

GUMPERTZ, M. L.; GRAHAM, J. M.; RISTIANO, J. B. Autologistic model of spatial pattern of phytophthora epidemic in bell pepper: effects of soil variables on disease presence. **Journal of Agricultural, Biological and Environmental Statistics**, New York, v. 2, n. 2, p. 131-156, June 1997.

ISAAKS, E. H.; SRIVASTAVA, R. M. **An introduction to applied geostatistics**. New York: Oxford University, 1989. 561 p.

KISSLING, W. D.; CARL, G. Spatial autocorrelation and the selection of simultaneous autoregressive models. **Global Ecology and Biogeography**, Oxford, v. 17, n. 1, p. 59-71, Jan. 2008.

LESAGE, J. P. **Spatial econometrics**. Columbus: University of Toledo, 1998. 273 p.

LICHSTEIN, J. W. et al. Spatial autocorrelation and autoregressive models in ecology. **Ecological Society of America**, Ithaca, v. 72, n. 3, p. 445-463, 2002.

LONG, D. S. Spatial statistics for analysis of variance of agronomic field trial. In: ARLINGHAUS, S. L. (Ed.). **Practical handbook of spatial statistics**. London: CRC, 1996. p. 181-197.

MENDIBURU, F. **Package agricolae statistical procedures for agricultural research**. Vienna: R Foundation for Statistical Computing, 2012. 141 p.

MIGON, H. S.; GAMERMAN, D. **Statistical inference: an integrated approach**. Oxford: Arnold, 1999. 261 p.

MILITINO, A. F.; UGARTE, M. D.; REINADOS, L. G. Alternative models for describing spatial dependence among dwelling prices. **Journal of Real Estate Finance and Economics**, Wageningen, v. 29, n. 2, p. 193-209, 2004.

MONTGOMERY, D. C. **Design and analysis of experiments**. 7<sup>th</sup> ed. Hoboken: J. Wiley, 2008. 656 p.

ORD, J. K. Estimation methods for models of spatial interaction. **Journal of the American Statistical Association**, Alexandria, v. 70, n. 3, p. 120-126, Nov. 1975.

PASCUAL, M. G. C. **A metodologia de análise de dados espaciais aplicadas a plantas forrageiras**. 2000. 82 p. Tese (Doutorado em Zootecnia) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

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

PLANT, R. E. **Spatial data analysis in ecology and agriculture in R**. New York: CRC, 2012. 617 p.

R DEVELOPMENT CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2012. Disponível em: <<http://www.R-project.org>>. Acesso em: 10 dez. 2012.

RESENDE, M. D. V. **Matemática e estatística na análise de experimentos e no melhoramento genético**. Colombo: EMBRAPA Florestas, 2007. 362 p.

ROSSONI, D. F. **Análise de variância para experimentos com dependência espacial**. 2011. 108 p. Dissertação (Mestrado em Estatística e Experimentação Agropecuária) - Universidade Federal de Lavras, Lavras, 2011.

SCHLATHER, M. et al. **RandonFields: simulation and analysis of random fields**. Vienna: R Foundation for Statistical Computing, 2012. 126 p.

SILVA, H. D.; GUIMARÃES, E. C.; PEDROSA, M. G. Incorporação da dependência espacial na análise de um experimento de avaliação de progênies de milho quanto à resistência à ferrugem comum. **Ciência e Agrotecnologia**, Lavras, v. 28, n. 5, p. 1144-1150, set./out. 2004.

TYSZLER, M. **Econometria espacial: discutindo medidas para a matriz de ponderação espacial**. 2006. 141 p. Dissertação (Mestrado em Zootecnia) - Fundação Getúlio Vargas, São Paulo, 2006.

WALLER, L. A.; GOTWAY, C. A. **Applied spatial statistics for public health data**. Hoboken: J. Wiley, 2004. 518 p.

YWATA, A. X. C.; ALBUQUERQUE, P. H. M. Métodos e modelos em econometria espacial: uma revisão. **Revista Brasileira de Biometria**, São Paulo, v. 29, n. 2, p. 273-306, 2011.

## APÊNDICES

## APÊNDICE A - Estimativas dos parâmetros espaciais autorregressivos

Tabela 14 Intervalo de credibilidade das estimativas de  $\rho$  e  $\lambda$  de todas as configurações dos experimentos com os respectivos padrões de proximidades

		<i>Gaus (0,05-1-2)</i>		<i>Gaus (0,25-1-2)</i>		<i>Gaus(0,75-1-2)</i>		
		<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	
<i>Experimento i</i>	$\rho$	<i>SAR1</i>	-0,112	0,131	-0,111	0,126	-0,114	0,114
		<i>SAR2</i>	-0,218	0,226	-0,199	0,225	-0,209	0,215
		<i>SAR3</i>	-0,258	0,304	-0,251	0,294	-0,286	0,257
	$\lambda$	<i>CAR1</i>	-0,212	0,979	-0,609	0,964	-0,772	0,845
		<i>CAR2</i>	-0,906	0,974	-1,319	0,948	-1,477	0,923
		<i>CAR3</i>	-1,816	0,962	-1,886	0,943	-1,952	0,917
<i>Experimento ii</i>	$\rho$	<i>SAR1</i>	-0,019	0,020	-0,017	0,022	-0,016	0,020
		<i>SAR2</i>	-0,029	0,040	-0,029	0,037	-0,026	0,034
		<i>SAR3</i>	-0,039	0,051	-0,035	0,054	-0,036	0,047
	$\lambda$	<i>CAR1</i>	0,867	0,975	0,584	0,914	0,195	0,804
		<i>CAR2</i>	0,854	0,978	0,650	0,948	0,284	0,907
		<i>CAR3</i>	0,788	0,978	0,609	0,961	0,217	0,934
<i>Experimento iii</i>	$\rho$	<i>SAR1</i>	-0,089	0,111	-0,090	0,111	-0,113	0,094
		<i>SAR2</i>	-0,195	0,215	-0,200	0,198	-0,303	0,241
		<i>SAR3</i>	-0,252	0,263	-0,269	0,251	-0,219	0,179
	$\lambda$	<i>CAR1</i>	-0,824	0,932	-0,895	0,775	-0,921	0,509
		<i>CAR2</i>	-1,298	0,954	-1,555	0,904	-1,922	0,683
		<i>CAR3</i>	-2,287	0,790	-2,332	0,638	-2,373	0,244
<i>Experimento iv</i>	$\rho$	<i>SAR1</i>	-0,051	0,123	-0,045	0,114	-0,067	0,099
		<i>SAR2</i>	-0,105	0,220	-0,100	0,213	-0,104	0,179
		<i>SAR3</i>	-0,133	0,289	-0,138	0,261	-0,173	0,202
	$\lambda$	<i>CAR1</i>	0,762	0,966	0,347	0,867	-0,084	0,694
		<i>CAR2</i>	0,756	0,969	0,464	0,901	0,018	0,786
		<i>CAR3</i>	0,625	0,972	0,213	0,918	-0,255	0,827

“Tabela 14, conclusão”

		<i>Gaus (0,05-1-4)</i>		<i>Gaus (0,25-1-4)</i>		<i>Gaus(0,75-1-4)</i>		
		<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	
<i>Experimento i</i>	$\rho$	<i>SAR1</i>	-0,110	0,137	-0,122	0,126	-0,125	0,113
		<i>SAR2</i>	-0,229	0,244	-0,199	0,225	-0,188	0,214
		<i>SAR3</i>	-0,275	0,337	-0,251	0,294	-0,284	0,259
	$\lambda$	<i>CAR1</i>	-0,544	0,982	-0,752	0,931	-0,849	0,774
		<i>CAR2</i>	-1,149	0,976	-1,474	0,961	-1,660	0,867
		<i>CAR3</i>	-1,749	0,967	-1,993	0,951	-2,023	0,890
<i>Experimento ii</i>	$\rho$	<i>SAR1</i>	-0,015	0,025	-0,019	0,023	-0,018	0,020
		<i>SAR2</i>	-0,032	0,042	-0,033	0,041	-0,034	0,030
		<i>SAR3</i>	-0,045	0,062	-0,049	0,057	-0,040	0,048
	$\lambda$	<i>CAR1</i>	0,830	0,991	0,347	0,947	-0,015	0,812
		<i>CAR2</i>	0,903	0,993	0,475	0,972	-0,003	0,904
		<i>CAR3</i>	0,926	0,994	0,560	0,986	0,099	0,946
<i>Experimento iii</i>	$\rho$	<i>SAR1</i>	-0,088	0,082	-0,093	0,087	-0,103	0,099
		<i>SAR2</i>	-0,172	0,174	-0,176	0,165	-0,225	0,164
		<i>SAR3</i>	-0,245	0,224	-0,226	0,234	-0,293	0,244
	$\lambda$	<i>CAR1</i>	-0,884	0,874	-0,931	0,572	-0,969	0,215
		<i>CAR2</i>	-1,574	0,926	-1,728	0,835	-2,020	0,439
		<i>CAR3</i>	-2,282	0,796	-2,317	0,452	-2,371	-0,039
<i>Experimento iv</i>	$\rho$	<i>SAR1</i>	-0,070	0,099	-0,112	0,192	-0,080	0,078
		<i>SAR2</i>	-0,125	0,212	-0,142	0,233	-0,116	0,161
		<i>SAR3</i>	-0,144	0,305	-0,115	0,176	-0,160	0,211
	$\lambda$	<i>CAR1</i>	0,509	0,976	-0,031	0,868	-0,346	0,610
		<i>CAR2</i>	0,646	0,988	0,121	0,922	-0,362	0,748
		<i>CAR3</i>	0,668	0,991	-0,028	0,961	-0,704	0,862

**APÊNDICE B - Intervalos de credibilidade dos parâmetros avaliados**

Tabela 15 Intervalo de credibilidade da abordagem autorregressiva para todas as configurações de alcance 2 e 4 do experimento i, com 95% de probabilidade

<b>Configuração Gaus(0,05-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_i$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	390,30	467,53	97,47	116,73	0,28	1,41
SAR1	382,65	479,15	95,50	119,65	0,17	1,28
SAR2	383,78	486,89	95,82	121,53	0,10	1,21
SAR3	375,20	494,88	93,62	123,58	0,15	1,22
CAR1	367,65	494,27	91,41	122,84	0,24	4,89
CAR2	376,28	494,75	93,60	123,03	0,23	3,60
CAR3	371,55	497,04	92,26	123,80	0,22	3,57

<b>Configuração Gaus(0,25-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_i$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	393,52	467,49	98,20	116,70	0,35	1,41
SAR1	386,00	479,64	96,28	119,69	0,27	1,31
SAR2	381,49	479,37	95,22	119,68	0,21	1,24
SAR3	375,06	484,74	93,44	120,90	0,24	1,29
CAR1	380,60	499,42	94,78	124,30	0,22	3,66
CAR2	370,17	493,14	92,64	123,02	0,29	3,69
CAR3	362,69	491,21	90,30	122,80	0,30	4,86

“Tabela 15, continuação”

<b>Configuração Gaus(0,75-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	390,84	465,60	97,49	116,16	0,44	1,39
SAR1	387,67	480,53	96,66	119,92	0,34	1,29
SAR2	385,68	480,51	96,28	119,93	0,31	1,29
SAR3	375,79	481,38	93,88	120,20	0,32	1,28
CAR1	368,92	497,89	91,96	124,21	0,26	3,01
CAR2	373,92	501,96	93,01	125,20	0,25	3,58
CAR3	362,76	504,87	90,51	125,83	0,23	5,06

<b>Configuração Gaus(0,05-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	393,54	467,32	98,14	116,65	0,16	1,37
SAR1	379,66	478,27	94,65	119,32	0,15	1,27
SAR2	375,64	482,60	93,82	120,55	0,12	1,23
SAR3	376,50	490,22	93,54	121,95	0,09	1,16
CAR1	371,97	502,80	92,56	125,40	0,23	5,36
CAR2	372,70	487,26	93,14	121,59	0,23	4,38
CAR3	375,82	493,44	93,55	122,95	0,19	3,28

“Tabela 15, conclusão”

<b>Configuração Gaus(0,25-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	394,05	467,45	98,33	116,70	0,36	1,45
SAR1	386,95	476,81	96,51	118,94	0,28	1,34
SAR2	383,39	481,76	96,00	120,61	0,21	1,26
SAR3	373,71	485,08	93,22	121,10	0,21	1,27
CAR1	374,95	499,76	93,35	124,36	0,25	3,84
CAR2	369,72	499,75	91,94	124,58	0,29	4,03
CAR3	364,74	504,38	89,17	124,65	0,21	6,52

<b>Configuração Gaus(0,75-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	393,66	468,11	98,26	116,81	0,48	1,40
SAR1	383,79	474,82	95,76	118,47	0,36	1,32
SAR2	387,34	478,97	96,61	119,46	0,36	1,31
SAR3	378,30	483,11	94,43	120,56	0,29	1,25
CAR1	368,57	501,63	91,82	125,11	0,27	3,73
CAR2	371,07	505,03	92,30	125,55	0,20	4,09
CAR3	362,27	507,45	89,54	126,13	0,29	5,98

Tabela 16 Intervalo de credibilidade da abordagem autorregressiva para todas as configurações de alcance 2 e 4 do experimento ii com 95% de probabilidade

<b>Configuração Gaus(0,05-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	4285,69	4401,00	714,16	733,35	0,56	1,08
SAR1	4285,09	4412,66	713,62	734,82	0,51	1,03
SAR2	4279,97	4417,86	713,20	736,21	0,51	1,04
SAR3	4283,28	4420,71	713,30	736,22	0,52	1,06
CAR1	4215,58	4498,53	701,76	749,06	1,29	9,83
CAR2	4225,33	4453,50	704,29	742,20	0,89	6,40
CAR3	4258,56	4438,23	709,43	739,49	0,84	3,37

<b>Configuração Gaus(0,25-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	4295,85	4406,96	715,83	734,35	0,62	1,08
SAR1	4291,24	4412,80	715,07	735,34	0,60	1,07
SAR2	4290,56	4418,03	714,97	736,19	0,59	1,06
SAR3	4285,81	4415,52	713,55	735,17	0,60	1,07
CAR1	4248,83	4452,93	707,83	741,75	0,92	3,66
CAR2	4250,89	4438,73	708,51	739,90	0,76	3,48
CAR3	4269,51	4434,99	710,79	738,63	0,73	2,49

“Tabela 16, continuação”

<b>Configuração Gaus(0,75-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	4285,92	4403,66	714,17	733,82	0,68	1,07
SAR1	4282,17	4409,88	713,52	734,80	0,67	1,06
SAR2	4281,93	4418,09	713,25	735,97	0,66	1,05
SAR3	4278,80	4415,84	712,99	735,83	0,65	1,05
CAR1	4271,80	4435,45	711,70	739,05	0,80	2,13
CAR2	4253,97	4429,89	708,57	737,95	0,76	2,10
CAR3	4267,64	4433,51	711,01	738,77	0,69	1,74

<b>Configuração Gaus(0,05-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	4296,53	4401,29	715,95	733,43	0,29	1,04
SAR1	4295,21	4409,42	715,93	734,94	0,28	1,03
SAR2	4288,94	4412,26	714,71	735,27	0,28	1,02
SAR3	4285,59	4411,83	714,18	735,21	0,28	1,03
CAR1	4199,18	4519,37	700,21	753,90	1,12	13,49
CAR2	4231,00	4491,91	702,76	746,06	1,10	9,88
CAR3	4242,55	4453,60	705,40	740,73	0,77	5,27

“Tabela 16, conclusão”

<b>Configuração Gaus(0,25-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	4298,35	4396,36	716,23	732,58	0,37	1,06
SAR1	4292,71	4402,64	715,33	733,66	0,37	1,04
SAR2	4285,40	4408,37	714,09	734,59	0,34	1,02
SAR3	4285,43	4416,01	714,16	735,89	0,34	1,01
CAR1	4262,61	4451,65	710,94	742,48	0,71	3,58
CAR2	4249,81	4445,25	708,75	741,37	0,76	4,13
CAR3	4254,67	4432,97	708,91	738,60	0,73	3,16

<b>Configuração Gaus(0,75-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	4293,07	4406,00	715,34	734,22	0,54	1,08
SAR1	4291,37	4415,80	715,10	735,84	0,52	1,06
SAR2	4285,46	4415,43	714,10	735,79	0,53	1,07
SAR3	4290,86	4423,03	715,01	737,05	0,51	1,05
CAR1	4257,46	4438,12	709,94	740,07	0,75	1,95
CAR2	4264,30	4433,58	710,17	738,47	0,69	2,06
CAR3	4271,24	4439,18	711,69	739,66	0,70	1,90

Tabela 17 Intervalo de credibilidade da abordagem autorregressiva para todas as configurações de alcance 2 e 4 do experimento iii com 95% de probabilidade

<b>Configuração Gaus(0,05-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	504,93	570,00	100,86	113,95	0,06	1,09
SAR1	485,83	596,93	97,1	119,34	0,04	0,97
SAR2	483,76	595,83	96,67	119,08	0,04	0,95
SAR3	467,15	610,92	93,06	121,86	0,05	0,95
CAR1	240,57	393,07	47,78	78,45	0,22	3,99
CAR2	487,61	593,83	97,45	118,61	0,19	2,46
CAR3	447,46	638,31	87,53	127,77	0,24	16,76

<b>Configuração Gaus(0,25-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	502,07	574,68	100,6	115,11	0,09	1,17
SAR1	483,15	589,24	96,52	117,68	0,11	1,12
SAR2	477,22	591,22	95,33	118,13	0,07	1,06
SAR3	459,97	594,31	91,86	118,78	0,08	1,08
CAR1	231,26	391,00	46,14	78,02	0,20	4,91
CAR2	472,76	609,69	94,39	121,84	0,24	3,69
CAR3	443,96	661,62	87,88	132,21	0,11	17,02

“Tabela 17, continuação”

<b>Configuração Gaus(0,75-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	501,94	582,59	100,25	116,3	0,26	1,31
SAR1	477,90	590,12	95,5	117,89	0,22	1,23
SAR2	481,58	590,31	96,2	117,92	0,18	1,16
SAR3	462,72	601,88	92,4	120,23	0,17	1,17
CAR1	240,25	399,11	47,89	79,3	0,24	8,21
CAR2	459,75	623,62	92,16	125,06	0,25	6,15
CAR3	429,12	677,22	86,08	134,91	0,27	17,01

<b>Configuração Gaus(0,05-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	510,51	568,36	102,02	113,51	0,02	0,93
SAR1	494,68	583,25	98,85	116,52	0,01	0,81
SAR2	498,12	586,12	99,54	117,15	0,02	0,76
SAR3	477,79	598,67	96,18	120,47	0,03	0,80
CAR1	220,05	409,25	43,68	81,68	0,19	5,95
CAR2	481,08	601,83	95,94	120,17	0,18	3,71
CAR3	441,83	639,67	86,91	127,53	0,16	14,86

“Tabela 17, conclusão”

<b>Configuração Gaus(0,25-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	505,48	575,65	101,38	115,41	0,10	1,11
SAR1	489,37	584,24	97,41	116,36	0,08	1,04
SAR2	492,26	589,02	98,22	117,58	0,11	1,03
SAR3	460,91	602,65	93,46	121,84	0,10	1,02
CAR1	227,85	410,23	44,2	81,07	0,19	8,93
CAR2	471,02	619,86	93,76	124,22	0,17	5,42
CAR3	431,15	687,19	82,84	133,48	0,22	18,73

<b>Configuração Gaus(0,75-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	497,64	575,01	99,45	114,88	0,24	1,30
SAR1	489,33	593,81	97,49	118,41	0,22	1,24
SAR2	478,70	582,41	95,59	116,31	0,23	1,24
SAR3	473,49	605,77	94,55	120,91	0,19	1,21
CAR1	241,15	404,99	48,19	80,45	0,24	9,54
CAR2	463,26	624,85	91,05	123,56	0,23	7,19
CAR3	408,37	661,98	82,25	132,1	0,27	23,31

Tabela 18 Intervalo de credibilidade da abordagem autorregressiva para todas as configurações de alcance 2 e 4 do experimento iv com 95% de probabilidade

<b>Configuração Gaus(0,05-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	346,29	385,41	34,58	38,48	0,34	1,01
SAR1	345,33	398,31	34,52	39,80	0,34	0,99
SAR2	345,78	398,15	34,51	39,76	0,30	0,96
SAR3	338,17	398,51	33,71	39,76	0,30	0,95
CAR1	84,61	170,47	8,46	17,11	0,90	4,54
CAR2	332,95	418,19	32,96	41,47	0,77	3,34
CAR3	329,60	407,17	33,03	40,78	0,63	2,06

<b>Configuração Gaus(0,25-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	346,60	389,03	34,58	38,82	0,45	1,05
SAR1	345,94	397,63	34,54	39,71	0,41	0,99
SAR2	344,78	395,63	34,39	39,51	0,40	0,98
SAR3	344,55	400,02	34,39	39,97	0,41	0,99
CAR1	94,19	169,77	9,23	16,79	0,70	2,11
CAR2	333,64	410,37	33,25	40,92	0,62	2,13
CAR3	336,18	405,71	33,52	40,44	0,65	1,56

“Tabela 18, continuação”

<b>Configuração Gaus(0,75-1-2)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	344,70	387,71	34,63	39,20	0,47	1,05
SAR1	341,58	392,58	34,26	39,54	0,46	1,02
SAR2	343,04	395,00	34,44	39,66	0,46	1,02
SAR3	343,29	402,02	34,07	39,66	0,47	1,02
CAR1	97,78	170,00	9,43	16,75	0,69	1,65
CAR2	333,72	403,42	33,19	40,73	0,66	1,70
CAR3	330,45	405,73	33,66	40,95	0,64	1,44

<b>Configuração Gaus(0,05-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	350,65	382,96	35,01	38,24	0,10	0,87
SAR1	350,55	392,69	35,02	39,21	0,07	0,80
SAR2	349,68	392,83	34,99	39,30	0,07	0,76
SAR3	347,54	399,34	34,70	39,92	0,08	0,77
CAR1	89,80	190,41	8,64	18,72	0,64	3,96
CAR2	330,83	415,48	33,16	41,61	0,74	3,89
CAR3	331,94	407,53	33,04	40,60	0,61	2,50

“Tabela 18, conclusão”

<b>Configuração Gaus(0,25-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	347,76	385,47	34,68	38,44	0,18	0,93
SAR1	347,46	391,24	34,68	39,05	0,20	0,93
SAR2	346,39	389,46	34,59	38,90	0,20	0,92
SAR3	344,57	396,03	34,42	39,54	0,17	0,88
CAR1	92,06	183,91	9,07	18,28	0,66	1,83
CAR2	336,47	404,92	33,55	40,40	0,68	1,92
CAR3	338,31	407,40	33,73	40,62	0,65	1,67

<b>Configuração Gaus(0,75-1-4)</b>						
	<i>QMT</i>		$\hat{\Phi}_t$		$\hat{\sigma}^2$	
	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>	<i>Inf.</i>	<i>Sup.</i>
ANOVA	348,70	391,33	34,63	39,20	0,39	1,03
SAR1	346,07	393,56	34,26	39,54	0,37	0,99
SAR2	343,31	391,50	34,44	39,66	0,37	0,98
SAR3	344,97	399,26	34,07	39,66	0,39	1,01
CAR1	94,69	173,57	9,43	16,75	0,66	1,47
CAR2	333,39	403,56	33,19	40,73	0,66	1,46
CAR3	338,57	409,95	33,66	40,95	0,67	1,45

## APÊNDICE C - Script da simulação dos experimentos

### Simulação para experimento em blocos completos

#### 1. Carregando as bibliotecas a serem utilizadas no processo de simulação

```
rm(list=ls())
library(agricolae)
library(geoR)
library(MASS)
library(spdep)
```

#### 2. Estabelecendo número de simulações a serem utilizadas

```
n<-1000 ## simulation number
```

#### 3. Criação de data.frames que irão receber os resultados da simulação

```
AIC<-data.frame(AIC_Model1=rep(0,n),AIC_Model2=rep(0,n),
AIC_Model3=rep(0,n),AIC_Model4=rep(0,n),AIC_Model5=rep(0,n),AIC_Model6=rep(0,n), AIC_Model7=rep(0,n))
QME< data.frame(QME1=rep(0,n),QME2=rep(0,n),
QME3=rep(0,n),QME4=rep(0,n),QME5=rep(0,n), QME6=rep(0,n),
QME7=rep(0,n))
QMB<-data.frame(QMB1=rep(0,n),QMB2=rep(0,n),QMB3=rep(0,n),
QMB4=rep(0,n),QMB5=rep(0,n),QMB6=rep(0,n),QMB7=rep(0,n))
QMT<-data.frame(QMT1=rep(0,n),QMT2=rep(0,n),QMT3=rep(0,n),
QMT4=rep(0,n),QMT5=rep(0,n),QMT6=rep(0,n),QMT7=rep(0,n))
Rhoest<-data.frame(Rho1=rep(0,n),Rho2=rep(0,n),Rho3=rep(0,n))
lambda<-data.frame(lambda1=rep(0,n),lambda2=rep(0,n),lambda3=rep(0,n))
Wald.out<-NULL
Wald1.out<-NULL
Wald2.out<-NULL
Wald3.out<-NULL
Wald4.out<-NULL
Wald5.out<-NULL
for(k in 1:n)
{
```

#### 4. Simulação do arranjo do delineamento

```
trat<-c(1:5)
dados <-design.rcbd(trat, 4, first=TRUE)
rm(trat)
#class(dados) # print field book.
dados$y<-rep(0,5)
#dados$y
eftrat<-c(105,110,120,125,130)
#eftrat
efbloco<-c(108,113,118,123)
#efbloco
```

#### 5. Simulando dados com erro dependente

```
for (i in 1:5)
  for (j in 1:4)
    dados$y[dados$trat==i & dados$block==j]<-
      dados$y[dados$trat==i & dados$block==j] + eftrat[i] + efbloco[j]
# dados
dep<-grf(20, grid="reg",ny=4, nx=5,xlims = c(0,4), ylims = c(0,3), nugget =
0.75, method="RF", RF=TRUE, cov.model="gaus",cov.pars=c(1,2),
messages=F)
###Configuração Gaus(0.75-1-2)
dep_pad<-(dep$data -mean(dep$data))/sqrt(var(dep$data))
```

#### 6. Gerando dados com dependência espacial incluindo a média

```
dados$y<-dados$y+275+dep_pad
dep$data<-dados$y
#dep$data
#points(dep)
+++++
+++++MODELO SAR DE 1ª ORDEM (SAR1)+++++
```

#### 7. Criação de coordenadas e matriz de proximidade espacial

```
coords<-dep$coords
nb_dados<-dnearneigh(coords,0,1)
# raio de tamanho 1 unidade de medida
w<-nb2mat(nb_dados, style="W",zero.policy=F)
#plot(nb_dados, coords)
```

```
listw<-nb2listw(nb_dados, glist=NULL, style="W",zero.policy=FALSE)
```

#### 8. Estimaco dos parmetros do modelo SAR

```
attach(dados, warn.conflicts=F)
#dados
SAR<-lagsarlm(y~trat+block, dados, listw, method="eigen",
quiet=T,tol.solve=1e-15)
ajuste<-summary(SAR)
rho<-ajuste["rho"]
rho<-rho[[1]][[1]]
```

#### 9. Extrairdo estatísticas do teste de Wald

```
Wald<-matrix(c(ajuste$Wald1$statistic, ajuste$Wald1$p.value),nrow=1)
#Wald
+++++Ajuste de dados+++++
beta<-mean(dados[,4])
Y_ajus<-dados[,4]-(rho*w%*%dados[,4]-rho*beta)
#Y_ajus
d.ajus<-dados
d.ajus$y<-Y_ajus
#d.ajus
#dados
+++++
+++++MODELO CAR DE 1ª ORDEM (CAR1)+++++
```

#### 10. Estimaco dos parmetros do Modelo CAR1

```
#attach(dados)
#dados
CAR1<-errorsarlm(y~trat+block, dados, listw,
method="eigen",quiet=T,tol.solve=1e-15)
ajuste1<-summary(CAR1)
#ajuste1
lambda1<-ajuste1$lambda[[1]]
#lambda1
```

#### 11. Extrairdo estatísticas do teste de Wald

```
Wald1<-matrix(c(ajuste1$Wald1$statistic, ajuste1$Wald1$p.value),nrow=1)
#Wald1
```

```

+++++Ajuste de dados+++++
X<-model.matrix(y~1+trat+block, data=dados)
beta<-ajuste1$coefficients
n<-20
e<-rnorm(n,0,1);
u=solve(diag(n)-lambda1*w)%*%e
Y_ajusCAR1<-X%*%beta+u
d.ajusCAR1<-dados
d.ajusCAR1$y<-Y_ajusCAR1
#d.ajusCAR1

```

### 12. Comparação entre Modelo Clássico e Autorregressivo (ANOVA vs SARI CAR1)

```

reg<-lm(y~factor(trat)+factor(block), dados)
#summary(reg)
aov<-anova(reg) #; aov ###Análise clássica (ANOVA)
#attach(d.ajus)
reg_dep<-lm(y~factor(trat)+factor(block), d.ajus)
#summary(reg_dep)
aovd<-anova(reg_dep) #; aovd ### Análise autorregressiva SARI
rhoest<-sum(aov[[2]])-sum(aovd[[2]]) #;rhoest
#attach(d.ajusCAR1)
reg_dep4<-lm(y~factor(trat)+factor(block), d.ajusCAR1)
#summary(reg_dep4)
aovdCAR1<-anova(reg_dep4) #; aovdCAR1 ##Análise autorregressiva CAR1
+++++
+++++MODELO SAR DE 2ª ORDEM (SAR2)+++++
nb_dados2<-dnearneigh(coords,0,sqrt(2))
# raio de tamanho raiz de 2 unidade de medida
w<-nb2mat(nb_dados2, style="W",zero.policy=F)
#plot(nb_dados2, coords)
listw2<-nb2listw(nb_dados2, glist=NULL, style="W",zero.policy=FALSE)

```

### 13. Estimação dos parâmetros do modelo SAR2

```

#attach(dados)
#dados

```

```

SAR<-lagsarlm(y~trat+block, dados, listw2,
method="eigen",quiet=T,tol.solve=1e-15)
ajuste2<-summary(SAR)
rho2<-ajuste2["rho"]
rho2<-rho2[[1]][1]
Wald2<-matrix(c(ajuste2$Wald1$statistic, ajuste2$Wald1$p.value),nrow=1)
#Wald2
+++++Ajuste de dados+++++
beta<-mean(dados[,4])
Y_ajus2<-dados[,4]-(rho2*w%*%dados[,4]-rho2*beta)
d.ajus2<-dados
d.ajus2$y<-Y_ajus2
#d.ajus2
#dados

+++++MODELO CAR DE 2ª ORDEM (CAR2)+++++
14. Estimação dos parâmetros do Modelo CAR2
#attach(dados)
#dados
CAR2<-errorsarlm(y~trat+block, dados, listw2,
method="eigen",quiet=T,tol.solve=1e-15)
ajuste3<-summary(CAR2)
lambda2<-ajuste3$lambda[[1]]
#lambda2
Wald3<-matrix(c(ajuste3$Wald1$statistic, ajuste3$Wald1$p.value),nrow=1)
#Wald3
+++++Ajuste de dados+++++
#str(dados)
X<-model.matrix(y~1+trat+block, data=dados)
beta2<-ajuste3$coefficients
n<-20
e<-rnorm(n,0,1);
u=solve(diag(n)-lambda2*w%*%e
Y_ajusCAR2<-X%*%beta2+u
d.ajusCAR2<-dados
d.ajusCAR2$y<-Y_ajusCAR2

```

```
#d.ajusCAR2
```

*15. Comparação entre Modelo Clássico e Autorregressivo (ANOVA vs SAR2 vs CAR2*

```
#attach(dados)
reg2<-lm(y~factor(trat)+factor(block), dados)
#summary(reg2)
aov2<-anova(reg2) #; aov2 ### ANOVA
#attach(d.ajus2)
reg_dep2<-lm(y~factor(trat)+factor(block), d.ajus2)
#summary(reg_dep2)
aovd2<-anova(reg_dep2) #; aovd2 ### SAR2
rhoest2<-sum(aov2[[2]])-sum(aovd2[[2]]) #;rhoest2
#attach(d.ajusCAR2)
reg_dep5<-lm(y~factor(trat)+factor(block), d.ajusCAR2)
#summary(reg_dep5)
aovdCAR2<-anova(reg_dep5) #; aovdCAR2 #CAR2
+++++
+++++MODELO SAR DE 3ª ORDEM (SAR3)+++++
nb_dados3<-dnearneigh(coords,0,2)
# raio de tamanho 2 unidade de medida
w<-nb2mat(nb_dados3, style="W",zero.policy=F)
#plot(nb_dados3, coords)
listw3<-nb2listw(nb_dados3, glist=NULL, style="W",zero.policy=FALSE)
```

*16. Estimação dos parâmetros do Modelo SAR3*

```
SAR<-lagsarlm(y~trat+block, dados, listw3,
method="eigen",quiet=T,tol.solve=1e-15)
ajuste4<-summary(SAR)
rho3<-ajuste4["rho"]
rho3<-rho3[[1]][[1]]
Wald4<-matrix(c(ajuste4$Wald1$statistic, ajuste4$Wald1$p.value),nrow=1)
#Wald4
+++++ Ajuste de dados+++++
beta<-mean(dados[,4])
Y_ajus3<-dados[,4]-(rho3*w%*%dados[,4]-rho3*beta)
d.ajus3<-dados
```

```

d.ajus3$y<-Y_ajus3
#d.ajus3
#dados
+++++
+++++MODELO CAR DE 3ª ORDEM (CAR3)+++++
17. Estimação dos parâmetros do Modelo CAR3
#attach(dados)
CAR3<-errorsarlm(y~trat+block, dados, listw3,
method="eigen",quiet=T,tol.solve=1e-15)
ajuste5<-summary(CAR3)
lambda3<-ajuste5$lambda[[1]]
#lambda3
Wald5<-matrix(c(ajuste1$Wald1$statistic, ajuste1$Wald1$P.value),nrow=1)
#Wald5
+++++Ajuste de dados+++++
X<-model.matrix(y~1+trat+block, data=dados)
beta3<-ajuste5$coefficients
n<-20
e<-rnorm(n,0,1);
u=solve(diag(n)-lambda3*w)%*%e
Y_ajusCAR3<-X%*%beta3+u
d.ajusCAR3<-dados
d.ajusCAR3$y<-Y_ajusCAR3
#d.ajusCAR3

```

*18. Comparação entre Modelo Clássico e Autorregressivo(ANOVA vs SAR3 vs CAR3*

```

reg3<-lm(y~factor(trat)+factor(block), dados)
#summary(reg3)
aov3<-anova(reg3) #; aov3 ###clássica
reg_dep3<-lm(y~factor(trat)+factor(block), d.ajus3)
#summary(reg_dep3)
aovd3<-anova(reg_dep3) #; aovd3 ###AR
rhoest3<-sum(aov3[[2]])-sum(aovd3[[2]]) #;rhoest3
#attach(d.ajusCAR3)
reg_dep6<-lm(y~factor(trat)+factor(block), d.ajusCAR3)
#summary(reg_dep6)

```

```
aovdCAR3<-anova(reg_dep6) #; aovdCAR3 ###CAR3
```

```
AIC[k,]<-c(AIC(reg),AIC(reg_dep), AIC(reg_dep2),AIC(reg_dep3),
AIC(reg_dep4),AIC(reg_dep5),AIC(reg_dep6))
QMT[k,]<-c(QMT1=aov[1,2]/aov[1,1],
QMT2=aovd[1,2]/aovd[1,1],QMT3=aovd2[1,2]/aovd2[1,1],
QMT4=aovd3[1,2]/aovd3[1,1],QMT5=aovdCAR1[1,2]/aovdCAR1[1,1],QMT6
=aovdCAR2[1,2]/aovdCAR2[1,1], QMT7=aovdCAR3[1,2]/aovdCAR3[1,1])
```

```
QMB[k,]<-c(QMB1=aov[2,2]/aov[2,1],
QMB2=aovd[2,2]/aovd[2,1],QMB3=aovd2[2,2]/aovd2[2,1],
QMB4=aovd3[2,2]/aovd3[2,1],QMB5=aovdCAR1[2,2]/aovdCAR1[2,1],QMB6
=aovdCAR2[2,2]/aovdCAR2[2,1], QMB7=aovdCAR3[2,2]/aovdCAR3[2,1])
```

```
QME[k,]<-c(QME1=aov[3,2]/aov[3,1],
QME2=aovd[3,2]/aovd[3,1],QME3=aovd2[3,2]/aovd2[3,1],
QME4=aovd3[3,2]/aovd3[3,1],QME5=aovdCAR1[3,2]/aovdCAR1[3,1],QME6
=aovdCAR2[3,2]/aovdCAR2[3,1], QME7=aovdCAR3[3,2]/aovdCAR3[3,1])
```

```
Rhoest[k,]<-c(rhoest,rhoest2,rhoest3)
```

```
lambda[k,]<-c(lambda1,lambda2,lambda3)
```

```
Wald.out<-rbind(Wald.out, matrix(c(ajuste$Wald1$Statistic,
ajuste$Wald1$p.value),nrow=1))
```

```
Wald1.out<-rbind(Wald1.out, matrix(c(ajuste1$Wald1$Statistic,
ajuste1$Wald1$p.value),nrow=1))
```

```
Wald2.out<-rbind(Wald2.out, matrix(c(ajuste2$Wald1$Statistic,
ajuste2$Wald1$p.value),nrow=1))
```

```
Wald3.out<-rbind(Wald3.out, matrix(c(ajuste3$Wald1$Statistic,
ajuste3$Wald1$p.value),nrow=1))
```

```
Wald4.out<-rbind(Wald4.out, matrix(c(ajuste4$Wald1$Statistic,
ajuste4$Wald1$p.value),nrow=1))
```

```
Wald5.out<-rbind(Wald5.out, matrix(c(ajuste5$Wald1$Statistic,
ajuste5$Wald1$p.value),nrow=1))
```

```
detach(dados)
```

```
}
```

```
write.table(Wald.out,file="075W11.CSV",sep=";",dec=",")
```

```
write.table(Wald1.out,file="075W12.CSV",sep=";",dec=",")
```

```

write.table(Wald2.out,file="075W13.CSV",sep=";",dec=",")
write.table(Wald3.out,file="075W14.CSV",sep=";",dec=",")
write.table(Wald4.out,file="075W15.CSV",sep=";",dec=",")
write.table(Wald5.out,file="075W16.CSV",sep=";",dec=",")
write.table(dados,file="075dados1.CSV",sep=";",dec=",")
write.table(QMT,file="075QMT54.CSV",sep=";",dec=",")
write.table(QMB,file="075QMB54.CSV",sep=";",dec=",")
write.table(QME,file="075QME54.CSV",sep=";",dec=",")
write.table(AIC,file="075AIC54.CSV",sep=";",dec=",")
write.table(Rhoest,file="075Rhoest54.CSV",sep=";",dec=",")
write.table(lambda,file="075lambda54.CSV", sep=";", dec=",")

```

### **Simulação para experimento em quadrado latino**

#### *1. Carregando as bibliotecas a serem utilizadas no processo de simulação*

```

rm(list=ls())
library(agricolae)
library(geoR)
library(MASS)
library(spdep)

```

#### *2. Estabelecendo número de simulações a serem utilizadas*

```
n<-1000 ## simulation number
```

#### *3. Criação de data.frames que irão receber os resultados da simulação*

```

AIC<-
data.frame(AIC_Model1=rep(0,n),AIC_Model2=rep(0,n),AIC_Model3=rep(0,n)
, AIC_Model4=rep(0,n), AIC_Model5=rep(0,n), AIC_Model6=rep(0,n),
AIC_Model7=rep(0,n))
QME<-data.frame(QME1=rep(0,n),QME2=rep(0,n),QME3=rep(0,n),
QME4=rep(0,n),QME5=rep(0,n), QME6=rep(0,n), QME7=rep(0,n))
QML<-data.frame(QML1=rep(0,n),QML2=rep(0,n),QML3=rep(0,n),
QML4=rep(0,n),QML5=rep(0,n),QML6=rep(0,n),QML7=rep(0,n))
QMC<-data.frame(QMC1=rep(0,n),QMC2=rep(0,n),QMC3=rep(0,n),
QMC4=rep(0,n),QMC5=rep(0,n),QMC6=rep(0,n),QMC7=rep(0,n))
QMT<-data.frame(QMT1=rep(0,n),QMT2=rep(0,n),QMT3=rep(0,n),
QMT4=rep(0,n),QMT5=rep(0,n),QMT6=rep(0,n),QMT7=rep(0,n))

```

```

Rhoest<-data.frame(Rho1=rep(0,n),Rho2=rep(0,n),Rho3=rep(0,n))
lambda<-data.frame(lambda1=rep(0,n),lambda2=rep(0,n),lambda3=rep(0,n))
Wald.out<-NULL
Wald1.out<-NULL
Wald2.out<-NULL
Wald3.out<-NULL
Wald4.out<-NULL
Wald5.out<-NULL

```

```

for(k in 1:n)
{
  4. Simulação do arranjo do delineamento
  trat<-c(1:10)
  # dados <-design.lsd(trat,seed=23)
  dados <-design.lsd(trat,first=T)
  #dados
  #class(dados) # print field book.
  dados$y<-0
  #eftrat
  eftrat<-c(105,107,109,111,113,115,117,119,121,123)
  #eflinha
  eflinha<-c(106,108,110,112,114,116,118,120,124,126)
  #efcoluna
  efcoluna<-c(98,100,102,104,106,108,110,102,104,106)

```

```

for (i in 1:100)
  dados$y[i]<-eftrat[dados$trat[i]] + eflinha[dados$row[i]] +
  efcoluna[dados$col[i]]

```

```

5. Simulando dados com erro dependente
dep<-grf(100, grid="reg",ny=10, nx=10,xlims = c(0,9), ylims = c(0,9),nugget =
0.05, method="RF", RF=TRUE, cov.model="gaus",cov.pars=c(1,2),
messages=F)

```

```

6. Gerando dados com dependência especial incluindo a média
# configuração Gaus(0.05-1-2)
dep_pad<-(dep$data -mean(dep$data))/sqrt(var(dep$data))

```

```

dados$y<-dados$y+335+dep_pad
dep$data<-dados$y
#dep$data
#points(dep)
coords<-dep$coords
#coords
+++++
+++++MODELO SAR DE 1ª ORDEM (SAR1)+++++
7. Criação de coordenadas e matriz de proximidade espacial
nb_dados<-dnearneigh(coords,0,1)
# raio de tamanho 1 unidade de medida

w<-nb2mat(nb_dados, style="W",zero.policy=F)
#plot(nb_dados, coords)
listw<-nb2listw(nb_dados, glist=NULL, style="W",zero.policy=FALSE)

8. Estimação dos parâmetros do modelo SAR
attach(dados, warn.conflicts=F)
#dados
SAR<-lagsarlm(y~trat+row+col, dados, listw,
method="eigen",quiet=T,tol.solve=1e-15)
ajuste<-summary(SAR)
#ajuste
rho<-ajuste["rho"]
rho<-rho[[1]][[1]]

9. Extrair estatísticas do teste de Wald
Wald<-matrix(c(ajuste$Wald1$statistic, ajuste$Wald1$p.value),nrow=1)
#Wald
beta<-mean(dados[,5])
Y_ajus<-dados[,5]-(rho*w%*%dados[,5]-rho*beta)
d.ajus<-dados
d.ajus$y<-Y_ajus
#d.ajus
#dados
+++++

```

```

+++++++MODELO CAR DE 1ª ORDEM (CAR1)+++++++
10. Estimação dos parâmetros do Modelo CAR1
#attach(dados)
#dados
CAR1<-errorsarlm(y~trat+row+col, dados, listw,
method="Matrix",quiet=T,tol.solve=1e-15)
ajuste1<-summary(CAR1)
lambda1<-ajuste1$lambda[[1]]
#lambda1

11. Extraindo estatísticas do teste de Wald
Wald1<-matrix(c(ajuste1$Wald1$statistic, ajuste1$Wald1$p.value),nrow=1)
#Wald1
+++++++Ajuste de dados+++++++
X<-model.matrix(y~col+row+trat, data=dados)
beta<-ajuste$coefficients
#beta
n<-100
e<-rnorm(n,0,1);
u=solve(diag(n)-lambda1*w)%*%e
Y_ajusCAR1<-X%*%beta+u
d.ajusCAR1<-dados
d.ajusCAR1$y<-Y_ajusCAR1
d.ajusCAR1

12. Comparação entre Modelo Clássico e Autorregressivo (ANOVA vs SARI
CAR1)
reg<-lm(y~factor(trat)+factor(row)+factor(col), dados)
#summary(reg)
aov<-anova(reg); #aov ###CLÁSSICA
#attach(d.ajus)
reg_dep<-lm(y~factor(trat)+factor(row)+factor(col), d.ajus)
#summary(reg_dep)
aovd<-anova(reg_dep); #aovd ###SARI
rhoest<-sum(aov[[2]])-sum(aovd[[2]]) #;rhoest
#attach(d.ajusCAR1)
reg_dep4<-lm(y~factor(trat)+factor(row)+factor(col), d.ajusCAR1)

```

```

#summary(reg_dep)
aovdCAR1<-anova(reg_dep4) #; aovdCAR1 ###CAR1

+++++
+++++MODELO SAR DE 2ª ORDEM (SAR2)+++++
nb_dados2<-dnearneigh(coords,0,sqrt(2))
# raio de tamanho raiz de 2 unidade de medida
w<-nb2mat(nb_dados2, style="W",zero.policy=F)
#plot(nb_dados2, coords)
listw2<-nb2listw(nb_dados2, glist=NULL, style="W",zero.policy=FALSE)
#attach(dados)
#dados
SAR<-lagsarlm(y~trat+row+col, dados, listw2,
method="eigen",quiet=T,tol.solve=1e-15)
ajuste2<-summary(SAR)
#ajuste2
rho2<-ajuste2["rho"]
rho2<-rho2[[1]][[1]]

```

### 13. Extraindo estatísticas do teste de Wald

```

Wald2<-matrix(c(ajuste2$Wald1$statistic, ajuste2$Wald1$p.value),nrow=1)
#Wald2
+++++ Ajuste de dados+++++
beta<-mean(dados[,5])
Y_ajus2<-dados[,5]-(rho2*w%*%dados[,5]-rho2*beta)
d.ajus2<-dados
d.ajus2$y<-Y_ajus2
#d.ajus2
#dados

```

```

+++++
+++++MODELO SAR DE 2ª ORDEM (SAR2)+++++

```

### 14. Estimaco dos parmetros do Modelos CAR2

```

#attach(dados)
#dados
CAR2<-errorsarlm(y~trat+row+col, dados, listw2,
method="eigen",quiet=T,tol.solve=1e-15)
ajuste3<-summary(CAR2)

```

```

lambda2<-ajuste3$lambda[[1]]
#lambda2
Wald3<-matrix(c(ajuste3$Wald1$statistic, ajuste3$Wald1$p.value),nrow=1)
#Wald3
+++++Ajuste de dados+++++
#str(dados)
X<-model.matrix(y~1+trat+row+col, data=dados)
beta2<-ajuste$coefficients
n<-100
e<-rnorm(n,0,1);
u=solve(diag(n)-lambda2*w)%*%e
Y_ajusCAR2<-X%*%beta2+u
d.ajusCAR2<-dados
d.ajusCAR2$y<-Y_ajusCAR2
#d.ajusCAR2

```

### 15. Comparação entre Modelo Clássico e Autorregressivo (ANOVA vs SAR2 vs CAR2)

```

#attach(dados)
reg2<-lm(y~factor(trat)+factor(row)+factor(col), dados)
#summary(reg2)
aov2<-anova(reg2) #; aov2 ###clássica
#attach(d.ajus2)
reg_dep2<-lm(y~factor(trat)+factor(row)+factor(col), d.ajus2)
#summary(reg_dep2)
aovd2<-anova(reg_dep2); aovd2 ###AR
rhoest2<-sum(aov2[[2]])-sum(aovd2[[2]]) #;rhoest2
####Calculando o índice de Moran
moran2<-lm.morantest(reg_dep2,listw2)
#attach(d.ajusCAR2)
reg_dep5<-lm(y~factor(trat)+factor(row)+factor(col), d.ajusCAR2)
#summary(reg_dep5)
aovdCAR2<-anova(reg_dep5) #; aovdCAR2 ###CAR2
####Calculando o índice de Moran
moran5<-lm.morantest(reg_dep5,listw2)

```

```
+++++
```

```

+++++++MODELO SAR DE 3ª ORDEM (SAR3)+++++++
nb_dados3<-dnearneigh(coords,0,2)
# raio de tamanho raiz de 2 unidade de medida
w<-nb2mat(nb_dados3, style="W",zero.policy=F)
#plot(nb_dados3, coords)
listw3<-nb2listw(nb_dados3, glist=NULL, style="W",zero.policy=FALSE)

```

#### 16. Estimação dos parâmetros do modelo SAR3

```

#attach(dados)
#dados
SAR<-lagsarlm(y~trat+row+col, dados, listw3,
method="eigen",quiet=T,tol.solve=1e-15)
ajuste4<-summary(SAR)
#ajuste4
rho3<-ajuste4["rho"]
rho3<-rho3[[1]][1]
Wald4<-matrix(c(ajuste4$Wald1$statistic, ajuste4$Wald1$p.value),nrow=1)
#Wald4
+++++++ Ajuste de dados+++++++
beta<-mean(dados[,5])
Y_ajus3<-dados[,5]-(rho3*w%*%dados[,5]-rho3*beta)
d.ajus3<-dados
d.ajus3$y<-Y_ajus3
#d.ajus3
#dados

```

#### 17. Estimação dos parâmetros do modelo CAR3

```

#attach(dados)
#dados
CAR3<-errorsarlm(y~trat+row+col, dados, listw3,
method="eigen",quiet=T,tol.solve=1e-15)
ajuste5<-summary(CAR3)
lambda3<-ajuste5$lambda[[1]]
#lambda3
Wald5<-matrix(c(ajuste5$Wald1$statistic, ajuste5$Wald1$p.value),nrow=1)
#Wald5
+++++++ Ajuste de dados+++++++

```

```

X<-model.matrix(y~1+trat+row+col, data=dados)
beta3<-ajuste$coefficients
n<-100
e<-rnorm(n,0,1);
u=solve(diag(n)-lambda3*w)%*%e
Y_ajusCAR3<-X%*%beta3+u
d.ajusCAR3<-dados
d.ajusCAR3$y<-Y_ajusCAR3
#d.ajusCAR3

```

### 18. Comparação entre Modelo Clássico e Autorregressivo (ANOVA vs SAR3 vs CAR3)

```

#attach(dados)
reg3<-lm(y~factor(trat)+factor(row)+factor(col), dados)
#summary(reg3)
aov3<-anova(reg3) #; aov3 ###clássica
#attach(d.ajus3)
reg_dep3<-lm(y~factor(trat)+factor(row)+factor(col), d.ajus3)
#summary(reg_dep3)
aovd3<-anova(reg_dep3); #aovd3 ###AR
rhoest3<-sum(aov3[[2]])-sum(aovd3[[2]]);rhoest3
#attach(d.ajusCAR3)
reg_dep6<-lm(y~factor(trat)+factor(row)+factor(col), d.ajusCAR3)
summary(reg_dep6)
aovdCAR3<-anova(reg_dep6); aovdCAR3 ###CAR3
AIC[k,]<-c(AIC(reg),AIC(reg_dep), AIC(reg_dep2),AIC(reg_dep3),
AIC(reg_dep4),AIC(reg_dep5),AIC(reg_dep6))
QMT[k,]<-c(QMT1=aov[1,2]/aov[1,1],
QMT2=aovd[1,2]/aovd[1,1],QMT3=aovd2[1,2]/aovd2[1,1],
QMT4=aovd3[1,2]/aovd3[1,1],QMT5=aovdCAR1[1,2]/aovdCAR1[1,1],QMT6
=aovdCAR2[1,2]/aovdCAR2[1,1], QMT7=aovdCAR3[1,2]/aovdCAR3[1,1])
QML[k,]<-c(QML1=aov[2,2]/aov[2,1],
QML2=aovd[2,2]/aovd[2,1],QML3=aovd2[2,2]/aovd2[2,1],
QML4=aovd3[2,2]/aovd3[2,1],QML5=aovdCAR1[2,2]/aovdCAR1[2,1],QML6
=aovdCAR2[2,2]/aovdCAR2[2,1], QML7=aovdCAR3[2,2]/aovdCAR3[2,1])
QMC[k,]<-c(QMC1=aov[3,2]/aov[3,1],
QMC2=aovd[3,2]/aovd[3,1],QMC3=aovd2[3,2]/aovd2[3,1],

```

```

QMC4=aovd3[3,2]/aovd3[3,1],QMC5=aovdCAR1[3,2]/aovdCAR1[3,1],QMC6
=aovdCAR2[3,2]/aovdCAR2[3,1], QMC7=aovdCAR3[3,2]/aovdCAR3[3,1])
  QME[k,]<-c(QME1=aov[4,2]/aov[4,1],
QME2=aovd[4,2]/aovd[4,1],QME3=aovd2[4,2]/aovd2[4,1],
QME4=aovd3[4,2]/aovd3[4,1],QME5=aovdCAR1[4,2]/aovdCAR1[4,1],QME6
=aovdCAR2[4,2]/aovdCAR2[4,1], QME7=aovdCAR3[4,2]/aovdCAR3[4,1])
Rhoest[k,]<-c(rhoest,rhoest2,rhoest3)
lambda[k,]<-c(lambda1,lambda2,lambda3)
Wald.out<-rbind(Wald.out, matrix(c(ajuste$Wald1$Statistic,
ajuste$Wald1$p.value),nrow=1))
Wald1.out<-rbind(Wald1.out, matrix(c(ajuste1$Wald1$Statistic,
ajuste1$Wald1$p.value),nrow=1))
Wald2.out<-rbind(Wald2.out, matrix(c(ajuste2$Wald1$Statistic,
ajuste2$Wald1$p.value),nrow=1))
Wald3.out<-rbind(Wald3.out, matrix(c(ajuste3$Wald1$Statistic,
ajuste3$Wald1$p.value),nrow=1))
Wald4.out<-rbind(Wald4.out, matrix(c(ajuste4$Wald1$Statistic,
ajuste4$Wald1$p.value),nrow=1))
Wald5.out<-rbind(Wald5.out, matrix(c(ajuste5$Wald1$Statistic,
ajuste5$Wald1$p.value),nrow=1))
detach(dados)

}

write.table(dados,file="005dados13.CSV",sep=";",dec=",")
write.table(QMC,file="005QMCSAR13.CSV",sep=";",dec=",")
write.table(QMT,file="005QMTSAR13.CSV",sep=";",dec=",")
write.table(QML,file="005QMLSAR13.CSV",sep=";",dec=",")
write.table(QME,file="005QMESAR13.CSV",sep=";",dec=",")
write.table(AIC,file="005AICSAR13.CSV",sep=";",dec=",")
write.table(Rhoest,file="005RhoestSAR13.CSV",sep=";",dec=",")
write.table(lambda,file="005lambdaSAR13.CSV", sep=";", dec=",")

```