



SÉRGIO DOMINGOS SIMÃO

**APLICAÇÃO DA TEORIA DE MODELOS MISTOS A DADOS
LONGITUDINAIS**

**LAVRAS - MG
2016**

SÉRGIO DOMINGOS SIMÃO

**APLICAÇÃO DA TEORIA DE MODELOS MISTOS A DADOS
LONGITUDINAIS**

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

Dr. Renato Ribeiro de Lima

Coorientadora

Dra. Izabela Regina Cardoso de Oliveira

**LAVRAS - MG
2016**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha
Catalográfica da Biblioteca Universitária da UFLA, com dados informados
pelo(a) próprio(a) autor(a).**

Simão, Sérgio Domingos.

Aplicação da teoria de modelos mistos a dados longitudinais/
Sérgio Domingos Simão. - Lavras: UFLA, 2016.
130 p.: il.

Dissertação (mestrado acadêmico) – Universidade Federal de
Lavras, 2016.

Orientador: Renato Ribeiro de Lima.
Bibliografia.

1. Modelos lineares mistos. 2. Medidas repetidas. 3. Parcela
subdividida no tempo. I. Universidade Federal de Lavras. II.
Título.

SÉRGIO DOMINGOS SIMÃO

**APLICAÇÃO DA TEORIA DE MODELOS
MISTOS A DADOS LONGITUDINAIS**

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 15 de setembro de 2016.

Prof. Dr. Júlio Sílvio de Sousa Bueno Filho	UFLA
Prof. Dr. Rogério Amaro Gonçalves	IFMG

Prof. Dr. Renato Ribeiro de Lima
Orientador

**LAVRAS - MG
2016**

*À minha família,
meus amigos,
que me ajudaram na hora em que precisei.
DEDICO*

AGRADECIMENTOS

Primeiramente a Deus pela oportunidade de ter a chance de continuar a estudar.

À Universidade Federal de Lavras, especialmente ao Departamento de Ciência Exatas, pela oportunidade.

À Capes, pela concessão da bolsa de mestrado.

Ao professor Renato Ribeiro de Lima, pela orientação, paciência e disposição para ajudar.

À professora Izabela Regina Cardoso de Oliveira, pela coorientação e apoio na condução da dissertação.

Aos professores Rogério Amaro Gonçalves e Júlio Sílvio de Sousa Bueno Filho por participarem da banca de defesa de dissertação.

Aos professores do IFMG Campus Bambuí Adriano Geraldo, Luiz Machado, Silvana Lúcia dos Santos Medeiros, e aos funcionários da escola pelo apoio e ajuda no tempo de graduação.

A todos funcionários do DEX/UFLA.

A todos os colegas de departamento, pois muitos se tornaram amigos!

Quero agradecer aos amigos e companheiros do departamento que fizeram parte dessa caminhada: Tatiane de Carvalho Alvarenga, Carlos Pereira da Silva, Henrique José de Paula Alves, Ernandes Guedes de Moura, Andrezza Kellen Alves Pamplona, Carolina Bicalho, Leila Maria Ferreira, Érica Pereira, Cristian Tiago Mendes, Fernando Ribeiro, Marcos Antônio Isaac Júnior, Joel Nuvunga, Rogério Romão, Andrezza Rosane, Michele Barbosa, Kelly Lima, Charles Felipe, André Luís, Paulo César, Jackelya Araujo da Silva, Janaína Marques, Sidcleide Barbosa e Peter de Matos.

Aos meus pais, José Domingos Simão Neto e Maria de Fátima de Sousa Simão pelo amor e apoio incondicional, em todas as minhas decisões nas diferentes etapas da minha vida e ao meu irmão Sinval Aparecido Simão e a minha cunhada Bruna Moreira e ao pequeno João Lucas meu sobrinho querido.

À Taís Alvarenga, pelo companheirismo, amor, apoio em todos os momentos e singular torcida.

RESUMO

O presente trabalho tem como objetivo elaborar um material descrevendo detalhadamente a análise de dados longitudinais usando modelos lineares mistos e abordando análise de resíduos. Foram feitas a análise exploratória dos dados, a comparação de diferentes estruturas de variância-covariância e a comparação dos resultados de parcela subdividida no tempo com a análise de modelos mistos em dados longitudinais. As análises estatísticas foram realizadas com uso do programa estatístico R e também com o programa estatístico SAS (*Statistical Analysis System*). A escolha da melhor estrutura de variância-covariância foi feita com base no critério de informação de Akaike (AIC) e no critério Bayesiano de Schwarz (BIC). As variáveis usadas para ilustração das análises foram: consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$) e peso da gema (gramas). Para a variável consumo médio de ração a estrutura de covariância escolhida foi a não estruturada, enquanto que para a variável peso da gema utilizou-se uma estrutura autorregressiva de primeira ordem (AR(1)). Esse manual é útil para pesquisadores, professores e estudantes de áreas aplicadas, para realizar a análise de dados longitudinais usando modelos lineares mistos considerando, diferentes estruturas de covariâncias e contemplando a análise de resíduos. A escolha da estrutura de covariâncias afetou a significância dos testes F dos efeitos fixos para a variável consumo médio de ração. Para a variável peso da gema a escolha da estrutura não afetou a significância dos testes F. A análise de resíduos foi importante na verificação das pressuposições do modelo e as características gerais dos dados.

Palavras-chave: Medidas repetidas, parcela subdividida, estruturas de covariância, análise de resíduos.

ABSTRACT

This study aims to develop a material describing in detail the analysis of longitudinal data using linear mixed models and addressing waste analysis. We performed an exploratory analysis of the data, the comparison of different structures of variance-covariance and comparison of share of results subdivided in time with the analysis of mixed models for longitudinal data. Statistical analyzes were carried out using the statistical program R and with the SAS statistical software. The choice of the best covariance structure will performed considering the Akaike information criterion (AIC) and Bayesian criterion Schwarz (BIC). The variables used for illustration of the analysis were: average feed intake ($\text{g.bird}^{-1}.\text{day}^{-1}$) and yolk weight (grams). For the variable average feed intake was chosen covariance structure unstructured, while for the variable yolk weight used a first-order autoregressive structure (AR (1)). This manual is useful for researchers, teachers and students of applied fields, to perform the analysis of longitudinal data using linear mixed models considering different covariance structures and contemplating the residuals analysis. The choice of covariance structure affected the significance of the F test of fixed effects for the variable average feed intake. For the variable yolk weight the choice of the structure did not affect the significance of the F test. The residuals analysis was important in the verification of the assumptions of the model and the general characteristics of the data.

Keywords: Repeated measures, split-plot, covariance structures, residual analysis.

LISTA DE FIGURAS

Figura 1-	Diposição dos dados na planilha do <i>Microsoft Excel</i> . . .	33
Figura 2-	Disposição dos dados em formato.txt.	34
Figura 3-	Consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$) de poedeiras com idade de 29 a 40 semanas nas diferentes dietas experimentais.	37
Figura 4-	Perfis individuais das parcelas experimentais em cada tratamento para o consumo médio de ração.	38
Figura 5-	<i>Boxplots</i> da variável consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$) durante o período 12 semanas nos diferentes tratamentos testados.	39
Figura 6-	Covariância residual em função das distâncias entre os pares de observações com a estrutura UN para a variável consumo médio de ração.	74
Figura 7-	Resíduos padronizados <i>versus</i> valores preditos para a variável consumo médio de ração.	76
Figura 8-	Valores ajustados dos resíduos padronizados para a variável consumo médio de ração nas diferentes dietas testadas.	77
Figura 9-	<i>Boxplots</i> dos resíduos para a variável consumo médio de ração.	78
Figura 10-	<i>QQ plots</i> da normal para a variável consumo médio de ração.	79
Figura 11-	Gráfico quantil-quantil da normal para a variável consumo médio de ração.	80
Figura 12-	Transformação Box-Cox da variável consumo médio de ração.	81
Figura 13-	Peso da gema em diferentes épocas de avaliação de poedeiras com idade de 29 a 40 semanas para os quatros tratamentos.	82
Figura 14-	Perfis individuais das parcelas experimentais em cada dieta para o peso da gema (g).	83
Figura 15-	<i>Boxplots</i> da variável peso da gema (g) ao longo das diferentes épocas de avaliação para os diferentes tratamentos.	83
Figura 16-	Covariância residual em função das distâncias entre os pares de observações com a estrutura UN para a variável peso da gema.	93

Figura 17-Resíduos padronizados <i>versus</i> valores ajustados para a variável peso da gema.	94
Figura 18-Valores ajustados dos resíduos padronizados para a va- riável peso da gema nas diferentes dietas testadas. . . .	95
Figura 19- <i>Boxplots</i> dos resíduos para a variável peso da gema. . . .	95
Figura 20- <i>QQ plots</i> da normal para a variável peso da gema. . . .	96
Figura 21-Gráfico quantil-quantil da normal para a variável peso da gema.	97

LISTA DE TABELAS

Tabela 1-	Valores do critério de Akaike (AIC) e do critério Bayesiano (BIC) para cada estrutura de variância-covariância para a variável consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$).	49
Tabela 2-	Valores do número de parâmetros (Npar), critério de Akaike (AIC), critério de Akaike corrigido (AICC), critério Bayesiano (BIC) e o $-2 \text{ Res Log Likelihood}$ para cada estrutura de variância-covariância para a variável consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$).	57
Tabela 3-	Estimativas das médias e erros-padrões da média para os tratamentos considerando diferentes estruturas de covariâncias para a variável consumo médio de ração.	64
Tabela 4-	Valores do número de parâmetros (Npar), critério de Akaike (AIC) e do critério Bayesiano (BIC) para cada estrutura de variância-covariância para a variável peso da gema.	84
Tabela 5-	Valores do critério de Akaike (AIC), critério de Akaike corrigido (AICC), critério Bayesiano (BIC) e o $-2 \text{ Res Log Likelihood}$ para cada estrutura de variância-covariância para a variável peso da gema (g).	86
Tabela 6-	Valores da estatística do teste de razão de verossimilhanças (TRV) da estrutura de variância-covariância AR(1) com as demais estruturas de covariâncias para a variável peso da gema (g).	87
Tabela 7-	Médias e erros-padrões da média para os tratamentos considerando diferentes estruturas de covariâncias para a variável peso da gema.	88

SUMÁRIO

1	INTRODUÇÃO	13
2	REVISÃO BIBLIOGRÁFICA	15
2.1	Medidas repetidas	15
2.1.1	Dados longitudinais	16
2.1.2	Parcela subdividida no tempo	17
2.2	Modelos lineares mistos	18
2.2.1	Inferência sobre os efeitos fixos	20
2.2.2	Estruturas das matrizes de covariâncias	21
2.3	Análise de resíduos em dados longitudinais	25
2.4	Transformação Box-Cox	26
3	MATERIAL E MÉTODOS	28
3.1	Material	28
3.2	Métodos	29
4	RESULTADOS E DISCUSSÃO	32
4.1	Variável consumo médio de ração	36
4.1.1	Análise exploratória da variável consumo médio de ração	36
4.1.2	Função <i>gls</i> para a variável consumo médio de ração.	40
4.1.3	Modelos lineares mistos com o procedimento <i>mixed</i> para a variável consumo médio de ração	51

4.1.4	Análise de variância da variável consumo médio de ração em esquema de parcela subdividida no tempo com a função <i>aov</i> .	64
4.1.5	Modelos lineares mistos com a função <i>lmer</i> para a variável consumo médio de ração	66
4.1.6	Análise gráfica das estruturas de covariância para a variável consumo médio de ração	70
4.1.7	Análise de resíduos para a variável consumo médio de ração.	75
4.2	Variável peso da gema	82
4.2.1	Análise exploratória da variável peso da gema	82
4.2.2	Função <i>gls</i> para a variável peso da gema.	84
4.2.3	Procedimento <i>mixed</i> para a variável peso da gema	86
4.2.4	Análise de variância da variável peso da gema em esquema de parcela subdividida no tempo com a função <i>aov</i>	88
4.2.5	Modelos lineares mistos com a função <i>lmer</i> para a variável peso da gema	89
4.2.6	Análise gráfica das estruturas de covariância para a variável peso da gema	91
4.2.7	Análise de resíduos para a variável peso da gema.	93
5	CONCLUSÕES	98
	REFERÊNCIAS.	99
	APÊNDICE.	104

1 INTRODUÇÃO

Nas diversas áreas de pesquisa, a coleta de dados correlacionados é muito comum. De acordo com Molenberghs e Verbeke (2005), utiliza-se este termo num sentido genérico e para a melhor compreensão das diversas estruturas como observações multivariadas, dados agrupados, medidas repetidas e dados longitudinais.

Quando a mesma característica é medida várias vezes ao longo do tempo e o próprio tempo é, pelo menos em parte, um tema de investigação científica, têm-se os denominados dados longitudinais, considerados um caso particular de medidas repetidas no tempo.

Na área de Ciências Agrárias é muito comum a utilização da Análise de Variância (ANAVA) em esquema de parcela subdividida no tempo para análise de dados longitudinais, devido a fatores como a facilidade de análise e de interpretação dos resultados (FREITAS et al., 2008). Porém, no caso dos dados longitudinais, como as observações são realizadas na mesma unidade experimental pode existir correlação entre diferentes observações, o que não é considerado nas análises em esquema de parcela subdividida no tempo. Assim, esse tipo de análise pode não ser adequado.

A ANAVA em esquema de parcela subdividida não considera as possíveis correlações entre medidas obtidas em diferentes tempos. Portanto, existem riscos em usar erros-padrões incorretos para a comparação de médias em diferentes tempos de avaliação (LITTELL; HENRY; AMMERMAN, 1998).

Com isso o modelo linear misto torna-se uma opção na modelagem de dados longitudinais. Pinheiro e Bates (2000) destacam que os mesmos tem flexibilidade na análise de dados balanceados e desbalanceados e na estimação dos componentes de variância. Além disso, a escolha correta da estrutura da matriz de covariâncias influencia as inferências estatísticas realizadas nos experimentos, pois permite modelar tanto a correlação entre as observações nos diferentes tempos avaliados quanto a heterogeneidade de variâncias.

A necessidade de se elaborar um material voltado para a análise de dados longitudinais é remanescente. Por isso, o presente trabalho tem como

objetivo principal elaborar um material, que seja útil para pesquisadores, professores e estudantes de áreas aplicadas, descrevendo detalhadamente a análise de dados longitudinais usando modelos lineares mistos e abordando a análise de resíduos. Os objetivos específicos do presente estudo são os seguintes:

- Elucidar os conceitos estatísticos envolvidos na análise de dados longitudinais em modelos mistos;
- Ensinar, realizar e discutir a análise exploratória de dados longitudinais;
- Ensinar, realizar e discutir a análise de resíduos de dados longitudinais;
- Ensinar e realizar comparações entre os resultados em esquema de parcela subdividida no tempo com a análise de modelos lineares mistos em dados longitudinais.

2 REVISÃO BIBLIOGRÁFICA

2.1 Medidas repetidas

Os experimentos com medidas repetidas envolvem a realização de duas ou mais observações na mesma unidade experimental ou parcela em estudo. Esses experimentos podem ser longitudinais, como por exemplo experimentos em parcelas subdivididas (*split-plot*) no tempo e experimentos do tipo *crossover* (SINGER; NOBRE; ROCHA, 2015).

Os dados longitudinais são um caso particular de medidas repetidas, em que se avalia o comportamento da unidade experimental em estudo ao longo do tempo. Sendo assim, uma característica dos dados longitudinais é a ausência de independência entre as observações, pois as mesmas são feitas na mesma unidade experimental ou indivíduo. Outra característica é a heterogeneidade de variâncias ao longo do tempo nas unidades experimentais (ALCARDE, 2012; SINGER; NOBRE; ROCHA, 2015).

Para todos os experimentos físicos existem incertezas que devem ser reduzidas por técnicas melhoradas e repetições. O erro experimental expressa o grau de confiança que temos no nosso resultado. Em geral, chamamos de discrepância a diferença entre o valor medido e um valor de referência. Por isso, quando a correlação dos erros é ignorada, as inferências podem ou não serem distorcidas, conforme o grau de homogeneidade ou heterogeneidade das variâncias dos dados nos diferentes tempos estudados (GILL, 1986).

Os experimentos com medidas repetidas, quando analisados sob o enfoque de parcela subdividida, violam duas pressuposições: a falta de casualização entre os tratamentos e as épocas de avaliação (tempo) e a dependência de erros, pelo fato de as medidas serem tomadas sobre as mesmas unidades experimentais ao longo do tempo, ocasionando a correlação entre os dados, sendo em geral essas correlações maiores para tempos mais próximos (REZENDE et al., 1999; ROSÁRIO, 2003).

2.1.1 Dados longitudinais

Dados longitudinais são aqueles em que a variável resposta é medida repetidamente, na mesma parcela, indivíduo, animal ou plantas, em tempos diferentes. Por isso, as observações no indivíduo ao longo do tempo não são independentes umas das outras, podendo ocorrer correlações entre as mensurações feitas em cada unidade experimental e isso deve ser levado em consideração na análise (TWISK, 2003).

Nas diversas áreas do conhecimento como Ciências Agrárias, Biológicas e Médicas é muito comum a ocorrência de dados longitudinais. Várias são as referências sobre a análise desses dados podendo citar: Diggle et al. (2002), Verbeke e Molenberghs (2000), Molenberghs e Verbeke (2005) e West, Welch e Gatecki (2015).

Especificamente em Ciências Agrárias, Silva, Duarte e Reis (2015) avaliaram diferentes estruturas para a matriz de variâncias e covariâncias residual, quanto ao ajuste via modelos lineares mistos em experimentos varietais de cana-de-açúcar. Em cada modelagem, variou-se ainda a suposição associada aos efeitos de tratamentos (variedades), como fixos e aleatórios. Os autores concluíram que a estrutura de erros independentes, em geral, não se mostra adequada para esse tipo de análise, também não é seguro definir previamente uma matriz de covariância específica e que houve pequenas alterações nos testes F ao se assumirem os efeitos de tratamentos como fixos ou aleatórios.

De acordo com Kowalchuk et al. (2004), realizar a modelagem da estrutura de covariância é uma importante consideração para os pesquisadores das áreas aplicadas, porque ocorre um aumento da precisão das estimativas e que a estrutura de covariância geralmente traduz-se em um aumento no poder estatístico para detectar os efeitos de tratamento.

De acordo com Fitzmaurice et al. (2008), os dados longitudinais têm uma longa história de estudos principalmente, quando se refere ao uso de parcelas subdivididas, no caso univariado de medidas repetidas.

2.1.2 Parcela subdividida no tempo

O modelo estatístico para o esquema em parcela subdividida no tempo em experimentos inteiramente ao acaso (DIC) é dado por (HINKELMANN; KEMPTHORNE, 2008):

$$y_{ijk} = \mu + \alpha_i + \beta_{k(i)} + \gamma_j + \alpha\gamma_{ij} + \epsilon_{ijk}, \quad (1)$$

em que:

y_{ijk} é o valor observado para a variável resposta do i -ésimo tratamento no j -ésimo tempo e na k -ésima repetição, com $i=1,2,3,\dots,I$, $j=1,2,3,\dots,J$ e $k=1,2,3,\dots,K$;

μ é uma constante inerente a cada observação;

α_i é o efeito do i -ésimo nível do tratamento;

$\beta_{k(i)}$ é o efeito do erro experimental a nível de parcela;

γ_j é o efeito do j -ésimo tempo;

$\alpha\gamma_{ij}$ é o efeito da interação tratamento \times tempo;

ϵ_{ijk} é o erro experimental a nível de subparcelas.

As suposições do modelo descrito em (1) é que a constante μ e os efeitos α_i , γ_j e $\alpha\gamma_{ij}$ são considerados fixos e os erros $\beta_{k(i)}$ e ϵ_{ijk} são considerados aleatórios, normais e independentemente distribuídos com médias nulas e variâncias comuns σ_β^2 e σ_ϵ^2 , respectivamente.

O modelo estatístico para o esquema em parcela subdividida no tempo de experimentos em blocos casualizados (DBC) é dado por (HINKELMANN; KEMPTHORNE, 2008):

$$y_{ijk} = \mu + \delta_k + \alpha_i + \alpha\delta_{ik} + \gamma_j + \gamma\delta_{jk} + \alpha\gamma_{ij} + \epsilon_{ijk}, \quad (2)$$

em que:

y_{ijk} é o valor observado para a variável resposta do i -ésimo tratamento no j -ésimo tempo e no k -ésimo bloco, com $i=1,2,3,\dots,I$, $j=1,2,3,\dots,J$ e $k=1,2,3,\dots,K$;

μ é uma constante inerente a cada observação;

δ_k é o efeito do k -ésimo bloco;

α_i é o efeito do i -ésimo nível do tratamento;

$\alpha\delta_{ik}$ é erro experimental a nível de parcela (interação bloco \times tratamento);

γ_j é o efeito do j -ésimo tempo;

$\delta\gamma_{kj}$ é o efeito da interação bloco \times tempo (erro experimental);

$\alpha\gamma_{ij}$ é o efeito da interação tratamento \times tempo;

ϵ_{ijk} é o erro experimental a nível de subparcelas.

As suposições do modelo descrito em (2) são que a constante μ e os efeitos δ_k , α_i , γ_j e $\alpha\gamma_{ij}$ são considerados fixos, os efeitos dos erros $\alpha\delta_{ik}$, $\delta\gamma_{kj}$ e ϵ_{ijk} são considerados aleatórios, normais e independentemente distribuídos com médias nulas e variâncias comuns σ_δ^2 , $\sigma_{\alpha\delta}^2$, $\sigma_{\delta\gamma}^2$ e σ_ϵ^2 , respectivamente.

Quando se tem o esquema de parcela subdividida no tempo, uma abordagem muito utilizada nesse contexto é a análise de perfis, em que o perfil individual de resposta (*Individual Response Profile*) é a representação da variável resposta ao longo das diferentes épocas de avaliação (tempo) observadas.

De acordo com Barbosa (2009), a análise univariada dos perfis, nem sempre é recomendada para análise de medidas repetidas, pois pressupõe que a matriz de covariância seja do tipo uniforme (simetria composta), ou seja, com variâncias iguais nas diversas épocas de avaliação e covariâncias iguais entre duas épocas de avaliação quaisquer.

2.2 Modelos lineares mistos

Os modelos lineares nos parâmetros possuem pelo menos um efeito aleatório designado por erro experimental. Se o modelo apresenta todos os demais efeitos fixos, ele é denominado de modelo fixo. Quando o modelo

linear apresenta, além do erro experimental, outros efeitos aleatórios e também outros efeitos fixos, além da média, é denominado de modelo linear misto (SEARLE; CASELLA; MCCULLOCH, 1992).

Os efeitos aleatórios podem ser definidos como sendo aqueles que ao retirarmos uma amostra aleatória de um conjunto infinito de níveis, as inferências estatísticas são válidas para toda a população. Por exemplo, se de um rebanho retiramos uma amostra de animais, as inferências estatísticas serão válidas para todo o rebanho. Os efeitos fixos são aqueles atribuídos a um conjunto finito de níveis de tratamentos em teste no experimento. Por exemplo, níveis de nutrientes em determinada ração animal (SEARLE; CASELLA; MCCULLOCH, 1992; BARBIN, 1993).

A abordagem de forma matricial de modelos lineares mistos pode ser representada como em Mrode (2015) e é dada por:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b} + \boldsymbol{\epsilon}, \quad (3)$$

em que:

\mathbf{y} é um vetor $n \times 1$ de observações da variável resposta ou variável dependente, sendo n o número de observações;

\mathbf{X} é uma matriz $n \times p$ de incidência dos efeitos fixos, sendo p o número de parâmetros de efeitos fixos;

$\boldsymbol{\beta}$ é um vetor $p \times 1$ de parâmetros de efeitos fixos;

\mathbf{Z} é uma matriz $n \times q$ de incidência dos efeitos aleatórios, sendo q o número de parâmetros de efeitos aleatórios;

\mathbf{b} é um vetor $q \times 1$ de parâmetros dos efeitos aleatórios;

$\boldsymbol{\epsilon}$ é um vetor $n \times 1$ de erros aleatórios, com

$$\mathbf{b} \sim N(\mathbf{0}, \mathbf{G}) \text{ e } \boldsymbol{\epsilon} \sim N(\mathbf{0}, \mathbf{R}), \quad (4)$$

sendo que \mathbf{G} é a matriz de variâncias-covariâncias dos efeitos aleatórios e \mathbf{R} é a matriz de variâncias-covariâncias residuais.

Desse modo têm-se,

$$\mathbf{y} \sim N(\mathbf{X}\boldsymbol{\beta}, \mathbf{ZGZ}' + \mathbf{R}). \quad (5)$$

As matrizes \mathbf{G} e \mathbf{R} podem assumir diferentes estruturas de covariâncias. Por exemplo, se essas matrizes apresentam a estrutura de covariância denominada componentes de variância (VC) têm-se que $\text{var}(\boldsymbol{\epsilon}) = \mathbf{R} = \mathbf{I}\sigma_{\epsilon}^2$ e $\text{var}(\mathbf{b}) = \mathbf{G} = \mathbf{I}\sigma_b^2$.

O modelo linear misto simplifica e unifica diversas análises estatísticas como: análise de variância, de regressão e de covariância (PASCUAL, 2000). No caso dos modelos (1) e (2), a parte fixa do modelo (3) representa parâmetros associados a fatores como tratamentos, tempo e a interação tratamentos x tempo. Já a parte aleatória representa o efeito de blocos e os erros associados às parcelas e subparcelas.

2.2.1 Inferência sobre os efeitos fixos

O teste F é usado para testar hipóteses sobre múltiplos efeitos fixos em modelos lineares mistos. Considere uma hipótese geral do efeitos fixos da seguinte forma:

$$H_0 : \mathbf{L}\boldsymbol{\beta} = \mathbf{0} \text{ vs } H_a : \mathbf{L}\boldsymbol{\beta} \neq \mathbf{0},$$

em que \mathbf{L} é uma matriz conhecida, $\boldsymbol{\beta}$ é um vetor de efeitos fixos ($p \times 1$) sendo o número de colunas da matriz \mathbf{L} o mesmo que o número de elementos de $\boldsymbol{\beta}$. A estatística F pode ser representada como em Verbeke e Molenberghs (2000), dada por:

$$F = \frac{\hat{\boldsymbol{\beta}}' \mathbf{L} \left(\mathbf{L} (\sum \mathbf{X}' \mathbf{V}^{-1} \mathbf{X})^{-1} \mathbf{L}' \right)^{-1} \mathbf{L}' \hat{\boldsymbol{\beta}}}{\text{posto}(\mathbf{L})}, \quad (6)$$

em que a \mathbf{V} é a matriz de covariâncias definida em (5) e segue aproximadamente uma distribuição F com graus de liberdade para o numerador igual

ao posto de \mathbf{L} , podendo ter diferentes aproximações dos graus de liberdade para o denominador como, por exemplo, *Satterthwaite* (VERBEKE; MOLENBERGHS, 1997).

2.2.2 Estruturas das matrizes de covariâncias

Com a utilização de modelos lineares mistos pode-se estimar os efeitos fixos, prever os efeitos aleatórios e estimar os componentes de variância. A estimação dos componentes de variância depende do método utilizado, como por exemplo, métodos da máxima verossimilhança (*Maximum Likelihood Estimation: ML*) e da máxima verossimilhança restrita (*Restricted Maximum Likelihood Estimation: REML*). Além disso, esse processo de estimação também é dependente da escolha da estrutura das matrizes \mathbf{G} e \mathbf{R} , uma vez que diferentes números de variâncias e covariâncias devem ser estimados (PERRI; IEMMA, 1999).

De acordo com Toral, Alencar e Freitas (2006), a escolha da melhor estrutura de covariância residual e do modelo mais adequado é fundamental na análise de dados de medidas repetidas. Caso contrário, os resultados podem ocasionar conclusões equivocadas.

Segundo Littell, Henry e Ammerman (1998), a escolha da estrutura de covariância para os resíduos é importante porque os erros-padrões das médias são dependentes dessa escolha e, caso se opte por uma estrutura inadequada, os erros-padrões podem ser superestimados.

Diversos autores como Searle, Casella e McCulloch (1992), Wolfinger (1993), Littell, Pendergast e Natarajan (2000), Pinheiro e Bates (2000) e Barbosa (2009) trazem diversas estruturas para as matrizes de variâncias e covariâncias \mathbf{G} e \mathbf{R} .

Serão apresentadas, a seguir, algumas estruturas de matrizes mais utilizadas e que estão implementadas em pacotes estatísticos como SAS e R (LITTELL et al., 2006; R CORE TEAM, 2016; SAS, 2008).

Considerando uma situação simples com quatro tempos têm-se:

1. Componente de variância (VC)

Essa matriz supõe independência e homogeneidade de variâncias nos quatro tempos. Envolve um único parâmetro e é dada por:

$$\begin{pmatrix} \sigma^2 & 0 & 0 & 0 \\ 0 & \sigma^2 & 0 & 0 \\ 0 & 0 & \sigma^2 & 0 \\ 0 & 0 & 0 & \sigma^2 \end{pmatrix}.$$

2. Simetria composta (CS)

A simetria composta supõe variâncias iguais nos quatro tempos e a mesma covariância entre medidas feitas em tempos distintos, envolvendo dois parâmetros. Sendo ρ a correlação entre as medições, essa estrutura é frequentemente usada quando a suposição de mesma correlação dos resíduos é plausível e somente se o ensaio repetido for realizado na mesma condição experimental (WEST; WELCH; GATECKI, 2015).

A estrutura simetria composta é dada por:

$$\begin{pmatrix} \sigma^2 & \rho\sigma^2 & \rho\sigma^2 & \rho\sigma^2 \\ \rho\sigma^2 & \sigma^2 & \rho\sigma^2 & \rho\sigma^2 \\ \rho\sigma^2 & \rho\sigma^2 & \sigma^2 & \rho\sigma^2 \\ \rho\sigma^2 & \rho\sigma^2 & \rho\sigma^2 & \sigma^2 \end{pmatrix}.$$

3. Simetria composta heterogênea (CSH)

A simetria composta heterogênea supõe parâmetros de variâncias diferentes para cada elemento da diagonal principal e raiz quadrada desses parâmetros nos elementos fora da diagonal principal multiplicada pelo ρ , sendo σ_i^2 a i -ésima variância e ρ a correlação entre as medições, satisfazendo $|\rho| < 1$. Considerando quatro tempos, o número de parâmetros nesse caso é igual a cinco e a matriz é dada por:

$$\begin{pmatrix} \sigma_1^2 & \sigma_1\sigma_2\rho & \sigma_1\sigma_3\rho & \sigma_1\sigma_4\rho \\ \sigma_2\sigma_1\rho & \sigma_2^2 & \sigma_2\sigma_3\rho & \sigma_2\sigma_4\rho \\ \sigma_3\sigma_1\rho & \sigma_3\sigma_2\rho & \sigma_3^2 & \sigma_3\sigma_4\rho \\ \sigma_4\sigma_1\rho & \sigma_4\sigma_2\rho & \sigma_4\sigma_3\rho & \sigma_4^2 \end{pmatrix}.$$

4. Autorregressiva de primeira ordem - AR(1)

A estrutura AR(1) é frequentemente usada para ajustar modelos em conjunto de dados longitudinais igualmente espaçados nos tempos em cada unidade experimental. Essa estrutura implica que as observações feitas em tempos mais próximos têm maior correlação do que aquelas feitas em tempos mais distantes. O número de parâmetros avaliados são dois: σ^2 e o parâmetro de correlação ρ , sendo este $|\rho| < 1$ (WEST; WELCH; GATECKI, 2015). Essa estrutura é dada por:

$$\sigma^2 \begin{pmatrix} 1 & \rho & \rho^2 & \rho^3 \\ \rho & 1 & \rho & \rho^2 \\ \rho^2 & \rho & 1 & \rho \\ \rho^3 & \rho^2 & \rho & 1 \end{pmatrix}.$$

5. Autorregressiva heterogênea de primeira ordem - ARH(1)

A estrutura ARH(1) apresenta variâncias e covariâncias diferentes. O número de parâmetros depende dos tempos avaliados, sendo obtido somando à quantidade de tempos + 1. Nesse caso, têm-se cinco parâmetros e a matriz é dada por:

$$\begin{pmatrix} \sigma_1^2 & \sigma_1\sigma_2\rho & \sigma_1\sigma_3\rho^2 & \sigma_1\sigma_4\rho^3 \\ \sigma_2\sigma_1\rho & \sigma_2^2 & \sigma_2\sigma_3\rho & \sigma_2\sigma_4\rho^2 \\ \sigma_3\sigma_1\rho^2 & \sigma_3\sigma_2\rho & \sigma_3^2 & \sigma_3\sigma_4\rho \\ \sigma_4\sigma_1\rho^3 & \sigma_4\sigma_2\rho^2 & \sigma_4\sigma_3\rho & \sigma_4^2 \end{pmatrix}.$$

6. Não estruturada (UN)

A não estruturada é caracterizada pelas variâncias e covariâncias desiguais e o número de parâmetros avaliados é dado pela multiplicação do número de tempos pelo número de tempos mais um, dividindo-se por dois. No exemplo, considerando quatro tempos têm-se, $\frac{4(4+1)}{2} = 10$ parâmetros avaliados. A matriz é dada por:

$$\begin{pmatrix} \sigma_1^2 & \sigma_{12} & \sigma_{13} & \sigma_{14} \\ \sigma_{21} & \sigma_2^2 & \sigma_{23} & \sigma_{24} \\ \sigma_{31} & \sigma_{32} & \sigma_3^2 & \sigma_{34} \\ \sigma_{41} & \sigma_{42} & \sigma_{43} & \sigma_4^2 \end{pmatrix}.$$

7. Huynh-Feldt (HF)

A estrutura Huynh-Feldt (HF) é caracterizada pelas variâncias desiguais e covariâncias obtidas pela média aritmética entre as variâncias e subtraindo λ , sendo λ a diferença entre a média das variâncias e a média das covariâncias. O número de parâmetros avaliados é obtido somando a quantidade de tempos + 1. Nesse caso, têm-se cinco parâmetros. A matriz é dada por:

$$\begin{pmatrix} \sigma_1^2 & \frac{\sigma_1^2 + \sigma_2^2}{2} - \lambda & \frac{\sigma_1^2 + \sigma_3^2}{2} - \lambda & \frac{\sigma_1^2 + \sigma_4^2}{2} - \lambda \\ \frac{\sigma_2^2 + \sigma_1^2}{2} - \lambda & \sigma_2^2 & \frac{\sigma_2^2 + \sigma_3^2}{2} - \lambda & \frac{\sigma_2^2 + \sigma_4^2}{2} - \lambda \\ \frac{\sigma_3^2 + \sigma_1^2}{2} - \lambda & \frac{\sigma_3^2 + \sigma_2^2}{2} - \lambda & \sigma_3^2 & \frac{\sigma_3^2 + \sigma_4^2}{2} - \lambda \\ \frac{\sigma_4^2 + \sigma_1^2}{2} - \lambda & \frac{\sigma_4^2 + \sigma_2^2}{2} - \lambda & \frac{\sigma_4^2 + \sigma_3^2}{2} - \lambda & \sigma_4^2 \end{pmatrix}.$$

Outras estruturas de covariâncias, tais como as estruturas Primeira Antedependência (ANTE), *Toeplitz* (TOEP), *Toeplitz* Heterogênea (TOEPH) e Fator analítico (FA-1) podem ser utilizadas. De acordo com West, Welch e Gatecki (2015), as diversas estruturas de covariância permitem uma maior flexibilidade nas correlações. Em qualquer análise de dados, busca-se escolher a estrutura correta para a matriz \mathbf{R} que seja mais adequada e parcimoniosa, com conhecimento dos dados observados e sobre as relações entre as observações de cada parcela nos experimentos ao longo do período de avaliação (LITTELL et al., 2006).

2.3 Análise de resíduos em dados longitudinais

A análise de resíduos em dados longitudinais é importante para verificar se as pressuposições do modelo são adequadas, sendo estas a normalidade, homocedasticidade e independência dos resíduos, além da detecção de valores extremos e possíveis observações influentes no conjunto de dados (DAMASCENA, 2015; WEST; WELCH; GATECKI, 2015).

Nessa análise, os resíduos são obtidos por meio de $\epsilon = \mathbf{y} - \hat{\mathbf{y}}$, que mensura a diferença entre o valor observado e o valor ajustado, chamado de resíduo ordinário da variável resposta do modelo (OLIVEIRA, 2013).

De acordo com Singer, Nobre e Rocha (2015), a análise de diagnóstico de resíduos é mais complexa em modelos lineares mistos do que no caso do modelo fixo, devido aos efeitos aleatórios presentes no modelo além dos resíduos e, conseqüentemente devido às diferentes estruturas de covariâncias. Assim, podem ser gerados três tipos de resíduos: marginais, condicionais e de efeitos aleatórios.

Dado o modelo linear misto definido em (3), os resíduos marginais são obtidos pela diferença entre os valores observados e os esperados. Esses são utilizados para a verificação da linearidade dos efeitos fixos e para a detecção de observações discrepantes (NOBRE; SINGER, 2007). Os resíduos marginais são definidos por:

$$\epsilon = \mathbf{y} - E(\mathbf{y}) = \mathbf{y} - \mathbf{X}\beta,$$

e o seu estimador é:

$$\hat{\epsilon} = \mathbf{y} - \mathbf{X}\hat{\beta}. \quad (7)$$

Os resíduos condicionais referem-se às diferenças entre os valores observados e os preditos de cada observação. Os resíduos condicionais são definidos por:

$$\epsilon = \mathbf{y} - E(\mathbf{y}|\mathbf{b}) = \mathbf{y} - (\mathbf{X}\beta + \mathbf{Zb}) = \mathbf{y} - \mathbf{X}\beta - \mathbf{Zb},$$

e o seu estimador é:

$$\hat{\boldsymbol{\varepsilon}} = \mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}} - \mathbf{Z}\hat{\mathbf{b}}. \quad (8)$$

Com os resíduos condicionais são avaliadas as hipóteses de homocedasticidade e normalidade, bem como a identificação de observações discrepantes (NOBRE; SINGER, 2007).

Os resíduos de efeitos aleatórios, $\mathbf{Z}\hat{\mathbf{b}}$, denominado de EBLUP (*Empirical BLUP*), segundo Nobre e Singer (2007) e West, Welch e Gatecki (2015), são obtidos conforme a definição dos preditores dos efeitos aleatórios, dados por:

$$\mathbf{Z}\mathbf{b} = \mathbf{E}(\mathbf{y}|\mathbf{b}) - \mathbf{E}(\mathbf{y}) = (\mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b}) - \mathbf{X}\boldsymbol{\beta},$$

e o seu estimador é: $\mathbf{Z}\hat{\mathbf{b}}$.

De acordo com West, Welch e Gatecki (2015), o uso de gráficos de diagnósticos padrões como histogramas, gráficos quantil-quantil e gráficos de dispersão dos EBLUPs são úteis para a identificação de potenciais *outliers*. De acordo com Nobre e Singer (2007), esses também são utilizados na verificação da normalidade dos efeitos aleatórios \mathbf{b} .

2.4 Transformação Box-Cox

A transformação Box-Cox é realizada na variável resposta, a transformação Box-Cox consiste em encontrar um valor de λ em que os dados transformados se aproximem de uma distribuição normal (BOX; COX, 1964). Essa transformação é dada por:

$$y^{(\lambda)} = \begin{cases} \frac{y^\lambda - 1}{\lambda} & (\lambda \neq 0) \\ \log y & (\lambda = 0) \end{cases}$$

em que $y^{(\lambda)}$ é a variável transformada e quando λ tem diferentes valores a variável y^λ pode receber as seguintes transformações (KUTNER et al., 2005):

$$\lambda = 2 \quad y^{(\lambda)} = y^2$$

$$\lambda = 1 \quad y^{(\lambda)} = y^1$$

$$\lambda = 0.5 \quad y^{(\lambda)} = \sqrt{y}$$

$$\lambda = 0 \quad y^{(\lambda)} = \log y$$

$$\lambda = -0.5 \quad y^{(\lambda)} = \frac{1}{\sqrt{y}}$$

$$\lambda = -1 \quad y^{(\lambda)} = \frac{1}{y}$$

Por exemplo, quando o valor de λ for 1 a variável analisada não precisa ser transformada.

3 MATERIAL E MÉTODOS

3.1 Material

Os dados utilizados no presente estudo foram obtidos em um experimento realizado no Setor de Avicultura do Instituto Federal de Minas Gerais (IFMG - Campus Bambuí), no período de abril a julho de 2011. Nesse experimento foi avaliado o desempenho de poedeiras semipesadas que receberam dietas que consideram a associação da fitase com um complexo enzimático composto por carboidrases (α -galactosidase, galactomananase, xilanase e β -glucanase).

O delineamento experimental foi o inteiramente casualizado (DIC) em esquema de parcela subdividida, sendo quatro tratamentos com dez repetições cada. Os tratamentos foram: controle positivo (CP), onde não houve adição de enzimas, sendo uma ração com todos os níveis nutricionais; no controle negativo (CN), no qual retirou-se cerca de 100 kcal.kg⁻¹ na energia metabolizável do tratamento CP, sem adição de enzimas; tratamento T1, que consistiu no CN com a adição de 30 gramas.tonelada⁻¹ de fitase e a enzima carboidrase com adição de 200 gramas.tonelada⁻¹; tratamento T2, sendo o CN mais a adição de 30 gramas.tonelada⁻¹ de fitase e a enzima carboidrase com adição de 300 gramas.tonelada⁻¹.

Foram utilizadas 400 aves da linhagem comercial Isa Brown avaliadas por um período de 12 semanas (29 a 40 semanas de idade) e distribuídas em 40 parcelas experimentais, com dez aves por parcela.

As variáveis de desempenho avaliadas foram: consumo médio de ração (g.ave⁻¹.dia⁻¹) e peso médio dos ovos (gramas). As coletas foram realizadas diariamente, calculando-se as médias semanais, totalizando 12 semanas.

As variáveis de qualidade de ovos foram: comprimento e largura do ovo (mm), peso da gema (gramas), peso da casca (gramas), porcentagem de gema, albúmen e casca (%), espessura de casca (mm), Unidade Haugh, densidade dos ovos (gramas.mL⁻¹) e peso médio dos ovos (gramas). As variáveis de qualidade de ovos foram avaliadas a cada 21 dias, ou seja, aos 21, 42, 63 e 84 dias após o início do experimento.

As variáveis usadas para ilustração das análises neste trabalho foram: consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$) e peso da gema (gramas).

3.2 Métodos

De acordo com os objetivos propostos, foram realizadas análise exploratória do conjunto de dados, com *boxplots* e análise de perfis individuais. As análises realizadas foram em esquema de parcela subdividida no tempo e análise via modelos lineares mistos, com a escolha correta das estruturas de covariância. Além disso, foram realizadas as análises de resíduos.

A análise exploratória foi realizada com o pacote *lattice* do programa estatístico R (R CORE TEAM, 2016).

A análise em esquema de parcela subdividida no tempo foi realizada utilizando a função *aov* do pacote *car* (Fox; Weisberg, 2011) do programa estatístico R.

Os modelos lineares mistos foram ajustados utilizando a função *lmer* do pacote *lme4* e a função *gls* do pacote *nlme* (Pinheiro; Bates, 2000) no programa estatístico R e no procedimento *mixed* do programa estatístico SAS.

O procedimento *mixed* e a função *lmer* têm a flexibilidade de ajustar modelos lineares mistos a dados longitudinais, permitindo fazer inferências estatísticas. Essas são poderosas ferramentas de análise de dados com medidas repetidas.

O modelo estatístico para o esquema de parcela subdividida no tempo em DIC para a variável consumo médio de ração é o seguinte:

$$y_{ijk} = \mu + \alpha_i + \beta_{k(i)} + \gamma_j + \alpha\gamma_{ij} + \epsilon_{ijk}, \quad (9)$$

em que:

y_{ijk} é o valor observado para a variável consumo de ração da i -ésima dieta na j -ésima semana e na k -ésima repetição, com $i=1, 2, 3, 4$, $j=1, 2, \dots, 12$ e $k=1, 2, \dots, 10$;

μ é uma constante inerente a cada observação;

α_i é o efeito do i -ésimo nível da dieta;

$\beta_{k(i)}$ é o efeito do erro experimental a nível de parcela;

γ_j é o efeito da j -ésima semana;

$\alpha\gamma_{ij}$ é o efeito da interação dieta \times semana;

ϵ_{ijk} é o erro experimental a nível de subparcelas.

As suposições do modelo descrito em (9) é que a constante μ e os efeitos α_i , γ_j e $\alpha\gamma_{ij}$ são considerados fixos e os erros $\beta_{k(i)}$ e ϵ_{ijk} são considerados aleatórios, normais e independentemente distribuídos com médias nulas e variâncias comuns σ_β^2 e σ_ϵ^2 , respectivamente.

A forma matricial de modelos lineares mistos para o consumo de ração pode ser representado da seguinte forma:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b} + \boldsymbol{\epsilon}, \quad (10)$$

em que:

\mathbf{y} é um vetor 480×1 de observações da variável consumo de ração, sendo 480 o número de observações;

\mathbf{X} é uma matriz 480×65 de incidência dos efeitos fixos (4 dietas, 12 semanas e a interação dietas \times semanas são 48 e a média geral), sendo 65 o número de parâmetros de efeitos fixos;

$\boldsymbol{\beta}$ é um vetor 65×1 de parâmetros de efeitos fixos;

\mathbf{Z} é uma matriz 480×40 de incidência dos efeitos aleatórios, sendo 40 o número de parâmetros de efeitos aleatórios (40 parcelas experimentais);

\mathbf{b} é um vetor 40×1 de parâmetros dos efeitos aleatórios;

$\boldsymbol{\epsilon}$ é um vetor 480×1 de erros aleatórios, com

$$\mathbf{b} \sim N(\mathbf{0}, \mathbf{G}) \text{ e } \boldsymbol{\epsilon} \sim N(\mathbf{0}, \mathbf{R}). \quad (11)$$

O diagnóstico dos modelos ajustados foi feito com o objetivo de avaliar as pressuposições do modelo por meio de métodos gráficos, analisando re-

síduos padronizados *versus* valores observados. Foram realizados *boxplots* dos resíduos ao longo do tempo para os diferentes tratamentos, gráficos *QQ plots* da normal em cada tratamento e o gráfico *QQ plot* para detecção de normalidade dos resíduos.

Foram realizados diagnóstico dos resíduos marginais, condicionais e de efeitos aleatórios. Também foi aplicado o teste de Shapiro-Wilk para verificação da normalidade dos resíduos e a transformação Box-Cox na variável resposta, no caso de não haver normalidade dos resíduos.

Para a escolha da estrutura das matrizes de covariâncias (**G** e **R**) de forma adequada é preciso utilizar algum critério de seleção. No presente trabalho foram utilizados o critério de Akaike (AIC) (AKAIKE, 1974) e o critério Bayesiano de Schwarz (BIC) (SCHWARZ, 1978). Foi considerada a melhor estrutura de covariância aquela que apresentar o menor valor do critério utilizado. Além disso, foi realizada análise gráfica da estrutura de covariância UN.

4 RESULTADOS E DISCUSSÃO

No presente estudo serão descritos os principais passos para análise de dados longitudinais em esquema de parcela subdividida no tempo, com abordagem dos modelos lineares mistos, utilizando diferentes estruturas de covariância e análises de resíduos. Os passos para análise de dados longitudinais considerados foram os seguintes:

- Primeiramente, deve-se criar um arquivo de dados em formato *Excel* ou *txt* e em seguida realiza-se importação dos dados para o programa estatístico (R ou SAS);
- Em seguida, deve-se realizar uma análise exploratória dos dados com gráficos de perfis dos tratamentos ao longo do tempo, perfis individuais das parcelas experimentais em cada tratamento ao longo do tempo e *boxplots* dos tratamentos ao longo do tempo;
- Logo após, deve-se realizar a escolha da estrutura da matriz de covariâncias utilizando os programas estatísticos SAS e R;
- Depois realiza-se a análise de variância do modelo escolhido;
- E, com todas essas etapas realizadas, assim deve-se realizar a análise de resíduos do modelo escolhido com a estrutura da matriz de covariâncias.

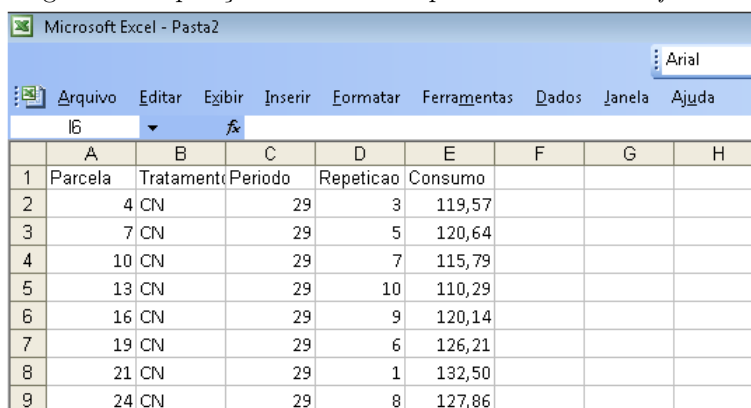
No conjunto de dados longitudinais foi realizada primeiramente uma análise exploratória. As variáveis utilizadas no presente estudo foram: consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$) e peso da gema (gramas).

Em seguida utilizaram-se os modelos lineares mistos com a função *gls* do programa R e também no procedimento *mixed* do SAS, considerando diferentes estruturas de covariância como: simetria composta (CS), simetria composta heterogênea (CSH), autorregressiva de primeira ordem (AR(1)), autorregressiva heterogênea de primeira ordem (ARH(1)), não estruturada (UN), componentes de variância (VC) e Huynh-Feldt (HF). Logo após,

realizou-se a análise de variância em esquema de parcela subdividida no tempo com a função *aov* do programa R e a análise de variância da estrutura de covariância escolhida, e a análise de variância com a função *lmer*. Em seguida realizaram-se análise gráfica da estrutura de covariância UN e análise gráfica dos resíduos condicionais, marginais e aleatórios, também foi feito o teste de Shapiro-Wilk para verificação da normalidade dos resíduos.

Os dados longitudinais estão em uma planilha do *Microsoft Excel*, na Figura 1 tem-se a disposição dos dados para a variável consumo médio de ração.

Figura 1 – Disposição dos dados na planilha do *Microsoft Excel*.



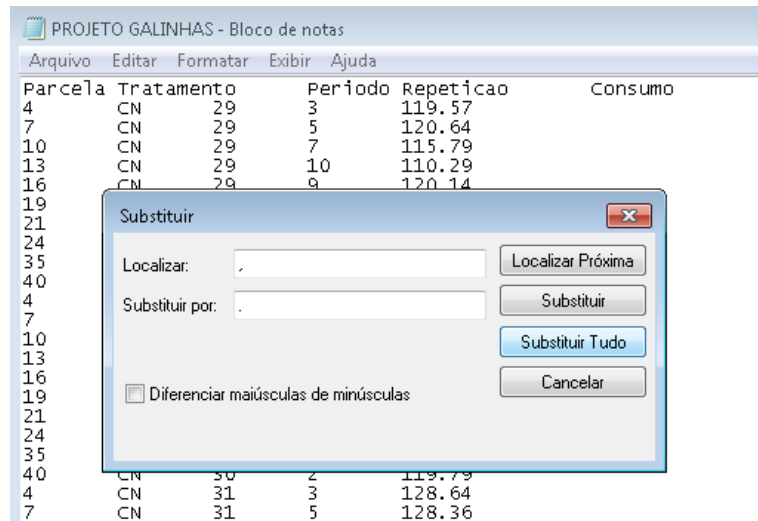
	A	B	C	D	E	F	G	H
1	Parcela	Tratament	Período	Repeticao	Consumo			
2	4	CN	29	3	119,57			
3	7	CN	29	5	120,64			
4	10	CN	29	7	115,79			
5	13	CN	29	10	110,29			
6	16	CN	29	9	120,14			
7	19	CN	29	6	126,21			
8	21	CN	29	1	132,50			
9	24	CN	29	8	127,86			

Na Figura 1 têm-se os nomes das fontes de variação e da resposta (Parcela, Tratamento, Período, Repeticao e Consumo), os dados estão dispostos por tratamentos (CN, CP, T1 e T2) ao longo das 12 semanas de avaliação (29,30, ..., 40). O primeiro passo é realizar a importação dos dados a partir de uma planilha do *Microsoft Excel*, é necessário antes salvar essa planilha no formato.txt (Texto separado por tabulações). Para salvá-la nesse formato, acione em Arquivo do menu, em seguida Salvar como... Na parte inferior da caixa de diálogo, clique sobre as opções de Salvar como tipo e selecione Texto (separado por tabulações). Agora basta escolher a pasta de destino e acionar no botão Salvar.

Surgirão algumas mensagens indicando a incompatibilidade de alguns recursos do *Microsoft Excel* com esse formato, mas como o que nos interessa

são apenas os dados, acione em OK e em seguida em Sim. Em seguida abre o arquivo em formato.txt. Ao abrir o arquivo, é necessário fazer a mudança de vírgula para ponto, vai na opção Editar e seleciona a opção Substituir... e logo a seguir aciona com o *mouse* em Substituir tudo, na Figura 2 tem a demonstração desses passos no arquivo.txt.

Figura 2 – Disposição dos dados em formato.txt.



No arquivo criado os nomes das variáveis não podem conter acentos, til e cedilha, se o usuário deixar esses ocorrerem mensagens de erros e o arquivo não é lido no programa R. Agora realiza-se a leitura dos dados do arquivo do tipo Texto (txt- separado por tabulações) no programa R. Primeiramente buscamos o arquivo salvo no diretório do computador com a função *setwd*, em seguida o comando *read.table* para armazenar os dados desse arquivo em um objeto do R chamado dados. Para importar os dados provenientes do arquivo “PROJETO GALINHAS.txt”, presente no *drive C*, pasta *Users/-note/Documents*, subpasta pasta frangos, e com a função *header= TRUE*, assume-se que a primeira linha do conjunto de dados contém os nomes das variáveis. As linhas de comando no programa estão descritas a seguir:

```
> setwd("C:/Users/note/Documents/pasta frangos")
> dados<-read.table("PROJETO GALINHAS.txt",header=TRUE)
```

As linhas de comando no programa R para realizar a leitura das primeiras linhas do conjunto de dados são feitas com a função *head* do objeto dados. Essa linha de comando está a seguir:

```
> head(dados)
```

	Parcela	Tratamento	Periodo	Repeticao	Consumo
1	4	CN	29	3	119.57
2	7	CN	29	5	120.64
3	10	CN	29	7	115.79
4	13	CN	29	10	110.29
5	16	CN	29	9	120.14
6	19	CN	29	6	126.21

Com a função *attach* pode-se anexar o conjunto de dados de modo a poder chamar as colunas diretamente. Depois deve-se transformar em fator as variáveis, pois o fator é número de níveis de cada tratamento (*trat.f*), das semanas de avaliação (*periodo.f*) e das repetições (*repeticao.f*). A transformação em fatores estão descritos a seguir:

```
> attach(dados)
> trat.f=factor(Tratamento)
> periodo.f=factor(Periodo)
> repeticao.f=factor(Repeticao)
> erroA <- repeticao.f:trat.f
```

No caso do esquema de parcela subdividida no tempo em DIC, deve-se especificar que a nível de parcela as repetições dentro de tratamentos (*erroA*

`<- repeticao.f:trat.f`). A transformação dos fatores vai ser útil para realizar as análises e são esses nomes que vão sair nos resultados das análises.

A descrição das linhas de comando no programa R e no SAS foram exemplificadas com a variável consumo médio de ração (Apêndice A - programa R e Apêndice C - programa SAS), para a variável peso da gema (Apêndice B - programa R e Apêndice D - programa SAS) foram descritos os resultados com destaque apenas nas diferenças entre as variáveis. Os passos descritos acima para análise de dados longitudinais para a variável consumo médio de ração está a seguir.

4.1 Variável consumo médio de ração

4.1.1 Análise exploratória da variável consumo médio de ração


Para análise exploratória da variável consumo médio de ração foi utilizado o pacote *lattice* do programa R na obtenção da Figura 3 utilizaram-se as seguintes linhas de comandos:

```
> library(lattice)
> par(mar=c(4,4,0,0)+.1)
> interaction.plot(periodo.f, trat.f, Consumo, col=1,
+                 lty=c(1,3,5,6), lwd=3, xlab="Tempo
+                 (Semanas)", ylab="Consumo de ração
+                 (g/ave/dia)", legend =FALSE)
> legend("topright", c("CN", "CP", "T1", "T2"), xpd=TRUE,
+       horiz=FALSE, inset=c(0,0), bty="n", cex=1.40,
+       lty=c(1,3,5,6), col=1, lwd=3)
```

Na função *interaction.plot* do pacote *lattice* deve-se especificar os fatores *periodo.f*, *trat.f* e a variável *Consumo*. As opções *xlab* e *ylab* nomeiam os eixos x e y do gráfico. Para a legenda tem a opção de deixar o da própria função, ou colocar *legend =FALSE* e logo depois adiciona-se a função *legend*, no canto superior direito do gráfico *topright*, com as siglas dos tratamentos em teste e com o tipo de linha tracejada *lty=c(1,3,5,6)*.

A Figura 3 reflete o comportamento da variável consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$) para os quatro tratamentos ao longo do período de avaliação (29 a 40 semanas de idade).

Figura 3 – Consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$) de poedeiras com idade de 29 a 40 semanas nas diferentes dietas experimentais.



De acordo com a Figura 3, houve oscilações no consumo médio de ração em cada semana nas diferentes rações testadas, sendo esse gráfico útil para mostrar o comportamento dos tratamentos ao longo das semanas em estudo no experimento. As diferentes dietas avaliadas no experimento apresentaram comportamento semelhante ao longo das 12 semanas de avaliação.

Quando o interesse é analisar o comportamento de cada parcela experimental, composta de 10 aves em cada repetição, deve-se utilizar os seguintes comandos no programa R:


```
> parc.dados <- subset(dados, as.numeric(Parcela)
+                       %in% seq(1, 40, 1))
> perfisconsumo<- xyplot(Consumo ~ periodo.f |trat.f,
+                        groups = Parcela,type = "l",
+                        lty=1,data=parc.dados,lwd=2,
+                        col=1)
> update(perfisconsumo,xlab="Idade (semanas)",
```

```
+ ylab="Consumo de ração (g/ave/dia)",grid = "h")
```

Para criar a sequência correta das parcelas experimentais em que são 40 no experimento e na função *xyplot* deve-se especificar a variável *Consumo*, sendo o *periodo.f* nos diferentes tratamentos (*trat.f*) e na função *update* especifica o nome *perfisconsumo* e o nome dos eixos x e y, além da opção *grid = "h"*, para colocar linhas tracejadas na horizontal.

Na Figura 4 são mostrados os perfis individuais das parcelas experimentais para o consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$) ao longo do período de avaliação (29 a 40 semanas de idade) nas dietas experimentais. Essa figura é útil para a detecção de possíveis pontos discrepantes e para verificar o comportamento das parcelas experimentais ao longo das semanas.

Figura 4 – Perfis individuais das parcelas experimentais em cada tratamento para o consumo médio de ração.



Na Figura 5 têm-se os *boxplots* ao longo das 12 semanas de avaliação da variável consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$), considerando diferentes tratamentos. Os comandos do programa R para realizar esses gráficos estão a seguir:

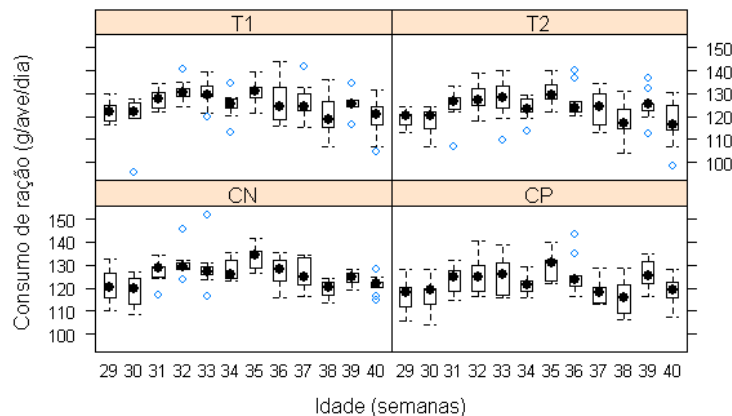
```

> boxconsumo <- bwplot(Consumo ~ periodo.f | trat.f,
+                       data=dados,layout=c(2,2),
+                       xlab="Idade (semanas)",
+                       ylab="Consumo de ração (g/ave/dia)"
+                       ,par.settings = list(box.umbrella=
+                       list(col=1),box.dot=list(col= 1),
+                       box.rectangle =list(col= 1)))
> boxconsumo

```

Na função *bwplot* deve-se especificar a variável *Consumo* em que o fator *periodo.f* deve ser em função dos tratamentos (*trat.f*), tem-se que cada janela é um *boxplot*, têm-se 4 por isso o *layout=c(2,2)*.

Figura 5 – *Boxplots* da variável consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$) durante o período 12 semanas nos diferentes tratamentos testados.



O gráfico apresentado na Figura 5 é útil para avaliar como a variável resposta comporta-se em cada tratamento em teste no experimento e para verificar a suposição de homocedasticidade. Além disso, também pode ser utilizado para detecção de possíveis *outliers* e pontos discrepantes no conjunto de dados.

4.1.2 Função *gls* para a variável consumo médio de ração

A função *gls* (*Generalized Least Squares* - mínimos quadrados generalizados) pertence ao pacote *nlme* (Pinheiro; Bates, 2000). Primeiramente, deve-se especificar os termos fixos do modelo (tratamento, tempo e a interação tratamento \times tempo) e o efeito aleatório (*erroA*). Para as matrizes \mathbf{R} e \mathbf{G} foram utilizadas diversas estruturas de covariância, sendo elas: simetria composta (CS), simetria composta heterogênea (CSH), autorregressiva de primeira ordem (AR(1)), autorregressiva heterogênea de primeira ordem (ARH(1)) e a não estruturada (UN).

De acordo com Gatecki e Burzykowski (2013) a característica mais interessante da função *gls* é que essa pode ser utilizada em modelos com matrizes de covariâncias para observações correlacionadas.

As rotinas com as estruturas de covariância CS, CSH, AR(1), ARH(1) e UN para o esquema de parcela subdividida no tempo considerando a variável consumo médio de ração e usando a função *gls* estão descritos a seguir:

```
> library(nlme)
> Cons.CS<-gls(Consumo~trat.f+periodo.f+
+             (trat.f:periodo.f),data=dados,
+             method="REML",correlation=
+             corCompSymm(form= ~ 1 |erroA))
> Cons.CSH<-gls(Consumo~trat.f+periodo.f+
+              (trat.f:periodo.f),data=dados,
+              method="REML",correlation =
+              corCompSymm(form= ~ 1 |erroA),
+              weights=varIdent(form=~1|periodo.f))
> Cons.AR1<-gls(Consumo~trat.f+periodo.f+
+              (trat.f:periodo.f),data=dados,
+              method="REML",correlation =
+              corAR1(form= ~ 1 |erroA))
> Cons.ARH<-gls(Consumo~trat.f+periodo.f+
+              (trat.f:periodo.f), data=dados,
+              method="REML",correlation =
```

```

+           corAR1(form= ~ 1 |erroA),
+           weights=varIdent(form=~1|periodo.f))
> Cons.UN<-gls(Consumo~trat.f+periodo.f+
+           (trat.f:periodo.f),data=dados,
+           method="REML",correlation =
+           corSymm(form= ~ 1 |erroA),
+           weights=varIdent(form=~1|periodo.f))

```

Com a função *gls* especifica-se a variável *Consumo* e os efeitos fixos (*trat.f*, *periodo.f* e (*trat.f:periodo.f*)) e com a função *correlation* a estrutura de covariância especificada. A seguir são detalhadas cada estrutura de covariância na função *gls*:

- Para a estrutura de covariância simetria composta (CS) na opção *Cons.CS*, na função *correlation=corCompSymm(form= ~ 1 |erroA)*, com essa função indica que nessa estrutura tem a mesma variância e mesma covariância;
- Para a estrutura de covariância simetria composta heterogênea (CSH), *Cons.CSH*, na função *correlation=corCompSymm(form= ~ 1 |erroA)*, *weights=varIdent(form=~1|periodo.f)*, em que deve-se colocar a função *weights*, pois a CSH têm a mesma variância e covariâncias diferentes ao longo do tempo;
- Para a estrutura de covariância autorregressiva de primeira ordem (AR(1)) na opção *Cons.AR1*, na função *correlation* deve-se especificar *corAR1(form= ~ 1 |erroA)*, pois na AR(1) são estimados dois parâmetros;
- Para a estrutura de covariância autorregressiva heterogênea de primeira ordem (ARH(1)) com a opção *Cons.ARH*, quando especifica-se *correlation=corAR1(form= ~ 1 |erroA)*, *weights=varIdent(form=~1|periodo.f)*, na ARH(1) são a mesma variância e covariâncias diferentes ao longo do tempo (*periodo.f*);

- Para a estrutura de covariância não estruturada (UN) quando têm-se a opção *Cons.UN*, na função *correlation=corSymm(form= ~ 1 | erroA), weights=varIdent(form=~1|periodo.f)* têm-se a especificação, em que essa considera variâncias e covariâncias diferentes.

Utiliza-se a função *summary* para obter as respostas das análises. Para exemplificar, vamos utilizar o *summary* do modelo *Cons.CS*. Para a estrutura de covariância CS têm-se estatísticas relacionadas ao ajuste do modelo (AIC, BIC, *log* da razão de verossimilhanças, o parâmetro ρ) e as estimativas dos erros-padrões (*Std.Error*) e estatística t (*t-value*). Os resultados estão descritos a seguir:

```
> summary(Cons.CS)
```

```
Generalized least squares fit by REML
Model: Consumo ~ trat.f + periodo.f + (trat.f:periodo.f)
Data: dados
      AIC      BIC    logLik
2896.776 3100.197 -1398.388

Correlation Structure: Compound symmetry
Formula: ~1 | erroA
Parameter estimate(s):
      Rho
0.4182453

Coefficients:
              Value Std.Error  t-value p-value
(Intercept)    120.965   2.044906  59.15430  0.0000
trat.fCP        -3.772   2.891934  -1.30432  0.1928
trat.fT1         1.135   2.891934   0.39247  0.6949
trat.fT2        -1.628   2.891934  -0.56295  0.5738
periodo.f30     -1.586   2.205760  -0.71903  0.4725
periodo.f31      6.442   2.205760   2.92053  0.0037
periodo.f32      9.706   2.205760   4.40030  0.0000
periodo.f33      7.691   2.205760   3.48678  0.0005
periodo.f34      6.535   2.205760   2.96270  0.0032
periodo.f35     12.456   2.205760   5.64703  0.0000
```

periodo.f36	6.485	2.205760	2.94003	0.0035
periodo.f37	4.850	2.205760	2.19879	0.0284
periodo.f38	-1.273	2.205760	-0.57713	0.5642
periodo.f39	3.514	2.205760	1.59310	0.1119
periodo.f40	0.464	2.205760	0.21036	0.8335
trat.fCP:periodo.f30	1.908	3.119416	0.61165	0.5411
trat.ft1:periodo.f30	-0.156	3.119416	-0.05001	0.9601
trat.ft2:periodo.f30	0.755	3.119416	0.24203	0.8089
trat.fCP:periodo.f31	-0.377	3.119416	-0.12086	0.9039
trat.ft1:periodo.f31	-1.191	3.119416	-0.38180	0.7028
trat.ft2:periodo.f31	-0.764	3.119416	-0.24492	0.8066
trat.fCP:periodo.f32	-1.462	3.119416	-0.46868	0.6395
trat.ft1:periodo.f32	-0.962	3.119416	-0.30839	0.7579
trat.ft2:periodo.f32	-1.006	3.119416	-0.32250	0.7472
trat.fCP:periodo.f33	1.303	3.119416	0.41771	0.6764
trat.ft1:periodo.f33	-0.198	3.119416	-0.06347	0.9494
trat.ft2:periodo.f33	0.279	3.119416	0.08944	0.9288
trat.fCP:periodo.f34	-2.357	3.119416	-0.75559	0.4503
trat.ft1:periodo.f34	-3.793	3.119416	-1.21593	0.2247
trat.ft2:periodo.f34	-2.578	3.119416	-0.82644	0.4090
trat.fCP:periodo.f35	-0.212	3.119416	-0.06796	0.9458
trat.ft1:periodo.f35	-3.713	3.119416	-1.19029	0.2346
trat.ft2:periodo.f35	-1.692	3.119416	-0.54241	0.5878
trat.fCP:periodo.f36	1.806	3.119416	0.57895	0.5629
trat.ft1:periodo.f36	-2.267	3.119416	-0.72674	0.4678
trat.ft2:periodo.f36	0.318	3.119416	0.10194	0.9188
trat.fCP:periodo.f37	-3.557	3.119416	-1.14028	0.2548
trat.ft1:periodo.f37	-1.116	3.119416	-0.35776	0.7207
trat.ft2:periodo.f37	-0.429	3.119416	-0.13753	0.8907
trat.fCP:periodo.f38	0.587	3.119416	0.18818	0.8508
trat.ft1:periodo.f38	-0.234	3.119416	-0.07501	0.9402
trat.ft2:periodo.f38	0.365	3.119416	0.11701	0.9069
trat.fCP:periodo.f39	5.584	3.119416	1.79008	0.0741
trat.ft1:periodo.f39	-0.056	3.119416	-0.01795	0.9857
trat.ft2:periodo.f39	1.986	3.119416	0.63666	0.5247
trat.fCP:periodo.f40	0.856	3.119416	0.27441	0.7839
trat.ft1:periodo.f40	-3.151	3.119416	-1.01012	0.3130
trat.ft2:periodo.f40	-2.580	3.119416	-0.82708	0.4086

Com o *summary(Cons.CS)* têm-se os valores de AIC (2896,776), BIC

(3100,197) e o máximo do logaritmo natural da função de verossimilhança (-1398,388) e do parâmetro $\rho = 0,4182453$, também têm as estimativas dos efeitos fixos (erros-padrões e a estatística t).

Para obter-se a matriz de covariância \mathbf{R} deve-se especificar no programa R a seguinte linha de comando `getVarCov(Cons.CS)`. Tem-se o seguinte resultado:

```
> getVarCov(Cons.CS)
```

```
Marginal variance covariance matrix
      [,1] [,2] [,3] [,4] [,5] [,6] [,7] [,8] [,9] [,10] [,11] [,12]
[1,] 41.816 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490
[2,] 17.490 41.816 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490
[3,] 17.490 17.490 41.816 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490
[4,] 17.490 17.490 17.490 41.816 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490
[5,] 17.490 17.490 17.490 17.490 41.816 17.490 17.490 17.490 17.490 17.490 17.490 17.490
[6,] 17.490 17.490 17.490 17.490 17.490 41.816 17.490 17.490 17.490 17.490 17.490 17.490
[7,] 17.490 17.490 17.490 17.490 17.490 17.490 41.816 17.490 17.490 17.490 17.490 17.490
[8,] 17.490 17.490 17.490 17.490 17.490 17.490 17.490 41.816 17.490 17.490 17.490 17.490
[9,] 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 41.816 17.490 17.490 17.490
[10,] 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 41.816 17.490 17.490
[11,] 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 41.816 17.490
[12,] 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 17.490 41.816
Standard Deviations: 6.4666 6.4666 6.4666 6.4666 6.4666 6.4666 6.4666 6.4666 6.4666 6.4666 6.4666 6.4666
```

Na matriz de covariâncias acima são estimados dois parâmetros: uma variância (41,816) e uma covariância que é obtida ao multiplicar o parâmetro $\rho = 0,4182453$ pela variância, com isso têm-se o valor de 17,490 da covariância. Essa matriz de covariâncias tem a dimensão de 12×12 , pois são 12 semanas de avaliação.

Outro exemplo que será apresentado foi obtido com a estrutura de covariância UN, utilizando a opção `summary(Cons.UN)`. Têm-se os seguintes resultados:

```
> summary(Cons.UN)
```

```
Generalized least squares fit by REML
Model: Consumo ~ trat.f + periodo.f + (trat.f:periodo.f)
Data: dados
      AIC      BIC    logLik
2814.155 3326.776 -1281.077
```

Correlation Structure: General

Formula: $\sim 1 \mid \text{erroA}$

Parameter estimate(s):

Correlation:

	1	2	3	4	5	6	7	8	9	10	11
2	0.032										
3	0.497	0.394									
4	0.342	0.266	0.718								
5	0.368	0.053	0.639	0.692							
6	0.230	0.291	0.668	0.716	0.575						
7	0.311	0.320	0.661	0.588	0.471	0.765					
8	0.368	0.030	0.494	0.407	0.246	0.545	0.607				
9	0.410	-0.14	0.611	0.469	0.502	0.600	0.538	0.721			
10	0.146	0.282	0.595	0.471	0.499	0.649	0.649	0.621	0.712		
11	0.229	0.224	0.623	0.568	0.603	0.758	0.689	0.483	0.702	0.813	
12	0.025	0.341	0.268	0.181	0.421	0.388	0.400	0.089	0.163	0.581	0.507

Variance function:

Structure: Different standard deviations per stratum

Formula: $\sim 1 \mid \text{periodo.f}$

Parameter estimates:

	29	30	31	32	33	34
1.0000000	1.2348653	0.9600557	1.0392757	1.3856129	0.8168426	
35	36	37	38	39	40	
0.9179477	1.3605867	1.1663858	1.2309993	0.8985159	1.2783495	

Coefficients:

	Value	Std.Error	t-value	p-value
(Intercept)	120.965	1.821422	66.41241	0.0000
trat.fCP	-3.772	2.575879	-1.46435	0.1438
trat.ft1	1.135	2.575879	0.44063	0.6597
trat.ft2	-1.628	2.575879	-0.63202	0.5277
periodo.f30	-1.586	2.848401	-0.55680	0.5779
periodo.f31	6.442	1.791857	3.59515	0.0004
periodo.f32	9.706	2.132008	4.55252	0.0000
periodo.f33	7.691	2.510164	3.06394	0.0023
periodo.f34	6.535	2.070020	3.15697	0.0017
periodo.f35	12.456	2.054003	6.06426	0.0000
periodo.f36	6.485	2.477040	2.61804	0.0092
periodo.f37	4.850	2.157737	2.24773	0.0251
periodo.f38	-1.273	2.674408	-0.47599	0.6343

periodo.f39	3.514	2.151586	1.63321	0.1032
periodo.f40	0.464	2.919924	0.15891	0.8738
trat.fCP:periodo.f30	1.908	4.028248	0.47366	0.6360
trat.ft1:periodo.f30	-0.156	4.028248	-0.03873	0.9691
trat.ft2:periodo.f30	0.755	4.028248	0.18743	0.8514
trat.fCP:periodo.f31	-0.377	2.534068	-0.14877	0.8818
trat.ft1:periodo.f31	-1.191	2.534068	-0.47000	0.6386
trat.ft2:periodo.f31	-0.764	2.534068	-0.30149	0.7632
trat.fCP:periodo.f32	-1.462	3.015115	-0.48489	0.6280
trat.ft1:periodo.f32	-0.962	3.015115	-0.31906	0.7498
trat.ft2:periodo.f32	-1.006	3.015115	-0.33365	0.7388
trat.fCP:periodo.f33	1.303	3.549908	0.36705	0.7138
trat.ft1:periodo.f33	-0.198	3.549908	-0.05578	0.9555
trat.ft2:periodo.f33	0.279	3.549908	0.07859	0.9374
trat.fCP:periodo.f34	-2.357	2.927451	-0.80514	0.4212
trat.ft1:periodo.f34	-3.793	2.927451	-1.29567	0.1958
trat.ft2:periodo.f34	-2.578	2.927451	-0.88063	0.3790
trat.fCP:periodo.f35	-0.212	2.904799	-0.07298	0.9419
trat.ft1:periodo.f35	-3.713	2.904799	-1.27823	0.2019
trat.ft2:periodo.f35	-1.692	2.904799	-0.58248	0.5605
trat.fCP:periodo.f36	1.806	3.503064	0.51555	0.6064
trat.ft1:periodo.f36	-2.267	3.503064	-0.64715	0.5179
trat.ft2:periodo.f36	0.318	3.503064	0.09078	0.9277
trat.fCP:periodo.f37	-3.557	3.051501	-1.16566	0.2444
trat.ft1:periodo.f37	-1.116	3.051501	-0.36572	0.7148
trat.ft2:periodo.f37	-0.429	3.051501	-0.14059	0.8883
trat.fCP:periodo.f38	0.587	3.782185	0.15520	0.8767
trat.ft1:periodo.f38	-0.234	3.782185	-0.06187	0.9507
trat.ft2:periodo.f38	0.365	3.782185	0.09651	0.9232
trat.fCP:periodo.f39	5.584	3.042802	1.83515	0.0672
trat.ft1:periodo.f39	-0.056	3.042802	-0.01840	0.9853
trat.ft2:periodo.f39	1.986	3.042802	0.65269	0.5143
trat.fCP:periodo.f40	0.856	4.129396	0.20729	0.8359
trat.ft1:periodo.f40	-3.151	4.129396	-0.76307	0.4458
trat.ft2:periodo.f40	-2.580	4.129396	-0.62479	0.5324

Para a estrutura de covariância UN têm-se os valores de AIC (2814,155), BIC (3326,776) e \log da razão de verossimilhanças (-1281,077) e dos parâmetros de correlação (*correlation*) e a função de variância (*variance func-*

tion), as estimativas dos efeitos fixos com os seus respectivos erros-padrões (*Std.Error*) e a estatística *t* (*t-value*).

Para a estrutura de covariância UN, foi utilizado a função *corandcov* (SINGER; WILLET, 2003), a função e a rotina com o resultado estão descritos a seguir:

```
> corandcov <- function(glsob,cov=T,...){
+   corm <- corMatrix(glsob$modelStruct$corStruct)[[5]]
+   print(corm)
+   varstruct <- print(glsob$modelStruct$varStruct)
+   varests <- coef(varstruct, uncons=F, allCoef=T)
+   covm <- corm*glsoB$sigma^2*t(varests)%*%t(varests)
+   return(covm)}
```

```
> corandcov(Cons.UN)
```

```
      [,1]      [,2]      [,3]      [,4]      [,5]      [,6]      [,7]      [,8]
[1,] 1.0000000 0.03211496 0.4967979 0.3415744 0.36830942 0.2299289 0.3109862 0.36812616
[2,] 0.03211496 1.0000000 0.3941666 0.2663697 0.05286832 0.2913990 0.3203634 0.02986496
[3,] 0.49679787 0.39416663 1.0000000 0.7177511 0.63896289 0.6684318 0.6611679 0.49446425
[4,] 0.34157443 0.26636974 0.7177511 1.0000000 0.69206726 0.7155562 0.5883642 0.40693194
[5,] 0.36830942 0.05286832 0.6389629 0.6920673 1.0000000 0.5753417 0.4708310 0.24592464
[6,] 0.22992888 0.29139903 0.6684318 0.7155562 0.57534172 1.0000000 0.7654643 0.54481820
[7,] 0.31098619 0.32036343 0.6611679 0.5883642 0.47083098 0.7654643 1.0000000 0.60749629
[8,] 0.36812616 0.02986496 0.4944642 0.4069319 0.24592464 0.5448182 0.6074963 1.0000000
[9,] 0.41027296 -0.14497884 0.6114171 0.4691440 0.50242907 0.5997495 0.5381877 0.72050696
[10,] 0.14599115 0.28160894 0.5946974 0.4712342 0.49886649 0.6486730 0.6494816 0.62129398
[11,] 0.22923243 0.22386660 0.6233534 0.5684396 0.60301831 0.7583443 0.6890787 0.48254917
[12,] 0.02512733 0.34089972 0.2682903 0.1805443 0.42098913 0.3878559 0.3995856 0.08917559
      [,9]      [,10]      [,11]      [,12]
[1,] 0.4102730 0.1459912 0.2292324 0.02512733
[2,] -0.1449788 0.2816089 0.2238666 0.34089972
[3,] 0.6114171 0.5946974 0.6233534 0.26829032
[4,] 0.4691440 0.4712342 0.5684396 0.18054428
[5,] 0.5024291 0.4988665 0.6030183 0.42098913
[6,] 0.5997495 0.6486730 0.7583443 0.38785586
[7,] 0.5381877 0.6494816 0.6890787 0.39958556
[8,] 0.7205070 0.6212940 0.4825492 0.08917559
[9,] 1.0000000 0.7123148 0.7015130 0.16312712
[10,] 0.7123148 1.0000000 0.8134300 0.58098581
[11,] 0.7015130 0.8134300 1.0000000 0.50654560
[12,] 0.1631271 0.5809858 0.5065456 1.0000000
Variance function structure of class varIdent representing
      29      30      31      32      33      34      35      36      37
1.0000000 1.2348653 0.9600557 1.0392757 1.3856129 0.8168426 0.9179477 1.3605867 1.1663858
      38      39      40
1.2309993 0.8985159 1.2783495
      29      30      31      32      33      34      35      36      37
29 33.175768 1.315673 15.82330 11.777066 16.930732 6.230931 9.470656 16.616666 15.875817
```

```

30 1.315673 50.589473 15.50304 11.341127 3.001083 9.751402 12.047626 1.664672 -6.927673
31 15.823303 15.503039 30.57834 23.758665 28.199081 17.390533 19.330680 21.427847 22.714187
32 11.777066 11.341127 23.758667 35.832946 33.062977 20.152730 18.621556 19.089729 18.866884
33 16.930732 3.001083 28.19908 33.062977 63.694920 21.603651 19.867622 15.381234 26.938900
34 6.230931 9.751402 17.39053 20.152730 21.603651 22.135930 19.041549 20.088024 18.957083
35 9.470656 12.047626 19.33068 18.621556 19.867622 19.041549 27.954833 25.171483 19.116787
36 16.616666 1.664672 21.42785 19.089729 15.381234 20.088024 25.171483 61.414857 37.933910
37 15.875817 -6.927673 22.71419 18.866884 26.938900 18.957083 19.116787 37.933910 45.134164
38 5.962183 14.201846 23.31692 20.000755 28.229619 21.639290 24.348015 34.522493 33.930711
39 6.833179 8.240539 17.83929 17.610100 24.906870 18.465097 18.855304 19.571069 24.390723
40 1.065656 17.853232 10.92376 7.957655 24.739072 13.436290 15.556015 5.145681 8.069358
      38      39      40
29 5.962183 6.833179 1.065656
30 14.201846 8.240539 17.853232
31 23.316924 17.839289 10.923757
32 20.000755 17.610100 7.957655
33 28.229619 24.906870 24.739072
34 21.639290 18.465097 13.436290
35 24.348015 18.855304 15.556015
36 34.522493 19.571069 5.145681
37 33.930711 24.390723 8.069358
38 50.273205 29.848651 30.331503
39 29.848651 26.783819 19.302560
40 30.331503 19.302560 54.215096

```

Utilizando-se a função *corandcov* obtém-se a matriz de correlação e a matriz de covariâncias no caso da estrutura UN. Essa matriz têm a dimensão de 12×12 e vai ser útil para análise gráfica da estrutura de covariância UN. Foi realizada a comparação das diferentes estruturas de covariâncias, o que é feito utilizando-se o comando *anova*:

```
> anova(Cons.CS,Cons.CSH,Cons.AR1,Cons.ARH,Cons.UN)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
Cons.CS	1	50	2896.776	3100.197	-1398.388			
Cons.CSH	2	61	2869.275	3117.449	-1373.637	1 vs 2	49.50144	<.0001
Cons.AR1	3	50	2894.597	3098.019	-1397.299	2 vs 3	47.32253	<.0001
Cons.ARH	4	61	2860.121	3108.295	-1369.061	3 vs 4	56.47583	<.0001
Cons.UN	5	126	2814.155	3326.776	-1281.077	4 vs 5	175.96662	<.0001

Nota-se que no resultado acima têm a comparação das estruturas de covariâncias 1 (*Cons.CS*) e 2 (*Cons.CSH*), 2 e 3, e assim sucessivamente. Ainda nessa seção será discutido e comparado as estruturas de covariâncias duas a duas. Os resultados acima estão resumidos na Tabela 1 em que têm-se os valores dos critérios de Akaike (AIC) e do critério Bayesiano (BIC) para a variável consumo médio de ração.

Tabela 1 – Valores do critério de Akaike (AIC) e do critério Bayesiano (BIC) para cada estrutura de variância-covariância para a variável consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$).

Tipo de estrutura	Número de parâmetros	AIC	BIC
CS	50	2896,776	3100,197
CSH	61	2869,275	3117,449
AR(1)	50	2894,597	3098,019
ARH(1)	61	2860,121	3108,295
UN	126	2814,155	3326,776

Na Tabela 1 o número de parâmetros é calculado considerando o número de efeitos estimáveis do modelo (48) mais o número de parâmetros da matriz de covariâncias, por exemplo, a CS (2), totalizando 50 parâmetros. As estruturas de matrizes de covariância CSH, AR(1), ARH(1) e UN possuem 13, 2, 13 e 78 parâmetros, respectivamente.

Para cálculo dos valores de AIC e BIC são considerados o número de parâmetros estimáveis mais o número de parâmetros da estrutura de covariância. O cálculo para a estrutura de covariância CS está a seguir:

$$AIC = -2 * (-1398,388) + 2 * 50 = 2896,776$$

$$BIC = -2 * (-1398,388) + 50 * \ln(480 - 48) = 3100,197.$$

Podemos observar que os valores de BIC tem maiores valores à medida que se aumenta a quantidade de parâmetros dos modelos com as diferentes estruturas de covariâncias. Ambos os critérios AIC e BIC, penalizam modelos com maior número de parâmetros. Entretanto, para o BIC, esta penalidade é mais rigorosa, favorecendo modelos mais parcimoniosos (NUNEZ-ANTON; ZIMMERMAN, 2000).

De acordo com Barnett et al. (2010) e Littell et al. (2006) o objetivo é tentar selecionar uma estrutura de covariâncias que é o mais próximo possível da realidade dos dados e com escolha de uma estrutura mais parcimoniosa.

Para a variável consumo médio de ração, a estrutura de covariância não estruturada obteve menor valor de AIC (2814,155) em comparação com as demais estruturas (Tabela 1), sendo uma estrutura de covariância adequada

aos dados. A seguir está a comparação das estruturas de covariância UN com as demais estruturas.

Realizando a comparação das estruturas de covariâncias CS e UN pela função *anova* têm-se o seguinte resultado:

```
> anova(Cons.CS,Cons.UN)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
Cons.CS	1	50	2896.776	3100.197	-1398.388			
Cons.UN	2	126	2814.155	3326.776	-1281.077	1 vs 2	234.6214	<.0001

Então, a estatística do teste de razão de verossimilhanças (TRV) é dado por:

$$TRV = 2(-1281,077 + 1398,388) = 234,6214.$$

A estatística do TRV é um valor (234,6214) de uma qui-quadrado com 76 graus de liberdade (126 - 50) e valor-p <0,0001. A conclusão é que a estrutura de covariância não estruturada (UN) é significativamente melhor do que a simetria composta, a UN obteve menor valor de AIC (2814,155) do que a CS (2896,776). Outra comparação feita foi das estruturas de covariâncias UN e CSH, utilizando o comando *anova* têm-se o seguinte resultado:

```
> anova(Cons.UN,Cons.CSH)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
Cons.UN	1	126	2814.155	3326.776	-1281.077			
Cons.CSH	2	61	2869.275	3117.449	-1373.637	1 vs 2	185.1199	<.0001

A estatística do TRV é um valor (185,1199) de uma qui-quadrado com 65 graus de liberdade (126 - 61) e valor-p <0,0001. A conclusão é que a estrutura da matriz de covariância não estruturada (UN) é significativamente melhor do que a estrutura de covariância simetria composta heterogênea (CSH), a UN obteve um menor valor de AIC (2814,155) do que a CS (2869,275). A seguir têm-se a comparação das estruturas de covariâncias UN com a AR(1):

```
> anova(Cons.UN,Cons.AR1)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
Cons.UN	1	126	2814.155	3326.776	-1281.077			
Cons.AR1	2	50	2894.597	3098.019	-1397.299	1 vs 2	232.4424	<.0001

A estatística do TRV é um valor (232,4424) de uma qui-quadrado com 76 graus de liberdade (126 - 50) e valor-p <0,0001. A conclusão é que a estrutura da matriz de covariâncias UN é significativamente melhor do que a estrutura de covariância autorregressiva de primeira ordem (AR(1)), a UN obteve um menor valor de AIC (2814,155) do que a AR(1) (2894,597). A rotina e o resultado para comparar as estruturas de covariâncias UN com a ARH(1) estão a seguir:

```
> anova(Cons.UN,Cons.ARH)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
Cons.UN	1	126	2814.155	3326.776	-1281.077			
Cons.ARH	2	61	2860.121	3108.295	-1369.061	1 vs 2	175.9666	<.0001

A estatística do TRV é um valor (175,9666) de uma qui-quadrado com 65 graus de liberdade (126 - 61) e valor-p <0,0001. A conclusão é que a estrutura de covariância UN é significativamente melhor do que a estrutura de covariância autorregressiva heterogênea de primeira ordem (ARH(1)), pois a UN obteve um menor valor de AIC (2814,155) do que a ARH(1) (2860,121).

4.1.3 Modelos lineares mistos com o procedimento *mixed* para a variável consumo médio de ração

No procedimento *mixed* do pacote estatístico SAS foram utilizadas as estruturas de covariâncias VC, CS, CSH, AR(1), ARH(1), UN e HF. Para realizar a leitura dos dados do arquivo do tipo Texto (txt-separado por tabulações) no programa SAS. Primeiramente com a opção *Import Data...*,

com isso seleciona a opção *Tab Delimited File (*.txt)* que é o arquivo em formato. txt (PROJETO GALINHAS.txt) e aí buscamos o arquivo salvo no diretório do computador e logo em seguida nomeamos os dados (galinhas) e em seguida salva essas etapas no diretório do computador. Em seguida abre esse arquivo e acrescenta as rotinas. As linhas de comandos no programa SAS para importar os dados estão descritos a seguir:

```
/*Importando os dados no Programa SAS: Variável Consumo de ração*/
PROC IMPORT OUT= WORK.galinhas
DATAFILE= "C:\Users\note\Documents\pasta frangos\PROJETO GALINHAS.txt"
DBMS=TAB REPLACE;
GETNAMES=YES;
DATAROW=2;
RUN;
```

Quando têm-se o símbolo */** significa que essa linha de comando é algum comentário sobre o que está realizando. Para a variável consumo médio de ração as análises foram realizadas considerando a estrutura de covariância CS, para as demais as rotinas estão no Apêndice C. Foram as seguintes linhas de comandos no programa SAS:

```
/*Estrutura de covariância: Simetria composta (CS) */
title1 'Simetria composta (CS)';
title2 'Consumo de racao (gramas/ave/dia)';
proc mixed data=galinhas method=reml covtest;
class Tratamento Periodo Repeticao;
model Consumo=Tratamento Periodo Tratamento*Periodo/solution ddfm=sat;
repeated Periodo / subject = Repeticao(Tratamento) type=CS r rcorr;
ods output fitstatistics =fitcrs;
lsmeans Tratamento Periodo;
run;
```

Quando têm-se o nome *data=galinhas*, esse foi especificado no processo de importar os dados descritos acima e o método (*method = REML*) é o da máxima verossimilhança restrita. Na linha *class* têm todas as fontes de variação (Tratamento, Periodo e Repeticao). No procedimento *mixed*, primeiramente escreve o nome da variável Consumo, em seguida todos os

efeitos fixos são indicados na linha *model*, logo após escreve a solução (*solution*) dos efeitos fixos e a aproximação dos graus de liberdade é *Satterthwaite* (*ddfm=sat*). Ao utilizar o comando *repeated*, indicamos que o Período é um fator repetido, e que os dados estão ordenado pelas semanas de idade das poedeiras (29 a 40 semanas).

A linha de comando *Subject* indica o nível em que acontecem as medidas repetidas. Geralmente é o nível mais específico do modelo hierárquico que, nesse caso, refere-se a Repeticao (Tratamento), sendo uma variável no conjunto de dados. Com a opção *type* são escolhidos as diversas estruturas de covariâncias, como VC, CS, CSH, AR(1), ARH(1), UN e HF, no caso foi a CS. Finalmente, a opção *r* é utilizada para que a matriz de covariância para Repeticao (Tratamento) seja fornecido na análise para uma parcela experimental. Mais detalhes podem ser encontrados em Littel et al. (2006) e Verbeke e Molenberghs (2000).

As informações referentes ao nome da variável Consumo (*Dependent Variable*), da estrutura de covariância (*Covariance Structure*) utilizada, do método de estimação utilizado (*REML*), da aproximação dos graus de liberdade (*Degrees of Freedom Method*) em que esse foi *Satterthwaite*, o número de parâmetros de covariâncias (2), o número de níveis dos tratamentos (Tratamento) que são 4, das Semanas (Período) em um total de 12 e o número de repetições (Repeticao) que é 10 e as dimensões das matrizes (\mathbf{X}, \mathbf{Z}), do número de observações (480) do experimento, entre outras informações, estão descritos a seguir:

Simetria Composta (CS)	
Consumo de racao (gramas/ave/dia)	
The Mixed Procedure	
Model Information	
Data Set	WORK.GALINHAS
Dependent Variable	Consumo
Covariance Structure	Compound Symmetry
Subject Effect	Repeticao(Tratament)

2	17.4895	41.8164	17.4895	17.4895	17.4895	17.4895	17.4895
3	17.4895	17.4895	41.8164	17.4895	17.4895	17.4895	17.4895
4	17.4895	17.4895	17.4895	41.8164	17.4895	17.4895	17.4895
5	17.4895	17.4895	17.4895	17.4895	41.8164	17.4895	17.4895
6	17.4895	17.4895	17.4895	17.4895	17.4895	41.8164	17.4895
7	17.4895	17.4895	17.4895	17.4895	17.4895	17.4895	41.8164
8	17.4895	17.4895	17.4895	17.4895	17.4895	17.4895	17.4895
9	17.4895	17.4895	17.4895	17.4895	17.4895	17.4895	17.4895
10	17.4895	17.4895	17.4895	17.4895	17.4895	17.4895	17.4895
11	17.4895	17.4895	17.4895	17.4895	17.4895	17.4895	17.4895
12	17.4895	17.4895	17.4895	17.4895	17.4895	17.4895	17.4895
Estimated R Matrix for Repeticao(Tratament) 1 CN							
Row	Col8	Col9	Col10	Col11	Col12		
1	17.4895	17.4895	17.4895	17.4895	17.4895		
2	17.4895	17.4895	17.4895	17.4895	17.4895		
3	17.4895	17.4895	17.4895	17.4895	17.4895		
4	17.4895	17.4895	17.4895	17.4895	17.4895		
5	17.4895	17.4895	17.4895	17.4895	17.4895		
6	17.4895	17.4895	17.4895	17.4895	17.4895		
7	17.4895	17.4895	17.4895	17.4895	17.4895		
8	41.8164	17.4895	17.4895	17.4895	17.4895		
9	17.4895	41.8164	17.4895	17.4895	17.4895		
10	41.8164	17.4895	41.8164	17.4895	17.4895		
11	17.4895	17.4895	17.4895	41.8164	17.4895		
12	17.4895	17.4895	17.4895	17.4895	41.8164		

Nota-se que os valores 41,816 e 17,4895 da matriz de covariâncias que têm dimensão 12×12 são os mesmos encontrados com a função *getVarCov(Cons.CS)* da função *gls*. As estimativas dos parâmetros da matriz de covariâncias CS são apresentados a seguir:

Covariance Parameter Estimates					
Cov Parm	Subject	Estimate	Standard Error	Z Value	Pr > Z
CS	Repeticao(Tratament)	17.4895	4.6024	3.80	0.000
Residual		24.3269	1.7288	14.07	<.0001

O valor 17,4895 refere-se à variância a nível de parcela (erro (a)) e 24,3269 é valor da variância a nível de subparcela (erro (b)), em que a soma das duas variâncias têm-se o valor de 41,816. Com a opção *ods output fitstatistics=fitcrs* o usuário tem a opção de salvar e depois ver o resultado (*proc print data=fitcrs*) dos valores do critério de Akaike (AIC), critério de Akaike corrigido (AICC), critério Bayesiano (BIC) e duas vezes o máximo do logaritmo natural da função de verossimilhança (*-2 Res Log Likelihood*) da estrutura de covariância CS. A rotina e o resultado estão a seguir:

```
/* Definindo título Fit Statistics */
title1 'Simetria composta (CS)';
title2 'Consumo de racao (gramas/ave/dia)';
proc print data=fitcrs;
run;
```

Simetria composta (CS)		
Consumo de racao (gramas/ave/dia)		
Obs	Descr	Value
1	-2 Res Log Likelihood	2796.8
2	AIC (smaller is better)	2800.8
3	AICC (smaller is better)	2800.8
4	BIC (smaller is better)	2804.2

Para as demais estruturas de covariâncias consideradas foram comparados os valores de AIC, AICC, BIC e o *-2 Res Log Likelihood* (TABELA

2).

Tabela 2 – Valores do número de parâmetros (Npar), critério de Akaike (AIC), critério de Akaike corrigido (AICC), critério Bayesiano (BIC) e o -2 *Res Log Likelihood* para cada estrutura de variância-covariância para a variável consumo médio de ração ($\text{g.ave}^{-1}.\text{dia}^{-1}$).

Estrutura	Npar	-2 <i>Res Log Likelihood</i>	AIC	AICC	BIC
VC	1	2949,3	2951,3	2951,3	2953,0
CS	2	2796,8	2800,8	2800,8	2804,2
CSH	13	2747,3	2773,3	2774,1	2795,2
AR(1)	2	2794,6	2798,6	2798,6	2802,0
ARH(1)	13	2738,1	2764,1	2765,0	2786,1
UN	78	2562,2	2718,2	2753,1	2849,9
HF	13	2779,7	2805,7	2806,5	2827,6

Os valores do AIC (2718,2), do AICC (2753,1) e do -2 *Res Log Likelihood* (2562,2) da estrutura de covariância UN são menores em relação as demais estruturas de covariâncias. Para o critério Bayesiano (BIC) a estrutura de covariâncias ARH(1) apresentou menor valor (2786,1) em relação as demais estruturas de covariâncias. De acordo com Wolfinger (1996) deve-se escolher estruturas de covariâncias mais parcimoniosas e que adeque-se a realidade dos dados. Os resultados em valores absolutos dos critérios AIC, BIC do programa SAS são diferentes dos valores encontrados no programa R, pois o método de cálculo é diferente, será apresentada a seguir a fórmula utilizada para a estrutura de covariâncias CS:

$$AIC = 2796,8 + 2 * 2 = 2800,8$$

$$BIC = 2796,8 + 2 * \ln(480 - 2) = 2804,2.$$

Foram realizadas a comparação da estrutura de covariância UN com as demais estruturas de covariâncias. A rotina e os resultados da comparação da UN com a CS no programa SAS estão descritos a seguir:

```
/*CS:UN-Teste de razão de verossimilhanças*/
data _null_;
merge fitcrs(rename=(value=reference)) fitcrun(rename=(value=nested));
retain trv;
```

```

if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 78 - 2;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp;
format valorp 10.8;
end;
run;

```

```

trv=234.62134935 gl=76 valorp=0.00000000

```

Para realizar o teste na linha *merge* deve especificar o nome da estrutura de covariância salvo na opção *proc print* (*fitcrs*) e renomeia essa por *reference* e o mesmo é feito para a estrutura de covariância UN (*nested*) e com a função *retain* especifica o nome da estatística do teste de razão de verossimilhanças (*trv*) e logo a seguir seleciona *-2 Res Log Likelihood* de cada estrutura de covariância. Depois define os graus de liberdade 78 da UN e 2 da CS e o valor-p (*valorp*). Na linha de comando *put* define o *trv*, *gl* e o *valorp*.

A estatística do teste qui-quadrado para a comparação da estrutura de covariância simetria composta com a não estruturada é a seguinte: $\chi^2 = 2796,8 - 2562,2 = 234,62$ com $78 - 2 = 76$ graus de liberdade. Pelo estatística do teste de razão de verossimilhanças (TRV) têm-se que o valor-p=0,00000000, com isso a estrutura de covariância não estruturada é mais adequada do que a simetria composta, em que o resultado é o mesmo ao encontrado com o programa estatístico R. Também foi realizada a comparação das estrutura de covariância UN com a CSH, a rotina e o resultado são os seguintes:

```

/*UN:ARH(1)-Teste de razão de verossimilhanças*/
data _null_;
merge fitcrarh1(rename=(value=reference))
fitcrun(rename=(value=nested));

```

```

retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 78 - 13;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp=;
format valorp 10.8;
end;
run;

```

```
trv=175.96661602 gl=65 valorp=0.00000000
```

A estatística do teste qui-quadrado para a comparação da estrutura de covariância autorregressiva heterogênea de primeira ordem (ARH(1)) com a não estruturada (UN) é a seguinte: $\chi^2 = 2738,1 - 2562,2 = 175,966$ com $78 - 13 = 65$ graus de liberdade. Pelo estatística do TRV têm-se que o valor-p = 0,00000000, com isso a estrutura de covariância não estruturada é mais adequada do que a ARH(1). As rotinas para a comparação das estruturas de covariâncias UN com a VC, CSH, AR(1) e HF estão descritos a seguir:

```

/*UN:VC- Teste de razão de verossimilhanças*/
data _null_;
merge fitcrvc(rename=(value=reference)) fitcrun(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 78 - 1;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp=;
format valorp 10.8;
end;
run;

```

```
trv=387.11298754 gl=77 valorp=0.00000000
```

```

/*UN:CSH - Teste de razão de verossimilhanças*/
data _null_;
merge fitcrcsh(rename=(value=reference))
fitcrun(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 78 - 13;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp;
format valorp 10.8;
end;
run;

```

```
trv=185.11991231 gl=65 valorp=0.00000000
```

```

/*UN:AR(1)-Teste de razão de verossimilhanças*/
data _null_;
merge fitcrar1(rename=(value=reference))
fitcrun(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 78 - 2;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp;
format valorp 10.8;
end;
run;

```

```
trv=232.44244329 gl=76 valorp=0.00000000
```

```

/*UN:HF-Teste de razão de verossimilhanças*/
data _null_;
merge fitcrhf(rename=(value=reference)) fitcrun(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;

```

```

if descr="-2 Res Log Likelihood" then do;
gl= 78 - 13;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp=;
format valorp 10.8;
end;
run;

```

```
trv=217.51319368 gl=65 valorp=0.00000000
```

Comparando a estrutura de covariância UN com a estrutura de covariância componentes de variância (VC) pela estatística do TRV (387,11298754) com 77 graus de liberdade, têm-se que o valor-p= 0,00000000, com isso a estrutura de covariância não estruturada é mais adequada do que a VC.

E a mesma comparação foi realizada com a estrutura de covariância simetria composta heterogênea (CSH), na estatística do TRV (185,11991231) em que têm-se um valor-p=0,00000000, com 65 graus de liberdade com isso a estrutura de covariância UN é mais adequada do que a CSH. Comparando a estrutura de covariância UN com as estruturas de covariâncias autorregressiva de primeira ordem (AR(1)) e a Huynh-Feldt (HF) pela estatística do TRV, a UN foi mais adequada do que a AR(1) e HF. Com os resultados apresentados acima têm-se que a estrutura de covariâncias UN foi mais adequada em relação as demais estruturas de covariâncias (VC, CS, CSH, AR(1), ARH(1) e HF).

A seguir são apresentados os testes F para os efeitos fixos quando-se utiliza a estrutura de covariâncias simetria composta (CS).

Estrutura Simetria Composta				
Type 3 Tests of Fixed Effects				
	Num	Den		
Effect	DF	DF	F Value	Pr > F
Tratamento	3	36	1.34	0.2782
Periodo	11	396	28.36	<.0001
Tratamento*Periodo	33	396	0.63	0.9469

Os resultados mostram que não houve diferença significativa entre os tratamentos (*Tratamento*) com valor-p=0,2782, nem para a interação tratamentos \times semanas (*Tratamento*Periodo*) com valor-p=0,9469. No entanto, foi encontrada diferença significativa no consumo médio de ração ao longo das semanas de avaliação (*Periodo*) com valor-p < 0,0001. Os graus de liberdade são calculados de forma aproximada, utilizando-se a fórmula de *Satterthwaite*. Para a estrutura de covariâncias UN os testes F estão apresentados a seguir:

Estrutura Não estruturada				
Type 3 Tests of Fixed Effects				
	Num	Den		
Effect	DF	DF	F Value	Pr > F
Tratamento	3	36	1.34	0.2782
Periodo	11	36	50.55	<.0001
Tratamento*Periodo	33	36	2.46	0.0046

Nota-se que os testes F são influenciados pela escolha da estrutura de covariâncias, na estrutura UN, o valor-p do efeito de interação Tratamento \times Periodo é 0,00046, enquanto que com a estrutura simetria composta o valor-p da estatística F é 0,9469.

Com o comando *lsmeans (Least Squares Means)* têm-se as estimativas das médias (*Estimate*), os erros-padrões da média (*Standard Error*), os graus de liberdade (*DF*) e o teste t (*t Value*) para os efeitos fixos (Tratamento e Periodo). Os resultados desse comando considerando a estrutura CS são apresentados a seguir:

Simetria Composta (CS)
Consumo de racao (gramas/ave/dia)
The Mixed Procedure
Least Squares Means
Standard

Effect	Tratamento	Periodo	Estimate	Error	DF	t Value	Pr > t
Tratamento	CN		125.57	1.3970	36	89.89	<.0001
Tratamento	CP		122.14	1.3970	36	87.43	<.0001
Tratamento	T1		125.30	1.3970	36	89.69	<.0001
Tratamento	T2		123.50	1.3970	36	88.40	<.0001
Periodo		29	119.90	1.0225	148	117.27	<.0001
Periodo		30	118.94	1.0225	148	116.33	<.0001
Periodo		31	125.76	1.0225	148	123.00	<.0001
Periodo		32	128.75	1.0225	148	125.92	<.0001
Periodo		33	127.94	1.0225	148	125.13	<.0001
Periodo		34	124.25	1.0225	148	121.52	<.0001
Periodo		35	130.95	1.0225	148	128.07	<.0001
Periodo		36	126.35	1.0225	148	123.57	<.0001
Periodo		37	123.47	1.0225	148	120.76	<.0001
Periodo		38	118.81	1.0225	148	116.20	<.0001
Periodo		39	125.29	1.0225	148	122.54	<.0001
Periodo		40	119.14	1.0225	148	116.53	<.0001

Na linha de comando *lsmeans* quando têm-se a estrutura de covariância CS, tem as médias para os tratamentos (*Tratamento*) e os valores de erros-padrões da média (1,397), para o efeito de semanas (*Periodo*) em que têm-se as médias e os respectivos erros-padrões da média com valor de 1,0225 para cada semana, pois na estrutura de covariância CS têm-se a mesma estimativa de erro-padrão da média.

Na Tabela 3 estão apresentadas as médias e os respectivos erros-padrões para cada estrutura de covariância considerada e para as diferentes dietas experimentais.

Tabela 3 – Estimativas das médias e erros-padrões da média para os tratamentos considerando diferentes estruturas de covariâncias para a variável consumo médio de ração.

Estrutura	Tratamentos			
	CN	CP	T1	T2
VC	125,57±0,590	122,14±0,590	125,30±0,590	123,50±0,590
CS	125,57±1,397	122,14±1,397	125,30±1,397	123,50±1,397
CSH	125,57±1,460	122,14±1,460	125,30±1,460	123,50±1,460
AR(1)	125,57±1,048	122,14±1,048	125,30±1,048	123,50±1,048
ARH(1)	125,57±1,094	122,14±1,094	125,30±1,094	123,50±1,094
UN	125,57±1,397	122,14±1,397	125,30±1,397	123,50±1,397
HF	125,57±1,531	122,14±1,531	125,30±1,531	123,50±1,531

As estruturas de covariâncias CS e UN apresentam os mesmos valores de estimativas dos erros-padrões da média (1,397). As estruturas VC, AR(1) e ARH(1) apresentam menores valores de erros-padrões da média em comparação com as demais e as estruturas HF e CSH apresentam maiores valores de erros-padrões da média. Os erros-padrões da média são importantes para verificar a precisão das estimativas, quanto menor os valores mais precisos são as estimativas.

4.1.4 Análise de variância da variável consumo médio de ração em esquema de parcela subdividida no tempo com a função *aov*

Foi realizada a análise de variância da variável consumo médio de ração em esquema em parcela subdividida no tempo, com os tratamentos (CN, CP, T1 e T2) a na parcela e o tempo na subparcela, a estrutura de covariância do esquema de parcela subdividida no tempo é a CS. Essa análise foi realizada a título de comparação com o uso da técnica de modelos lineares mistos.

No presente estudo a análise de variância foi realizada utilizando a função *aov* do pacote *car* do programa estatístico R (R CORE TEAM, 2016).

Na função *aov*, quando têm-se o esquema de parcela subdividida no tempo em DIC ou DBC, é necessário especificar os erros na parcela, com

a adição do termo *Error*, colocando entre parênteses o termo especificado. O modelo utilizado foi em esquema de parcela subdividida no tempo com DIC. Na função *aov*, quando especifica-se o termo *Error*, o erroA refere-se às repetições dentro de tratamentos. A rotina é a seguinte:

```
> library(car)
> modelo.consumo<- aov(Consumo~trat.f*periodo.f+
+                      Error(erroA),data=dados)
```

Por meio da função *aov* especifica a variável *Consumo*, os fatores *trat.f*periodo.f* e do termo *Error(erroA)* dos dados. Com a função *summary()* têm-se a análise de variância do *modelo.consumo*. Os resultados são os seguintes:

```
> summary(modelo.consumo)
```

```
Error: erroA
      Df Sum Sq Mean Sq F value Pr(>F)
trat.f   3   938   312.7   1.335  0.278
Residuals 36  8431   234.2

Error: Within
      Df Sum Sq Mean Sq F value Pr(>F)
periodo.f   11  7590   690.0  28.36 <2e-16 ***
trat.f:periodo.f 33   506   15.3   0.63  0.947
Residuals   396  9633   24.3

---
Signif. codes:
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Na função *aov* a análise têm-se duas partes, a primeira avalia a parcela com os fatores *trat.f* e *Residuals*, em que esse é o *erroA* e na subparcela

têm-se os fatores *periodo.f*, *trat.f:periodo.f* e *Residuals*, esse é o valor dos resíduos na subparcela com 396 graus de liberdade.

Os resultados mostram que não houve diferença significativa entre os tratamentos(*trat.f*) com valor-p=0,278, nem para a interação tratamentos × semanas (*trat.f:periodo.f*) com valor-p=0,947. No entanto, foi encontrada diferença significativa no consumo médio de ração ao longo das semanas de avaliação (*periodo.f*) com valor-p $< 2 \times 10^{-16}$.

Assim, pode-se concluir que a adição de enzimas não afetou o consumo de ração de poedeiras no período de 29 a 40 semanas de idade. Freitas, Fuentes e Espíndola (2000) não perceberam diferença significativa sobre o consumo de ração entre as aves que receberam as dietas sem e com suplementação enzimática o que indica que a adição de enzimas não foi capaz de influenciar no consumo de ração.

4.1.5 Modelos lineares mistos com a função *lmer* para a variável consumo médio de ração

Com a função *lmer* do programa estatístico R também foram feitas as análises das variáveis sob estudo considerando tratamento, tempo e a interação entre eles como fatores fixos. Como efeitos aleatórios têm-se os erros, em que o erroA corresponde à fonte de variação repetição dentro dos tratamentos, no DIC em um esquema em parcela subdividida no tempo.

Essa função pertence ao pacote *lme4* e não apresenta os valores-p na análise de variância. Kuznetsova, Brockhoff e Christensen (2012) criaram o pacote *lmerTest* que considera a análise de variância do tipo III com aproximação *Satterthwaite* para os graus de liberdade do denominador . A função *lmer* é a mesma nos dois pacotes, sendo que essa função no pacote *lmerTest* é um complemento do pacote *lme4*. A especificação da rotina com a função *lmer* para a variável consumo médio de ração quando têm-se o esquema de parcela subdividida no tempo são as seguintes:

```
> library(lmerTest)
> CR.lmertest<-lmer(Consumo~trat.f+ (1|erroA)+periodo.f
+
+ (trat.f:periodo.f),data=dados)
```

Com a função *lmer*, quando têm-se algum efeito aleatório, no presente estudo o erroA, foi especificado (1|erroA) e os efeitos fixos (*trat.f*, *periodo.f* e (*trat.f:periodo.f*)), além da variável *Consumo*. A análise de variância da função *lmer* com o pacote *lmerTest* é obtida pela função *anova*, especificando o nome (*CR.lmertest*) para a variável consumo médio de ração. A rotina e o resultado estão a seguir:

```
>anova(CR.lmertest)
```

```
Analysis of Variance Table of type III with Satterthwaite
approximation for degrees of freedom
```

	Sum Sq	Mean Sq	NumDF	DenDF	F.value	Pr(>F)
trat.f	97.4	32.48	3	36	1.3350	0.2782
periodo.f	7589.7	689.98	11	396	28.3627	<2e-16 ***
trat.f:periodo.f	505.7	15.32	33	396	0.6299	0.9469

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Os resultados da análise de variância da função *lmer* são equivalentes aos encontrados com a função *aov* no que se refere aos testes F. As somas de quadrados de tratamentos são diferentes nas duas funções, pois na função *aov* o método utilizado para a estimação dos efeitos fixos é dos mínimos quadrados ordinários (OLS - *Ordinary Least Squares*) e já na função *lmer* é o método dos mínimos quadrados generalizados (GLS- *Generalized Least Squares*). O método da máxima verossimilhança restrita REML é usado para estimação de componentes de variância e na predição (BLUP) dos efeitos aleatórios (GARCIA, 2004).

Pelo fato do método de estimação ser diferente o valor da soma de quadrados de tratamentos pela função *aov* é 938 e pela função *lmer* o valor

é 97,4, mas essa diferença nos valores das somas de quadrados das duas funções não afetam o resultado do teste F.

Os resultados da análise de variância para a variável consumo médio de ração mostram que não houve diferença significativa para os tratamentos, e para tratamentos \times semanas, apenas para o efeito de semanas.

Ao utilizar a função *Varcorr* têm-se as estimativas dos desvios-padrões (*Std.Dev.*) para os efeitos aleatórios. A rotina e o resultado estão descritos a seguir:

```
> VarCorr(CR.lmertest)
```

Groups	Name	Std.Dev.
erroA	(Intercept)	4.1820
Residual		4.9322

Os valores das estimativas das variâncias são obtidas ao elevar o desvio-padrão ao quadrado, os resultados estão descritos a seguir:

$$\sigma_{\beta_{k(i)}}^2 = 4,1820^2 = 17,4895$$

$$\sigma_{\epsilon_{ijk}}^2 = 4,9322^2 = 24,3269$$

O valor 17,4895 refere-se à variância na parcela e 24,3269 é valor da variância na subparcela no caso do esquema de parcela subdividida no tempo.

No pacote *lmerTest* do programa R pode-se obter as médias para os tratamentos (*trat.f*), semanas (*periodo.f*) e a interação dos dois fatores, mas apenas o fator semanas (*periodo.f*) foi significativo no teste F. A rotina e os resultados estão descritos a seguir com as médias e seus respectivos erros-padrões para os efeitos fixos:

```
> CR.lsmmeans<-step(CR.lmertest,reduce.fixed = FALSE,
+                   reduce.random = FALSE)
```

```
> names(CR.lsmmeans)
```

```
[1] "response"          "call"
[3] "corr.ints1"        "rand.table"
[5] "anova.table"       "lsmeans.table"
[7] "diffs.lsmeans.table" "model"
```

Acima foi definido a função *step* e com a opção de colocar o nome (*names(CR.lsmeans)*) têm-se as opções de análise que a função realiza, por exemplo, com a opção *anova.table* têm-se a análise de variância. Mas agora o usuário do programa R deve escolher o nome *lsmeans.table* para obter as estimativas da média e os seus respectivos erros-padrões. Para isso, deve-se colocar o nome *CR.lsmeans\$lsmeans.table*, pois com o nome *CR.lsmeans*, mais o símbolo *\$* e acrescenta a opção *lsmeans.table*. A rotina e os resultados estão a seguir:

```
>CR.lsmeans$lsmeans.table
```

	trat.f	periodo.f	Estimate	Standard Error	DF	t-value	Lower CI	Upper CI	p-value
trat.f	CN	CN	<NA> 125.5720	1.3970	36.0	89.89	122.7387	128.4053	0
trat.f	CP	CP	<NA> 122.1399	1.3970	36.0	87.43	119.3066	124.9732	0
trat.f	T1	T1	<NA> 125.3039	1.3970	36.0	89.69	122.4706	128.1372	0
trat.f	T2	T2	<NA> 123.4985	1.3970	36.0	88.40	120.6652	126.3318	0
periodo.f	29	<NA>	29 119.8988	1.0225	147.7	117.27	117.8782	121.9193	0
periodo.f	30	<NA>	30 118.9395	1.0225	147.7	116.33	116.9190	120.9600	0
periodo.f	31	<NA>	31 125.7578	1.0225	147.7	123.00	123.7372	127.7783	0
periodo.f	32	<NA>	32 128.7473	1.0225	147.7	125.92	126.7267	130.7678	0
periodo.f	33	<NA>	33 127.9357	1.0225	147.7	125.13	125.9152	129.9563	0
periodo.f	34	<NA>	34 124.2518	1.0225	147.7	121.52	122.2312	126.2723	0
periodo.f	35	<NA>	35 130.9505	1.0225	147.7	128.07	128.9300	132.9710	0
periodo.f	36	<NA>	36 126.3480	1.0225	147.7	123.57	124.3275	128.3685	0
periodo.f	37	<NA>	37 123.4732	1.0225	147.7	120.76	121.4527	125.4938	0
periodo.f	38	<NA>	38 118.8053	1.0225	147.7	116.20	116.7847	120.8258	0
periodo.f	39	<NA>	39 125.2913	1.0225	147.7	122.54	123.2707	127.3118	0
periodo.f	40	<NA>	40 119.1440	1.0225	147.7	116.53	117.1235	121.1645	0
trat.f:periodo.f	CN 29	CN	29 120.9650	2.0449	147.7	59.15	116.9240	125.0060	0
trat.f:periodo.f	CP 29	CP	29 117.1930	2.0449	147.7	57.31	113.1520	121.2340	0
trat.f:periodo.f	T1 29	T1	29 122.1000	2.0449	147.7	59.71	118.0590	126.1410	0
trat.f:periodo.f	T2 29	T2	29 119.3370	2.0449	147.7	58.36	115.2960	123.3780	0
trat.f:periodo.f	CN 30	CN	30 119.3790	2.0449	147.7	58.38	115.3380	123.4200	0
trat.f:periodo.f	CP 30	CP	30 117.5150	2.0449	147.7	57.47	113.4740	121.5560	0
trat.f:periodo.f	T1 30	T1	30 120.3580	2.0449	147.7	58.86	116.3170	124.3990	0
trat.f:periodo.f	T2 30	T2	30 118.5060	2.0449	147.7	57.95	114.4650	122.5470	0
trat.f:periodo.f	CN 31	CN	31 127.4070	2.0449	147.7	62.30	123.3660	131.4480	0
trat.f:periodo.f	CP 31	CP	31 123.2580	2.0449	147.7	60.28	119.2170	127.2990	0
trat.f:periodo.f	T1 31	T1	31 127.3510	2.0449	147.7	62.28	123.3100	131.3920	0
trat.f:periodo.f	T2 31	T2	31 125.0150	2.0449	147.7	61.13	120.9740	129.0560	0
trat.f:periodo.f	CN 32	CN	32 130.6710	2.0449	147.7	63.90	126.6300	134.7120	0
trat.f:periodo.f	CP 32	CP	32 125.4370	2.0449	147.7	61.34	121.3960	129.4780	0

trat.f:periodo.f	T1	32	130.8440	2.0449	147.7	63.99	126.8030	134.8850	0
trat.f:periodo.f	T2	32	128.0370	2.0449	147.7	62.61	123.9960	132.0780	0
trat.f:periodo.f	CN	33	128.6560	2.0449	147.7	62.92	124.6150	132.6970	0
trat.f:periodo.f	CP	33	126.1870	2.0449	147.7	61.71	122.1460	130.2280	0
trat.f:periodo.f	T1	33	129.5930	2.0449	147.7	63.37	125.5520	133.6340	0
trat.f:periodo.f	T2	33	127.3070	2.0449	147.7	62.26	123.2660	131.3480	0
trat.f:periodo.f	CN	34	127.5000	2.0449	147.7	62.35	123.4590	131.5410	0
trat.f:periodo.f	CP	34	121.3710	2.0449	147.7	59.35	117.3300	125.4120	0
trat.f:periodo.f	T1	34	124.8420	2.0449	147.7	61.05	120.8010	128.8830	0
trat.f:periodo.f	T2	34	123.2940	2.0449	147.7	60.29	119.2530	127.3350	0
trat.f:periodo.f	CN	35	133.4210	2.0449	147.7	65.25	129.3800	137.4620	0
trat.f:periodo.f	CP	35	129.4370	2.0449	147.7	63.30	125.3960	133.4780	0
trat.f:periodo.f	T1	35	130.8430	2.0449	147.7	63.98	126.8020	134.8840	0
trat.f:periodo.f	T2	35	130.1010	2.0449	147.7	63.62	126.0600	134.1420	0
trat.f:periodo.f	CN	36	127.4500	2.0449	147.7	62.33	123.4090	131.4910	0
trat.f:periodo.f	CP	36	125.4840	2.0449	147.7	61.36	121.4430	129.5250	0
trat.f:periodo.f	T1	36	126.3180	2.0449	147.7	61.77	122.2770	130.3590	0
trat.f:periodo.f	T2	36	126.1400	2.0449	147.7	61.68	122.0990	130.1810	0
trat.f:periodo.f	CN	37	125.8150	2.0449	147.7	61.53	121.7740	129.8560	0
trat.f:periodo.f	CP	37	118.4860	2.0449	147.7	57.94	114.4450	122.5270	0
trat.f:periodo.f	T1	37	125.8340	2.0449	147.7	61.54	121.7930	129.8750	0
trat.f:periodo.f	T2	37	123.7580	2.0449	147.7	60.52	119.7170	127.7990	0
trat.f:periodo.f	CN	38	119.6920	2.0449	147.7	58.53	115.6510	123.7330	0
trat.f:periodo.f	CP	38	116.5070	2.0449	147.7	56.97	112.4660	120.5480	0
trat.f:periodo.f	T1	38	120.5930	2.0449	147.7	58.97	116.5520	124.6340	0
trat.f:periodo.f	T2	38	118.4290	2.0449	147.7	57.91	114.3880	122.4700	0
trat.f:periodo.f	CN	39	124.4790	2.0449	147.7	60.87	120.4380	128.5200	0
trat.f:periodo.f	CP	39	126.2910	2.0449	147.7	61.76	122.2500	130.3320	0
trat.f:periodo.f	T1	39	125.5580	2.0449	147.7	61.40	121.5170	129.5990	0
trat.f:periodo.f	T2	39	124.8370	2.0449	147.7	61.05	120.7960	128.8780	0
trat.f:periodo.f	CN	40	121.4290	2.0449	147.7	59.38	117.3880	125.4700	0
trat.f:periodo.f	CP	40	118.5130	2.0449	147.7	57.96	114.4720	122.5540	0
trat.f:periodo.f	T1	40	119.4130	2.0449	147.7	58.40	115.3720	123.4540	0
trat.f:periodo.f	T2	40	117.2210	2.0449	147.7	57.32	113.1800	121.2620	0

Com os resultados da função *step* com a opção *CR.lsmmeans\$lsmmeans.table*, têm-se os valores das médias (*Estimate*) de cada fator em estudo, os seus respectivos erros-padrões (*Standard Error*) para todos os efeitos fixos, com valores semelhantes ao do procedimento *mixed* do SAS. Para a estrutura de covariância CS nas diferentes dietas têm-se o valor de 1,397 para o erro-padrão da média, 1,0225 para as semanas e 2,0449 para a interação dos dois fatores.

4.1.6 Análise gráfica das estruturas de covariância para a variável consumo médio de ração

O gráfico que será apresentado nessa seção é útil como análise exploratória, fornecendo indicativos sobre a estrutura de covariância não estruturada (UN), se essa é adequada aos dados e deve ser escolhida.

Para análise gráfica das estruturas de covariância da variável consumo médio de ração foram utilizados o pacote *lattice* do programa R e as informações da função *gls* utilizada na seção 4.1.2. Para a confecção da Figura 6 utilizou-se as seguintes linhas de comandos:

```
> Semanas<-c(1,1,2,1,2,3,1,2,3,4,1,2,3,4,5,1,2,3,4,5,6,1,
+           2,3,4,5,6,7,1,2,3,4,5,6,7,8,1,2,3,4,5,6,7,8,
+           9,1,2,3,4,5,6,7,8,9,10,1,2,3,4,5,6,7,8,9,10,
+           11,1,2,3,4,5,6,7,8,9,10,11,12)
> distancia.cr<-c(0,1,0,2,1,0,3,2,1,0,4,3,2,1,0,5,4,3,2,
+                1,0,6,5,4,3,2,1,0,7,6,5,4,3,2,1,0,8,7,
+                6,5,4,3,2,1,0,9,8,7,6,5,4,3,2,1,0,10,
+                9,8,7,6,5,4,3,2,1,0,11,10,9,8,7,6,5,4,
+                3,2,1,0)
> Covun.cr<-c(33.175768,1.315673,50.589473,15.82330,
+             15.50304,30.57834,11.777066,11.341127,
+             23.758665,35.832946,16.930732,3.001083,
+             28.199081,33.062977,63.694920,6.230931,
+             9.751402,17.390533,20.152730,21.603651,
+             22.135930,9.470656,12.047626,19.330680,
+             18.621556,19.867622,19.041549,27.954833,
+             16.616666,1.664672,21.427847,19.089729,
+             15.381234,20.088024,25.171483,61.414857,
+             15.875817,-6.927673,22.714187,18.866884,
+             26.938900,18.957083,19.116787,37.933910,
+             45.134164,5.962183,14.201846,23.316924,
+             20.000755,28.229619,21.639290,24.348015,
+             34.522493,33.930711,50.273205,6.833179,
+             8.240539,17.839289,17.610100,24.906870,
+             18.465097,18.855304,19.571069,24.390723,
+             29.848651,26.783819,1.065656,17.853232,
+             10.923757,7.957655,24.739072,13.436290,
+             15.556015,5.145681,8.069358,30.331503,
```

```

+           19.302560,54.215096)
> distancia.cr<-factor(distancia.cr)
> Semanas<-factor(Semanas)
> require(lattice)
> par(mar=c(4,4,0,0)+.1)
> interaction.plot(distancia.cr,Semanas,Covun.cr,type="l",
+                 lty=1:6,xlab="Distância (Semanas)",
+                 legend =F,ylab="Covariância Residual",
+                 lwd=3, col=1)
> legend("topright", bty='n',xpd=NA,title = "Semanas",
+       c("1","2","3","4","5","6","7","8","9","10",
+       "11","12"),lwd=1,lty=1:12,cex=0.8)

```

Os valores na linha de comando *Semanas* indicam que temos informações referentes a matriz de covariâncias UN, são 78 parâmetros e como essa matriz é uma triangular superior definida positiva, têm-se as informações referentes a semana 1, depois 1,2, logo após 1,2,3 e assim sucessivamente até 1,2,...,12. A partir dessas informações pode realizar as dimensões entre as observações (*distancia.cr*) a distância 0 representa a variância e essas distâncias vão seguindo 1,0, depois 2,1,0 e assim sucessivamente até 11,10,...,0.

Os valores descritos na linha de comando *Covun.cr* como por exemplo, 33,175768 representam a variância para a distância 0, o valor 1,315673 representam a covariância para a distância 1, o valor 50,589473 representa a distância 2 e o valor 15,82330 a distância 1 e assim sucessivamente. Na distância 0 são plotadas as variâncias, na distância 1 tem a covariância entre a semana 1 e 2, na distância 2 tem a covariância entre as semanas 1 e 3, 2 e 4, e assim sucessivamente. Para facilitar o entendimento dessas informações foi utilizado o programa SAS com a matriz de covariâncias UN:

Obs	semana1	semana2	distancia	CovParm	Subject	Estimate	StdErr	ZValue	ProbZ
1	1	1	0	UN(1,1)	Repeticao(Tratament)	33.1753	7.8195	4.24	<.0001
2	2	1	1	UN(2,1)	Repeticao(Tratament)	1.3161	6.8314	0.19	0.8472
3	2	2	0	UN(2,2)	Repeticao(Tratament)	50.5896	11.9241	4.24	<.0001
4	3	1	2	UN(3,1)	Repeticao(Tratament)	15.8237	5.9275	2.67	0.0076
5	3	2	1	UN(3,2)	Repeticao(Tratament)	15.5037	7.0462	2.20	0.0278

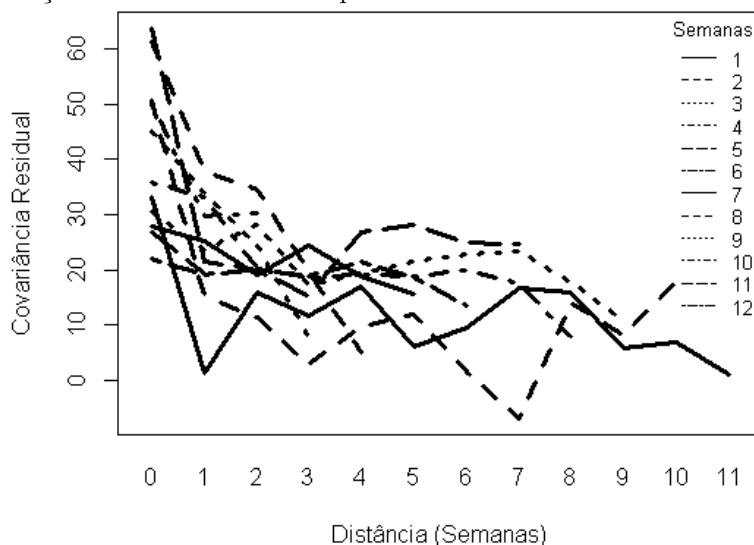
6	3	3	0	UN(3,3)	Repeticao(Tratament)	30.5798	7.2077	4.24	<.0001
7	4	1	3	UN(4,1)	Repeticao(Tratament)	11.7775	6.0725	1.94	0.0524
8	4	2	2	UN(4,2)	Repeticao(Tratament)	11.3418	7.3437	1.54	0.1225
9	4	3	1	UN(4,3)	Repeticao(Tratament)	23.7601	6.7912	3.50	0.0005
10	4	4	0	UN(4,4)	Repeticao(Tratament)	35.8342	8.4462	4.24	<.0001
11	5	1	4	UN(5,1)	Repeticao(Tratament)	16.9313	8.1647	2.07	0.0381
12	5	2	3	UN(5,2)	Repeticao(Tratament)	3.0019	9.4742	0.32	0.7514
13	5	3	2	UN(5,3)	Repeticao(Tratament)	28.2009	8.7291	3.23	0.0012
14	5	4	1	UN(5,4)	Repeticao(Tratament)	33.0645	9.6836	3.41	0.0006
15	5	5	0	UN(5,5)	Repeticao(Tratament)	63.6966	15.0134	4.24	<.0001
16	6	1	5	UN(6,1)	Repeticao(Tratament)	6.2315	4.6345	1.34	0.1788
17	6	2	4	UN(6,2)	Repeticao(Tratament)	9.7520	5.8095	1.68	0.0932
18	6	3	3	UN(6,3)	Repeticao(Tratament)	17.3919	5.2160	3.33	0.0009
19	6	4	2	UN(6,4)	Repeticao(Tratament)	20.1538	5.7721	3.49	0.0005
20	6	5	1	UN(6,5)	Repeticao(Tratament)	21.6049	7.2204	2.99	0.0028
21	6	6	0	UN(6,6)	Repeticao(Tratament)	22.1369	5.2177	4.24	<.0001
22	7	1	6	UN(7,1)	Repeticao(Tratament)	9.4712	5.3155	1.78	0.0748
23	7	2	5	UN(7,2)	Repeticao(Tratament)	12.0483	6.5816	1.83	0.0672
24	7	3	4	UN(7,3)	Repeticao(Tratament)	19.3322	5.8419	3.31	0.0009
25	7	4	3	UN(7,4)	Repeticao(Tratament)	18.6227	6.1205	3.04	0.0023
26	7	5	2	UN(7,5)	Repeticao(Tratament)	19.8689	7.7737	2.56	0.0106
27	7	6	1	UN(7,6)	Repeticao(Tratament)	19.0427	5.2214	3.65	0.0003
28	7	7	0	UN(7,7)	Repeticao(Tratament)	27.9560	6.5893	4.24	<.0001
29	8	1	7	UN(8,1)	Repeticao(Tratament)	16.6172	8.0167	2.07	0.0382
30	8	2	6	UN(8,2)	Repeticao(Tratament)	1.6656	9.2943	0.18	0.8578
31	8	3	5	UN(8,3)	Repeticao(Tratament)	21.4297	8.0577	2.66	0.0078
32	8	4	4	UN(8,4)	Repeticao(Tratament)	19.0911	8.4414	2.26	0.0237
33	8	5	3	UN(8,5)	Repeticao(Tratament)	15.3826	10.7350	1.43	0.1519
34	8	6	2	UN(8,6)	Repeticao(Tratament)	20.0895	6.9983	2.87	0.0041
35	8	7	1	UN(8,7)	Repeticao(Tratament)	25.1730	8.0806	3.12	0.0018
36	8	8	0	UN(8,8)	Repeticao(Tratament)	61.4167	14.4761	4.24	<.0001
37	9	1	8	UN(9,1)	Repeticao(Tratament)	15.8764	6.9711	2.28	0.0228
38	9	2	7	UN(9,2)	Repeticao(Tratament)	-6.9268	8.0474	-0.86	0.3894
39	9	3	6	UN(9,3)	Repeticao(Tratament)	22.7159	7.2577	3.13	0.0017
40	9	4	5	UN(9,4)	Repeticao(Tratament)	18.8683	7.4039	2.55	0.0108
41	9	5	4	UN(9,5)	Repeticao(Tratament)	26.9404	10.0011	2.69	0.0071
42	9	6	3	UN(9,6)	Repeticao(Tratament)	18.9585	6.1432	3.09	0.0020
43	9	7	2	UN(9,7)	Repeticao(Tratament)	19.1183	6.7234	2.84	0.0045
44	9	8	1	UN(9,8)	Repeticao(Tratament)	37.9358	10.8157	3.51	0.0005
45	9	9	0	UN(9,9)	Repeticao(Tratament)	45.1361	10.6387	4.24	<.0001
46	10	1	9	UN(10,1)	Repeticao(Tratament)	5.9632	6.8788	0.87	0.3860
47	10	2	8	UN(10,2)	Repeticao(Tratament)	14.2027	8.7323	1.63	0.1039
48	10	3	7	UN(10,3)	Repeticao(Tratament)	23.3190	7.6033	3.07	0.0022
49	10	4	6	UN(10,4)	Repeticao(Tratament)	20.0024	7.8203	2.56	0.0105
50	10	5	5	UN(10,5)	Repeticao(Tratament)	28.2313	10.5401	2.68	0.0074
51	10	6	4	UN(10,6)	Repeticao(Tratament)	21.6408	6.6275	3.27	0.0011
52	10	7	3	UN(10,7)	Repeticao(Tratament)	24.3496	7.4506	3.27	0.0011
53	10	8	2	UN(10,8)	Repeticao(Tratament)	34.5245	10.9032	3.17	0.0015
54	10	9	1	UN(10,9)	Repeticao(Tratament)	33.9328	9.7477	3.48	0.0005
55	10	10	0	UN(10,10)	Repeticao(Tratament)	50.2752	11.8500	4.24	<.0001
56	11	1	10	UN(11,1)	Repeticao(Tratament)	6.8339	5.0971	1.34	0.1800
57	11	2	9	UN(11,2)	Repeticao(Tratament)	8.2412	6.2870	1.31	0.1899
58	11	3	8	UN(11,3)	Repeticao(Tratament)	17.8409	5.6208	3.17	0.0015
59	11	4	7	UN(11,4)	Repeticao(Tratament)	17.6113	5.9395	2.97	0.0030
60	11	5	6	UN(11,5)	Repeticao(Tratament)	24.9082	8.0390	3.10	0.0019
61	11	6	5	UN(11,6)	Repeticao(Tratament)	18.4662	5.0934	3.63	0.0003
62	11	7	4	UN(11,7)	Repeticao(Tratament)	18.8565	5.5387	3.40	0.0007
63	11	8	3	UN(11,8)	Repeticao(Tratament)	19.5726	7.5058	2.61	0.0091
64	11	9	2	UN(11,9)	Repeticao(Tratament)	24.3923	7.0788	3.45	0.0006
65	11	10	1	UN(11,10)	Repeticao(Tratament)	29.8502	7.8840	3.79	0.0002
66	11	11	0	UN(11,11)	Repeticao(Tratament)	26.7850	6.3133	4.24	<.0001
67	12	1	11	UN(12,1)	Repeticao(Tratament)	1.0664	7.0706	0.15	0.8801
68	12	2	10	UN(12,2)	Repeticao(Tratament)	17.8538	9.2218	1.94	0.0529

69	12	3	9	UN(12,3)	Repeticao(Tratament)	10.9252	7.0263	1.55	0.1200
70	12	4	8	UN(12,4)	Repeticao(Tratament)	7.9586	7.4649	1.07	0.2864
71	12	5	7	UN(12,5)	Repeticao(Tratament)	24.7401	10.6268	2.33	0.0199
72	12	6	6	UN(12,6)	Repeticao(Tratament)	13.4372	6.1930	2.17	0.0300
73	12	7	5	UN(12,7)	Repeticao(Tratament)	15.5569	6.9874	2.23	0.0260
74	12	8	4	UN(12,8)	Repeticao(Tratament)	5.1468	9.6555	0.53	0.5940
75	12	9	3	UN(12,9)	Repeticao(Tratament)	8.0705	8.3537	0.97	0.3340
76	12	10	2	UN(12,10)	Repeticao(Tratament)	30.3325	10.0634	3.01	0.0026
77	12	11	1	UN(12,11)	Repeticao(Tratament)	19.3034	7.1196	2.71	0.0067
78	12	12	0	UN(12,12)	Repeticao(Tratament)	54.2156	12.7787	4.24	<.0001

As informações utilizadas foram da Semana2, das distâncias e as estimativas de variâncias e covariâncias (*Estimate*), no Apêndice C têm as rotinas para obter esses valores acima com a estrutura de covariância UN. Esses valores também foram obtidos com a função *corandcov(Cons.UN)* na seção 4.1.2.

Depois transforma em fatores a *distância.cr* e *Semanas* em seguida com a função *interaction.plot* especificando os fatores e os valores da linha de comando *Covun.cr*. Na Figura 6 está a covariância residual em função das distâncias entre os pares de observações com a estrutura UN para a variável consumo médio de ração.

Figura 6 – Covariância residual em função das distâncias entre os pares de observações com a estrutura UN para a variável consumo médio de ração.



De acordo com Littell et al. (2006) o modelo apropriado na escolha

da matriz de covariâncias decresce com o aumento das distâncias. Isso acontece com a UN comparada com a simetria composta que tem a mesma covariância entre os tempos avaliados. A partir da Figura 6 pode-se ter uma ideia de que ao aumentar as distâncias entre as medições ocorre uma diminuição da covariância.

Os critérios AIC e BIC podem ser utilizados para seleção do modelos mais formalmente, mas se o pesquisador realizar o gráfico apresentado na Figura 6 é possível visualizar e comparar o comportamento da estrutura de covariância UN.


4.1.7 Análise de resíduos para a variável consumo médio de ração

A análise de resíduos é importante para a verificação das pressuposições do modelo em estudo e sua validação. Foram realizadas análises de resíduos dos modelos com as estruturas de covariâncias escolhidas. Para a variável consumo médio de ração foi considerada a análise de resíduos do modelo com a estrutura de covariância UN. Para análise gráfica utilizou-se o pacote *lattice*. No programa R têm-se os resíduos condicionais a seguir:

```
> require(lattice)
> plot(predict(Cons.UN), residuals(Cons.UN),
+       xlab="Valores preditos",ylab="Resíduos")
```

A rotina nesse caso é simples, foi utilizado a função *plot* com especificação nos eixos x (*predict(Cons.UN)*) e y (*residuals(Cons.UN)*). Na Figura 7 têm-se o gráfico com valores preditos e os resíduos padronizados.

Figura 7 – Resíduos padronizados *versus* valores preditos para a variável consumo médio de ração.

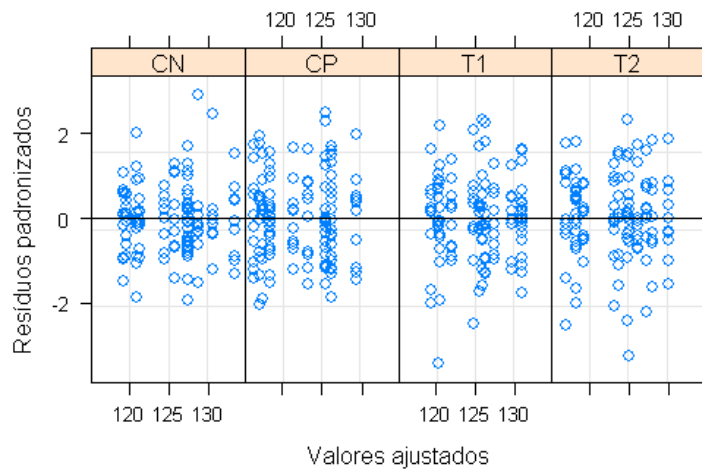


Nobre e Singer (2007) sugerem que a presença de observações discrepantes é avaliada no gráfico dos resíduos padronizados *versus* valores preditos. E que a homocedasticidade é avaliada no gráfico dos resíduos padronizados *versus* os valores ajustados pelo modelo. Para realizar o gráfico dos resíduos padronizados *versus* valores ajustados, em que esses são os resíduos condicionais têm-se as seguintes linhas de comando no programa R:

```
> plot(Cons.UN, resid(., type = "p") ~ fitted(.) |
+     factor(Tratamento), layout= c(4,1), aspect=2,
+     abline=0, xlab = "Valores ajustados",
+     ylab = "Resíduos padronizados")
```

Na Figura 8 têm-se os valores ajustados *versus* os resíduos padronizados para a variável consumo médio de ração nas diferentes dietas testadas.

Figura 8 – Valores ajustados dos resíduos padronizados para a variável consumo médio de ração nas diferentes dietas testadas.



A principal diferença entre as Figuras 7 e 8 é que no primeiro gráfico são os resíduos para todas observações e na segunda figura são para cada tratamento em teste. Na Figura 8 são os resíduos condicionais de Pearson *versus* valores ajustados, com esses gráficos, têm-se todos os resíduos de todas as parcelas e separados por tratamentos, apesar do fato de que os resíduos obtidos a partir da mesma parcela são potencialmente correlacionados. No entanto, esses podem servir para detectar, por exemplo, valores muito discrepantes.

Para realizar os *boxplots* dos resíduos utilizou-se a função *bwplot* e a função *panel.bwplot* (GATECKI; BURZYKOWSKI, 2013). As linhas de comando no programa R são:

```
> panel.bwxplot <-
+ function(x,y, subscripts, ...){
+   panel.grid(h = -1)
+   panel.stripplot(x, y, col = "grey", ...)
+   panel.bwplot(x, y, pch = "|", ...)}
```

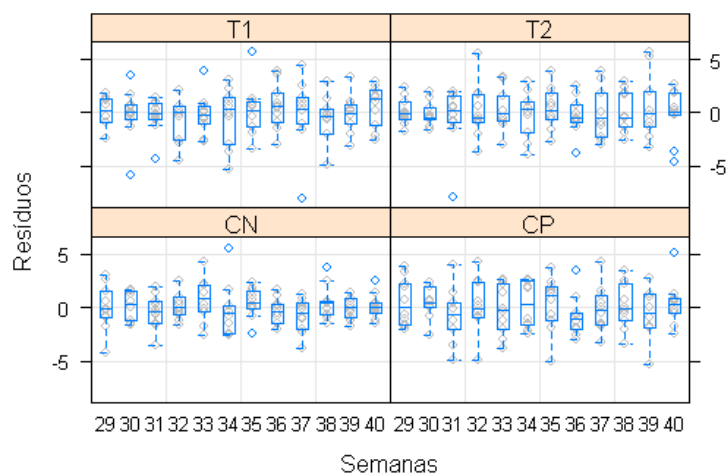
```

> bwplot(resid(Cons.UN, type = "n") ~ periodo.f | trat.f,
+       panel = panel.bwplot, ###Use painel acima###
+       data = dados,xlab="Semanas",ylab = "Resíduos")

```

Na Figura 9 tem os *boxplots* dos resíduos ao longo do tempo para os diferentes tratamentos.

Figura 9 – *Boxplots* dos resíduos para a variável consumo médio de ração.



De acordo com a Figura 9, observa-se que a variância dos resíduos nos tratamentos claramente mostram variação nos valores com o passar do tempo. Isso reflete na heterogeneidade de variâncias, como são 480 observações têm-se valores discrepantes, que são possíveis candidatos a *outliers*.

Para verificar se os resíduos são normais, foram obtidos os gráficos dos quantis-quantis nos diferentes tratamentos. A função utilizada é apresentada a seguir:


```

> qqnorm(Cons.UN, ~resid(., type="n") | factor(Tratamento),
+       layout= c(4,1), xlab = "Resíduos normalizados",
+       ylab = "Quantis da normal padrão", aspect=2,
+       abline = c(0,1))

```

Com a função *qqnorm* deve-se especificar o nome *Cons.UN*, depois os resíduos (*resid*) dentro dos tratamentos e com a função *abline = c(0,1)*, é possível adicionar uma linha entre o primeiro e o terceiro quantil das coordenadas. Na Figura 10 têm-se os *QQ plots* da normal para a variável consumo médio de ração nos diferentes tratamentos em teste.

Figura 10 – *QQ plots* da normal para a variável consumo médio de ração.




A Figura 10 permite uma avaliação da distribuição condicional dos resíduos normalizados nos diferentes tratamentos, indicando que não há normalidade dos resíduos, pois os valores desviam muito da reta. O gráfico dos quantis-quantis (*QQ plots*) da normal é obtido com os seguintes comandos:

```
> qqnorm(residuals(Cons.UN),xlab="Quantil",
+        ylab="Resíduos",main="")
> qqline(residuals(Cons.UN))
```

Com a função *qqnorm* têm-se o gráfico quantil-quantil da normal, enquanto que na função *qqline* é para adicionar uma linha que passa através do primeiro e terceiro quantil das coordenadas. Na Figura 11 têm-se o gráfico quantil-quantil da normal.

Figura 11 – Gráfico quantil-quantil da normal para a variável consumo médio de ração.



O gráfico quantil-quantil da normal apresentado na Figura 11 é uma ferramenta muito útil para verificar se os resíduos apresentam distribuição normal, além de ser mais informativo para o pesquisador. Nessa figura, mostra que a partir de uma linha reta no gráfico, os valores dos resíduos desviam da reta. Isso pode ser uma indicação de um problema com a normalidade dos resíduos. O teste de Shapiro-Wilk foi realizado com as seguintes linhas de comando:

```
> shapiro.test(residuals(Cons.UN))
```

```
Shapiro-Wilk normality test
```

```
data: residuals(Cons.UN)
W = 0.9917, p-value = 0.009005
```

O teste de Shapiro-Wilk indica que não há normalidade dos resíduos, valor-p= 0,009005. Para a variável consumo médio de ração foram 480 observações, em que têm-se um número grande de observações. Com o problema da falta de normalidade dos resíduos, foi realizada a transformação


Box-Cox (BOX; COX, 1964). Essa transformação é realizada na variável consumo médio de ração, a transformação Box-Cox consiste em encontrar um valor de λ em que os dados transformados se aproximem de uma distribuição normal.

Utilizou-se o pacote *MASS* com a função *boxcox*, a transformação Box-Cox está descrita a seguir:

```
>require(MASS)
>boxcox(Consumo~trat.f*periodo.f,data=dados,
        plotit=TRUE,lam=seq(-2, 6, 0.2),
        ylab="Função log verossimilhança")
```

Com a função *boxcox* é necessário descrever a variável *Consumo* e os fatores (*trat.f* e *periodo.f*) e com a opção *plotit= TRUE* têm-se o gráfico referente a transformação Box-Cox (FIGURA 12).

Figura 12 – Transformação Box-Cox da variável consumo médio de ração.



Na Figura 12 o valor de λ que maximiza a função *log* verossimilhança é 1,3939, com um valor de *log* verossimilhança de -38,69120, mas como o valor de $\lambda = 1$ está dentro do intervalo de confiança de 95% não é necessário realizar a transformação Box-Cox, pois a significância dos efeitos não será afetada.

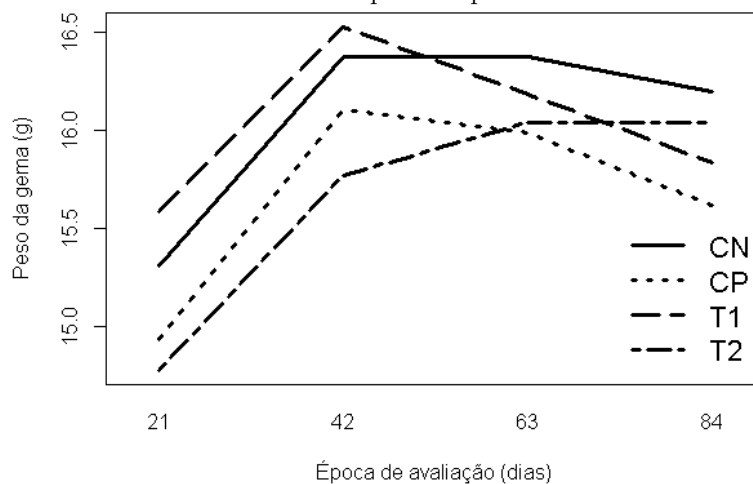
Até o presente momento foram mostrados todos os passos de análise para a variável consumo médio de ração, a seguir tem os mesmos passos de análise para a variável peso da gema e que as rotinas para análise dessa variável estão no Apêndice B.

4.2 Variável peso da gema

4.2.1 Análise exploratória da variável peso da gema

A Figura 13 reflete o comportamento da variável peso da gema (g) ao longo das diferentes épocas de avaliação (21, 42, 63 e 84 dias) para as diferentes dietas testadas.

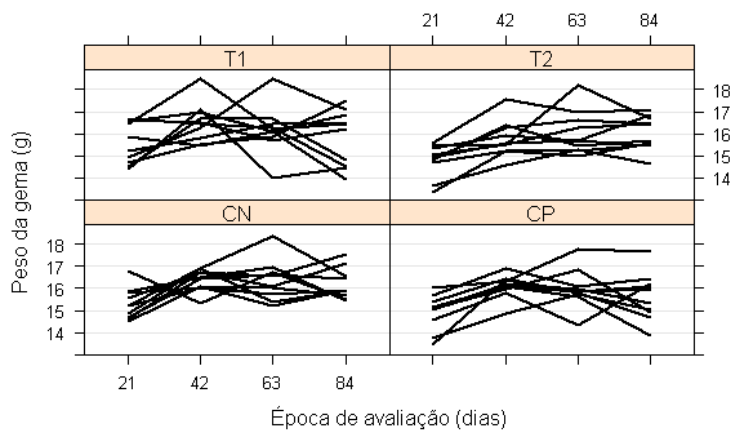
Figura 13 – Peso da gema em diferentes épocas de avaliação de poedeiras com idade de 29 a 40 semanas para os quatros tratamentos.



O peso da gema aumentou da época de avaliação 21 para 42 dias para todas as dietas em teste. Para a dieta T1, o peso da gema diminuiu até o fim do experimento aos 84 dias. Com as demais dietas houve um comportamento ao longo do tempo diferente (FIGURA 13).


Na Figura 14 nota-se que o comportamento de algumas parcelas experimentais ao longo das diferentes épocas de avaliação em todos os tratamentos é diferente, sendo que peso da gema aumenta em determinadas parcelas e em outras diminui.

Figura 14 – Perfis individuais das parcelas experimentais em cada dieta para o peso da gema (g).



Boxplots da variável peso da gema (g) nas avaliações 21, 42, 63 e 84 dias para os diferentes tratamentos estão apresentados na Figura 15. Nessa figura observa-se um aumento do peso da gema em todas as dietas, de 21 dias para 42 dias. Nas demais épocas o comportamento foi semelhante. Além disso, a variabilidade não é constante nas diferentes dietas em teste.

Figura 15 – *Boxplots* da variável peso da gema (g) ao longo das diferentes épocas de avaliação para os diferentes tratamentos.



A análise exploratória de dados longitudinais é importante para ter-se uma visão geral da estrutura dos dados, seja dos tratamentos ou das parcelas experimentais ao longo do tempo.

4.2.2 Função *gls* para a variável peso da gema

Como anteriormente, com a função *anova* têm-se os valores dos critérios de Akaike (AIC) e do critério Bayesiano (BIC) para os modelos ajustados:

```
>anova(pg.CS,pg.CSH,pg.AR1,pg.ARH,pg.UN)
```

Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
pg.CS	1 18	433.4613	486.9180	-198.7307			
pg.CSH	2 21	434.2507	496.6168	-196.1254	1 vs 2	5.210603	0.1570
pg.AR1	3 18	433.3330	486.7897	-198.6665	2 vs 3	5.082307	0.1659
pg.ARH	4 21	434.5235	496.8896	-196.2618	3 vs 4	4.809517	0.1863
pg.UN	5 26	439.0430	516.2581	-193.5215	4 vs 5	5.480518	0.3601

Os resultados acima são resumidos na Tabela 4.

Tabela 4 – Valores do número de parâmetros (Npar), critério de Akaike (AIC) e do critério Bayesiano (BIC) para cada estrutura de variância-covariância para a variável peso da gema.

Tipo de estrutura	Npar	AIC	BIC
CS	18	433,4613	486,9180
CSH	21	434,2507	496,6168
AR(1)	18	433,3330	486,7897
ARH(1)	21	434,5235	496,8896
UN	26	439,0430	516,2581

Nota-se que a estrutura AR(1) apresentou um menor valor do critério de AIC (433,3330) e um menor valor de BIC (486,7897). Por isso, foram realizadas a comparação da estrutura de covariância AR(1) com as demais estruturas de covariância (CS, CSH, ARH(1) e UN). Realizando-se o teste de razão de verossimilhanças (TRV) dos modelos com as estruturas de covariâncias AR(1) e CS têm-se os seguintes resultados:

```
>anova(pg.AR1,pg.CS)
```

Model	df	AIC	BIC	logLik
pg.AR1	1 18	433.3330	486.7897	-198.6665
pg.CS	2 18	433.4613	486.9180	-198.7307

Com os resultados acima, pode-se concluir que entre as estruturas de covariância AR(1) e CS são equivalentes, com isso pode-se usar qualquer uma das duas estruturas de covariâncias.

Realizando-se o teste de razão de verossimilhanças (TRV) dos modelos com as estruturas de covariâncias AR(1) e CSH têm-se os seguintes resultados:

```
>anova(pg.AR1,pg.CSH)
```

Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
pg.AR1	1 18	433.3330	486.7897	-198.6665			
pg.CSH	2 21	434.2507	496.6168	-196.1254	1 vs 2	5.082307	0.1659

O valor-p (0,1659) indica que o TRV foi não significativo, indicando que a estrutura de covariância AR(1) é mais parcimoniosa do que a CSH, deve-se considerar a AR(1). Também foi realizado o TRV dos modelos com as estruturas de covariância AR(1) e ARH(1) têm-se os seguintes resultados:

```
>anova(pg.AR1,pg.ARH)
```

Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
pg.AR1	1 18	433.3330	486.7897	-198.6665			
pg.ARH	2 21	434.5235	496.8896	-196.2618	1 vs 2	4.809517	0.1863

A estatística do TRV é um valor (0,1863) de uma qui-quadrado com 3 graus de liberdade (21 - 18). A conclusão é que a estrutura da matriz de covariâncias AR(1) é uma estrutura de covariância mais parcimoniosa do que a ARH(1), em que a AR(1) ajustou bem aos dados. Realizando-se o teste de razão de verossimilhanças dos modelos com as estruturas de covariâncias AR(1) e UN têm-se os seguintes resultados:

```
>anova(pg.AR1,pg.UN)
```

Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
pg.AR1	1	18 433.333	486.7897	-198.6665			
pg.UN	2	26 439.043	516.2581	-193.5215	1 vs 2	10.29003	0.2453

O valor-p (0,2453) indica que a estatística do TRV foi não significativa, indicando que uma estrutura mais parcimoniosa como a AR(1) pode ser utilizada.

4.2.3 Procedimento *mixed* para a variável peso da gema

Os critérios AIC, AICC, BIC e o *-2 Res Log Likelihood* para as estruturas de covariâncias consideradas estão resumidas na Tabela 5.

Tabela 5 – Valores do critério de Akaike (AIC), critério de Akaike corrigido (AICC), critério Bayesiano (BIC) e o *-2 Res Log Likelihood* para cada estrutura de variância-covariância para a variável peso da gema (g).

Estrutura	Npar	<i>-2 Res Log Likelihood</i>	AIC	AICC	BIC
VC	1	406,5	408,5	408,5	410,1
CS	2	397,5	401,5	401,5	404,8
CSH	5	392,3	402,3	402,3	410,7
AR(1)	2	397,3	401,3	401,4	404,7
ARH(1)	5	392,5	402,5	403,0	411,0
UN	10	387,0	407,0	408,7	423,9
HF	5	393,3	403,3	403,7	411,7

Os valores do AIC (401,3), do AICC (401,4) e do BIC (404,7) da estrutura de covariância AR(1) são menores em relação as demais estruturas de covariâncias. Foram realizadas a comparação da estrutura de covariância AR(1) com as demais estruturas de covariâncias. Os resultados da comparação da UN com as estruturas VC, CSH, ARH(1), UN e HF no programa SAS (Apêndice D) estão na Tabela 6.

Tabela 6 – Valores da estatística do teste de razão de verossimilhanças (TRV) da estrutura de variância-covariância AR(1) com as demais estruturas de covariâncias para a variável peso da gema (g).

Estruturas	TRV	Graus de liberdade	Valor-p
AR(1)×VC	9,1186856159	1	0,00126506
AR(1)×CSH	5,082307596	3	0,08293422
AR(1)×ARH(1)	4,809517596	3	0,09314425
AR(1)×UN	10,290035453	8	0,12262823
AR(1)×HF	4,029548026	3	0,12914555

Pelo teste de razão de verossimilhanças, comparando a estrutura de covariância autorregressiva de primeira ordem (AR(1)) com a VC, têm-se: $\chi^2 = 406,5 - 397,3 = 9,1186$ com $2 - 1 = 1$ grau de liberdade. O nível de significância observado correspondente é um valor-p= 0,0011256, ou seja, são significativos, a estrutura de covariância é mais adequada do que a estrutura de covariância VC.

Pelo teste de razão de verossimilhanças, comparando a estrutura de covariância autorregressiva de primeira ordem (AR(1)) com a estrutura de covariância UN, têm-se: $\chi^2 = 397,3 - 387,0 = 10,30$ com $10 - 2 = 8$ graus de liberdade. O nível de significância observado correspondente é um valor-p= 0,1291, ou seja, não significativo. A estrutura de covariância AR(1) é mais adequada pois têm menores valores de AIC, BIC e AICC. E como deve-se escolher estruturas de covariâncias mais parcimoniosas e adequada aos dados (WOLFINGER, 1993).

Para a variável peso da gema a solução para os efeitos fixos dos testes F usando o procedimento *mixed* está descrita a seguir:

Autorregressiva de primeira ordem - AR(1)				
Type 3 Tests of Fixed Effects				
	Num	Den		
Effect	DF	DF	F Value	Pr > F
Tratamento	3	44.8	1.74	0.1733
Periodo	3	99.2	14.79	<.0001

Tratamento*Periodo	9	99.2	0.56	0.8247
--------------------	---	------	------	--------

Os resultados mostram que não houve diferença significativa entre os tratamentos (*Tratamento*) com valor-p=0,1733, nem para a interação tratamentos \times épocas de avaliação (*Tratamento*Periodo*) com valor-p=0,8247. No entanto, foi encontrada diferença significativa no peso da gema ao longo das épocas de avaliação (*Periodo*) com valor-p < 0,0001.

Na Tabela 7 têm-se as médias e os erros-padrões em cada estrutura de covariância, para os diferentes tratamentos em estudo. As estimativas dos erros-padrões da média são muito similares para todas as estruturas de covariâncias consideradas.

Tabela 7 – Médias e erros-padrões da média para os tratamentos considerando diferentes estruturas de covariâncias para a variável peso da gema.

Estrutura	Tratamentos			
	CN	CP	T1	T2
VC	16,061 \pm 0, 1381	15,657 \pm 0, 1381	16,030 \pm 0, 1381	15,655 \pm 0, 1381
CS	16,061 \pm 0, 1788	15,657 \pm 0, 1788	16,030 \pm 0, 1788	15,655 \pm 0, 1788
CSH	16,061 \pm 0, 1778	15,657 \pm 0, 1778	16,030 \pm 0, 1778	15,655 \pm 0, 1778
AR(1)	16,061 \pm 0, 1710	15,657 \pm 0, 1710	16,030 \pm 0, 1710	15,655 \pm 0, 1710
ARH(1)	16,061 \pm 0, 1687	15,657 \pm 0, 1687	16,030 \pm 0, 1687	15,655 \pm 0, 1687
UN	16,061 \pm 0, 1788	15,657 \pm 0, 1788	16,030 \pm 0, 1788	15,655 \pm 0, 1788
HF	16,061 \pm 0, 1776	15,657 \pm 0, 1776	16,030 \pm 0, 1776	15,655 \pm 0, 1776

Os valores dos erros-padrões da média para a variável peso da gema, mostram que a estrutura de covariância AR(1) tem menores valores em comparação as estruturas de covariâncias CS, CSH, UN e HF.

4.2.4 Análise de variância da variável peso da gema em esquema de parcela subdividida no tempo com a função *aov*

A rotina quando têm-se o esquema de parcela subdividida no tempo e o resultado da análise de variância para a variável peso da gema estão a seguir:

```
> modelo.pesodagama<- aov(pesodagama~trat*periodo+
+                           Error(erroa),data=dados)
> summary(modelo.pesodagama)
```

```
Error: erroa
          Df Sum Sq Mean Sq F value Pr(>F)
trat      3  6.09   2.029   1.588  0.209
Residuals 36 46.01   1.278

Error: Within
          Df Sum Sq Mean Sq F value  Pr(>F)
periodo    3 27.93   9.310 15.763 1.43e-08 ***
trat:periodo  9  4.06   0.451  0.763  0.651
Residuals 108 63.79   0.591
---
Signif. codes:
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Os resultados da análise de variância da variável peso da gema mostram que não houve diferença significativa entre os tratamentos (valor-p=0,209), nem para a interação tratamentos \times épocas de avaliação (valor-p=0,651). No entanto, foi encontrada diferença significativa ao longo das diferentes épocas de avaliação (valor-p= $1,43 \times 10^{-08}$).

De acordo com Braz et al. (2011) o aumento do tamanho do ovo em aves de mesma idade pode ser seguido por redução na proporção de gema e casca e acréscimo na proporção do albúmen. O peso da gema foi influenciado pela época de avaliação.

4.2.5 Modelos lineares mistos com a função *lmer* para a variável peso da gema

A rotina quando têm-se o esquema de parcela subdividida no tempo e o resultado da análise de variância para a variável peso da gema (g) estão

descritos a seguir:

```
> pg.lmertest=lmer(pesodagama~trat+ (1|erroa)+
+                 periodo+(trat:periodo),data=dados)
```

```
>anova(pg.lmertest)
```

```
Analysis of Variance Table of type III with Satterthwaite
approximation for degrees of freedom
              Sum Sq Mean Sq NumDF DenDF F.value    Pr(>F)
trat          2.8134  0.9378     3    36  1.5878    0.2093
periodo       27.9298  9.3099     3   108 15.7628 1.431e-08 ***
trat:periodo   4.0558  0.4506     9   108  0.7630    0.6506
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

A função *lmer* é uma opção para uso quando se tem o esquema em parcela subdividida no tempo. Para a variável peso da gema os resultados mostram que houve diferença significativa pelo teste F apenas ao longo do tempo (época de avaliação), para as demais fontes de variação não houve diferença significativa. A rotina e os resultados estão descritos a seguir com as médias e seus respectivos erros-padrões para os fatores tratamentos (*trat*), épocas de avaliação (*periodo*) e a interação tratamentos × épocas de avaliação (*trat:periodo*):

```
> pg.lsmmeans<-step(pg.lmertest,reduce.fixed = FALSE,
+                  reduce.random = FALSE)
```

Para a variável peso da gema têm-se as médias e os seus respectivos erros-padrões, a rotina e os resultados estão a seguir:

```
>pg.lsmmeans$lsmmeans.table
```

	trat	periodo	Estimate	Standard Error	DF	t-value	Lower CI	Upper CI	p-value
trat	CN	<NA>	16.0617	0.1788	36	89.85	15.6992	16.4243	0
trat	CP	<NA>	15.6572	0.1788	36	87.59	15.2947	16.0198	0

trat	T1	T1	<NA>	16.0302	0.1788	36	89.68	15.6677	16.3928	0
trat	T2	T2	<NA>	15.6557	0.1788	36	87.58	15.2932	16.0183	0
periodo	21	<NA>	21	15.1495	0.1381	125	109.72	14.8762	15.4228	0
periodo	42	<NA>	42	16.1908	0.1381	125	117.27	15.9175	16.4640	0
periodo	63	<NA>	63	16.1440	0.1381	125	116.93	15.8707	16.4173	0
periodo	84	<NA>	84	15.9208	0.1381	125	115.31	15.6475	16.1940	0
trat:periodo	CN 21	CN	21	15.3060	0.2761	125	55.43	14.7595	15.8525	0
trat:periodo	CP 21	CP	21	14.9320	0.2761	125	54.07	14.3855	15.4785	0
trat:periodo	T1 21	T1	21	15.5860	0.2761	125	56.44	15.0395	16.1325	0
trat:periodo	T2 21	T2	21	14.7740	0.2761	125	53.50	14.2275	15.3205	0
trat:periodo	CN 42	CN	42	16.3700	0.2761	125	59.28	15.8235	16.9165	0
trat:periodo	CP 42	CP	42	16.1000	0.2761	125	58.30	15.5535	16.6465	0
trat:periodo	T1 42	T1	42	16.5230	0.2761	125	59.84	15.9765	17.0695	0
trat:periodo	T2 42	T2	42	15.7700	0.2761	125	57.11	15.2235	16.3165	0
trat:periodo	CN 63	CN	63	16.3730	0.2761	125	59.29	15.8265	16.9195	0
trat:periodo	CP 63	CP	63	15.9830	0.2761	125	57.88	15.4365	16.5295	0
trat:periodo	T1 63	T1	63	16.1800	0.2761	125	58.59	15.6335	16.7265	0
trat:periodo	T2 63	T2	63	16.0400	0.2761	125	58.09	15.4935	16.5865	0
trat:periodo	CN 84	CN	84	16.1980	0.2761	125	58.66	15.6515	16.7445	0
trat:periodo	CP 84	CP	84	15.6140	0.2761	125	56.54	15.0675	16.1605	0
trat:periodo	T1 84	T1	84	15.8320	0.2761	125	57.33	15.2855	16.3785	0
trat:periodo	T2 84	T2	84	16.0390	0.2761	125	58.08	15.4925	16.5855	0

Com os resultados da função *step* com a opção *pg.lsmmeans\$lsmeans.table*, têm-se os valores das médias (*Estimate*) de cada fator em estudo, os seus respectivos erros-padrões (*Standard Error*) para todos os efeitos fixos, com valores semelhantes ao do procedimento *mixed* do SAS. Os valores dos erros-padrões da média para a estrutura de covariâncias simetria composta para os tratamentos foram (0,1788), para as épocas de avaliação (0,1381) e para a interação dos dois fatores (0,2761).

4.2.6 Análise gráfica das estruturas de covariância para a variável peso da gema

A variável peso da gema foi avaliada em 4 épocas (21, 42, 63 e 84 dias após o início do experimento). Para obtenção do gráfico foram utilizadas as seguintes linhas de comando no programa R:

```
> epoca <- c(1,1,2,1,2,3,1,2,3,4)
> distancia.pdg<-c(0,1,0,2,1,0,3,2,1,0)
> Covun.pdg<-c(0.64215378,0.17231891,0.50091429,
+             0.25529171,0.09688191,0.94506903,
+             0.04640328,0.09002967,0.37036065,
+             0.96190247)
```

```


> distancia.pdg<-factor(distancia.pdg)
> epoca<-factor(epoca)
> library(lattice)
> par(mar=c(4,4,0,0)+.1)
> interaction.plot(distancia.pdg,epoca,Covun.pdg,
+                 type="l",col=1,lty=1:6,pch=1:4,
+                 xlab="Distância (Época de avaliação)",
+                 ylab = "Covariância Residual",lwd=3,
+                 legend =F)
> legend("topright",bty='n',xpd=NA,col= 1,
+       title ="Época de avaliação",lty=1:4,
+       c("1", "2","3","4"),lwd=1,cex=1)

```

Como foram 4 épocas de avaliação, as distâncias entre as medições são no máximo 3. A diferença entre as medições na distância 0 são as variâncias, com os seguintes valores: 0,64215378, 0,50091429, 0,94506903 e 0,96190247. Na distância 1 tem a covariância entre a semana 1 e 2, com os seguintes valores: 0,17231891, 0,09688191 e 0,37036065. Na distância 2, têm-se a covariância entre as semanas 1 e 3, 2 e 4, sendo os valores: 0,25529171 e 0,09002967. Por fim, para a distância 3 entre 1 e 4 têm-se o valor 0,04640328.

A Figura 16 é o gráfico referente aos valores de covariâncias em função das distâncias entre as medições.

Figura 16 – Covariância residual em função das distâncias entre os pares de observações com a estrutura UN para a variável peso da gema.




Na Figura 16 têm-se a covariância residual nas 4 épocas de avaliação, sugere-se que os valores não decrescem muito, pois as épocas de avaliação foram poucas. Os critérios AIC e BIC indicaram que a estrutura de covariância adequada é a AR(1). Mas, o gráfico apresentado na Figura 16 é para analisar e verificar como seria considerar a estrutura de covariância UN.

4.2.7 Análise de resíduos para a variável peso da gema

A Figura 17 refere-se ao gráfico de resíduos padronizados *versus* os valores ajustados, obtidos a partir do modelo com a estrutura de covariância AR(1) para a variável peso da gema.

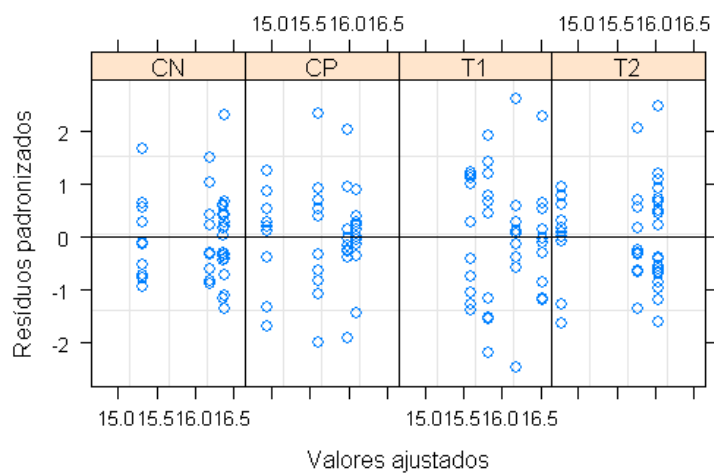
Na Figura 17, pode-se observar a validação do pressuposto de homocedasticidade, assumindo assim que os resíduos mostram-se aleatórios e apresentam variâncias constantes.

Figura 17 – Resíduos padronizados *versus* valores ajustados para a variável peso da gema.



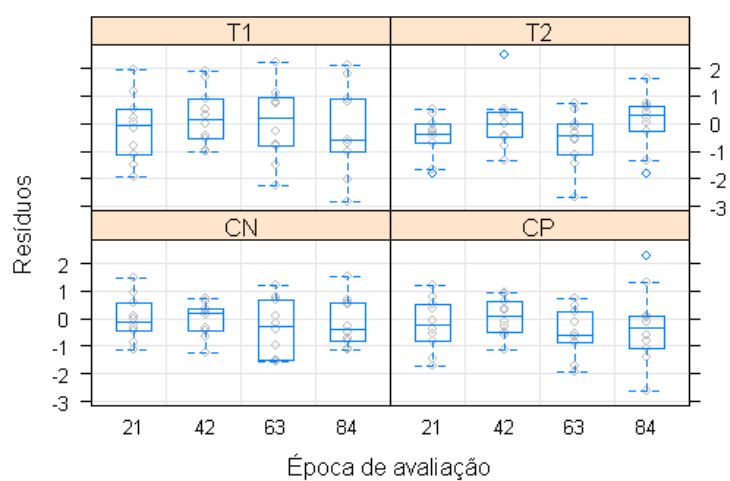
Na Figura 18 têm-se os resíduos padronizados *versus* os valores ajustados nas diferentes dietas testadas, o resultado desse gráfico é o mesmo da Figura 17. Esses gráficos podem servir para detecção de possíveis valores discrepantes.

Figura 18 – Valores ajustados dos resíduos padronizados para a variável peso da gema nas diferentes dietas testadas.



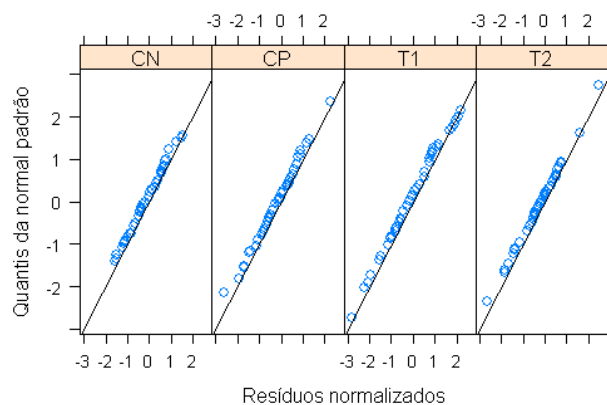
Na Figura 19 estão os *boxplots* dos resíduos para a variável peso da gema.

Figura 19 – *Boxplots* dos resíduos para a variável peso da gema.



Pode-se observar que os *boxplots* dos resíduos ao longo das épocas de avaliação têm amplitude semelhantes nas diferentes dietas em teste, indicando homogeneidade de variâncias. Os *QQ plots* da normal para a variável peso da gema estão apresentados na Figura 20.


Figura 20 – *QQ plots* da normal para a variável peso da gema.



Na Figura 20 têm-se que o gráfico quantil-quantil da normal para os diferentes tratamentos, com esse gráfico é possível verificar que os resíduos apresentam distribuição normal. Nessa figura, mostra que a partir de uma linha reta no gráfico, os valores dos resíduos estão bem próximos da reta.

Na Figura 21 têm-se o gráfico quantil-quantil da normal para a variável peso da gema.

Figura 21 – Gráfico quantil-quantil da normal para a variável peso da gema.



A Figura 21 indica que há um pequeno desvio na reta. Pelo teste de Shapiro-Wilk têm-se valor- $p=0,2706$, ou seja, os resíduos são considerados normais. A análise gráfica dos resíduos é uma ferramenta muito importante para verificar o comportamento dos resíduos.

5 CONCLUSÕES

No presente trabalho utilizamos os conceitos ligados a dados longitudinais em esquema de parcela subdividida no tempo com delineamento inteiramente ao acaso com abordagem de diferentes estruturas de covariâncias. Esse manual é útil para pesquisadores, professores e estudantes de áreas aplicadas, para realizar a análise de dados longitudinais usando modelos lineares mistos considerando diferentes estruturas de covariâncias e contemplando a análise de resíduos por meio de gráficos.

A escolha da estrutura de covariância afetou a significância dos testes F para os efeitos fixos para a variável consumo médio de ração. Para a variável peso da gema, a escolha da estrutura não afetou a significância dos testes F. A análise de resíduos foi importante na verificação das pressuposições do modelo escolhido e das características dos dados.

REFERÊNCIAS

- AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v.19, n.6, p.716-723, 1974.
- ALCARDE, R. **Modelos lineares mistos em dados longitudinais com o uso do pacote ASReml-R**. 2012. 156 p. Tese (Doutorado em Estatística e Experimentação Agronômica) - Universidade de São Paulo: Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2012.
- BARBIN, D. **Componentes de variância: teoria e aplicações**. Piracicaba: FEALQ. 1993. 120 p.
- BARNETT, A.G.; KOPER, N.; DOBSON, A.J. et al. Using information criteria to select the correct variance-covariance structure for longitudinal data in ecology. **Methods in Ecology and Evolution**, v.1, p.15-24, 2010.
- BARBOSA, M. **Uma abordagem para análise de dados com medidas repetidas utilizando modelos lineares mistos**. 2009. 118 p. Dissertação (Mestrado em Estatística e Experimentação Agronômica) - Universidade de São Paulo: Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2009.
- BOX, G.E.P; COX, D.R. An analysis of transformations. **Journal of the Royal Statistical Society. Series B (Methodological)**, v.26, n.2, p.211-252, 1964.
- BRAZ, N.M.; FREITAS, E.R.; BEZERRA, R.M. et al. Fibra na ração de crescimento e seus efeitos no desempenho de poedeiras nas fases de crescimento e postura. **Revista Brasileira de Zootecnia**, v.40, n.12, p.2744-2753, 2011.
- DAMASCENA, A.S. **Análise bayesiana de modelos lineares mistos**. 2015. 52 p. Dissertação (Mestrado em Ciências) - Universidade de São Paulo: Instituto de Matemática e Estatística, São Paulo, 2015.
- DIGGLE, P.J.; HEAGERTY, P.; LIANG, K.Y.; ZEGER, S.L. **Analysis**

of longitudinal data. 2 ed. Oxford: Oxford University Press, 2002. 369 p.

FITZMAURICE, G.; DAVIDIAN, M.; VERBEKE, G.; MOLENBERGHS, G. **Longitudinal data analysis.** New York: Chapman and Hall/CRC, 2008. 613 p.

FOX, J.; WEISBERG, S. **An R companion to applied regression.** 2 ed. Thousand Oaks: Sage Publications, 2011. 450 p.

FREITAS, E.G.; BARBIN, D.; BARBOSA, G.V.S. et al. Modelo univariado aplicado a dados longitudinais de cana-de-açúcar. **Revista Brasileira de Biometria**, v.26, p.93-16, 2008.

FREITAS, E.R.; FUENTES, M. de F.F.; ESPÍNDOLA, G.B. Efeito da suplementação enzimática em rações à base de milho/farelo de soja sobre o desempenho de poedeiras comerciais. **Revista Brasileira de Zootecnia**, v.29, n.4, p.1103-1109, 2000.

GARCIA, C.H. **Aplicações de equações de modelo mistos em testes clonais de *Eucalyptus spp.*** 2004. 74 p. Dissertação (Mestrado em Agronomia) - Universidade de São Paulo: Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2004.

GATECKI, A.; BURZYKOWSKI, T. **Linear mixed-effects models using R: A step-by-step approach .** New York: Springer-Verlang, 2013. 555 p.

GILL, J.L. **Design and analysis of experiments in the animal and medical sciences.** Ames: The Iowa State University Press, 1986. 301 p.

HINKELMANN, K.; KEMPTHORNE, O. **Design and analysis of experiments: introduction to experimental design.** 2 ed. New Jersey: John Wiley, 2008. 631 p.

KOWALCHUK, R.K.; HESELMAN, H.J.; ALGINA, J.; WOLFINGER, R.D. The analysis of repeated measurements with mixed-mode adjusted F tests. **Educational and Psychological Measurement**, v. 64, n. 2, p.224-242, 2004.

KUTNER, M.H.; NACHTSHEIM, C.J.; NETER, J.; LI, W. **Applied linear statistical models**. 5 ed. New York: McGraw-Hill/Irwin, 2005. 1396 p.

KUZNETSOVA, A.; BROCKHOFF, P.B.; CHRISTENSEN, R.H.B. lmerTest: tests for random and fixed effects for linear mixed effect models (lmer objects of lme4 package). Version 2.0-6. 2012.

LITTELL, R.C.; HENRY, P.R.; AMMERMAN, C.B. Statistical analysis of repeated measures using SAS procedures. **Journal of Animal Science**, v.76, p.1216-1231, 1998.

LITTELL, R.C.; PENDERGAST, J.; NATARAJAN, R. Modelling covariance structure in the analysis of repeated measures data. **Statistics in Medicine**, v.19, p.1793-1819, 2000.

LITTELL, R.C.; MILLIKEN, G.A.; STROUP, W.W.; WOLFINGER, R.D.; SCHABENBERGER, O. **SAS[®] for mixed models**. 2 ed. Cary: SAS Institute Inc., 2006. 795 p.

MOLENBERGHS, G.; VERBEKE, G. **Models for discrete longitudinal data**. New York: Springer, 2005. 671 p.

MRODE, R.A. **Linear models for the prediction of animal breeding values**. 3 ed. Wallingford: CAB International, 2015. 343 p.

NOBRE, J.S.; SINGER, J.M. Residual analysis for linear mixed models. **Biometrical Journal**, v.49, p.863-875, 2007.

NUNEZ-ANTÓN, V.N.; ZIMMERMAN, D.L. Modelling nonstationary longitudinal data. **Biometrics**, v.56, p.699-705, 2000.

OLIVEIRA, S. **Inferência e análise de resíduos e de diagnóstico em modelos lineares generalizados**. Trabalho de conclusão de curso: Universidade Federal de Juiz de Fora, 2013. 62 p.

PASCUAL, M.G.C.A. **Metodologia de dados espaciais aplicados a plantas forrageiras**. 2000. 100 p. Tese (Doutorado em Zootecnia) - Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul.

Porto Alegre, 2000.

PERRI, S.H.V.; IEMMA, A.F. Procedimento MIXED do SAS® para análise de modelos mistos. **Scientia Agricola**, v.56, n.4, p.959-967, 1999.

PINHEIRO, J.C.; BATES, D.M. **Mixed-effects models in S and S-PLUS**. New York: Springer-Verlang, 2000. 528 p.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna, Austria: R Foundation for Statistical Computing. 2016. Disponível em: <<http://www.R-project.org/>>. Acesso em: 27 de fevereiro de 2016.

REZENDE, D.M.L.C.; FERREIRA, D.F.; MUNIZ, J.A. et al. Comparações de técnicas de análises de experimentos utilizando medidas repetidas no tempo. **Ciência e Agrotecnologia**, v.23, n.4, p.928-938, 1999.

ROSÁRIO, M.F. **Emprego do conceito de medidas repetidas na avaliação do desempenho de genótipos de frangos de corte**. 2003. 66 p. Dissertação (Mestrado em Genética e Melhoramento de Plantas) - Universidade de São Paulo: Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2003.

SAS Institute, SAS (Statistical Analysis System). **SAS/STAT 9.2 User's Guide: The mixed procedure**. Cary: SAS Institute Inc. 2008. 224 p.

SCHWARZ, G. Estimating the dimensional of a model. **Annals of Statistics**, v.6, n.2, p.461-464, 1978.

SEARLE, S.R.; CASELLA, G.; MCCULLOCH, C. **Variance components**. New York: John Wiley, 1992. 501 p.

SILVA, E.N.; DUARTE, J.B.; REIS, A.J.S. Seleção da matriz de variância-covariância residual na análise de ensaios varietais com medidas repetidas em cana-de-açúcar. **Ciência Rural**, v.10, n.2, p.52-58, 2015.

SINGER, J.D.; WILLETT, J.B. **Applied longitudinal data analysis:**

Modeling change and event occurrence. New York: Oxford University Press, 2003. 644 p.

SINGER, J. M.; NOBRE, J.S.; ROCHA, F.M.M. (2015). **Análise de dados longitudinais** (versão parcial preliminar). Disponível em: <<http://www.ime.usp.br/~jmsinger/MAE0610/Singer&&Rocha&Nobre2015fev.pdf>>. Acesso em: 18 de agosto de 2015.

TORAL, F.L.B.; ALENCAR, M.M.; FREITAS, A.R. Arranjos para efeitos fixos e estruturas de (co)variâncias residuais para análises de medidas repetidas do peso de bovinos da raça Canchim. **Revista Brasileira de Zootecnia**, v.35, n.5, p.1951-1958, 2006.

TWISK, J.W.R. **Applied longitudinal data analysis for epidemiology: A practical guide**. New York: Cambridge University Press, 2003. 295 p.

VERBEKE, G.; MOLENBERGHS, G. **Linear mixed models for longitudinal data**. New York: Springer, 2000. 554 p.

VERBEKE, G.; MOLENBERGHS, G. **Linear mixed models in practice: A SAS-oriented approach**. New York: Springer-Verlag, 1997. 318 p.

WEST, B.T.; WELCH, K.B.; GATECKI, A.T. **Linear mixed models: a practical guide using statistical software**. 2 ed. Ann Arbor: Chapman and Hall/CRC, 2015. 405 p.

WOLFINGER, R.D. Heterogeneous variance covariance structures for repeated measures. **Journal of Agricultural Biological and Environmental Statistics**, v.1, n.2, p.205-230, 1996.

WOLFINGER, R.D. Covariance structure in general mixed models. **Communications in Statistics**, v.22, p.1079-1106, 1993.

APÊNDICE

APÊNDICE A - Rotina no programa estatístico R para a variável consumo médio de ração

```

> rm(list=ls())###Limpa a memória do histórico do R####
> #####Variável consumo médio de ração####
> #####Leitura dos dados:
> setwd("C:/Users/note/Documents/pasta frangos")
> dados<-read.table("PROJETO GALINHAS.txt",head=T)
> attach(dados)
> str(dados)
> names(dados)####Nomes das variáveis
> head(dados)##Lê as seis primeiras linhas dos dados
> #####Transformando em fator as variáveis#####
> trat.f=factor(Tratamento)
> periodo.f=factor(Periodo)
> repeticao.f=factor(Repeticao)
> erroA <- repeticao.f:trat.f
> #####Plotando gráficos exploratórios####
> ###Buscando pacote lattice####
> library(lattice)
> #####Análise de perfis individuais por tratamento####
> par(mar=c(4,4,0,0)+.1)
> interaction.plot(periodo.f,trat.f,Consumo,col=1,
+                   lty=c(1,3,5,6),lwd=3,legend =F,
+                   xlab="Tempo (Semanas)",ylab="Consumo
+                   de ração (g/ave/dia)")
> legend("topright", c("CN","CP","T1","T2"),xpd=TRUE,
+       horiz=FALSE,inset=c(0,0),bty="n",lty=c(1,3,5,6),
+       col=1,cex=1.40,lwd=3)
> #####Perfis individuais por tratamento#####
> parc.dados <- subset(dados, as.numeric(Parcela)

```

```

+                               %in% seq(1, 40, 1))
> perfisconsumo<- xyplot(Consumo ~ periodo.f |trat.f,
+                       groups = Parcela,type = "l",
+                       lty=1,data=parc.dados,lwd=2,
+                       col=1)
> update(perfisconsumo,xlab="Idade (semanas)",
+        ylab="Consumo de ração (g/ave/dia)",grid = "h")
> #####Boxplots do consumo médio de ração#####
> boxconsumo<-bwplot(Consumo ~ periodo.f | trat.f,
+                   data=dados,layout=c(2,2),
+                   xlab="Idade (semanas)",
+                   ylab="Consumo de ração (g/ave/dia)",
+                   par.settings = list(box.umbrella=
+                   list(col=1),box.dot=list(col= 1),
+                   box.rectangle =list(col= 1)))
> boxconsumo
> #####Estruturas de covariâncias: Função gls#####
> #####Simetria Composta Consumo médio de ração#####
> require(nlme)###Buscando o pacote nlme###
> #####Escrevendo o modelo com a função gls: CS#####
> Cons.CS<-gls(Consumo~trat.f+periodo.f+
+             (trat.f:periodo.f), data = dados,
+             correlation=corCompSymm(form= ~ 1|erroA))
> summary(Cons.CS)##Detalha a análise com a função gls##
> ###Imprime a matriz de correlação e covariâncias#####
> getVarCov(Cons.CS)
> #####Simetria Composta Heterogênea Consumo#####
> #####Função corandcov(SINGER;WILLET, 2003)#####
> corandcov <- function(glsob,cov=T,...){
+   corm <- corMatrix(glsob$modelStruct$corStruct)[[5]]
+   print(corm)
+   varstruct <- print(glsob$modelStruct$varStruct)

```

```

+ varests <- coef(varstruct, uncons=F, allCoef=T)
+ covm <- corm*glsob$sigma^2*t(t(varests))%*%t(varests)
+ return(covm)}
> #####Escrevendo o modelo com a função gls: CSH####
> Cons.CSH<-gls(Consumo~trat.f+periodo.f+
+             (trat.f:periodo.f), data = dados,
+             method="REML", correlation=
+             corCompSymm(form=~1|erroA),
+             weights=varIdent(form=~1|periodo.f))
> summary(Cons.CSH)##Detalha a análise com a função gls##
> ###Imprime a matriz de correlação e covariâncias####
> corandcov(Cons.CSH)
> ##### Estrutura Não Estruturada Consumo#####
> #####Escrevendo o modelo com a função gls: UN####
> Cons.UN<-gls(Consumo~trat.f+periodo.f+
+             (trat.f:periodo.f), data = dados,
+             method="REML", correlation =
+             corSymm(form= ~ 1 |erroA),
+             weights = varIdent(form = ~ 1|periodo.f))
> summary(Cons.UN)##Detalha a análise com a função gls##
> ###Imprime a matriz de correlação e covariâncias####
> (Cons.UN$sigma*coef(Cons.UN$modelStruct$varStruct,
+ uncons = FALSE, allCoef = TRUE))^2
> corandcov(Cons.UN)
> #####Estrutura ARH(1) Consumo####
> #####Escrevendo o modelo com a função gls: ARH(1)####
> Cons.ARH<-gls(Consumo~trat.f+periodo.f+
+             (trat.f:periodo.f), data = dados,
+             method="REML", correlation =
+             corAR1(form= ~ 1 |erroA),
+             weights=varIdent(form =~ 1|periodo.f))
> summary(Cons.ARH)##Detalha a análise com a função gls##

```

```

> ###Imprime a matriz de correlação e covariâncias####
> (Cons.ARH$sigma*coef(Cons.ARH$modelStruct$varStruct,
+ uncons = FALSE, allCoef = TRUE))^2
> corandcov(Cons.ARH)
> #####Autorregressiva de primeira ordem Consumo####
> #####Escrevendo o modelo com a função gls: AR(1)####
> Cons.AR1<-gls(Consumo~trat.f+periodo.f+
+             (trat.f:periodo.f), data = dados,
+             method="REML", correlation =
+             corAR1(form= ~ 1 |erroA))
> summary(Cons.AR1)##Detalha a análise com a função gls##
> ###Imprime a matriz de correlação e covariâncias####
> CRAR1 <- corMatrix(Cons.AR1$modelStruct$corStruct)[[5]]
> print(CRAR1)
> CRAR1 * Cons.AR1$sigma^2
> getVarCov(Cons.AR1)
> #####Comparação de modelos com a função anova####
> anova(Cons.CS,Cons.CSH,Cons.AR1,Cons.ARH,Cons.UN)
> anova(Cons.UN,Cons.CS)
> anova(Cons.UN,Cons.CSH)
> anova(Cons.UN,Cons.AR1)
> anova(Cons.UN,Cons.ARH)
> ###Análise de resíduos da variável consumo de ração###
> require(lattice)###Buscando o pacote lattice####
> #####Gráfico dos preditos versus valores ajustados####
> plot(predict(Cons.UN), residuals(Cons.UN),
+       xlab = "Valores preditos", ylab = "Resíduos")
> #Gráfico dos resíduos padronizados x valores ajustados#
> plot(Cons.UN,resid(., type ="p") ~ fitted(.) |
+       factor(Tratamento),layout=c(4,1),aspect=2,
+       abline=0)
> #####Boxplots dos resíduos do modelo####

```

```

> panel.bwxplot<-function(x,y, subscripts, ...){
+   panel.grid(h = -1)
+   panel.stripplot(x, y, col = "grey", ...)
+   panel.bwplot(x, y, pch = "|", ...)}
> bwplot(resid(Cons.UN, type = "n") ~ periodo.f | trat.f,
+   panel = panel.bwxplot, ###Use painel acima###
+   data = dados)
> #####Gráfico quantil-quantil da normal
> qqnorm(Cons.UN,~resid(.,type = "n")|factor(Tratamento),
+   layout= c(4,1),aspect=2,abline = c(0,1),
+   xlab = "Resíduos normalizados",
+   ylab = "Quantis da normal padrão")
> qqnorm(residuals(Cons.UN),xlab = "Quantis teóricos",
+   ylab = "Resíduos",main="")
> qqline(residuals(Cons.UN))
> #####Teste de normalidade####
> shapiro.test(residuals(Cons.UN))
> #####Transformação box-cox####
> require(MASS)
> boxcox(Consumo~trat.f*periodo.f,data=dados,
+   plotit=T,lam=seq(-2, 6, 0.2),
+   ylab="Função log verossimilhança")
> a<-boxcox(Consumo~trat.f*periodo.f,
+   data=dados, lam=seq(-2, 6, 0.2))
> a
> lambda<-a$x
> lambda
> lik<-a$y
> lik
> bc=cbind(lambda,lik)
> bc[order(-lik),]
> ###Variável transformada: Consumo médio de ração##

```

```

> Consumo1 <- (Consumo^(1.3939) - 1)/1.3939
> Consumo1
> #####Esquema de parcela subdividida no tempo####
> require(car)####Buscando o pacote car no programa R
> #####Escrevendo o modelo####
> modelo.consumo<- aov(Consumo~trat.f*periodo.f+
+                       Error(erroA),data=dados)
> summary(modelo.consumo)####Análise de variância###
> ###Variável Consumo médio de ração (g/ave/dia)###
> #####Função lmer####
> require(lme4)###Buscando o pacote lme4###
> CR.lmer=lmer(Consumo~trat.f+ (1|erroA)+ periodo.f+
+              (trat.f:periodo.f),data=dados)
> summary(CR.lmer)####Detalha a análise###
> anova(CR.lmer)###Análise de variância da função lmer###
> #####Valores-p para o teste de F####
> pf(anova(CR.lmer)[1,4],df1=3, df2=36, lower.tail=F)
> pf(anova(CR.lmer)[2,4],df1=11, df2=396, lower.tail=F)
> pf(anova(CR.lmer)[3,4],df1=33, df2=396, lower.tail=F)
> print(CR.lmer,corr=TRUE)##Imprime os detalhes do modelo
> VarCorr(CR.lmer)##Imprime os componentes de variância###
> #####Função lmerTest####
> require(lmerTest)###Buscando o pacote lmerTest###
> #####Descrevendo o modelo####
> CR.lmertest=lmer(Consumo~trat.f+ (1|erroA)+ periodo.f+
+                 (trat.f:periodo.f),data=dados)
> summary(CR.lmertest)###Detalha a análise com a função##
> anova(CR.lmertest)###Análise de variância da função####
> #####Médias e erros-padrões com a função step####
> CR.lsmmeans<-step(CR.lmertest,reduce.fixed = FALSE,
+                   reduce.random = FALSE)
> CR.lsmmeans$lsmmeans.table

```

```
> ###Análise gráfica das estruturas de covariância###
> ##Não estruturada (UN): Consumo de ração (g/ave/dia)#
> ##Criando as observações das semanas de avaliação##
> Semanas<-c(1,1,2,1,2,3,1,2,3,4,1,2,3,4,5,1,2,3,4,5,6,1,
+           2,3,4,5,6,7,1,2,3,4,5,6,7,8,1,2,3,4,5,6,7,8,
+           9,1,2,3,4,5,6,7,8,9,10,1,2,3,4,5,6,7,8,9,10,
+           11,1,2,3,4,5,6,7,8,9,10,11,12)
> #####Criando as distâncias entre as observações#####
> distancia.cr<-c(0,1,0,2,1,0,3,2,1,0,4,3,2,1,0,5,4,3,2,
+           1,0,6,5,4,3,2,1,0,7,6,5,4,3,2,1,0,8,7,
+           6,5,4,3,2,1,0,9,8,7,6,5,4,3,2,1,0,10,
+           9,8,7,6,5,4,3,2,1,0,11,10,9,8,7,6,5,4,
+           3,2,1,0)
> ###Criando as observações da covariância residual#
> Covun.cr<-c(33.175768,1.315673,50.589473,15.82330,
+           15.50304,30.57834,11.777066,11.341127,
+           23.758665,35.832946,16.930732,3.001083,
+           28.199081,33.062977,63.694920,6.230931,
+           9.751402,17.390533,20.152730,21.603651,
+           22.135930,9.470656,12.047626,19.330680,
+           18.621556,19.867622,19.041549,27.954833,
+           16.616666,1.664672,21.427847,19.089729,
+           15.381234,20.088024,25.171483,61.414857,
+           15.875817,-6.927673,22.714187,18.866884,
+           26.938900,18.957083,19.116787,37.933910,
+           45.134164,5.962183,14.201846,23.316924,
+           20.000755,28.229619,21.639290,24.348015,
+           34.522493,33.930711,50.273205,6.833179,
+           8.240539,17.839289,17.610100,24.906870,
+           18.465097,18.855304,19.571069,24.390723,
+           29.848651,26.783819,1.065656,17.853232,
+           10.923757,7.957655,24.739072,13.436290,
```

```
+           15.556015,5.145681,8.069358,30.331503,
+           19.302560,54.215096)
> #####Transformando em fatores#####
> distancia.cr<-factor(distancia.cr)
> Semanas<-factor(Semanas)
> require(lattice)###Buscando o pacote no programa R###
> #####Plotando o gráfico#####
> par(mar=c(4,4,0,0)+.1)
> interaction.plot(distancia.cr,Semanas,Covun.cr,type="l",
+                 col=1,lty=1:6,xlab="Distância (Semanas)"
+                 ,legend =F,ylab="Covariância Residual",
+                 lwd=3)
> #####Adicionando a legenda#####
> legend("topright", bty='n',xpd=NA,title = "Semanas",
+       c("1","2","3","4","5","6","7","8","9","10",
+       "11","12"),lwd=1,lty=1:12,cex=0.8)
```

APÊNDICE B - Rotina no programa estatístico R para a variável peso da gema

```

> rm(list=ls())###Limpa a memória do histórico do R###
> #####Variável Peso da gema####
> #####Leitura dos dados:
> setwd("C:/Users/note/Documents/pasta frangos")
> dados<-read.table("POEDEIRAS QUALIDADE.txt",head=T)
> attach(dados)
> str(dados)
> names(dados)####Nomes das variáveis
> head(dados)#Lê as seis primeiras linhas dos dados
> #####Transformando em fator as variáveis#####
> trat=factor(Tratamento)
> periodo=factor(Periodo)
> repeticao=factor(Repeticao)
> erroa<- repeticao:trat
> #####Plotando gráficos exploratórios####
> ###Buscando pacote lattice###
> library(lattice)
> #####Análise de perfis individuais por tratamento####
> par(mar=c(4,4,0,0)+.1)
> interaction.plot(periodo,trat,pesodagama,
+                   col=1,lty=c(1,3,5,6),lwd=3,
+                   xlab="Época de avaliação (dias)",
+                   ylab="Peso da gema (g)",legend =F)
> legend("topright", c("CN","CP","T1","T2"),xpd=TRUE,
+       horiz=FALSE,inset=c(0,0),bty="n",cex=1.40,
+       lwd=3,lty=c(1,3,5,6),col=1)
> #####Perfis individuais por tratamento#####
> parc.dados <- subset(dados, as.numeric(Parcela)
+                       %in% seq(1, 40, 1))
> perfispesodagama<-xyplot(pesodagama ~ periodo |trat,

```

```

+             groups = Parcela,type = "l",
+             lty=1,data=parc.dados,lwd=2,
+             col=1)
> update(perfispesodagama,
+       xlab="Época de avaliação (dias)",
+       ylab="Peso da gema (g)",grid = "h")
> #####Boxplots do peso da gema#####
> boxpesodagama<-bwplot(pesodagama ~ periodo | trat,
+       data=dados,layout=c(2,2),
+       xlab="Época de avaliação (dias)",
+       ylab="Peso da gema (g)",
+       par.settings = list(box.umbrella=
+       list(col=1),box.dot=list(col= 1),
+       box.rectangle =list(col= 1)))
> boxpesodagama
> #####Estruturas de covariâncias: Função gls#####
> #####Simetria Composta Peso da gema (g)#####
> require(nlme)###Buscando o pacote nlme###
> #####Escrevendo o modelo com a função gls: CS#####
> pg.CS<- gls(pesodagama~trat+periodo+
+       (trat:periodo), data = dados,
+       correlation = corCompSymm(form= ~ 1 |erroa))
> summary(pg.CS)###Detalha a análise com a função gls###
> ###Imprime a matriz de correlação e covariâncias#####
> getVarCov(pg.CS)
> #####Simetria Composta Heterogênea Peso da gema(g)#####
> #####Função corandcov(SINGER;WILLET, 2003)#####
> corandcov <- function(glsob,cov=T,...){
+   corm <- corMatrix(glsob$modelStruct$corStruct)[[5]]
+   print(corm)
+   varstruct <- print(glsob$modelStruct$varStruct)
+   varests <- coef(varstruct, uncons=F, allCoef=T)

```

```

+   covm <- corm*glsob$sigma^2*t(t(varests))%*%t(varests)
+   return(covm)}
> #####Escrevendo o modelo com a função gls: CSH####
> pg.CSH <- gls(pesodagama~trat+periodo+
+             (trat:periodo), data = dados,
+             method="REML", correlation=
+             corCompSymm(form=~1|erroa),
+             weights=varIdent(form=~1|periodo))
> summary(pg.CSH)###Detalha a análise com a função gls###
> ###Imprime a matriz de correlação e covariâncias####
> corandcov(pg.CSH)
> ##### Estrutura Não Estruturada Peso da gema (g)#####
> #####Escrevendo o modelo com a função gls: UN####
> pg.UN<- gls(pesodagama~trat+periodo+
+            (trat:periodo), data = dados,
+            method="REML", correlation =
+            corSymm(form= ~ 1 |erroa),
+            weights = varIdent(form = ~ 1 | periodo))
> summary(pg.UN)###Detalha a análise com a função gls###
> ###Imprime a matriz de correlação e covariâncias####
> (pg.UN$sigma*coef(pg.UN$modelStruct$varStruct,
+ uncons = FALSE, allCoef = TRUE))^2
> corandcov(pg.UN)
> #####Estrutura ARH(1) Peso da gema (g)####
> #####Escrevendo o modelo com a função gls: ARH(1)####
> pg.ARH<-gls(pesodagama~trat+periodo+
+            (trat:periodo), data = dados,
+            method="REML", correlation =
+            corAR1(form= ~ 1 |erroa),
+            weights = varIdent(form = ~ 1 | periodo))
> summary(pg.ARH)###Detalha a análise com a função gls###
> ###Imprime a matriz de correlação e covariâncias####

```

```

> (pg.ARH$sigma*coef(pg.ARH$modelStruct$varStruct,
+ uncons = FALSE, allCoef = TRUE))^2
> corandcov(pg.ARH)
> ###Autorregressiva de primeira ordem Peso da gema (g)###
> ####Escrevendo o modelo com a função gls: AR(1)####
> pg.AR1<-gls(pesodagema~trat+periodo+
+           (trat:periodo), data = dados,
+           method="REML", correlation =
+           corAR1(form= ~ 1 |erroa))
> summary(pg.AR1)###Detalha a análise com a função gls###
> ###Imprime a matriz de correlação e covariâncias####
> PGAR1 <- corMatrix(pg.AR1$modelStruct$corStruct)[[5]]
> print(PGAR1)
> PGAR1 * pg.AR1$sigma^2
> getVarCov(pg.AR1)
> ####Comparação de modelos com a função anova####
> anova(pg.CS,pg.CSH,pg.AR1,pg.ARH,pg.UN)
> anova(pg.AR1,pg.CS)
> anova(pg.AR1,pg.CSH)
> anova(pg.AR1,pg.ARH)
> anova(pg.AR1,pg.UN)
> ####Análise de resíduos da variável peso da gema####
> require(lattice)###Buscando o pacote lattice####
> ####Gráfico dos preditos x valores ajustados####
> plot(predict(pg.AR1), residuals(pg.AR1),
+       xlab = "Valores preditos", ylab = "Resíduos")
> ##Gráfico dos resíduos padronizados x valores ajustados
> plot(pg.AR1, resid(., type = "p") ~ fitted(.) |
+       factor(Tratamento),layout= c(4,1),aspect=2,
+       abline=0)
> #####Boxplots dos resíduos do modelo####
> panel.bwxplot <-function(x,y, subscripts, ...){

```

```

+   panel.grid(h = -1)
+   panel.stripplot(x, y, col = "grey", ...)
+   panel.bwplot(x, y, pch = "|", ...)}
> bwplot(resid(pg.AR1, type = "n") ~ periodo | trat,
+         panel = panel.bwplot, ###Use painel acima###
+         data = dados)
> #####Gráficos quantil-quantil da normal
> qqnorm(pg.AR1, ~resid(., type = "n")|factor(Tratamento),
+        layout= c(4,1),aspect=2,abline = c(0,1),
+        xlab = "Resíduos normalizados",
+        ylab = "Quantis da normal padrão")
> qqnorm(residuals(pg.AR1),xlab = "Quantis teóricos",
+        ylab = "Resíduos",main="")
> qqline(residuals(pg.AR1))
> #####Teste de normalidade#####
> shapiro.test(residuals(pg.AR1))
> #####Esquema de parcela subdividida no tempo#####
> require(car)#####Buscando o pacote car no programa R
> #####Escrevendo o modelo#####
> modelo.pesodagama<-aov(pesodagama~trat*periodo+
+                        Error(erroa),data=dados)
> summary(modelo.pesodagama)###Análise de variância###
> #####Função lmer#####
> require(lme4)###Buscando o pacote lme4###
> pg.lmer=lmer(pesodagama~trat+(1|erroa)+periodo+
+             (trat:periodo),data=dados)
> summary(pg.lmer)###Detalha a análise###
> anova(pg.lmer)###Análise de variância da função lmer###
> #####Valores-p para o teste F#####
> pf(anova(pg.lmer)[1,4],df1=3, df2=36, lower.tail=F)
> pf(anova(pg.lmer)[2,4],df1=9, df2=108, lower.tail=F)
> pf(anova(pg.lmer)[3,4],df1=9, df2=108, lower.tail=F)

```



```
+             ylab = "Covariância Residual",lwd=3)
> #####Adicionando a legenda#####
> legend("topright",bty='n',xpd=NA,col= 1,lwd=1,cex=1,
+       lty=1:4,title ="Época de avaliação",
+       c("1","2","3","4"))
```

APÊNDICE C - Rotina no programa estatístico SAS para a variável consumo médio de ração

```

/*Importando os dados no Programa SAS: Variável Consumo de ração*/
PROC IMPORT OUT= WORK.galinhas
  DATAFILE= "C:\Users\note\Documents\pasta frangos\PROJETO GALINHAS.txt"
    DBMS=TAB REPLACE;
    GETNAMES=YES;
    DATAROW=2;
RUN;

*Modelo misto com o procedimento MIXED;
*Variável resposta: Consumo de ração (gramas/ave/dia);
/*Estrutura de covariância: Componentes de de variância(VC) */
title1 'Componentes de variancia (VC)';
title2 'Consumo de racao (gramas/ave/dia)';
proc mixed data=galinhas method=reml covtest;
class Tratamento Período Repeticao;
model Consumo =Tratamento Período Tratamento*Período/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=VC r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitcrvc;
run;

/*Estrutura de covariância: Simetria composta (CS) */
title1 'Simetria composta (CS)';
title2 'Consumo de racao (gramas/ave/dia)';
proc mixed data=galinhas method=reml covtest;
class Tratamento Período Repeticao;
model Consumo =Tratamento Período Tratamento*Período/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=CS r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitcrs;
run;

/*Estrutura de covariância: Simetria Composta Heterogenea (CSH) */
title1 'Simetria Composta Heterogenea (CSH)';
title2 'Consumo de racao (gramas/ave/dia)';
proc mixed data=galinhas method=reml covtest;
class Tratamento Período Repeticao;

```

```

model Consumo =Tratamento Período Tratamento*Período/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=CSH r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitcrcsh;
run;

/*Estrutura de covariância: Autorregressiva de primeira ordem (AR(1));
title1 'Autorregressiva de primeira ordem - AR(1)';
title2 'Consumo de ração (gramas/ave/dia)';
proc mixed data=galinhas method=reml covtest;
class Tratamento Período Repeticao;
model Consumo =Tratamento Período Tratamento*Período/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=AR(1) r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitcrar1;
run;

*Estrutura de covariância: Autorregressiva Heterogênea (ARH(1));
title1 'Autorregressiva heterogenea de primeira ordem - ARH(1)';
title2 'Consumo de ração (gramas/ave/dia)';
proc mixed data=galinhas method=reml covtest;
class Tratamento Período Repeticao;
model Consumo =Tratamento Período Tratamento*Período/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=ARH(1) r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitcrarh1;
run;

/*Estrutura de covariância: Não estruturada (UN) */
title1 'Componentes de variancia (UN)';
title2 'Consumo de ração (gramas/ave/dia)';
proc mixed data=galinhas method=reml covtest;
class Tratamento Período Repeticao;
model Consumo =Tratamento Período Tratamento*Período/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=UN r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitcrun;
run;

*Estrutura de covariância: Huynh-Feldt (HF);

```

```
title1 'Huynh-Feldt (HF)';
title2 'Consumo de racao (gramas/ave/dia)';
proc mixed data=galinhas method=reml covtest;
class Tratamento Período Repeticao;
model Consumo =Tratamento Período Tratamento*Período/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=HF r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitcrhf;
run;

/* Fit statistics Teste de razão de verossimilhanças*/
title1 'Componentes de variancia (VC)';
title2 'Consumo de racao (gramas/ave/dia)';
proc print data=fitcrvc;
run;

title1 'Simetria composta (CS)';
title2 'Consumo de racao (gramas/ave/dia)';
proc print data=fitcracs;
run;

title1 'Simetria composta heterogênea (CSH)';
title2 'Consumo de racao (gramas/ave/dia)';
proc print data=fitcrash;
run;

title1 'Autorregressiva primeira ordem - AR(1)';
title2 'Consumo de racao (gramas/ave/dia)';
proc print data=fitcrar1;
run;

title1 'Autorregressiva heterogenea de primeira ordem - ARH(1)';
title2 'Consumo de racao (gramas/ave/dia)';
proc print data=fitcrarh1;
run;

title1 'Nao estruturada (UN)';
title2 'Consumo de racao (gramas/ave/dia)';
proc print data=fitcrun;
run;
```

```
title1 'Huynh-Feldt (HF)';
title2 'Consumo de racao (gramas/ave/dia)';
proc print data=fitcrhf;
run;

/*UN:VC - Teste de razão de verossimilhanças*/
data _null_;
merge fitcrvc(rename=(value=reference)) fitcrun(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 78 - 1;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp;
format valorp 10.8;
end;
run;

/*UN:CS - Teste de razão de verossimilhanças*/
data _null_;
merge fitcracs(rename=(value=reference)) fitcrun(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl=78-2;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp;
format valorp 10.8;
end;
run;

/*UN:CSH - Teste de razão de verossimilhanças*/
data _null_;
merge fitcrash(rename=(value=reference))
fitcrun(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
```

```

trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 78 - 13;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp=;
format valorp 10.8;
end;
run;

/*UN:AR(1) - Teste de razão de verossimilhanças*/
data _null_;
merge fitcrar1(rename=(value=reference))
fitcrun(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 78 - 2;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp=;
format valorp 10.8;
end;
run;

/*UN:ARH(1) - Teste de razão de verossimilhanças*/
data _null_;
merge fitcrarh1(rename=(value=reference))
fitcrun(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 78 - 13;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp=;
format valorp 10.8;
end;
run;

/*UN:HF - Teste de razão de verossimilhanças*/

```

```
data _null_;
merge fitcrhf(rename=(value=reference)) fitcrun(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 78 - 13;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp=;
format valorp 10.8;
end;
run;
```

APÊNDICE D - Rotina no programa estatístico SAS para a variável peso da gema

```

*Importando os dados no Programa SAS: Variável peso da gema;
PROC IMPORT OUT= WORK.POEDEIRASQUALIDADE
DATAFILE= "C:\Users\note\Documents\pasta
           frangos\POEDEIRAS QUALIDADEr.txt"
           DBMS=TAB REPLACE;
           GETNAMES=YES;
           DATAROW=2;
RUN;

*Variável: Peso da gema (gramas);
*Estrutura de covariância: Componentes de de variância (VC);
title1 'Componentes de variancia (VC)';
title2 'Peso da gema (gramas)';
proc mixed data =poedeirasqualidade method=reml covtest;
class Tratamento Período Repeticao;
model pesodagama=Tratamento Período Tratamento*Período
/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=VC r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitpdgvc;
run;

*Estrutura de covariância: Simetria Composta (CS);
title1 'Simetria Composta (CS)';
title2 'Peso da gema (gramas)';
proc mixed data =poedeirasqualidade method=reml covtest;
class Tratamento Período Repeticao;
model pesodagama=Tratamento Período Tratamento*Período
/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=CS r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitpdgcs;
run;

*Estrutura de covariância: Simetria Composta Heterogênea (CSH);
title1 'Simetria Composta Heterogenea (CSH)';
title2 'Peso da gema (gramas)';

```

```

proc mixed data =poedeirasqualidade method=reml covtest;
class Tratamento Período Repeticao;
model pesodagama=Tratamento Período Tratamento*Período
/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=CSH r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitpdgcsh;
run;

*Estrutura de covariância: Autorregressiva de Primeira Ordem (AR(1));
title1 'Autorregressiva de primeira ordem - AR(1)';
title2 'Peso da gema (gramas)';
proc mixed data =poedeirasqualidade method=reml covtest;
class Tratamento Período Repeticao;
model pesodagama=Tratamento Período Tratamento*Período
/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=AR(1) r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitpdgar1;
run;

*Estrutura de covariância: ARH(1);
title1 'Autorregressiva heterogenea de primeira ordem - ARH(1)';
title2 'Peso da gema (gramas)';
proc mixed data =poedeirasqualidade method=reml covtest;
class Tratamento Período Repeticao;
model pesodagama=Tratamento Período Tratamento*Período
/solution ddfm=sat;
repeated Período / subject = Repeticao(Tratamento) type=ARH(1) r rcorr;
lsmeans Tratamento Período Tratamento*Período;
ods output fitstatistics =fitpdgarh1;
run;

*Estrutura de covariância: Não estruturada (UN);
title1 'Nao estruturada (UN)';
title2 'Peso da gema (gramas)';
proc mixed data =poedeirasqualidade method=reml covtest;
class Tratamento Período Repeticao;
model pesodagama=Tratamento Período Tratamento*Período
/solution ddfm=sat;

```

```
repeated Perodo / subject = Repeticao(Tratamento) type=UN r rcorr;
lsmeans Tratamento Perodo Tratamento*Perodo;
ods output fitstatistics =fitpdgun;
run;

*Estrutura de covariância: Huynh-Feldt (HF);
title1 'Huynh-Feldt (HF)';
title2 'Peso da gema (gramas)';
proc mixed data =poedeirasqualidade method=reml covtest;
class Tratamento Perodo Repeticao;
model pesodagama=Tratamento Perodo Tratamento*Perodo
/solution ddfm=sat;
repeated Perodo / subject = Repeticao(Tratamento) type=HF r rcorr;
lsmeans Tratamento Perodo Tratamento*Perodo;
ods output fitstatistics =fitpdghf;
run;

/* Fit statistics Teste de razão de verossimilhanças*/

title1 'Componentes de variancia (VC)';
title2 'Peso da gema (gramas)';
proc print data=fitpdgvc;
run;

title1 'Simetria composta (CS)';
title2 'Peso da gema (gramas)';
proc print data=fitpdgcs;
run;

title1 'Simetria composta heterogênea (CSH)';
title2 'Peso da gema (gramas)';
proc print data=fitpdgcsh;
run;

title1 'Autorregressiva primeira ordem - AR(1)';
title2 'Peso da gema (gramas)';
proc print data=fitpdgar1;
run;

title1 'Autorregressiva heterogenea de primeira ordem - ARH(1)';
```

```
title2 'Peso da gema (gramas)';
proc print data=fitpdgarh1;
run;

title1 'Nao estruturada (UN)';
title2 'Peso da gema (gramas)';
proc print data=fitpdgun;
run;

title1 'Huynh-Feldt (HF)';
title2 'Peso da gema (gramas)';
proc print data=fitpdghf;
run;

/*AR(1):VC- Teste de razão de verossimilhanças*/
data _null_;
merge fitpdgvc(rename=(value=reference))
fitpdgar1(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 2 - 1;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp;
format valorp 10.8;
end;
run;

/*AR(1):CSH - Teste de razão de verossimilhanças*/
data _null_;
merge fitpdgar1(rename=(value=reference))
fitpdgcsh(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 5 - 2;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp;
```

```
format valorp 10.8;
end;
run;

/*AR(1):ARH(1) - Teste de razão de verossimilhanças*/
data _null_;
merge fitpdgar1(rename=(value=reference))
fitpdgarh1(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 5 - 2;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp=;
format valorp 10.8;
end;
run;

/*AR(1):UN - Teste de razão de verossimilhanças*/
data _null_;
merge fitpdgar1(rename=(value=reference))
fitpdgun(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 10 - 2;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp=;
format valorp 10.8;
end;
run;

/*AR(1):HF - Teste de razão de verossimilhanças*/
data _null_;
merge fitpdgar1(rename=(value=reference))
fitpdghf(rename=(value=nested));
retain trv;
if descr="-2 Res Log Likelihood" then
```

```
trv = reference - nested;
if descr="-2 Res Log Likelihood" then do;
gl= 5 - 2;
valorp=0.5*(1-probchi(trv,gl));
put trv=gl=valorp=;
format valorp 10.8;
end;
run;
```