



Universidade Federal de Pernambuco  
Centro de Ciências Exatas e da Natureza  
Departamento de Estatística  
Pós-Graduação em Estatística

Roberto Ferreira Manghi

**Técnicas de Diagnóstico em Modelos Parcialmente  
Lineares Aditivos Generalizados para Dados  
Correlacionados**

Recife  
2016

Roberto Ferreira Manghi

**Técnicas de Diagnóstico em Modelos Parcialmente  
Lineares Aditivos Generalizados para Dados  
Correlacionados**

Orientador:  
Prof. Dr. Francisco José de Azevêdo Cysneiros

Tese apresentada ao Programa de Pós-Graduação em Estatística da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutor em Estatística.

Recife  
2016

Catalogação na fonte  
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

M277t Manghi, Roberto Ferreira.  
Técnicas de diagnóstico em modelos parcialmente lineares aditivos generalizados para dados correlacionados / Roberto Ferreira Manghi. – 2016.  
149 f.: il., fig., tab.

Orientador: Francisco José de Azevêdo Cysneiros.  
Tese (Doutorado) – Universidade Federal de Pernambuco. CCEN.  
Estatística, Recife, 2016.  
Inclui referências.

1. Probabilidade. 2. Distribuição de probabilidade. 3. Estatística aplicada – Modelagem. 4. Regressão. I. Cysneiros, Francisco José de Azevêdo (orientador). II. Título.

519.2

CDD (23. ed.)

UFPE- MEI 2016-041

**ROBERTO FERREIRA MANGHI**

**TÉCNICAS DE DIAGNÓSTICO EM MODELOS PARCIALMENTE LINEARES  
ADITIVOS GENERALIZADOS PARA DADOS CORRELACIONADOS**

Tese apresentada ao Programa de Pós-Graduação em Estatística da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutor em Estatística.

Aprovada em: 26 de fevereiro de 2016.

**BANCA EXAMINADORA**

---

Prof. Francisco José de Azevedo Cysneiros  
UFPE

---

Prof.<sup>a</sup> Audrey Helen Mariz de Aquino Cysneiros  
UFPE

---

Prof. Getúlio José Amorim do Amaral  
UFPE

---

Prof. Gilberto Alvarenga Paula  
USP

---

Prof. Manoel Ferreira do Santos Neto  
UFCG

# Agradecimentos

- Gostaria de agradecer primeiramente aos meus familiares, em especial ao meu Pai **Roberto** e à minha Mãe **Raquel**, que sempre acreditaram nos meus objetivos e sempre me deram todo o suporte nesta jornada.
- Ao meu irmão **Gustavo**, aos meus sobrinhos **Eduardo**, **Arthur** e **Gabriel** e aos meus tios e tias, com muito carinho.
- Dedico também este trabalho aos meus **avós** (*in memorian*).
- À minha noiva **Paula**, a quem devo tanta compreensão e tanto amor durante todo o tempo desde a Graduação, nas felicidades e também nos momentos difíceis.
- Ao meu enteado **Renato**, grande amigo e companheiro e à minha cunhada **Profa. Dra. Renata Akemi Shinozaki Mendes**, amiga e parceira em trabalhos científicos.
- Ao meu orientador **Prof. Dr. Francisco José de Azevêdo Cysneiros**, pela paciência e dedicação fornecidas ao longo da realização deste trabalho.
- Ao **Prof. Dr. Gilberto Alvarenga Paula**, pela honra e satisfação de trabalhar com um professor de tanto gabarito a partir do mestrado, e que tanto contribuiu em minha formação acadêmica.
- Aos amigos e professores do **Departamento de Estatística** da **Universidade Federal de Pernambuco**, por sempre acreditarem em meu potencial e por sempre me incentivarem.
- Ao **Prof. Dr. Paulo de Paula Mendes** e à **Profa. Dra. Emiko Shinozaki Mendes**, ambos professores da **Universidade Federal Rural de Pernambuco**, pelo apoio e pelos conselhos a respeito da vida acadêmica.
- Aos colegas de pós-graduação do **Departamento de Estatística** da **Universidade Federal de Pernambuco**, pelo convívio durante o tempo de Doutorado, uma experiência ímpar em meu desenvolvimento.
- Ao apoio financeiro da **CAPES**.

# Resumo

Nesta tese desenvolvemos técnicas de diagnóstico nos Modelos Parcialmente Lineares Aditivos Generalizados (MPLAG) (ver Lian et al., 2014) para dados correlacionados com distribuição marginal pertencente à família exponencial, em que a média depende de componentes paramétricos e não-paramétricos. Adicionalmente, propomos equações para estimação conjunta dos efeitos fixos e parâmetros de correlação. Desenvolvemos o processo de estimação conjunta dos parâmetros e estimadores “naive” e “robustos” dos erros-padrão dos estimadores são propostos. São desenvolvidas medidas de alavancagem, análise de resíduos e análise de influência local baseada na curvatura normal sob diferentes cenários de perturbação. Três tipos de resíduos são derivados e um estudo de simulação é realizado para verificar propriedades empíricas dos resíduos propostos e dos estimadores dos efeitos fixos. Gráficos de quantis normais com envelopes simulados são utilizados para investigar a adequabilidade dos modelos ajustados sob a suposição de uma distribuição marginal pertencente à família exponencial e aplicações a dados reais são apresentadas.

**Palavras-chave:** Análise de resíduos. Dados correlacionados. Equações de estimação generalizadas. Influência local. Modelos semiparamétricos.

# Abstract

In this thesis we developed diagnostic techniques on Generalized Additive Partial Linear Models (GAPLM) (see Lian et al., 2014) for correlated data with marginal distribution on the exponential family, where the mean depends on parametric and non-parametric components. In addition, we propose equations for joint estimation of fixed effects and correlation parameters. We developed the joint parameter estimation process and “naive” and “robust” estimators for the standard-errors of the estimators are proposed. Leverage measures, residual analysis and local influence analysis based on the normal curvature under different perturbation scenarios are developed. Three types of residuals are derived and a simulation study is conducted to verify empirical properties of the proposed residuals and the fixed effects estimators. Normal quantile graphics with simulated envelopes are used to investigate the fitted models adequacy under the assumption of a marginal distribution on the exponential family and applications to real data are presented.

**Keywords:** Residuals analysis. Correlated data. Generalized estimating equations. Local influence. Semiparametric models.

# **Lista de Figuras**

5.1	Valores da medida de função pulmonar FEV1 versus altura para os vinte indivíduos considerados no Estudo de Poluição do Ar.	102
5.2	Gráfico da função não-paramétrica estimada (a) e gráficos de quantis normais com envelopes simulados (95% de confiança) para os resíduos de Pearson (b) “naive” (c) e “robustos” (d) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 1 para os dados referentes ao Estudo de Poluição do Ar.	105
5.3	Gráficos das medidas de alavancagem por período observado para cada observação (a) e para cada indivíduo (b) considerado sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 1 para os dados referentes ao Estudo de Poluição do Ar.	106
5.4	Gráficos das medidas de influência local segundo a perturbação de casos (a), perturbação na variável resposta (b) e perturbação em uma variável explicativa (c) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 1 para os dados referentes ao Estudo de Poluição do Ar.	107
5.5	Dosagem de PBG versus pressão sanguínea média segundo os dois tratamentos considerados nos Dados de Pressão Sanguínea.	109
5.6	Gráfico da função não-paramétrica estimada (a) e gráficos de quantis normais com envelopes simulados (95% de confiança) para os resíduos de Pearson (b) “naive” (c) e “robustos” (d) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 1 para os Dados de Pressão Sanguínea.	111
8.1	Gráfico da função não-paramétrica estimada (a) e gráficos de quantis normais com envelopes simulados (95% de confiança) para os resíduos de Pearson (b) “naive” (c) e “robustos” (d) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 2 para os dados referentes ao Estudo de Poluição do Ar.	135
8.2	Gráficos das medidas de alavancagem por período observado para cada observação (a) e para cada indivíduo (b) considerado sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 2 para os dados referentes ao Estudo de Poluição do Ar.	136

- 8.3 Gráficos das medidas de influência local segundo a perturbação de casos (a), perturbação na variável resposta (b) e perturbação em uma variável explicativa (c) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 2 para os dados referentes ao Estudo de Poluição do Ar. 137
- 8.4 Gráfico da função não-paramétrica estimada (a) e gráficos de quantis normais com envelopes simulados (95% de confiança) para os resíduos de Pearson (b) “naive” (c) e “robustos” (d) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 2 para os Dados de Pressão Sanguínea. 140

# Lista de Tabelas

4.1	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização $\alpha = 0,001$ .	46
4.2	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização $\alpha = 10$ .	47
4.3	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização $\alpha = 10.000$ .	48
4.4	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 0,01$ .	49
4.5	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10$ .	50
4.6	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10.000$ .	51
4.7	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 0,01$ .	52
4.8	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 10$ .	53
4.9	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 10.000$ .	54

4.10	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização $\alpha = 0,01$ .	55
4.11	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização $\alpha = 10$ .	56
4.12	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização $\alpha = 10.000$ .	57
4.13	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 0,01$ .	58
4.14	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10$ .	59
4.15	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10.000$ .	60
4.16	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 0,01$ .	61
4.17	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 10$ .	62
4.18	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 10.000$ .	63
4.19	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização $\alpha = 0,01$ .	64
4.20	Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização $\alpha = 10$ .	65

4.21 Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização $\alpha = 10.000$ .	66
4.22 Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 0,01$ .	67
4.23 Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10$ .	68
4.24 Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10.000$ .	69
4.25 Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 0,01$ .	70
4.26 Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 0,01$ .	71
4.27 Estatísticas para as observações de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$ obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 10.000$ .	72
4.28 Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização $\alpha = 0,01$ .	74
4.29 Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização $\alpha = 10$ .	75
4.30 Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização $\alpha = 10.000$ .	76
4.31 Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 0,01$ .	77
4.32 Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10$ .	78

4.33	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10.000$ .	79
4.34	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 0,01$ .	80
4.35	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 10$ .	81
4.36	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 10.000$ .	82
4.37	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização $\alpha = 0,01$ .	83
4.38	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização $\alpha = 10$ .	84
4.39	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização $\alpha = 10.000$ .	85
4.40	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 0,01$ .	86
4.41	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10$ .	87
4.42	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10.000$ .	88
4.43	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 0,01$ .	89
4.44	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 10$ .	90
4.45	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 10.000$ .	91
4.46	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização $\alpha = 0,01$ .	92

4.47	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização $\alpha = 10$ .	93
4.48	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização $\alpha = 10.000$ .	94
4.49	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 0,01$ .	95
4.50	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10$ .	96
4.51	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização $\alpha = 10.000$ .	97
4.52	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 0,01$ .	98
4.53	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 10$ .	99
4.54	Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização $\alpha = 10.000$ .	100
5.1	Estimativas dos parâmetros sob o MPLAG para dados correlacionados ajustado aos dados referentes ao Estudo de Poluição do Ar.	103
5.2	Estimativas dos parâmetros sob o MPLAG para dados correlacionados ajustado aos Dados de Pressão Sanguínea.	110
8.1	Estimativas dos parâmetros sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo os casos 1 e 2 para os dados referentes ao Estudo de Poluição do Ar.	133
8.2	Estimativas dos parâmetros sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo os casos 1 e 2 para os Dados de Pressão Sanguínea.	138

# Sumário

<b>Capítulo 1—Introdução</b>	<b>16</b>
1.1 Introdução	16
1.2 Suporte Computacional	21
<b>I MPLAG para Dados Correlacionados - Caso 1</b>	<b>22</b>
<b>Capítulo 2—Definição do Modelo, Estimação e Inferência</b>	<b>23</b>
2.1 Estimação de $\xi$	26
2.2 Estimação de $\rho$	27
2.3 Estimação de $\phi$	28
2.4 Erros-padrão Aproximados	29
2.5 Graus de Liberdade Efetivos	30
2.6 Seleção do Parâmetro de Suavização	31
<b>Capítulo 3—Técnicas de Diagnóstico</b>	<b>33</b>
3.1 Medidas de Alavancagem	33
3.2 Análise de Resíduos	35
3.2.1 Resíduos de Pearson	35
3.2.2 Resíduos “Naive”	35
3.2.3 Resíduos “Robustos”	36
3.3 Influência Local	37
3.3.1 Perturbação de Casos	40
3.3.2 Perturbação na Variável Resposta	40
3.3.3 Perturbação em Uma das Variáveis Explicativas	41
<b>Capítulo 4—Estudos de Simulação</b>	<b>43</b>
4.1 Simulação de $\hat{\xi}$ , $\widehat{\text{Var}}_N(\hat{\xi})$ e $\widehat{\text{Var}}_R(\hat{\xi})$	44
4.2 Simulação dos Resíduos	73
<b>Capítulo 5—Exemplos de Aplicações</b>	<b>101</b>
5.1 Aplicação 1: Estudo de Poluição do Ar	101
5.2 Aplicação 2: Dados de Pressão Sanguínea	108

<b>II MPLAG para Dados Correlacionados - Caso 2</b>	<b>113</b>
<b>Capítulo 6—Definição do Modelo, Estimação e Inferência</b>	<b>114</b>
6.1 Estimação de $\delta$	117
6.2 Estimação de $\phi$	118
6.3 Erros-padrão Aproximados	119
6.4 Graus de Liberdade Efetivos	120
6.5 Seleção do Parâmetro de Suavização	121
<b>Capítulo 7—Técnicas de Diagnóstico</b>	<b>122</b>
7.1 Medidas de Alavancagem	122
7.2 Análise de Resíduos	123
7.2.1 Resíduos de Pearson	123
7.2.2 Resíduos “Naive”	124
7.2.3 Resíduos “Robustos”	125
7.3 Influência Local	125
7.3.1 Perturbação de Casos	129
7.3.2 Perturbação na Variável Resposta	129
7.3.3 Perturbação em Uma das Variáveis Explicativas	129
<b>Capítulo 8—Exemplos de Aplicações</b>	<b>132</b>
8.1 Aplicação 1: Estudo de Poluição do Ar	132
8.2 Aplicação 2: Dados de Pressão Sanguínea	138
<b>Capítulo 9—Conclusões e Trabalhos Futuros</b>	<b>142</b>
<b>Referências</b>	<b>145</b>

## Capítulo 1

# Introdução

### 1.1 Introdução

Fenômenos que envolvem dados correlacionados estão presentes em diversas áreas do conhecimento. Dados provenientes de estudos nas ciências biológicas, por exemplo, geralmente são caracterizados pela existência de mais de uma observação para cada indivíduo considerado. Estas observações podem ser coletadas, por exemplo, ao longo do tempo sob diferentes níveis de um determinado tratamento para cada instante. Podemos ainda observar dados caracterizados pela presença de um único tratamento para cada indivíduo e a observação de mais de um valor para a variável de interesse.

Sob normalidade, diversos trabalhos já foram realizados no estudo de dados correlacionados, como por exemplo os modelos de componentes de variância, nos quais pode ser considerada a presença de efeitos aleatórios para determinados fatores considerados no estudo (CRUMP, 1946; SEARLE; CASELLA; MCCULLOCH, 1992). Nesses modelos, existe a possibilidade de ser imposta uma determinada estrutura de variância e covariância aos dados. Contudo, sob a presença de dados não balanceados o processo de estimação dos parâmetros não apresenta equações em forma fechada. Generalizações desta última classe de modelos foram propostas, como por exemplo os modelos mistos (LAIRD; WARE, 1982; WATERNAUX; LAIRD; WARE, 1989), aplicados eficientemente

em dados com estrutura longitudinal. McLean, Sanders e Stroup (1991) compararam resultados de aplicações envolvendo os modelos de análise de variância convencionais com o uso dos modelos mistos. Verbeke e Molenberghs (2003) discutem o uso de testes do tipo escore propostos por Silvapulle e Silvapulle (1995) em modelos de componentes de variância e Giampaoli e Singer (2009) discutem o uso do teste da razão de verossimilhanças para os parâmetros de variância e covariância em modelos mistos.

Quando a suposição de normalidade não é satisfeita, uma alternativa é o uso dos modelos de quase-verossimilhança (WEDDERBURN, 1974; NELDER; PREGIBON, 1987) sob a proposta de uma matriz de “trabalho” que faz o papel de uma matriz de correlação. Quando esta matriz depende dos efeitos fixos do modelo, as equações de estimação tornam-se difíceis de serem obtidas analiticamente, além de não garantir que as correlações entre as variáveis encontrem-se entre os valores de -1 e 1. Neste contexto, Liang e Zeger (1986) propuseram as Equações de Estimação Generalizadas (EEG), em que a matriz de trabalho não depende dos efeitos fixos, mas de um vetor de parâmetros adicional (ARTES; JØRGENSEN, 2000). Neste sentido, Crowder (1987) discute o conceito de otimalidade em equações de estimação, Crowder (1995) trata do problema de estimar a matriz de correlação nas EEG e Pan (2001a) estuda o critério de informação de Akaike sob as referidas equações.

As EEG vistas, por exemplo, em Liang e Zeger (1986) também são denominadas EEG-1, devido ao fato de que os parâmetros de correlação são estimados separadamente (pelo método de momentos, por exemplo). Neste caso as EEG-1 podem ser entendidas como uma generalização das equações de estimação dos parâmetros de efeitos fixos sob os Modelos Lineares Generalizados (MLG), agora introduzindo a matriz de trabalho no processo de estimação. Contudo, podemos definir equações para estimação conjunta dos parâmetros, referentes tanto aos efeitos fixos quanto à estrutura de correlação dos dados. Estas equações de estimação são conhecidas na literatura como EEG-2 (LIANG; ZEGER; QAQISH, 1992). Neste caso, suposições adicionais devem ser consideradas (envolvendo

momentos de ordens maiores que 2 da variável resposta). Considerando as EEG-2, Zhao e Prentice (1990) trabalham com estas equações de estimação considerando dados binários através de modelos pertencentes à família exponencial quadrática, Prentice e Zhao (1991) extendem os resultados obtidos em Zhao e Prentice (1990) para respostas contínuas, Liang, Zeger e Qaqish (1992) utilizam as EEG-2 para análise de dados categorizados na presença de correlação, Ziegler (1995) estuda as diferentes parametrizações das EEG-1 e EEG-2 e Balemi e Lee (2009) compararam as performances das EEG-1 e EEG-2 via regressão logística na presença de correlação entre as variáveis resposta.

Nas EEG assume-se que o preditor linear é especificado de forma paramétrica, mas esta suposição nem sempre é válida, uma vez que variáveis preditoras podem influenciar a variável resposta através de uma função (não necessariamente linear) desconhecida. Sendo assim, sob independência e para dados com distribuição na família exponencial temos os modelos aditivos generalizados, ou *Generalized Additive Models* (GAM) (HASTIE; TIBSHIRANI, 1990; GREEN; SILVERMAN, 1994), que definem o preditor de forma não-paramétrica através de uma ou mais funções suaves das variáveis preditoras. Eilers e Marx (1996) realizam um estudo detalhado acerca de estimação não paramétrica via B-splines e P-splines. Buja, Hastie e Tibshirani (1989) tratam dos diversos tipos de suavizadores de funções, inclusive explicitando algumas características dos modelos aditivos que se utilizam destes suavizadores para a estimação de funções não-paramétricas.

Sob dados correlacionados, Lin e Carroll (2001) estudam as EEG semiparamétricas com funções do tipo “kernel” para a parte não-paramétrica. Xue e Zhu (2007) tratam de modelos de regressão semiparamétricos para dados longitudinais com o uso de verossimilhança empírica. Chen et al. (2011) estudam os modelos lineares generalizados mistos com uma estrutura semiparamétrica para a média das observações. Ibacache-Pulgar, Paula e Galea (2012) estudam os modelos mistos semiparamétricos com distribuições elípticas. Chen e Zhou (2013) investigam os modelos parcialmente lineares generalizados para dados longitudinais sob a característica de dados faltantes. Suliadi, Ibrahim e Daud

(2013) propõem o uso de modelos semiparamétricos para dados binários e recentemente, Wang et al. (2014) e Lian, Liang e Wang (2014) estudaram os modelos parcialmente lineares aditivos generalizados (MPLAG) para dados correlacionados, que possuem a característica de modelar aditivamente componentes paramétricos e não-paramétricos. Estes modelos também fazem o uso de uma matriz de trabalho como nas EEG.

No contexto dos MPLAG para dados correlacionados, encontrar uma relação apropriada entre as observações da variável resposta e as covariáveis segundo um modelo semiparamétrico requer o uso de algumas técnicas no intuito de investigar se o modelo proposto ajusta os dados de forma adequada. Estas técnicas servem também para investigar as suposições realizadas acerca do modelo. Neste sentido, Eubank (1984) discute as propriedades da matriz de projeção em modelos de regressão não-paramétricos considerando o uso de splines. Kim (1996) apresenta uma versão da distância de Cook aplicável para grupos de observações em modelos não-paramétricos. Preisser e Qaqish (1996) discutem a técnica de deleção de pontos nas EEG. Tan, Qu e Kutner (1997) desenvolveram algumas técnicas de diagnóstico em modelos para dados binários correlacionados. Lin e Zhang (1999) apresentam alguns procedimentos inferenciais nos modelos mistos aditivos generalizados com uso de funções do tipo splines. Chang (2000) estuda a análise de resíduos na modelagem de dados longitudinais. Hu, Wang e Carroll (2004) investigam funções do tipo kernel e algoritmos do tipo *backfitting* em modelos parcialmente lineares para dados correlacionados. Venezuela, Botter e Sandoval (2007) propõem algumas medidas de diagnóstico e métodos gráficos nas EEGs. Jung (2008) e Venezuela, Sandoval e Botter (2011) investigam a influência de clusters e/ou observações nos parâmetros considerados nas EEG utilizando a abordagem de influência local. Ibacache-Pulgar, Paula e Galea (2012) estudam técnicas de diagnóstico via influência local nos modelos mistos semiparamétricos elípticos. Boente et al. (2013) propõem uma família de estatísticas robustas que permitem a escolha entre um modelo paramétrico ou semiparamétrico. Cheng, Yu e Huang (2013) realizam inferência via bootstrap nas EEG e Gosh, Hamada e Yoshimira

(2014) discutem a seleção da matriz de trabalho nas EEG.

Considerando a teoria assintótica nos MPLAG, Heckman (1986) e Rice (1986) investigam as propriedades dos estimadores em modelos semiparamétricos. Chokri e Louani (2011) expõem alguns resultados assintóticos nos modelos parcialmente lineares para o estimador da componente paramétrica. Eubank e Whitney (1989) estudam as taxas de convergência em modelos não-paramétricos utilizando splines cúbicas. Cheng (1995) investiga alguns resultados assintóticos em estimação de funções tipo kernel e Opsomer e Ruppert (1999) propõem um estimador  $\sqrt{n}$ -consistente via backfitting para o componente paramétrico nos modelos semiparamétricos aditivos.

O objetivo deste trabalho é propor algumas técnicas de diagnóstico nos MPLAG para dados correlacionados, abordados tanto sob as EEG-1 como sob as EEG-2. As abordagens do modelo sob estes dois enfoques estão apresentadas em duas partes. Na Parte I temos o desenvolvimento dos MPLAG para dados correlacionados via EEG-1. No Capítulo 2 apresentamos a definição do modelo e suas equações de estimação, o processo de estimação dos parâmetros e alguns aspectos inferenciais. No Capítulo 3 derivamos algumas técnicas de diagnóstico, no Capítulo 4 exibimos resultados referentes a um estudo de simulação realizado no intuito de investigar algumas quantidades referentes aos ajustes dos MPLAG para dados correlacionados e no Capítulo 5 temos dois exemplos de aplicações analisados sob os MPLAG para dados correlacionados sob as EEG-1.

Na Parte II apresentamos os MPLAG para dados correlacionados via EEG-2. No Capítulo 6 definimos o modelo e suas equações de estimação, desenvolvemos o processo de estimação dos parâmetros e propomos alguns aspectos inferenciais. No Capítulo 7 são derivadas algumas técnicas de diagnóstico e no Capítulo 8 os dados referentes aos exemplos de aplicações (apresentados no Capítulo 5 sob o enfoque das EEG-1) são analisados sob as EEG-2 e realizamos uma comparação entre os resultados obtidos sob os dois enfoques. Finalmente, no Capítulo 9 temos algumas conclusões e propostas para trabalhos futuros.

## 1.2 Suporte Computacional

Todas as análises apresentadas nesta tese foram realizadas utilizando o software gratuito Ox em sua versão 7.01 (DOORNIK, 2007), disponível no endereço eletrônico <http://www.doornik.com/download.html> e o software R, em sua versão 3.1.2 (R CORE TEAM, 2014), que pode ser obtido em <http://www.r-project.org> de forma gratuita. A redação da tese foi realizada através do ambiente de desenvolvimento integrado TeXnicCenter, que pode ser obtido em <http://www.texniccenter.org/download/> gratuitamente. Este editor foi utilizado segundo o uso da linguagem TeX, através de integração com o programa MikTeX, disponível em <http://miktex.org/download> de forma gratuita.

## **PARTE I**

# **MPLAG PARA DADOS CORRELACIONADOS - CASO 1**

Nesta parte estudamos os MPLAG para dados correlacionados a partir da proposta de equações de estimação semiparamétricas definidas apenas para a estimação dos parâmetros referentes aos efeitos fixos. No caso paramétrico estas equações de estimação são conhecidas na literatura como EEG-1 (ZIEGLER; KASTNER; BLETTNER, 1998). Sob esta abordagem, os parâmetros de correlação são estimados separadamente, por exemplo através do método de momentos (HANSEN, 1982; LIANG; ZEGER, 1986).

## Capítulo 2

# Definição do Modelo, Estimação e Inferência

Seja  $\mathbf{y}_i = (y_{i1}, \dots, y_{im_i})^\top$  o vetor de dimensão  $m_i \times 1$  contendo os valores da variável resposta para o  $i$ -ésimo indivíduo e  $\mathbf{X}_i = (\mathbf{x}_{1i}, \dots, \mathbf{x}_{pi})$  a matriz de dimensão  $m_i \times p$  contendo os respectivos valores das variáveis preditoras, em que  $\mathbf{x}_{li} = (x_{li1}, \dots, x_{lim_i})^\top$ , para  $l = 1, \dots, p$  e  $i = 1, \dots, n$ . Assume-se que a distribuição marginal de  $y_{ij}$  é da forma

$$f(y_{ij}) = \exp\{\phi[y_{ij}\theta_{ij} - b(\theta_{ij})] + c(y_{ij}, \phi)\}. \quad (1)$$

O valor esperado e a variância de  $y_{ij}$  são dados, respectivamente, por  $E(y_{ij}) = \mu_{ij}$  e  $\text{Var}(y_{ij}) = \phi^{-1}V_{ij}$ , em que  $\mu_{ij} = \partial b(\theta_{ij})/\partial\theta_{ij}$  e  $V_{ij} = \partial^2 b(\theta_{ij})/\partial\theta_{ij}^2$ . Ainda, seja  $g(\cdot)$  uma função invertível tal que

$$g(\mu_{ij}) = \eta_{ij} = \mathbf{x}_{ij}\boldsymbol{\beta}, \quad (2)$$

em que  $\mathbf{x}_{ij} = (x_{1ij}, \dots, x_{pij})$  e  $\boldsymbol{\beta}$  é o vetor de parâmetros, de dimensão  $p \times 1$ , associado às variáveis em  $\mathbf{X}_i$ , para  $i = 1, \dots, n$  e  $j = 1, \dots, m_i$ . Sob a suposição de independência entre as observações em  $\mathbf{y}_i$ , temos os Modelos Lineares Generalizados (NELDER; WEDDERBURN, 1972). Neste caso, as equações de estimação para o vetor  $\boldsymbol{\beta}$  são dadas por

$$\Psi(\boldsymbol{\beta}) = \sum_{i=1}^n \mathbf{X}_i^\top \mathbf{W}_i \mathbf{D}_i^{-1} (\mathbf{y}_i - \boldsymbol{\mu}_i) = \mathbf{0}, \quad (3)$$

em que,  $\mathbf{W}_i = \mathbf{D}_i \mathbf{V}_i^{-1} \mathbf{D}_i$ , com as matrizes  $\mathbf{D}_i = \text{diag}\{\partial\mu_{i1}/\partial\eta_{i1}, \dots, \partial\mu_{im_i}/\partial\eta_{im_i}\}$ ,  $\mathbf{V}_i = \text{diag}\{V_{i1}, \dots, V_{im_i}\}$  e  $\boldsymbol{\mu}_i = (\mu_{i1}, \dots, \mu_{im_i})^\top$ . O estimador  $\hat{\boldsymbol{\beta}}$  de  $\boldsymbol{\beta}$  é obtido como sendo a solução de (3). Sob certas condições de regularidade,  $\hat{\boldsymbol{\beta}}$  é consistente e segue uma distribuição normal quando  $n \rightarrow \infty$  (LIANG; ZEGER, 1986), mas na presença de alta correlação, o referido estimador pode não apresentar boas propriedades de eficiência. Sendo assim, neste cenário define-se uma matriz que faz o papel de uma matriz de correlação, denominada de matriz de “trabalho”  $\mathbf{R}_i = \mathbf{R}_i(\boldsymbol{\rho})$ , em que  $\boldsymbol{\rho}$  é um vetor de parâmetros de correlação, de dimensão  $d \times 1$ . Neste caso, seja  $\mathbf{V}_i^* = \mathbf{V}_i^{1/2} \mathbf{R}_i \mathbf{V}_i^{1/2}$ , o que implica em  $\text{Var}(\mathbf{y}_i) = \phi^{-1} \mathbf{V}_i^*$ , desde que  $\mathbf{R}_i$  seja a verdadeira matriz de correlação de  $\mathbf{y}_i$ .

Dados  $\phi$  e  $\boldsymbol{\rho}$ , as equações de estimação para  $\boldsymbol{\beta}$  são dadas, então, por

$$\Psi(\boldsymbol{\beta}) = \sum_{i=1}^n \mathbf{X}_i^\top \mathbf{W}_i^* \mathbf{D}_i^{-1} (\mathbf{y}_i - \boldsymbol{\mu}_i) = \mathbf{0}, \quad (4)$$

em que  $\mathbf{W}_i^* = \mathbf{D}_i \mathbf{V}_i^{*-1} \mathbf{D}_i$ . Se  $\mathbf{R}_i$  é a matriz identidade, as equações de estimação em (4) reduzem-se às equações de estimação sob independência em (3). Sob certas condições de regularidade, o estimador  $\hat{\boldsymbol{\beta}}$  de  $\boldsymbol{\beta}$  obtido como sendo a solução de (4) é consistente e assintoticamente normal, dados estimadores consistentes de  $\boldsymbol{\rho}$  e  $\phi$  (LIANG; ZEGER, 1986). Os parâmetros  $\boldsymbol{\rho}$  e  $\phi$  são considerados, neste caso, como parâmetros de perturbação. Sendo assim, o estimador de  $\boldsymbol{\beta}$  é obtido por uma modificação do algoritmo escore de Fisher, sendo expresso como

$$\boldsymbol{\beta}^{(b+1)} = \{\mathbf{X}^\top \mathbf{W}^{*(b)} \mathbf{X}\}^{-1} \{\mathbf{X}^\top \mathbf{W}^{*(b)} \mathbf{z}^{(b)}\}, \quad b = 0, 1, 2, \dots$$

Aqui,  $\mathbf{X} = (\mathbf{X}_1^\top, \dots, \mathbf{X}_n^\top)^\top$ ,  $\mathbf{W}^* = \text{diag}\{\mathbf{W}_1^*, \dots, \mathbf{W}_n^*\}$  e  $\mathbf{z} = (\mathbf{z}_1^\top, \dots, \mathbf{z}_n^\top)^\top$ , em que  $\mathbf{z}_i = \mathbf{D}_i^{-1}(\mathbf{y}_i - \boldsymbol{\mu}_i) + \boldsymbol{\eta}_i$ , com  $\boldsymbol{\eta}_i = (\eta_{i1}, \dots, \eta_{im_i})^\top$ . Em cada passo do algoritmo, estimativas de  $\phi$  e  $\boldsymbol{\rho}$  devem ser fornecidas e aplicadas nas atualizações de  $\mathbf{W}^*$  e  $\mathbf{z}$ , como visto em Liang e Zeger (1986). Para definir as equações de estimação generalizadas semiparamétricas,

consideramos a distribuição marginal de  $y_{ij}$  como em (1), porém neste caso o preditor é dado por

$$g(\mu_{ij}) = \eta_{ij} = \mathbf{x}_{ij}\boldsymbol{\beta} + \sum_{k=1}^q f_k(t_{kij}),$$

em que  $\mathbf{x}_{ij}\boldsymbol{\beta}$  é da mesma forma que em (2) e  $f_k(\cdot)$  é uma função (suave) desconhecida da variável  $t_k$ , para  $k = 1, \dots, q$ . Sendo assim, seja  $\mathbf{t}_{ki} = (t_{ki1}, \dots, t_{kim_i})^\top$  o vetor com as observações de  $t_k$  para o  $i$ -ésimo indivíduo,  $\mathbf{t}_k^0 = (t_{k1}^0, \dots, t_{kr_k}^0)^\top$  o vetor com os  $r_k$  valores distintos e ordenados de  $t_k$  para todos os  $n$  indivíduos,  $\mathbf{f}_k = (f_k(t_{k1}^0), \dots, f_k(t_{kr_k}^0))^\top$  e  $\mathbf{N}_{ki}$  uma matriz de incidência associada ao  $i$ -ésimo indivíduo, com seu termo  $(j, l)$  definido como sendo o valor da função indicadora  $I(t_{kij} = t_{kl}^0)$ , para  $j = 1, \dots, m_i$  e  $l = 1, \dots, r_k$ . O preditor linear  $\boldsymbol{\eta}_i = (\eta_{i1}, \dots, \eta_{im_i})^\top$  para o  $i$ -ésimo indivíduo é expresso, então, por

$$\boldsymbol{\eta}_i = \mathbf{X}_i\boldsymbol{\beta} + \sum_{k=1}^q \mathbf{N}_{ki}\mathbf{f}_k.$$

Seja  $\boldsymbol{\xi} = (\boldsymbol{\beta}^\top, \mathbf{f}_1^\top, \dots, \mathbf{f}_q^\top)^\top \subset \boldsymbol{\Xi} \subseteq \mathcal{R}^s$ , em que  $s = p + \sum_{k=1}^q r_k$ . Sob a suposição de independência, o estimador de  $\boldsymbol{\xi}$  é obtido pela maximização do logaritmo da função de verossimilhança penalizada

$$l_p(\boldsymbol{\xi}) = l(\boldsymbol{\xi}) - \frac{1}{2} \sum_{k=1}^q \alpha_k \mathbf{f}_k^\top \mathbf{K}_k \mathbf{f}_k, \quad (5)$$

em que  $l(\boldsymbol{\xi}) = \sum_{i=1}^n \sum_{j=1}^{m_i} \{\phi[y_{ij}\theta_{ij} - b(\theta_{ij})] + c(y_{ij}, \phi)\}$ ,  $\alpha_k$  é um parâmetro de suavização que controla a escolha entre qualidade do ajuste e suavidade da função estimada  $\hat{\mathbf{f}}_k$  e  $\mathbf{K}_k$  é uma matriz não-negativa definida que depende somente dos valores  $t_{kg}^0$ , para  $k = 1, \dots, q$  e  $g = 1, \dots, r_k$ . Uma vez que  $f_k(\cdot)$  pode ser visto como um parâmetro associado a um espaço paramétrico de dimensão infinita, para seu estimador considera-se aquele que maximiza (5), resultando em uma spline cúbica natural, com nós nos valores  $t_{kg}^0$ , para  $k = 1, \dots, q$  e  $g = 1, \dots, r_k$ . Portanto, o estimador de máxima verossimilhança penalizada de  $\boldsymbol{\xi}$ , dados  $\phi$  e  $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_q)^\top$ , é obtido como sendo a solução das equações

de estimação penalizadas

$$\Psi_{\alpha}(\xi) = \sum_{i=1}^n \mathbf{X}_i^{*\top} \mathbf{W}_i \mathbf{D}_i^{-1} (\mathbf{y}_i - \boldsymbol{\mu}_i) - \mathbf{P}(\alpha) = \mathbf{0},$$

em que  $\mathbf{X}_i^* = (\mathbf{X}_i, \mathbf{N}_{1i}, \dots, \mathbf{N}_{qi})$  e  $\mathbf{P}(\alpha) = (\mathbf{0}^\top, \mathbf{P}_1(\alpha)^\top)^\top$ , com  $\mathbf{P}_1(\alpha) = \mathbf{K}(\alpha)\mathbf{f}$ , em que  $\mathbf{K}(\alpha) = \text{diag}\{\alpha_1 \mathbf{K}_1, \dots, \alpha_q \mathbf{K}_q\}$  e  $\mathbf{f} = (\mathbf{f}_1^\top, \dots, \mathbf{f}_q^\top)^\top$ . Segundo Green e Silverman (1994), o estimador de  $\xi$  é obtido através de um algoritmo escore de Fisher “local”, dado por

$$\xi^{(b+1)} = \{\mathbf{X}^{*\top} \mathbf{W}^{(b)} \mathbf{X}^* + \mathbf{K}^*(\alpha)\}^{-1} \{\mathbf{X}^{*\top} \mathbf{W}^{(b)} \mathbf{z}^{(b)}\}, \quad b = 0, 1, 2, \dots \quad (6)$$

em que  $\mathbf{X}^* = (\mathbf{X}_1^{*\top}, \dots, \mathbf{X}_n^{*\top})^\top$ ,  $\mathbf{W} = \text{diag}\{\mathbf{W}_1, \dots, \mathbf{W}_n\}$  e  $\mathbf{K}^*(\alpha) = \text{diag}\{\mathbf{0}, \mathbf{K}(\alpha)\}$ , com  $\mathbf{0}$  denotando uma matriz de zeros com dimensão  $p \times p$ . Sob a presença de correlação entre as observações dos indivíduos, utiliza-se a definição de matriz de trabalho como em (4), e definem-se as equações de estimação generalizadas penalizadas referentes ao MPLAG para dados correlacionados (sob as EEG-1) da forma (LIAN; LIANG; WANG, 2014)

$$\Psi_{\alpha}(\xi) = \sum_{i=1}^n \mathbf{X}_i^{*\top} \mathbf{W}_i^* \mathbf{D}_i^{-1} (\mathbf{y}_i - \boldsymbol{\mu}_i) - \mathbf{P}(\alpha) = \mathbf{0}. \quad (7)$$

Aqui, temos alguns aspectos a respeito do processo de estimação dos parâmetros nos MPLAG para dados correlacionados, ou seja, procedimentos para estimação de  $\xi$ ,  $\rho$  e  $\phi$ .

## 2.1 Estimação de $\xi$

Para a estimação de  $\xi$  nos MPLAG para dados correlacionados, devemos considerar as equações de estimação dadas em (7). Sendo assim, a partir de (6), temos o processo iterativo (assumindo  $\rho$  e  $\phi$  fixados) dado por

$$\xi^{(b+1)} = \{\mathbf{X}^{*\top} \mathbf{W}^{*(b)} \mathbf{X}^* + \mathbf{K}^*(\alpha)\}^{-1} \{\mathbf{X}^{*\top} \mathbf{W}^{*(b)} \mathbf{z}^{(b)}\}, \quad b = 0, 1, 2, \dots \quad (8)$$

Aqui, o método de *backfitting* (Gauss-Siedel) pode ser utilizado na obtenção do estimador de  $\boldsymbol{\xi}$ . O processo iterativo é dado, então, por

$$\boldsymbol{\xi}_k^{(b+1)} = \mathbf{C}_k^{(b)} \mathbf{z}_k^{(b,b+l)}, \quad k = 0, 1, 2, \dots, q, \quad b = 0, 1, 2, \dots,$$

em que

$$\begin{aligned} \boldsymbol{\xi}_k^{(b+1)} &= \begin{cases} \boldsymbol{\beta}^{(b+1)}, & \text{para } k = 0; \\ \mathbf{f}_k^{(b+1)}, & \text{para } k = 1, \dots, q; \end{cases} \\ \mathbf{C}_k^{(b)} &= \begin{cases} \{\mathbf{X}^\top \mathbf{W}^{*(b)} \mathbf{X}\}^{-1} \mathbf{X}^\top \mathbf{W}^{*(b)}, & \text{para } k = 0; \\ \{\mathbf{N}_k^\top \mathbf{W}^{*(b)} \mathbf{N}_k + \mathbf{K}_k(\alpha_k)\}^{-1} \mathbf{N}_k^\top \mathbf{W}^{*(b)}, & \text{para } k = 1, \dots, q; \end{cases} \\ \mathbf{z}_k^{(b,b+l)} &= \begin{cases} \mathbf{z}^{(b,b)} - \sum_{l=1}^q \mathbf{N}_l \mathbf{f}_l^{(b)}, & \text{para } k = 0; \\ \mathbf{z}^{(b,b+l)} - \mathbf{X} \boldsymbol{\beta}^{(b+1)} - \sum_{l < k} \mathbf{N}_l \mathbf{f}_l^{(b+1)} - \sum_{l > k}^q \mathbf{N}_l \mathbf{f}_l^{(b)}, & \text{para } k = 1, \dots, q, \end{cases} \end{aligned}$$

com  $\mathbf{N}_k = (\mathbf{N}_{k1}^\top, \dots, \mathbf{N}_{kn}^\top)^\top$  e  $\mathbf{K}_k(\alpha_k) = \alpha_k \mathbf{K}_k$ . Aqui,  $b$  deve ser incrementado após  $k$  ser incrementado de 0 a  $q$ . Para  $q = 1$ , as atualizações de  $\boldsymbol{\xi}$  podem ser obtidas diretamente por

$$\boldsymbol{\beta}^{(b+1)} = \{\mathbf{X}^\top \mathbf{W}^{*(b)} [\mathbf{I} - \mathbf{S}^{*(b)}] \mathbf{X}\}^{-1} \mathbf{X}^\top \mathbf{W}^{*(b)} [\mathbf{I} - \mathbf{S}^{*(b)}] \mathbf{z}^{(b,b)};$$

$$\mathbf{f}^{(b+1)} = \{\mathbf{N}^\top \mathbf{W}^{*(b)} \mathbf{N} + \mathbf{K}(\alpha)\}^{-1} \mathbf{N}^\top \mathbf{W}^{*(b)} [\mathbf{z}^{(b,b+1)} - \mathbf{X} \boldsymbol{\beta}^{(b+1)}],$$

em que  $\mathbf{S}^* = \mathbf{N} \{\mathbf{N}^\top \mathbf{W}^* \mathbf{N} + \mathbf{K}(\alpha)\}^{-1} \mathbf{N}^\top \mathbf{W}^*$ ,  $\mathbf{N} = (\mathbf{N}_1^\top, \dots, \mathbf{N}_n^\top)^\top$ ,  $\mathbf{K}(\alpha) = \alpha \mathbf{K}$ , e  $\mathbf{I}$  é a matriz identidade de dimensão  $\sum_{i=1}^n m_i \times \sum_{i=1}^n m_i$ .

## 2.2 Estimação de $\rho$

Para obter as estimativas dos parâmetros de correlação no vetor  $\boldsymbol{\rho}$ , Wang et al. (2014) utilizam o método dos momentos generalizados (HANSEN, 1982). Aqui, nós propomos o uso de estimadores vistos, por exemplo, em Liang e Zeger (1986) e em Pan (2001b). Para tanto, sob uma estrutura de correlação uniforme, ou seja,  $\text{Cor}(y_{ij}, y_{ik}) = \rho, \forall j \neq k$ ,

para  $k, j = 1, \dots, m_i$  e  $i = 1, \dots, n$  temos o estimador de  $\rho$  dado por

$$\hat{\rho} = \frac{\phi}{n} \sum_{i=1}^n \sum_{j \neq k} \frac{\hat{r}_{ij}\hat{r}_{ik}}{m_i(m_i - 1)},$$

em que  $r_{ij} = (y_{ij} - \mu_{ij})/V_{ij}^{1/2}$ . Sob uma estrutura de correlação autorregressiva de ordem 1 (AR-1), ou seja,  $\text{Cor}(y_{ij}, y_{ik}) = \rho^{|j-k|}, \forall j \neq k$ , para  $k, j = 1, \dots, m_i$  e  $i = 1, \dots, n$ , temos

$$\hat{\rho} = \frac{\phi}{n} \sum_{i=1}^n \sum_{j=1}^{m_i-1} \frac{\hat{r}_{ij}\hat{r}_{ij+1}}{m_i - 1}.$$

No caso em que a matriz de trabalho  $\mathbf{R}_i$  é não estruturada, podemos estimá-la por

$$\hat{\mathbf{R}}_i = \frac{\phi}{n} \sum_{i=1}^n \hat{\mathbf{r}}_i \hat{\mathbf{r}}_i^\top,$$

em que  $\mathbf{r}_i = (r_{i1}, \dots, r_{im_i})^\top$ .

### 2.3 Estimação de $\phi$

Para estimar o parâmetro  $\phi$ , utilizamos o fato de que

$$\text{Var}(r_{ij}) = E \left( \left[ \frac{y_{ij} - \mu_{ij}}{V_{ij}^{1/2}} \right]^2 \right) = \phi^{-1}.$$

Sendo assim, podemos estimar  $\phi$  por

$$\hat{\phi}^{-1} = \frac{\sum_{i=1}^n \sum_{j=1}^{m_i} \hat{r}_{ij}^2}{\text{tr}\{\mathbf{I} - \hat{\mathbf{H}}^*\}},$$

em que  $\text{tr}(\mathbf{A})$  denota o traço da matriz  $\mathbf{A}$ ,  $\mathbf{I}$  é a matriz identidade de dimensão  $\sum_{i=1}^n m_i \times \sum_{i=1}^n m_i$  e  $\mathbf{H}^* = \mathbf{X}^* \{ \mathbf{X}^{*\top} \mathbf{W}^* \mathbf{X}^* + \mathbf{K}^*(\boldsymbol{\alpha}) \}^{-1} \mathbf{X}^{*\top} \mathbf{W}^*$  (GREEN; SILVERMAN, 1994).

A seguir, discutimos alguns aspectos relacionados a inferência estatística nos MPLAG para dados correlacionados, mais especificamente o procedimento para a obtenção de

estimativas aproximadas para os erros-padrão de  $\hat{\boldsymbol{\xi}}$ , uma discussão a respeito da estimação dos graus de liberdade associados ao modelo e o procedimento para seleção dos parâmetros de suavização.

## 2.4 Erros-padrão Aproximados

Uma importante etapa na análise dos resultados referentes aos ajustes dos MPLAG para dados correlacionados é a realização de testes de hipóteses acerca da significância dos parâmetros e das funções não paramétricas. Sendo assim, estimativas dos erros-padrão associados às estimativas dos efeitos fixos devem ser obtidas. Sob a modelagem paramétrica via EEG-1, Liang e Zeger (1986) derivam expressões para estimadores “naive” e “robustos” para a variância de  $\hat{\boldsymbol{\beta}}$ . Para os MPLAG sob independência, podemos considerar a matriz de informação de Fisher penalizada (HASTIE; TIBSHIRANI, 1990) para a obtenção de estimativas dos erros-padrão das partes paramétrica e não paramétrica estimadas sob este respectivo modelo. Para a obtenção dos erros-padrão sob os MPLAG para dados correlacionados, podemos inicialmente observar que, na convergência do processo iterativo (dado  $\boldsymbol{\alpha}$ ),

$$\hat{\boldsymbol{\xi}} = \widehat{\mathbf{A}}^{*-1} \mathbf{X}^{*\top} \widehat{\mathbf{W}}^* \hat{\mathbf{z}},$$

em que  $\mathbf{A}^* = \mathbf{X}^{*\top} \mathbf{W}^* \mathbf{X}^* + \mathbf{K}^*(\boldsymbol{\alpha})$ . Assumindo que  $\boldsymbol{\mu} = \boldsymbol{\mu}_0$  é o verdadeiro vetor de médias de  $\mathbf{y}$  e que  $\hat{\boldsymbol{\mu}} \approx \boldsymbol{\mu}_0$ , temos que  $\hat{\boldsymbol{\xi}} \approx \mathbf{A}_0^{*-1} \mathbf{X}^{*\top} \mathbf{W}_0^* \mathbf{z}_0 = \mathbf{A}^{*-1} \mathbf{X}^{*\top} \mathbf{W}^* \mathbf{z}$ . Sendo assim,

$$\text{Var}(\hat{\boldsymbol{\xi}}) \approx \mathbf{A}^{-1} \mathbf{X}^{*\top} \mathbf{W}^* \mathbf{D}^{-1} \text{Var}(\mathbf{y}) \mathbf{D}^{-1} \mathbf{W}^* \mathbf{X}^* \mathbf{A}^{-1},$$

em que  $\mathbf{y} = (\mathbf{y}_1^\top, \dots, \mathbf{y}_n^\top)^\top$ . Se  $\mathbf{R}_i(\boldsymbol{\rho})$  é a verdadeira matriz de correlação de  $\mathbf{y}_i$ , para  $i = 1, \dots, n$ , temos que  $\text{Var}(\mathbf{y}) = \phi^{-1} \mathbf{V}^{1/2} \mathbf{R}(\boldsymbol{\rho}) \mathbf{V}^{1/2}$ , em que  $\mathbf{V} = \text{diag}\{\mathbf{V}_1, \dots, \mathbf{V}_n\}$  e  $\mathbf{R}(\boldsymbol{\rho}) = \text{diag}\{\mathbf{R}_1, \dots, \mathbf{R}_n\}$ . Portanto, devemos estimar  $\text{Var}(\hat{\boldsymbol{\xi}})$  por

$$\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}}) = \widehat{\mathbf{A}}^{*-1} \mathbf{X}^{*\top} \widehat{\mathbf{W}}^* \hat{\mathbf{D}}^{-1} \widehat{\text{Var}}_N(\mathbf{y}) \hat{\mathbf{D}}^{-1} \widehat{\mathbf{W}}^* \mathbf{X}^* \widehat{\mathbf{A}}^{*-1}, \quad (9)$$

em que  $\widehat{\text{Var}}_N(\mathbf{y}) = \hat{\phi}^{-1} \hat{\mathbf{V}}^{1/2} \mathbf{R}(\hat{\boldsymbol{\rho}}) \hat{\mathbf{V}}^{1/2}$ . Se  $\mathbf{R}_i(\boldsymbol{\rho})$  não é a verdadeira matriz de correlação de  $\mathbf{y}_i$ , para  $i = 1, \dots, n$ , podemos estimar  $\text{Var}(\hat{\boldsymbol{\xi}})$  por

$$\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}}) = \widehat{\mathbf{A}}^{*-1} \mathbf{X}^{*\top} \widehat{\mathbf{W}}^* \widehat{\mathbf{D}}^{-1} \widehat{\text{Var}}_R(\mathbf{y}) \widehat{\mathbf{D}}^{-1} \widehat{\mathbf{W}}^* \mathbf{X}^* \widehat{\mathbf{A}}^{*-1}, \quad (10)$$

em que  $\widehat{\text{Var}}_R(\mathbf{y}) = \text{diag}\{\widehat{\text{Var}}_R(\mathbf{y}_1), \dots, \widehat{\text{Var}}_R(\mathbf{y}_n)\}$  e  $\widehat{\text{Var}}_R(\mathbf{y}_i) = \hat{\mathbf{V}}_i^{1/2} \{\frac{1}{n} \sum_{i=1}^n \hat{\mathbf{r}}_i \hat{\mathbf{r}}_i^\top\} \hat{\mathbf{V}}_i^{1/2}$  (PAN, 2001b). Logo podemos obter estimativas do tipo “naive” e “robusta” para o erro-padrão de  $\hat{\boldsymbol{\xi}}$  a partir da diagonal de (9) e (10) respectivamente.

## 2.5 Graus de Liberdade Efetivos

Para a obtenção dos graus de liberdade efetivos a partir do ajuste do MPLAG para dados correlacionados devemos obter a matriz de projeção a partir do ajuste do modelo. Desta forma, ao estimarmos o preditor  $\boldsymbol{\eta}$  temos que, na convergência do processo iterativo,  $\hat{\boldsymbol{\eta}} = \mathbf{X}^* \hat{\boldsymbol{\xi}} = \widehat{\mathbf{H}}^* \hat{\mathbf{z}}$ , em que

$$\mathbf{H}^* = \mathbf{X}^* \mathbf{A}^{*-1} \mathbf{X}^{*\top} \mathbf{W}^*.$$

Por exemplo, se  $q = 1$  temos que

$$\mathbf{H}^* = \mathbf{S}^* + [\mathbf{I} - \mathbf{S}^*] \mathbf{B}^*,$$

em que  $\mathbf{B}^* = \mathbf{X} \{ \mathbf{X}^\top \mathbf{W}^* [\mathbf{I} - \mathbf{S}^*] \mathbf{X} \}^{-1} \mathbf{X}^\top \mathbf{W}^* [\mathbf{I} - \mathbf{S}^*]$ . Sendo assim, temos os graus de liberdade efetivos dados por (GREEN; SILVERMAN, 1994)

$$df(\boldsymbol{\alpha}) = \text{tr}(\widehat{\mathbf{H}}^*).$$

Seja  $\hat{\boldsymbol{\eta}} = \sum_{k=0}^q \hat{\boldsymbol{\eta}}_k$ , em que  $\hat{\boldsymbol{\eta}}_k = \mathbf{X}_k \hat{\boldsymbol{\xi}}_k$ , com  $\mathbf{X}_k = \mathbf{X}$ , se  $k = 0$  e  $\mathbf{X}_k = \mathbf{N}_k$ , para  $k = 1, 2, \dots, q$ . Seja também  $\widehat{\mathbf{A}}^{*-1}$  particionada da forma  $\widehat{\mathbf{A}}^{*-1} = \{\widehat{\mathbf{A}}^{*,k,l}\}$ , para  $k, l =$

$0, 1, \dots, q$ . Portanto, temos que  $\hat{\boldsymbol{\eta}}_k = \widehat{\mathbf{H}}^*_k \hat{\mathbf{z}}$ , em que

$$\widehat{\mathbf{H}}^*_k = \mathbf{X}_k \left[ \sum_{l=0}^q \widehat{\mathbf{A}}^{*,k,l} \mathbf{X}_l^\top \right] \widehat{\mathbf{W}}^*,$$

para  $k = 0, 1, \dots, q$ . Por exemplo, considerando os graus de liberdade efetivos associados à  $k$ -ésima componente não-paramétrica de  $\hat{\boldsymbol{\eta}}$ , temos que

$$df(\alpha_k) = \text{tr}(\widehat{\mathbf{H}}^*_k),$$

para  $k = 1, \dots, q$ .

## 2.6 Seleção do Parâmetro de Suavização

Segundo Eilers e Marx (1996), no caso do MPLAG sob independência, podemos obter os graus de liberdade efetivos associados à  $k$ -ésima componente não-paramétrica de  $\hat{\boldsymbol{\eta}}$  por

$$df(\alpha_k) = \text{tr}(\widehat{\mathbf{H}}^*_k) = \sum_{i=1}^n \sum_{j=1}^{m_i} \frac{1}{1 + \alpha_k \lambda_{kij}},$$

em que  $\lambda_{kij}$ , para  $i = 1, \dots, n$  e  $j = 1, \dots, m_i$  são os autovalores associados à matriz  $\mathbf{L}_k = \mathbf{Q}_k^{-1/2} \mathbf{Q}_{\alpha_k} \mathbf{Q}_k^{-1/2}$ , com  $\mathbf{Q}_k = \mathbf{N}_k^\top \widehat{\mathbf{W}}^* \mathbf{N}_k$  e  $\mathbf{Q}_{\alpha_k} = \alpha_k \mathbf{K}_k$ , para  $k = 1, \dots, q$ . Sendo assim,  $df(\alpha_k)$  é uma função inversa de  $\alpha_k$ . Para valores pequenos de  $\alpha_k$  temos que  $df(\alpha_k) \approx r_k$ , enquanto que para altos valores de  $\alpha_k$  temos que  $df(\alpha_k) \approx 2$ . Uma vez que  $df(\alpha_k) \in [2, r_k]$  e  $\alpha_k \in [0, \infty)$ , em situações práticas podemos considerar para a seleção do vetor de parâmetros de suavização os valores  $\alpha_k \in [\alpha_{k(\min)}, \alpha_{k(\max)}]$  tais que

$$df(\alpha_{k(\min)}) - df(\alpha_{k(\max)}) = \gamma_k(r_k - 2),$$

considerando um valor fixado de  $\gamma_k \in (0, 1)$ , para  $k = 1, \dots, q$ . No caso do uso de splines cúbicas, podemos considerar o método de validação cruzada generalizada (CRAVEN;

WAHBA, 1979) e selecionar o vetor de parâmetros de suavização como sendo o vetor  $\boldsymbol{\alpha}^* \in [\alpha_{1(\min)}, \alpha_{1(\max)}] \times [\alpha_{2(\min)}, \alpha_{2(\max)}] \times \dots \times [\alpha_{q(\min)}, \alpha_{q(\max)}]$  que minimiza

$$\text{GCV}(\boldsymbol{\alpha}) = \frac{(\sum_{i=1}^n m_i) \{(\mathbf{y} - \hat{\boldsymbol{\mu}})^\top \hat{\mathbf{V}}^{*-1} (\mathbf{y} - \hat{\boldsymbol{\mu}})\}}{\{\text{tr}(\mathbf{I} - \hat{\mathbf{H}}^*)\}^2}$$

(WOOD, 2006), em que  $\mathbf{I}$  é a matriz identidade de dimensão  $\sum_{k=1}^q r_k \times \sum_{k=1}^q r_k$ .

## Capítulo 3

# Técnicas de Diagnóstico

Neste capítulo serão apresentadas algumas técnicas de diagnóstico nos MPLAG para dados correlacionados. Na primeira seção temos uma proposta de medidas de alavancagem baseadas na matriz de projeção resultante do ajuste do modelo. As medidas de alavancagem podem ajudar na identificação de pontos que exercem peso desproporcional nas estimativas dos valores preditos em relação às demais observações. Posteriormente, temos a análise de resíduos através do uso de três diferentes tipos de resíduos. A análise residual é importante na detecção de pontos com valores discrepantes das variáveis (*outliers*), bem como na investigação de suposições a respeito das distribuições de probabilidade assumidas nos modelos. Finalmente, temos a análise de influência local, cuja idéia é exercer pequenas perturbações nos modelos e investigar a presença de pontos potencialmente influentes nas estimativas dos parâmetros sob estas perturbações.

### 3.1 Medidas de Alavancagem

Segundo Eubank (1984), a maioria das propriedades da matriz de projeção obtida a partir do ajuste de determinados modelos paramétricos se mantém no caso semiparamétrico, considerando independência e distribuição normal. Mais especificamente, a matriz de projeção no modelo semiparamétrico pode ser escrita em função de uma matriz referente ao ajuste de um modelo paramétrico polinomial. Ainda, se  $\hat{h}_{jj}^*$  é o elemento

$(j, j)$  da diagonal da matriz  $\widehat{\mathbf{H}}^*$ , o referido autor mostra que

$$0 \leq \hat{h}_{jj}^* \leq 1;$$

$$-1 \leq \hat{h}_{jl}^* \leq 1, \forall l \neq j;$$

$$\hat{h}_{jj}^* = 1, \text{ se } \hat{h}_{jl}^* = 0, \forall l \neq j,$$

para  $j = 1, \dots, \sum_{i=1}^n m_i$ . A partir destes resultados, propomos algumas medidas de alavancagem a serem utilizadas nos ajustes dos MPLAG para dados correlacionados, no intuito de identificarmos observações com valores discrepantes das variáveis explicativas. Estes pontos podem, por exemplo, inflacionar as estimativas dos erros-padrão referentes às estimativas dos parâmetros. Sendo assim, se  $\hat{h}_{ijj}^*$  é o elemento  $(j, j)$  da diagonal da matriz  $\widehat{\mathbf{H}}_i^* = \mathbf{X}_i^* \widehat{\mathbf{A}}^{*-1} \mathbf{X}_i^{*\top} \widehat{\mathbf{W}}_i^*$ , para  $i = 1, \dots, n$ , sugerimos observar  $\hat{h}_{ijj}^*$  para determinar o quanto o valor predito é influenciado pelo valor observado da variável resposta  $y_{ij}$  considerando o respectivo vetor observado das variáveis independentes  $\mathbf{x}_{ij}^*$ , para  $i = 1, \dots, n$  e  $j = 1, \dots, m_i$ . Quando todos os pontos exercem a mesma influência nas estimativas dos parâmetros, espera-se que  $\hat{h}_{ijj}^*$  apresente valor próximo à média geral  $\bar{h}^* = \text{tr}(\widehat{\mathbf{H}}^*) / \sum_{i=1}^n m_i$ . Portanto, um alto valor de  $\hat{h}_{ijj}^*$  pode indicar que  $\mathbf{x}_{ij}^*$  exerce alta influência sobre valor ajustado  $\hat{z}_{ij}$ . Sendo assim, podemos por exemplo observar o gráfico de  $\hat{h}_{ijj}^*$  versus  $i$ , para  $i = 1, \dots, n$  e  $j = 1, \dots, m_i$  no intuito de detectar pontos com alta alavancagem. Nestes pontos os valores preditos devem ser tratados com algum cuidado, uma vez que estes podem ser particularmente sensíveis a seus respectivos valores observados.

Para a detecção de grupos discrepantes, podemos utilizar a média das medidas de alavancagem  $\hat{h}_{ijj}^*$  dentro de cada grupo e investigar aqueles que apresentam alta alavancagem. Sendo assim, através das matrizes  $\mathbf{H}_i^*$ , podemos considerar o  $i$ -ésimo grupo como apresentando potencialmente alta influência no valor predito se  $\bar{h}_i^* > 2\bar{h}^*$  (ou se

$\bar{h}_i^* > 3\bar{h}^*$ ), em que  $\bar{h}_i^* = \text{tr}(\widehat{\mathbf{H}}^*_i)/m_i$ . Neste caso devemos observar o gráfico de  $\bar{h}_i^*$  versus  $i$ , para  $i = 1, \dots, n$ .

## 3.2 Análise de Resíduos

Nesta seção temos a proposta de três tipos de resíduos a serem utilizados na análise residual nos MPLAG para dados correlacionados. Estes resíduos devem ser considerados na investigação da presença de *outliers* nos dados, assim como para a investigação de suposições específicas feitas a respeito do modelo, por exemplo a suposição da distribuição marginal da variável resposta.

### 3.2.1 Resíduos de Pearson

Os resíduos de Pearson têm sido amplamente utilizados para detecção de *outliers* nos modelos lineares generalizados (MCCULLAGH; NELDER, 1983). Green e Silverman (1994) consideram estes resíduos nos ajustes dos MPLAG sob independência. Dado  $\phi$ , o resíduo de Pearson é definido por

$$\hat{r}_{Pij} = \phi^{1/2}(y_{ij} - \hat{\mu}_{ij})/\hat{V}_{ij}^{1/2},$$

para  $i = 1, \dots, n$  e  $j = 1, \dots, m_i$ . Uma vez que  $E(y_{ij}) = \mu_{ij}$  e  $\text{Var}(y_{ij}) = \phi^{-1}V_{ij}$ , se  $\hat{\mu}_{ij} \approx \mu_{ij}$  temos que  $E(\hat{r}_{Pij}) \approx 0$  e  $\text{Var}(\hat{r}_{Pij}) \approx 1$ . Portanto, observações com altos valores do resíduo de Pearson podem ser consideradas como *outliers* sob o MPLAG para dados correlacionados.

### 3.2.2 Resíduos “Naive”

Considerando o processo iterativo de estimação dos parâmetros dado em (8) temos que, na convergência

$$\hat{\boldsymbol{\epsilon}} = \widehat{\mathbf{W}}^{*1/2}[\hat{\mathbf{z}} - \hat{\boldsymbol{\eta}}] = [\mathbf{I} - \widehat{\mathbf{H}}^*]\widehat{\mathbf{W}}^{*1/2}\hat{\mathbf{z}},$$

em que  $\underline{\mathbf{H}}^* = \mathbf{W}^{*1/2} \mathbf{X}^* \mathbf{A}^{*-1} \mathbf{X}^{*\top} \mathbf{W}^{*1/2}$ . Novamente se assumimos  $\hat{\boldsymbol{\mu}} \approx \boldsymbol{\mu}_0 = \boldsymbol{\mu}$ , temos que  $\hat{\boldsymbol{\epsilon}} \approx \boldsymbol{\epsilon}_0 = \boldsymbol{\epsilon} = [\mathbf{I} - \underline{\mathbf{H}}^*] \mathbf{W}^{*1/2} \mathbf{z}$ . Sendo assim, temos ainda que

$$\text{Var}(\hat{\boldsymbol{\epsilon}}) \approx \text{Var}(\boldsymbol{\epsilon}) = [\mathbf{I} - \underline{\mathbf{H}}^*] \mathbf{W}^{*1/2} \mathbf{D}^{-1} \text{Var}(\mathbf{y}) \mathbf{D}^{-1} \mathbf{W}^{*1/2} [\mathbf{I} - \underline{\mathbf{H}}^*].$$

Se  $\mathbf{R}_i(\boldsymbol{\rho})$  é a verdadeira matriz de correlação de  $\mathbf{y}_i$ , pra  $i = 1, \dots, n$ , podemos estimar  $\text{Var}(\hat{\boldsymbol{\epsilon}})$  por

$$\widehat{\text{Var}}_N(\hat{\boldsymbol{\epsilon}}) = [\mathbf{I} - \widehat{\underline{\mathbf{H}}}^*] \widehat{\mathbf{W}}^{*1/2} \hat{\mathbf{D}}^{-1} \widehat{\text{Var}}_N(\mathbf{y}) \hat{\mathbf{D}}^{-1} \widehat{\mathbf{W}}^{*1/2} [\mathbf{I} - \widehat{\underline{\mathbf{H}}}^*]. \quad (11)$$

Portanto, definimos os resíduos “naive” (obtidos a partir da estimativa “naive” da variância de  $\mathbf{y}$ ) por

$$\hat{r}_{Nij} = \hat{\epsilon}_{ij} / \widehat{\text{ep}}_N(\hat{\epsilon}_{ij}),$$

para  $i = 1, \dots, n$  e  $j = 1, \dots, m_i$ , em que  $\widehat{\text{ep}}_N(\hat{\epsilon}_{ij})$  é a estimativa “naive” do erro-padrão de  $\hat{\epsilon}_{ij}$ , obtida a partir de (11).

### 3.2.3 Resíduos “Robustos”

Ainda na convergência do processo iterativo de estimação dos parâmetros dado em (8) e se  $\mathbf{R}_i(\boldsymbol{\rho})$  não é a verdadeira matriz de correlação de  $\mathbf{y}_i$ , podemos estimar  $\text{Var}(\hat{\boldsymbol{\epsilon}})$  por

$$\widehat{\text{Var}}_R(\hat{\boldsymbol{\epsilon}}) = [\mathbf{I} - \widehat{\underline{\mathbf{H}}}^*] \widehat{\mathbf{W}}^{*1/2} \hat{\mathbf{D}}^{-1} \widehat{\text{Var}}_R(\mathbf{y}) \hat{\mathbf{D}}^{-1} \widehat{\mathbf{W}}^{*1/2} [\mathbf{I} - \widehat{\underline{\mathbf{H}}}^*]. \quad (12)$$

Sendo assim, definimos os resíduos “robustos” (obtidos a partir da estimativa “robusta” da variância de  $\mathbf{y}$ ) por

$$\hat{\epsilon}_{Rij} = \hat{\epsilon}_{ij} / \widehat{\text{ep}}_R(\hat{\epsilon}_{ij}),$$

em que  $\widehat{\text{ep}}_R(\hat{\epsilon}_{ij})$  é a estimativa “robusta” para o erro-padrão de  $\hat{\epsilon}_{ij}$ , obtida via (12), para  $i = 1, \dots, n$  e  $j = 1, \dots, m_i$ . Embora assumindo que  $\mathbf{R}_i(\boldsymbol{\rho})$  não é a verdadeira matriz de correlação de  $\mathbf{y}_i$ , estes resíduos podem ser obtidos mesmo com a suposição de que  $\mathbf{R}_i(\boldsymbol{\rho})$  é a verdadeira matriz de correlação de  $\mathbf{y}_i$ .

### 3.3 Influênci a Local

Assumindo fixo o vetor de parâmetros de suavização  $\alpha$ , seja  $\mathcal{F}_\alpha(\xi)$  uma função (penalizada) de ajuste referente ao MPLAG para dados correlacionados, sendo pelo menos duas vezes diferenciável em  $\xi$  e que a estimativa de  $\xi$  seja solução de

$$\frac{\partial \mathcal{F}_\alpha(\xi)}{\partial \xi} = \Psi_\alpha(\xi) = 0.$$

Denotamos a função de afastamento em relação ao modelo perturbado como sendo

$$FD_\omega = 2\{\mathcal{F}_\alpha(\hat{\xi}) - \mathcal{F}_\alpha(\hat{\xi}_\omega)\},$$

em que  $\omega = (\omega_1, \dots, \omega_l)^\top$  é um vetor de perturbação de dimensão  $l \times 1$  em  $\Omega \in \mathbb{R}^l$ , representando um conjunto de perturbações. Temos ainda que  $\hat{\xi}$  e  $\hat{\xi}_\omega$  são as estimativas de  $\xi$  sob os modelos postulado e perturbado, respectivamente. A medida  $FD_\omega$  deve ser utilizada para investigar a influência na estimativa de  $\xi$  para diferentes valores de  $\omega$  em  $\Omega$ . Contudo, investigar o comportamento de  $FD_\omega$  em  $\Omega \in \mathbb{R}^l$  não é viável devido a grande quantidade de valores distintos que o vetor  $\omega$  em geral pode assumir. Sendo assim, Cook (1986) propõe estudar o comportamento de  $FD_\omega$  localmente para qualquer valor de  $\omega$  na vizinhança de um valor  $\omega_0$ , em que  $\omega_0$  representa a ausência de perturbação, i.e.,  $\omega_0$  é tal que  $\mathcal{F}_\alpha(\xi|\omega_0) = \mathcal{F}_\alpha(\xi)$  o que implica em  $FD_{\omega_0} = 0$ . Cook (1986) sugere investigar a curvatura normal do gráfico de  $FD_{\omega_0+a\mathbf{d}}$  versus  $a$ , em que  $a \in \mathbb{R}$  e  $\mathbf{d}$  representa uma direção com norma unitária, i.e.,  $\|\mathbf{d}\| = 1$ . Esta curvatura pode ser expressa de forma geral como sendo

$$C_d(\xi) = -2\{\mathbf{d}^\top \Delta^\top \ddot{\mathcal{F}}_\alpha^{-1} \Delta \mathbf{d}\}, \quad (13)$$

em que

$$\Delta = \frac{\partial^2 \mathcal{F}_\alpha(\xi|\omega)}{\partial \xi \partial \omega^\top} = \frac{\partial \Psi_\alpha(\xi|\omega)}{\partial \omega^\top}$$

e

$$\ddot{\mathcal{F}}_{\alpha} = \frac{\partial^2 \mathcal{F}_{\alpha}(\xi)}{\partial \xi \partial \xi^{\top}} = \frac{\partial \Psi_{\alpha}(\xi)}{\partial \xi^{\top}} = \mathbf{X}^{*\top} [\mathbf{M}_1 + \mathbf{M}_2] \mathbf{X}^* - \mathbf{K}^*(\alpha),$$

sendo

$$\begin{aligned} \mathbf{M}_1 &= \left[ \dot{\mathbf{D}} \mathbf{V}^{*-1} + \mathbf{D} \dot{\mathbf{V}}^{*-1} \right] \mathbf{C}, \quad \dot{\mathbf{D}} = \text{diag}\{\dot{\mathbf{D}}_1, \dots, \dot{\mathbf{D}}_n\}, \\ \dot{\mathbf{D}}_i &= \text{diag}\{\partial^2 \mu_{i1}/\partial \eta_{i1}^2, \dots, \partial^2 \mu_{im_i}/\partial \eta_{im_i}^2\}, \quad \dot{\mathbf{V}}^{*-1} = \text{diag}\{\dot{\mathbf{V}}_1^{*-1}, \dots, \dot{\mathbf{V}}_n^{*-1}\}, \\ \dot{\mathbf{V}}_i^{*-1} &= -\mathbf{V}_i^{*-1} \dot{\mathbf{V}}_i^* \mathbf{V}_i^{*-1}, \quad \dot{\mathbf{V}}_i^* = \mathbf{V}_i^{1/2} \mathbf{R}_i \dot{\mathbf{V}}_i + \dot{\mathbf{V}}_i \mathbf{R}_i \mathbf{V}_i^{1/2}, \\ \dot{\mathbf{V}}_i &= \frac{1}{2} \mathbf{V}_i^{-1/2} \{ \partial \mathbf{V}_i / \partial \boldsymbol{\mu}_i \} \mathbf{D}_i, \quad \partial \mathbf{V}_i / \partial \boldsymbol{\mu}_i = \text{diag}\{\partial V_{i1}/\partial \mu_{i1}, \dots, \partial V_{im_i}/\partial \mu_{im_i}\}, \\ \mathbf{C} &= \text{diag}\{\mathbf{C}_1, \dots, \mathbf{C}_n\}, \quad \mathbf{C}_i = \text{diag}\{y_{i1} - \mu_{i1}, \dots, y_{im_i} - \mu_{im_i}\} \text{ e } \mathbf{M}_2 = -\mathbf{W}^*. \end{aligned}$$

Aqui, estas quantidades são avaliadas em  $\xi = \hat{\xi}$  e  $\boldsymbol{\omega} = \boldsymbol{\omega}_0$ . Para identificar observações que exercem considerável influência em  $FD_{\boldsymbol{\omega}}$  sob pequenas perturbações devemos considerar, por exemplo, a direção  $\mathbf{d}_{max}$  referente à máxima curvatura, dada pelo autovetor correspondente ao maior autovalor da matriz  $-\Delta^{\top} \ddot{\mathcal{F}}_{\alpha}^{-1} \Delta$ .

Uma alternativa para definir a curvatura normal é utilizar no lugar da informação observada a matriz esperada (negativa) da informação (PAULA; CYSNEIROS, 2009; VENEZUELA; SANDOVAL; BOTTER, 2011), dada por

$$\mathcal{I}_{\alpha} = -E \left\{ \ddot{\mathcal{F}}_{\alpha} \right\} = -E \left\{ \frac{\partial \Psi_{\alpha}(\xi)}{\partial \xi^{\top}} \right\} = \mathbf{X}^{*\top} \mathbf{W}^* \mathbf{X}^* + \mathbf{K}^*(\alpha).$$

Neste caso, utilizamos como medida de influência local baseada na curvatura normal a quantidade

$$C_d(\xi) = 2 \{ \mathbf{d}^{\top} \Delta^{\top} \mathcal{I}_{\alpha}^{-1} \Delta \mathbf{d} \}.$$

Considerando novamente (13) e no intuito de obter uma medida de curvatura invari-

ante sob mudanças de escala, Poon e Poon (1999) propõem a curvatura normal conformal

$$B_d(\boldsymbol{\xi}) = -\frac{\mathbf{d}^\top \boldsymbol{\Delta}^\top \ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} \boldsymbol{\Delta} \mathbf{d}}{\sqrt{\text{tr}(\boldsymbol{\Delta}^\top \ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} \boldsymbol{\Delta})^2}}.$$

Esta curvatura é tal que, para toda direção unitária  $\mathbf{d}$ ,  $0 \leq B_d(\boldsymbol{\xi}) \leq 1$ . Podemos investigar, por exemplo, esta curvatura na direção  $\mathbf{d} = \mathbf{e}_{ij}$ , em que  $\mathbf{e}_{ij}$  é um vetor de dimensão  $\sum_{i=1}^n m_i \times 1$  com o valor 1 na  $ij$ -ésima posição e 0 nas demais posições e observar o gráfico de  $B_{\mathbf{e}_{ij}}(\boldsymbol{\xi})$  versus seus respectivos índices. Consideramos a  $ij$ -ésima observação como potencialmente influente se  $B_{ij} > 2\bar{B}$  (ou se  $B_{ij} > 3\bar{B}$ ), em que  $\bar{B}$  é a média de  $B = \{B_{ij} = B_{\mathbf{e}_{ij}}(\boldsymbol{\xi}) : i = 1, \dots, n \text{ e } j = 1, \dots, m_i\}$  (VERBEKE; MOLENBERGHS, 2000).

Considerando a partição  $\boldsymbol{\xi} = (\boldsymbol{\xi}_1^\top, \boldsymbol{\xi}_2^\top)^\top$ , segundo Cook (1986) a curvatura normal referente ao subvetor  $\boldsymbol{\xi}_1$  segundo uma direção unitária  $\mathbf{d}$  é dada por

$$C_d(\boldsymbol{\xi}_1) = -2\{\mathbf{d}^\top \boldsymbol{\Delta}^\top (\ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} - \mathcal{G}_{22}) \boldsymbol{\Delta} \mathbf{d}\},$$

em que

$$\mathcal{G}_{22} = \begin{bmatrix} \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \ddot{\mathcal{F}}_{\boldsymbol{\alpha}22}^{-1} \end{bmatrix},$$

com  $\ddot{\mathcal{F}}_{\boldsymbol{\alpha}22}^{-1}$  a inversa da matriz  $\ddot{\mathcal{F}}_{\boldsymbol{\alpha}22}$  obtida a partir da matriz  $\ddot{\mathcal{F}}_{\boldsymbol{\alpha}}$  particionada da forma

$$\ddot{\mathcal{F}}_{\boldsymbol{\alpha}} = \begin{bmatrix} \ddot{\mathcal{F}}_{\boldsymbol{\alpha}11} & \ddot{\mathcal{F}}_{\boldsymbol{\alpha}12} \\ \ddot{\mathcal{F}}_{\boldsymbol{\alpha}21} & \ddot{\mathcal{F}}_{\boldsymbol{\alpha}22} \end{bmatrix}.$$

Neste caso, o gráfico dos valores em  $\mathbf{d}_{max}$ , referentes à máxima curvatura dada pelo autovetor correspondente ao maior autovalor da matriz  $-\boldsymbol{\Delta}^\top (\ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} - \mathcal{G}_{22}) \boldsymbol{\Delta}$ . pode revelar observações que exercem alta influência nos valores ajustados de  $\boldsymbol{\xi}_1$ . Podemos ainda

considerar a curvatura normal conformal

$$B_d(\boldsymbol{\xi}_1) = -\frac{\mathbf{d}^\top \boldsymbol{\Delta}^\top (\ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} - \mathcal{G}_{22}) \boldsymbol{\Delta} \mathbf{d}}{\sqrt{\text{tr}(\boldsymbol{\Delta}^\top (\ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} - \mathcal{G}_{22}) \boldsymbol{\Delta})^2}}$$

e investigá-la, por exemplo, na direção  $\mathbf{d} = \mathbf{e}_{ij}$ , para  $i = 1, \dots, n$  e  $j = 1, \dots, m_i$ .

Aqui, apresentamos as expressões para a matriz  $\boldsymbol{\Delta}$  (já avaliadas em  $\boldsymbol{\omega} = \boldsymbol{\omega}_0$ ) segundo os cenários de perturbação de casos, perturbação na variável resposta e perturbação em uma das variáveis explicativas.

### 3.3.1 Perturbação de Casos

Para o cenário de perturbação de casos, temos a equação de estimação no modelo perturbado dada por

$$\Psi_{\boldsymbol{\alpha}}(\boldsymbol{\xi}|\boldsymbol{\omega}) = \mathbf{X}^{*\top} \mathbf{W}^* \mathbf{D}^{-1} \text{diag}\{\boldsymbol{\omega}\} (\mathbf{y} - \boldsymbol{\mu}) - \mathbf{P}(\boldsymbol{\alpha}),$$

em que  $\boldsymbol{\omega} = (\boldsymbol{\omega}_1^\top, \dots, \boldsymbol{\omega}_n^\top)^\top$ , com  $\boldsymbol{\omega}_i = (\omega_{i1}, \dots, \omega_{im_i})^\top$ , para  $i = 1, \dots, n$  e  $\boldsymbol{\omega}_0$  é um vetor de 1's de dimensão  $\sum_{i=1}^n m_i \times 1$ . Neste caso, a matriz  $\boldsymbol{\Delta}$  é dada por

$$\boldsymbol{\Delta} = \mathbf{X}^{*\top} \mathbf{W}^* \mathbf{D}^{-1} \mathbf{C}.$$

### 3.3.2 Perturbação na Variável Resposta

Seja a variável independente  $y_{ij}$  perturbada de tal forma que  $y_{\omega_{ij}} = y_{ij} + \omega_{ij} V_{ij}^{1/2}$ , com  $V_{ij}^{1/2}$  considerada fixa. Aqui,  $\omega_{ij} = 0$  representa  $\omega_{ij}$  na ausência de perturbação, para  $i = 1, \dots, n$  e  $j = 1, \dots, m_i$ . As equações de estimação sob o modelo perturbado são dadas, portanto, por

$$\Psi_{\boldsymbol{\alpha}}(\boldsymbol{\xi}|\boldsymbol{\omega}) = \mathbf{X}^{*\top} \mathbf{W}^* \mathbf{D}^{-1} (\mathbf{y} - \boldsymbol{\mu}_{\boldsymbol{\omega}}) - \mathbf{P}(\boldsymbol{\alpha}),$$

em que  $\boldsymbol{\mu}_{\omega} = \boldsymbol{\mu} - \mathbf{V}^{1/2}\boldsymbol{\omega}$ . Portanto, a matriz  $\boldsymbol{\Delta}$  é dada por

$$\boldsymbol{\Delta} = \mathbf{X}^{*\top} \mathbf{W}^* \mathbf{D}^{-1} \mathbf{V}^{1/2}.$$

### 3.3.3 Perturbação em Uma das Variáveis Explicativas

Para este cenário, perturbamos uma variável contínua  $\mathbf{x}_l = (\mathbf{x}_{l1}^\top, \dots, \mathbf{x}_{ln}^\top)^\top$ , para algum  $l \in \{1, \dots, p\}$ , tal que  $x_{l\omega_{ij}} = x_{lij} + \sigma_l \omega_{ij}$ , em que  $\sigma_l$  é o desvio padrão observado de  $\mathbf{x}_l$ . Sendo assim, temos que  $\mu_{\omega_{ij}} = g^{-1}(\eta_{\omega_{ij}})$ , em que

$$\eta_{\omega_{ij}} = \beta_1 x_{1ij} + \dots + \beta_l(x_{lij} + \sigma_l \omega_{ij}) + \dots + \beta_p x_{p_{ij}} + \sum_{k=1}^q f_k(t_{kij}),$$

para  $i = 1, \dots, n$  e  $j = 1, \dots, m_i$ . Neste caso as equações de estimação sob o modelo perturbado são dadas por

$$\Psi_{\alpha}(\boldsymbol{\xi}|\boldsymbol{\omega}) = \mathbf{X}_{\omega}^{*\top} \mathbf{W}_{\omega}^* \mathbf{D}_{\omega}^{-1} (\mathbf{y} - \boldsymbol{\mu}_{\omega}) - \mathbf{P}(\boldsymbol{\alpha}) = \mathbf{X}_{\omega}^{*\top} \mathbf{D}_{\omega} \mathbf{V}_{\omega}^{*-1} (\mathbf{y} - \boldsymbol{\mu}_{\omega}) - \mathbf{P}(\boldsymbol{\alpha}),$$

em que  $\mathbf{X}_{\omega}^* = \mathbf{X}^* + \mathbf{0}_{l\omega}$ , sendo  $\mathbf{0}_{l\omega}$  uma matriz de dimensão  $\sum_{i=1}^n m_i \times s$  com  $\sigma_l \omega$  na  $l$ -ésima coluna e 0's nas demais componentes. Temos ainda que

$$\mathbf{W}_{\omega}^* = \mathbf{D}_{\omega} \mathbf{V}_{\omega}^{*-1} \mathbf{D}_{\omega}, \quad \mathbf{D}_{\omega} = \text{diag}\{\mathbf{D}_{\omega_1}, \dots, \mathbf{D}_{\omega_n}\},$$

$$\mathbf{D}_{\omega_i} = \text{diag}\{\partial \mu_{\omega_{i1}} / \partial \eta_{\omega_{i1}}, \dots, \partial \mu_{\omega_{im_i}} / \partial \eta_{\omega_{im_i}}\}, \quad \mathbf{V}_{\omega}^* = \text{diag}\{\mathbf{V}_{\omega_1}^*, \dots, \mathbf{V}_{\omega_n}^*\},$$

$$\mathbf{V}_{\omega_i}^* = \mathbf{V}_{\omega_i}^{1/2} \mathbf{R}_i(\boldsymbol{\rho}) \mathbf{V}_{\omega_i}^{1/2}, \quad \mathbf{V}_{\omega_i} = \text{diag}\{V_{\omega_{i1}}, \dots, V_{\omega_{im_i}}\},$$

com  $V_{\omega_{ij}}$  sendo uma função de  $\mu_{\omega_{ij}}$ ,  $\boldsymbol{\mu}_{\omega} = (\boldsymbol{\mu}_{\omega_1}^\top, \dots, \boldsymbol{\mu}_{\omega_n}^\top)^\top$  e  $\boldsymbol{\mu}_{\omega_i} = (\mu_{\omega_{i1}}, \dots, \mu_{\omega_{im_i}})^\top$ . Sendo assim, temos a matriz  $\boldsymbol{\Delta} = (\boldsymbol{\Delta}_1, \dots, \boldsymbol{\Delta}_n)$ , em que  $\boldsymbol{\Delta}_i = (\boldsymbol{\Delta}_{i1}, \dots, \boldsymbol{\Delta}_{im_i})$ , com

$$\boldsymbol{\Delta}_{ij} = \frac{\partial \Psi_{\alpha}(\boldsymbol{\xi}|\boldsymbol{\omega})}{\partial \omega_{ij}} = \mathbf{T}_{1\omega_{ij}} + \mathbf{T}_{2\omega_{ij}},$$

$$\begin{aligned}
\mathbf{T}_{1\omega_{ij}} &= \mathbf{X}_{\boldsymbol{\omega}}^{*\top} \mathbf{D}_{\boldsymbol{\omega}} \left[ \frac{\partial \mathbf{V}_{\boldsymbol{\omega}}^{*-1}}{\partial \omega_{ij}} (\mathbf{y} - \boldsymbol{\mu}_{\boldsymbol{\omega}}) + \mathbf{V}_{\boldsymbol{\omega}}^{*-1} \frac{\partial (\mathbf{y} - \boldsymbol{\mu}_{\boldsymbol{\omega}})}{\partial \omega_{ij}} \right], \\
\mathbf{T}_{2\omega_{ij}} &= \left[ \frac{\partial \mathbf{X}_{\boldsymbol{\omega}}^{*\top}}{\partial \omega_{ij}} \mathbf{D}_{\boldsymbol{\omega}} + \mathbf{X}_{\boldsymbol{\omega}}^{*\top} \frac{\partial \mathbf{D}_{\boldsymbol{\omega}}}{\partial \omega_{ij}} \right] \mathbf{V}_{\boldsymbol{\omega}}^{*-1} (\mathbf{y} - \boldsymbol{\mu}_{\boldsymbol{\omega}}), \\
\frac{\partial \mathbf{V}_{\boldsymbol{\omega}}^{*-1}}{\partial \omega_{ij}} &= -\mathbf{V}_{\boldsymbol{\omega}}^{*-1} \frac{\partial \mathbf{V}_{\boldsymbol{\omega}}^*}{\partial \omega_{ij}} \mathbf{V}_{\boldsymbol{\omega}}^{*-1}, \quad \frac{\partial \mathbf{V}_{\boldsymbol{\omega}}^*}{\partial \omega_{ij}} = \beta_l \sigma_l \left[ \mathbf{V}_{\boldsymbol{\omega}}^{1/2} \mathbf{R}(\boldsymbol{\rho}) \dot{\mathbf{V}}_{\omega_{ij}} + \dot{\mathbf{V}}_{\omega_{ij}} \mathbf{R}(\boldsymbol{\rho}) \mathbf{V}_{\boldsymbol{\omega}}^{1/2} \right], \\
\dot{\mathbf{V}}_{\omega_{ij}} &= \frac{1}{2} \mathbf{V}_{\boldsymbol{\omega}}^{-1/2} \frac{\partial \mathbf{V}_{\boldsymbol{\omega}}}{\partial \mu_{\omega_{ij}}} \mathbf{D}_{\boldsymbol{\omega}}, \quad \frac{\partial \mathbf{V}_{\boldsymbol{\omega}}}{\partial \mu_{\omega_{ij}}} = \text{diag}\{0, \dots, \partial V_{\omega_{ij}} / \partial \mu_{\omega_{ij}}, \dots, 0\}, \\
\frac{\partial (\mathbf{y} - \boldsymbol{\mu}_{\boldsymbol{\omega}})}{\partial \omega_{ij}} &= -\beta_l \sigma_l (0, \dots, \partial \mu_{\omega_{ij}} / \partial \eta_{\omega_{ij}}, \dots, 0)^{\top}, \quad \frac{\partial \mathbf{X}_{\boldsymbol{\omega}}^{*\top}}{\partial \omega_{ij}} = \sigma_l \dot{\mathbf{X}}_{\omega_{ij}}^{*\top}, \\
\dot{\mathbf{X}}_{\omega_{ij}}^* &= (\dot{\mathbf{X}}_{1\omega_{ij}}^{*\top}, \dots, \dot{\mathbf{X}}_{n\omega_{ij}}^{*\top})^{\top}, \quad \frac{\partial \mathbf{D}_{\boldsymbol{\omega}}}{\partial \omega_{ij}} = \beta_l \sigma_l \text{diag}\{0, \dots, \partial^2 \mu_{\omega_{ij}} / \partial \eta_{\omega_{ij}}^2, \dots, 0\}
\end{aligned}$$

e  $\dot{\mathbf{X}}_{b\omega_{ij}}^*$  é uma matrix de dimensão  $m_b \times s$  com 1 sendo o elemento  $(j, l)$  e 0 nas demais componentes se  $b = i$  ou uma matriz de zeros de dimensão  $m_b \times s$  se  $b \neq i$ , para  $b = 1, \dots, n$  e  $j = 1, \dots, m_b$ .

## Capítulo 4

# Estudos de Simulação

Neste capítulo apresentamos um estudo de simulação realizado no intuito de investigar algumas propriedades de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$ , assim como para investigar algumas propriedades dos resíduos de Pearson, “naive” e “robustos”. Para tanto, estabelecemos MLAG para dados correlacionados sob o caso 1 com preditor linear  $g(\mu_{ij}) = \eta_{ij} = \beta x_{ij} + f(t_{ij})$ , para  $i = 1, \dots, n$  e  $j = 1, \dots, 5$ , em que o verdadeiro valor do parâmetro foi fixado em  $\beta_1 = 0,5$ , os valores de  $x_{ij}$  foram gerados uma única vez, segundo uma distribuição uniforme no intervalo  $(0, 1)$ ,  $t_{ij} = j$  e a função não-paramétrica foi definida como sendo  $f(t_{ij}) = \text{sen}(t_{ij})$ , portanto temos  $f(t_{i1}) = 0,841$ ,  $f(t_{i2}) = 0,909$ ,  $f(t_{i3}) = 0,141$ ,  $f(t_{i4}) = -0,757$  e  $f(t_{i5}) = -0,959$ , para  $i = 1, \dots, n$  e  $j = 1, \dots, 5$ .

Foram consideradas três distribuições marginais: normal, Poisson e gama. Sob o modelo normal temos a função de ligação identidade  $g(\mu_{ij}) = \mu_{ij}$  e sob os modelos Poisson e gama temos a função de ligação logarítmica  $g(\mu_{ij}) = \log(\mu_{ij})$ . Foram utilizados três valores distintos para os parâmetros de suavização:  $\alpha = 0,01$ ,  $\alpha = 10$  e  $\alpha = 10.000$ . Ainda, para cada configuração três estruturas de correlação foram utilizadas: independente, uniforme e AR-1. Para as estruturas de correlação uniforme e AR-1 o verdadeiro valor do parâmetro de correlação foi fixado em  $\rho = 0,30$  e nos modelos normal, Poisson e gama temos  $\phi = 1$ . O número de réplicas de Monte Carlo foi de 5.000 e em cada uma destas réplicas geramos um vetor de respostas  $\mathbf{y} = (\mathbf{y}_1^\top, \mathbf{y}_2^\top, \dots, \mathbf{y}_n^\top)^\top$ , em

que  $\mathbf{y}_i = (y_{i1}, y_{i2}, \dots, y_{i5})^\top$ , utilizando o algoritmo para gerar variáveis correlacionadas proposto em Park e Shin (1998). Para investigar os estimadores  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  consideramos três tamanhos amostrais:  $n = 20$ ,  $n = 30$ , e  $n = 50$ . Por outro lado, na investigação do comportamento dos resíduos consideramos o tamanho amostral  $n = 10$ . Para cada cenário, a matriz de “trabalho” considerada no ajuste foi a verdadeira matriz de correlação especificada e a função de ligação utilizada foi a verdadeira função especificada para cada modelo marginal.

## 4.1 Simulação de $\hat{\boldsymbol{\xi}}$ , $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$ e $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$

As Tabelas 4.1 a 4.27 contêm algumas medidas descritivas para os valores simulados de  $\hat{\beta}$  e  $\hat{\mathbf{f}} = (\hat{f}(1), \hat{f}(2), \hat{f}(3), \hat{f}(4), \hat{f}(5))^\top$ , assim como para os valores simulados de suas respectivas estimativas das variâncias do tipo “naive” e “robusta”. As medidas consideradas foram média (MED), desvio-padrão (DP), coeficiente de assimetria (CS), coeficiente de curtose (CK), viés (VIÉS), viés relativo em valor absoluto (VRA), erro quadrático médio (EQM) e raiz quadrada do erro quadrático médio (REQM).

Em geral, para todas as configurações, os valores do desvio-padrão e do erro quadrático médio dos estimadores decaem à medida que o tamanho da amostra cresce, indicando que os estimadores são consistentes. Considerando o viés e o viés relativo, os respectivos valores em geral decaem à medida que o tamanho amostral decresce e quanto menor for o valor do parâmetro de suavização considerado. Em geral as estimativas de  $\beta$  apresentam menor viés relativo em valor absoluto que os valores das estimativas das funções não paramétricas. Ainda, o viés e viés relativo crescem à medida que aumentamos os valores do parâmetro de suavização. Este comportamento é esperado, uma vez que valores maiores do parâmetro de suavização remetem a estimativas de funções mais próximas da linearidade e, sendo assim, a diferença entre os valores preditos e respectivos valores observados tendem a aumentar.

Em todas as configurações as estimativas das variâncias “naive” e “robusta” apresen-

taram viés (e portanto viés relativo em valor absoluto) próximo de zero. Os valores do coeficiente de assimetria também apresentaram valores próximos de zero, para os valores obtidos em  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$ , principalmente sob a distribuição normal, como evidenciado nos valores de CS nas tabelas 4.1 a 4.9. Sob as distribuições Poisson e gama os valores do coeficiente de assimetria também encontram-se próximos de zero, contudo são maiores em relação àqueles obtidos sob distribuição normal, indicando que sob as distribuições Poisson e gama os estimadores apresentam alguma assimetria. Isto pode ser notado nos valores de CS nas tabelas 4.10 a 4.27. Temos ainda que em geral, para todas as configurações consideradas, os valores do coeficiente de curtose CK se apresentam próximos de 3 (valor do coeficiente de curtose da distribuição normal padrão).

**Tabela 4.1** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização  $\alpha = 0, 001$ .

STAT.	$\hat{\beta}$	n			$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,50	0,50	0,50	0,50	0,84	0,84	0,85	0,91	0,91	0,91	0,14	0,14	0,14	-0,76	-0,76	-0,76	-0,96	-0,96	-0,96
DP	0,38	0,32	0,24	0,30	0,25	0,19	0,29	0,24	0,19	0,29	0,24	0,18	0,18	0,24	0,19	0,19	0,29	0,24	0,18
CS	0,07	0,05	-0,01	-0,04	-0,08	0,05	0,03	-0,02	-0,06	0,00	0,04	0,09	-0,06	0,02	0,05	-0,01	0,00	-0,01	0,00
CK	3,67	3,28	3,10	3,03	3,10	3,08	3,05	3,11	3,01	3,12	3,08	2,88	3,15	3,13	3,05	3,15	3,09	3,16	3,16
VIÉS	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00
EQM	0,15	0,10	0,06	0,09	0,06	0,04	0,08	0,06	0,04	0,09	0,06	0,03	0,09	0,06	0,03	0,09	0,06	0,03	0,03
REQM	0,38	0,32	0,24	0,30	0,25	0,19	0,29	0,24	0,19	0,29	0,24	0,18	0,29	0,24	0,19	0,29	0,24	0,18	0,18

STAT.	$\widehat{\text{Var}}_N(\hat{\beta})$	n			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,15	0,10	0,06	0,09	0,06	0,04	0,09	0,06	0,03	0,03	0,09	0,06	0,03	0,09	0,06	0,03	0,08	0,06	0,03
DP	0,02	0,01	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,00
CS	0,32	0,25	0,23	0,32	0,25	0,23	0,32	0,25	0,23	0,32	0,25	0,23	0,32	0,25	0,23	0,32	0,25	0,23	0,23
CK	3,35	3,04	3,07	3,35	3,04	3,07	3,35	3,04	3,07	3,35	3,04	3,07	3,35	3,04	3,07	3,35	3,04	3,07	3,07
VIÉS	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,02	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,01

STAT.	$\widehat{\text{Var}}_R(\hat{\beta})$	n			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,14	0,10	0,05	0,08	0,06	0,03	0,08	0,06	0,03	0,08	0,06	0,03	0,08	0,06	0,03	0,08	0,05	0,03	0,03
DP	0,03	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,01
CS	0,46	0,31	0,23	0,58	0,51	0,43	0,69	0,50	0,42	0,63	0,45	0,40	0,61	0,49	0,40	0,60	0,50	0,39	0,39
CK	3,36	3,07	3,01	3,51	3,33	3,27	4,01	3,38	3,32	3,73	3,33	3,23	3,61	3,29	3,21	3,66	3,37	3,14	3,14
VIÉS	-0,01	0,00	-0,01	0,00	0,00	-0,01	0,00	0,00	-0,01	0,00	0,00	-0,01	0,00	0,00	-0,01	0,00	-0,01	0,00	0,00
VRA	0,07	0,04	0,02	0,06	0,04	0,02	0,06	0,04	0,02	0,06	0,04	0,02	0,06	0,04	0,02	0,06	0,04	0,02	0,02
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,03	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,01

Fonte: O autor (2016).

**Tabela 4.2** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10$ .

STAT.	n	$\hat{\beta}$			$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,50	0,48	0,48	1,00	0,98	0,96	0,66	0,69	0,73	0,11	0,12	0,13	-0,52	-0,54	-0,57	-1,05	-1,04	-1,03	
DP	0,38	0,32	0,24	0,27	0,23	0,18	0,23	0,20	0,15	0,23	0,20	0,15	0,23	0,19	0,15	0,26	0,22	0,17	
CS	0,07	0,05	-0,01	-0,05	-0,09	0,04	-0,04	-0,02	0,01	-0,01	0,02	0,04	-0,04	-0,01	0,03	-0,02	0,00	-0,05	
CK	3,67	3,27	3,09	3,08	3,11	3,11	3,27	3,15	3,04	3,32	3,14	2,97	3,38	3,17	3,12	3,20	3,08	3,18	
VIÉS	-0,01	-0,02	-0,02	0,15	0,14	0,12	-0,25	-0,22	-0,18	-0,03	-0,02	-0,01	0,23	0,22	0,19	-0,09	-0,08	-0,07	
VRA	0,01	0,04	0,03	0,18	0,17	0,14	0,28	0,24	0,20	0,24	0,13	0,08	0,31	0,29	0,25	0,09	0,08	0,07	
EQM	0,15	0,10	0,06	0,10	0,07	0,05	0,12	0,09	0,06	0,05	0,04	0,02	0,11	0,08	0,06	0,08	0,06	0,03	
REQM	0,38	0,32	0,24	0,31	0,27	0,21	0,34	0,29	0,23	0,23	0,20	0,15	0,33	0,29	0,24	0,28	0,23	0,18	

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,15	0,11	0,06	0,08	0,05	0,03	0,06	0,04	0,02	0,06	0,04	0,02	0,05	0,04	0,02	0,07	0,05	0,03	
DP	0,02	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,01	0,00	
CS	0,33	0,25	0,23	0,33	0,25	0,23	0,33	0,25	0,23	0,33	0,25	0,23	0,33	0,25	0,23	0,25	0,25	0,23	
CK	3,34	3,05	3,08	3,34	3,05	3,08	3,34	3,05	3,08	3,34	3,05	3,08	3,34	3,05	3,08	3,34	3,05	3,08	
VIÉS	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
VRA	0,03	0,02	0,02	0,03	0,02	0,02	0,03	0,02	0,02	0,03	0,02	0,02	0,03	0,02	0,02	0,03	0,02	0,02	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,02	0,01	0,01	0,01	0,00	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,15	0,10	0,06	0,07	0,05	0,03	0,05	0,04	0,02	0,05	0,04	0,02	0,05	0,04	0,02	0,05	0,07	0,05	0,03
DP	0,03	0,01	0,01	0,02	0,01	0,01	0,00	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	
CS	0,45	0,30	0,23	0,57	0,48	0,40	0,50	0,35	0,30	0,47	0,38	0,35	0,48	0,43	0,33	0,56	0,47	0,36	
CK	3,33	3,07	3,02	3,59	3,30	3,14	3,49	3,04	3,01	3,34	3,06	3,08	3,34	3,28	3,20	3,51	3,28	3,07	
VIÉS	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
VRA	0,03	0,01	0,01	0,04	0,03	0,01	0,03	0,02	0,01	0,04	0,02	0,01	0,04	0,02	0,01	0,05	0,03	0,02	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,03	0,01	0,01	0,02	0,01	0,01	0,00	0,01	0,00	0,01	0,00	0,01	0,01	0,01	0,00	0,02	0,01	0,01	

Fonte: O autor (2016).

**Tabela 4.3** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10.000$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,50	0,48	0,46	1,09	1,10	1,11	0,57	0,58	0,04	0,04	0,06	-0,49	-0,48	-0,47	-1,02	-1,01	-1,00		
DP	0,38	0,32	0,24	0,26	0,22	0,16	0,23	0,19	0,14	0,21	0,18	0,13	0,22	0,18	0,14	0,25	0,21	0,16	
CS	0,07	0,05	-0,02	-0,03	-0,05	0,04	-0,03	-0,06	0,05	-0,04	-0,05	0,03	-0,04	-0,03	0,00	-0,02	-0,02	-0,02	
CK	3,66	3,27	3,07	3,15	3,14	3,11	3,31	3,18	3,11	3,46	3,21	3,13	3,41	3,17	3,15	3,23	3,09	3,13	
VIÉS	-0,01	-0,02	-0,04	0,25	0,26	0,27	-0,35	-0,34	-0,33	-0,10	-0,10	-0,09	0,27	0,27	0,28	-0,06	-0,05	-0,04	
VRA	0,01	0,04	0,08	0,30	0,30	0,32	0,38	0,37	0,36	0,73	0,69	0,61	0,35	0,36	0,38	0,06	0,05	0,04	
EQM	0,15	0,10	0,06	0,13	0,11	0,10	0,17	0,15	0,13	0,06	0,04	0,03	0,12	0,11	0,10	0,07	0,05	0,03	
REQM	0,38	0,32	0,24	0,36	0,34	0,31	0,41	0,39	0,36	0,24	0,20	0,16	0,35	0,33	0,32	0,26	0,21	0,16	

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,16	0,11	0,06	0,08	0,05	0,03	0,06	0,04	0,02	0,05	0,03	0,02	0,05	0,04	0,04	0,02	0,07	0,05	0,03	
DP	0,02	0,01	0,01	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,01	0,00	0,01	0,01	0,01	0,00	
CS	0,34	0,24	0,22	0,34	0,24	0,22	0,34	0,24	0,22	0,34	0,24	0,22	0,34	0,24	0,22	0,34	0,24	0,22	0,22	
CK	3,30	3,05	3,08	3,30	3,05	3,08	3,30	3,05	3,08	3,30	3,05	3,08	3,30	3,05	3,08	3,30	3,05	3,08	3,08	
VIÉS	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
VRA	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,02	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,00	0,01	0,00	0,01	0,00	0,01	0,01	0,01	0,00	

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,15	0,11	0,06	0,07	0,05	0,03	0,05	0,04	0,02	0,05	0,03	0,02	0,05	0,03	0,02	0,05	0,03	0,02	0,04	0,02
DP	0,03	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,00	
CS	0,44	0,28	0,22	0,53	0,41	0,33	0,51	0,34	0,29	0,53	0,35	0,27	0,51	0,39	0,28	0,52	0,45	0,45	0,33	
CK	3,31	3,04	3,02	3,60	3,16	3,05	3,54	3,03	3,00	3,45	3,08	3,01	3,40	3,22	3,04	3,42	3,32	3,11		
VIÉS	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
VRA	0,00	0,02	0,03	0,03	0,00	0,01	0,02	0,00	0,01	0,01	0,01	0,02	0,00	0,01	0,03	0,01	0,01	0,00	0,00	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,03	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,00	

Fonte: O autor (2016).

**Tabela 4.4** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 0,01$ .

STAT.	$\hat{\beta}$	$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,50	0,50	0,50	0,84	0,84	0,85	0,91	0,91	0,91	0,14	0,14	0,14	-0,76	-0,76	-0,96	-0,96	-0,96
DP	0,44	0,36	0,26	0,32	0,26	0,20	0,31	0,26	0,19	0,31	0,25	0,18	0,31	0,25	0,19	0,25	0,19
CS	0,08	0,04	-0,01	-0,05	-0,07	0,05	0,01	-0,01	-0,05	-0,02	0,03	0,07	-0,05	-0,01	0,04	-0,02	-0,01
CK	3,56	3,33	3,17	3,06	3,10	3,11	3,08	3,12	3,01	3,12	3,11	2,93	3,19	3,07	3,06	3,05	3,20
VIÉS	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00
EQM	0,19	0,13	0,07	0,10	0,07	0,04	0,10	0,07	0,04	0,10	0,06	0,03	0,10	0,06	0,04	0,06	0,04
REQM	0,44	0,36	0,26	0,32	0,26	0,20	0,31	0,26	0,19	0,31	0,25	0,18	0,31	0,25	0,19	0,25	0,19

STAT.	$\widehat{\text{Var}}_N(\hat{\beta})$	$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,15	0,10	0,06	0,09	0,06	0,04	0,09	0,06	0,03	0,09	0,06	0,03	0,08	0,06	0,08	0,06	0,03
DP	0,03	0,01	0,01	0,02	0,01	0,00	0,02	0,01	0,00	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,00
CS	0,46	0,34	0,27	0,46	0,34	0,27	0,46	0,34	0,27	0,46	0,34	0,27	0,46	0,34	0,27	0,34	0,27
CK	3,42	3,05	2,99	3,42	3,05	2,99	3,42	3,05	2,99	3,42	3,05	2,99	3,42	3,05	2,99	3,05	2,99
VIÉS	0,00	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,02	0,08	0,13	0,01	0,03	0,05	0,00	0,03	0,05	0,00	0,03	0,04	0,00	0,03	0,01	0,03	0,04
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,03	0,02	0,01	0,02	0,01	0,00	0,02	0,01	0,00	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,00

STAT.	$\widehat{\text{Var}}_R(\hat{\beta})$	$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50		
MED	0,18	0,12	0,06	0,10	0,06	0,04	0,09	0,06	0,04	0,09	0,06	0,03	0,09	0,06	0,04	0,08	0,03	
DP	0,04	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,02	0,01	0,01	
CS	0,62	0,45	0,33	0,63	0,49	0,43	0,65	0,46	0,36	0,60	0,46	0,41	0,62	0,49	0,38	0,66	0,50	0,33
CK	3,55	3,14	3,05	3,67	3,24	3,26	3,71	3,13	3,04	3,66	3,24	3,23	3,50	3,27	3,16	3,65	3,27	2,97
VIÉS	0,04	0,03	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,00	0,00	0,00	0,00	0,00
VRA	0,26	0,28	0,07	0,09	0,10	0,08	0,09	0,09	0,09	0,07	0,09	0,07	0,06	0,09	0,06	0,08	0,08	0,08
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,06	0,03	0,02	0,03	0,01	0,01	0,02	0,01	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,02	0,01	0,01

Fonte: O autor (2016).

**Tabela 4.5** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10$ .

STAT.	$n$			$\hat{\beta}$			$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
MED	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50			
DP	0,50	0,48	0,48	0,99	0,98	0,96	0,66	0,69	0,73	0,11	0,12	0,13	-0,52	-0,54	-0,57	-1,04	-1,04	-1,03			
CS	0,44	0,36	0,26	0,30	0,25	0,19	0,27	0,23	0,17	0,27	0,22	0,17	0,27	0,22	0,16	0,29	0,24	0,18			
CK	0,08	0,04	-0,02	-0,02	-0,05	-0,07	0,04	-0,03	-0,01	0,01	-0,02	0,01	0,03	-0,04	-0,02	0,02	-0,03	-0,02	-0,04		
VIÉS	3,56	3,32	3,17	3,11	3,13	3,19	3,13	3,13	3,06	3,21	3,11	2,99	3,26	3,08	3,09	3,20	3,03	3,20			
VRA	0,00	-0,02	-0,02	0,15	0,14	0,12	-0,25	-0,22	-0,18	-0,03	-0,02	-0,01	0,23	0,22	0,19	-0,09	-0,08	-0,07			
EQM	0,01	0,03	0,03	0,18	0,17	0,14	0,28	0,24	0,20	0,24	0,14	0,08	0,31	0,29	0,25	0,09	0,08	0,07			
REQM	0,19	0,13	0,07	0,11	0,08	0,05	0,14	0,10	0,06	0,07	0,05	0,03	0,13	0,10	0,06	0,09	0,06	0,04			
$n$																					
STAT.	$n$			$\widehat{\text{Var}}_N(\hat{\beta})$			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
MED	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50			
DP	0,15	0,11	0,06	0,08	0,05	0,03	0,06	0,04	0,02	0,06	0,04	0,02	0,05	0,04	0,02	0,07	0,05	0,03			
CS	0,03	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00			
CK	0,46	0,33	0,27	0,46	0,33	0,27	0,46	0,33	0,27	0,46	0,33	0,27	0,46	0,33	0,27	0,46	0,33	0,27			
VIÉS	3,44	3,05	2,99	3,44	3,05	2,99	3,44	3,05	2,99	3,44	3,05	2,99	3,44	3,05	2,99	3,44	3,05	2,99			
VRA	0,01	0,01	0,01	0,00	0,00	0,00	-0,01	0,00	0,00	-0,01	0,00	0,00	-0,01	-0,01	0,00	0,00	0,00	0,00			
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,10	0,14	0,10	0,09	0,14	0,11	0,04	0,01	0,01			
REQM	0,03	0,02	0,01	0,01	0,00	0,00	0,01	0,01	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00			
$n$																					
STAT.	$n$			$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
MED	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50			
DP	0,19	0,13	0,06	0,09	0,06	0,03	0,07	0,05	0,03	0,07	0,05	0,03	0,07	0,05	0,03	0,05	0,05	0,03			
CS	0,94	0,02	0,01	0,92	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01			
CK	0,62	0,44	0,33	0,63	0,47	0,41	0,62	0,43	0,35	0,60	0,46	0,38	0,61	0,50	0,37	0,64	0,49	0,32			
VIÉS	3,57	3,15	3,05	3,73	3,19	3,19	3,58	3,06	3,04	3,51	3,14	3,12	3,51	3,29	3,20	3,60	3,26	2,97			
VRA	0,04	0,03	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,00			
EQM	0,29	0,31	0,30	0,09	0,11	0,10	0,12	0,14	0,11	0,11	0,12	0,10	0,13	0,10	0,07	0,09	0,08				
REQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,00	0,02	0,01	0,01	0,00	0,01				

Fonte: O autor (2016).

**Tabela 4.6** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10.000$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,50	0,48	0,46	1,09	1,10	1,11	0,56	0,57	0,58	0,04	0,04	0,06	-0,49	-0,48	-0,47	-1,02	-1,01	-1,00		
DP	0,44	0,36	0,25	0,29	0,24	0,18	0,27	0,22	0,16	0,26	0,21	0,16	0,21	0,16	0,28	0,23	0,17			
CS	0,08	0,04	-0,02	-0,04	-0,04	-0,04	-0,04	-0,04	-0,04	-0,04	-0,03	-0,03	-0,04	-0,03	-0,03	-0,03	-0,03	-0,02		
CK	3,56	3,32	3,15	3,13	3,13	3,10	3,21	3,13	3,10	3,27	3,12	3,11	3,27	3,08	3,13	3,20	3,03	3,14		
VIÉS	0,00	-0,02	-0,04	0,25	0,26	0,27	-0,35	-0,34	-0,33	-0,10	-0,09	0,27	0,27	0,28	-0,06	-0,05	-0,04			
VRA	0,01	0,04	0,08	0,30	0,30	0,32	0,38	0,37	0,36	0,73	0,69	0,61	0,35	0,36	0,38	0,06	0,05	0,04		
EQM	0,19	0,13	0,07	0,15	0,12	0,10	0,19	0,16	0,13	0,08	0,05	0,03	0,14	0,12	0,11	0,08	0,05	0,03		
REQM	0,44	0,36	0,26	0,38	0,35	0,32	0,44	0,40	0,37	0,28	0,23	0,18	0,38	0,35	0,33	0,29	0,23	0,18		

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$		$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,16	0,11	0,06	0,07	0,05	0,03	0,06	0,04	0,02	0,05	0,03	0,02	0,05	0,04	0,04	0,02	0,06	0,05	0,03	
DP	0,03	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,00	
CS	0,44	0,31	0,25	0,44	0,31	0,25	0,44	0,31	0,25	0,44	0,31	0,25	0,44	0,31	0,25	0,44	0,31	0,25		
CK	3,41	3,03	2,99	3,41	3,03	2,99	3,41	3,03	2,99	3,41	3,03	2,99	3,41	3,03	2,99	3,41	3,03	2,99		
VIÉS	0,01	0,01	0,01	0,00	0,00	0,00	-0,01	0,00	0,00	-0,01	0,00	0,00	-0,01	0,00	0,00	0,00	0,00	0,00		
VRA	0,07	0,13	0,19	0,03	0,00	0,02	0,12	0,08	0,08	0,16	0,12	0,12	0,13	0,09	0,09	0,04	0,01	0,01		
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00		
REQM	0,03	0,02	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,00	0,01	0,00	0,01	0,01	0,01	0,00	0,01	0,01		

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$		$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,19	0,13	0,06	0,09	0,06	0,03	0,07	0,05	0,03	0,07	0,05	0,02	0,07	0,05	0,05	0,02	0,07	0,05	0,03	
DP	0,94	0,02	0,01	0,92	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,01	0,00	
CS	0,62	0,43	0,31	0,61	0,43	0,38	0,63	0,45	0,38	0,65	0,47	0,36	0,64	0,49	0,34	0,61	0,51	0,32		
CK	3,57	3,15	3,04	3,65	3,10	3,17	3,63	3,12	3,15	3,61	3,20	3,11	3,58	3,30	3,06	3,54	3,36	3,02		
VIÉS	0,05	0,03	0,02	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00		
VRA	0,32	0,34	0,13	0,15	0,14	0,15	0,17	0,16	0,15	0,18	0,17	0,14	0,17	0,16	0,11	0,13	0,12			
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00		
REQM	0,06	0,04	0,02	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01		

Fonte: O autor (2016).

**Tabela 4.7** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 0,01$ .

STAT.	$\hat{\beta}$	$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50		
MED	0,50	0,50	0,50	0,84	0,84	0,85	0,91	0,91	0,91	0,14	0,14	0,14	-0,76	-0,76	-0,96	-0,96	-0,96	
DP	0,41	0,34	0,25	0,30	0,25	0,19	0,30	0,25	0,19	0,30	0,25	0,18	0,25	0,19	0,29	0,24	0,18	
CS	0,08	0,05	-0,02	-0,05	-0,08	0,05	0,02	-0,01	-0,04	-0,01	0,03	0,07	-0,04	0,00	0,05	-0,02	-0,01	-0,05
CK	3,62	3,33	3,12	3,04	3,12	3,10	3,06	3,12	3,01	3,13	3,14	2,91	3,17	3,09	3,08	3,16	3,06	3,18
VIÉS	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00
EQM	0,17	0,11	0,06	0,09	0,06	0,04	0,09	0,06	0,04	0,09	0,06	0,03	0,09	0,06	0,04	0,09	0,06	0,03
REQM	0,41	0,34	0,25	0,30	0,25	0,19	0,30	0,25	0,19	0,30	0,25	0,18	0,30	0,25	0,19	0,29	0,24	0,18

STAT.	$\widehat{\text{Var}}_N(\hat{\beta})$	$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50		
MED	0,15	0,10	0,06	0,09	0,06	0,04	0,09	0,06	0,04	0,03	0,09	0,06	0,03	0,09	0,06	0,03	0,08	0,03
DP	0,02	0,01	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,00
CS	0,37	0,31	0,24	0,37	0,31	0,24	0,37	0,31	0,24	0,37	0,31	0,24	0,37	0,31	0,24	0,37	0,31	0,24
CK	3,35	3,04	2,97	3,35	3,04	2,97	3,35	3,04	2,97	3,35	3,04	2,97	3,35	3,04	2,97	3,35	3,04	2,97
VIÉS	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,03	0,06	0,08	0,01	0,02	0,03	0,01	0,02	0,03	0,01	0,02	0,01	0,02	0,03	0,01	0,02	0,02	0,03
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,02	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,00

STAT.	$\widehat{\text{Var}}_R(\hat{\beta})$	$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50		
MED	0,16	0,11	0,06	0,09	0,06	0,04	0,09	0,06	0,04	0,04	0,09	0,06	0,03	0,08	0,06	0,03	0,08	0,03
DP	0,93	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,01
CS	0,54	0,40	0,28	0,58	0,50	0,41	0,66	0,47	0,38	0,59	0,45	0,40	0,60	0,50	0,39	0,60	0,49	0,35
CK	3,45	3,09	3,00	3,61	3,30	3,19	3,84	3,24	3,16	3,57	3,21	3,22	3,49	3,31	3,18	3,60	3,29	3,05
VIÉS	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,09	0,12	0,14	0,00	0,03	0,04	0,00	0,03	0,04	0,00	0,03	0,03	0,01	0,04	0,01	0,02	0,04	0,03
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,04	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,01

Fonte: O autor (2016).

**Tabela 4.8** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 10$ .

STAT.	n	$\hat{\beta}$			$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,50	0,48	0,48	1,00	0,98	0,96	0,66	0,69	0,73	0,11	0,12	0,13	-0,52	-0,54	-0,57	-1,04	-1,04	-1,03	
DP	0,41	0,34	0,25	0,29	0,24	0,19	0,26	0,22	0,16	0,26	0,22	0,16	0,25	0,21	0,16	0,28	0,23	0,18	
CS	0,08	0,05	-0,03	-0,05	-0,08	0,04	-0,02	-0,01	0,02	-0,01	0,01	0,04	-0,03	-0,01	0,03	-0,03	-0,01	-0,04	
CK	3,61	3,33	3,11	3,07	3,12	3,18	3,16	3,05	3,22	3,14	2,98	3,28	3,12	3,11	3,19	3,04	3,18		
VIÉS	-0,01	-0,02	-0,02	0,15	0,14	0,12	-0,25	-0,22	-0,18	-0,03	-0,02	-0,01	0,23	0,22	0,19	-0,09	-0,08	-0,07	
VRA	0,01	0,04	0,03	0,18	0,17	0,14	0,28	0,24	0,20	0,24	0,14	0,08	0,31	0,29	0,25	0,09	0,08	0,07	
EQM	0,17	0,11	0,06	0,11	0,08	0,05	0,13	0,09	0,06	0,07	0,05	0,03	0,12	0,09	0,06	0,09	0,06	0,04	
REQM	0,41	0,34	0,25	0,33	0,28	0,22	0,36	0,31	0,24	0,26	0,22	0,16	0,34	0,30	0,25	0,30	0,25	0,19	

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,15	0,11	0,06	0,08	0,05	0,03	0,06	0,04	0,02	0,06	0,04	0,02	0,05	0,04	0,04	0,02	0,07	0,05	0,03
DP	0,02	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,00
CS	0,38	0,30	0,24	0,38	0,30	0,24	0,38	0,30	0,24	0,38	0,30	0,24	0,38	0,30	0,24	0,38	0,30	0,24	
CK	3,35	3,04	2,97	3,35	3,04	2,97	3,35	3,04	2,97	3,35	3,04	2,97	3,35	3,04	2,97	3,35	3,04	2,97	
VIÉS	0,01	0,01	-0,01	0,00	0,00	-0,01	0,00	0,00	-0,01	0,00	0,00	-0,01	0,00	0,00	-0,01	0,00	-0,01	0,00	
VRA	0,05	0,08	0,10	0,06	0,04	0,02	0,09	0,08	0,10	0,09	0,07	0,09	0,10	0,09	0,11	0,06	0,04	0,02	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,02	0,02	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,00	

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,16	0,11	0,06	0,08	0,06	0,03	0,07	0,05	0,03	0,06	0,05	0,03	0,06	0,04	0,06	0,04	0,07	0,05	0,03
DP	0,03	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,02	0,01	0,01	0,00
CS	0,54	0,39	0,27	0,59	0,47	0,39	0,57	0,40	0,33	0,55	0,44	0,37	0,56	0,50	0,35	0,58	0,48	0,33	
CK	3,45	3,10	3,00	3,71	3,27	3,11	3,54	3,04	3,05	3,44	3,10	3,11	3,45	3,34	3,19	3,52	3,26	3,01	
VIÉS	0,02	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
VRA	0,12	0,15	0,16	0,02	0,04	0,05	0,05	0,07	0,07	0,05	0,07	0,06	0,04	0,07	0,06	0,06	0,03	0,04	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,04	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,01	0,01	0,01	0,02	0,01	0,01	

Fonte: O autor (2016).

**Tabela 4.9** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 10.000$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,50	0,48	0,46	1,09	1,10	1,11	0,57	0,58	0,04	0,04	0,06	-0,49	-0,48	-0,47	-0,47	-1,01	-1,01	-1,00	
DP	0,41	0,34	0,25	0,29	0,24	0,18	0,25	0,21	0,16	0,24	0,19	0,15	0,25	0,20	0,15	0,28	0,23	0,23	0,17
CS	0,08	0,05	-0,03	-0,03	-0,04	0,04	-0,03	-0,05	0,05	-0,04	-0,04	0,04	-0,03	0,03	0,01	-0,02	-0,02	-0,02	-0,01
CK	3,61	3,32	3,10	3,15	3,11	3,22	3,17	3,09	3,35	3,18	3,10	3,32	3,12	3,13	3,18	3,05	3,05	3,14	
VIÉS	-0,01	-0,02	-0,04	0,25	0,26	0,27	-0,35	-0,34	-0,33	-0,10	-0,09	0,27	0,27	0,28	-0,06	-0,05	-0,05	-0,04	
VRA	0,01	0,04	0,08	0,30	0,30	0,32	0,38	0,37	0,36	0,73	0,69	0,61	0,35	0,36	0,38	0,06	0,05	0,04	
EQM	0,17	0,11	0,06	0,15	0,12	0,10	0,18	0,16	0,13	0,07	0,05	0,03	0,13	0,12	0,10	0,08	0,05	0,05	0,03
REQM	0,41	0,34	0,25	0,38	0,35	0,32	0,43	0,40	0,36	0,26	0,22	0,17	0,36	0,34	0,32	0,28	0,23	0,23	0,18

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$		$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,16	0,11	0,06	0,07	0,05	0,03	0,06	0,04	0,02	0,05	0,03	0,02	0,05	0,04	0,04	0,02	0,07	0,05	0,03
DP	0,02	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,01	0,01	0,00
CS	0,38	0,28	0,22	0,38	0,28	0,22	0,38	0,28	0,22	0,38	0,28	0,22	0,38	0,28	0,22	0,38	0,28	0,28	0,22
CK	3,33	3,02	2,96	3,33	3,02	2,96	3,33	3,02	2,96	3,33	3,02	2,96	3,33	3,02	2,96	3,33	3,02	3,02	2,96
VIÉS	0,01	0,01	-0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,01	0,00	0,00
VRA	0,08	0,11	0,14	0,06	0,05	0,05	0,05	0,03	0,04	0,05	0,02	0,03	0,03	0,06	0,04	0,08	0,05	0,06	0,06
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,03	0,02	0,01	0,01	0,00	0,01	0,01	0,01	0,00	0,01	0,00	0,01	0,00	0,00	0,01	0,01	0,01	0,01	0,00

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$		$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,17	0,12	0,06	0,08	0,06	0,03	0,06	0,04	0,02	0,06	0,04	0,02	0,06	0,04	0,04	0,02	0,07	0,05	0,03
DP	0,03	0,02	0,01	0,02	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,02	0,01	0,01	0,00
CS	0,54	0,38	0,26	0,56	0,42	0,36	0,58	0,40	0,34	0,60	0,44	0,33	0,58	0,48	0,31	0,56	0,50	0,50	0,33
CK	3,45	3,09	2,99	3,66	3,16	3,11	3,60	3,07	3,10	3,54	3,15	3,08	3,49	3,31	3,05	3,49	3,37	3,37	3,08
VIÉS	0,02	0,02	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,15	0,19	0,20	0,05	0,08	0,09	0,07	0,11	0,11	0,08	0,12	0,13	0,07	0,10	0,11	0,04	0,07	0,08	0,08
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,04	0,03	0,01	0,02	0,01	0,01	0,02	0,01	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,02	0,01	0,01	0,01

Fonte: O autor (2016).

**Tabela 4.10** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização  $\alpha = 0,01$ .

STAT.	$n$			$\hat{f}(1)$					$\hat{f}(2)$					$\hat{f}(3)$					$\hat{f}(4)$					$\hat{f}(5)$				
	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,50	0,51	0,50	0,83	0,84	0,84	0,90	0,90	0,91	0,12	0,13	0,13	-0,80	-0,79	-0,77	-1,02	-1,00	-0,98										
DP	0,30	0,24	0,18	0,21	0,17	0,13	0,21	0,16	0,13	0,24	0,20	0,15	0,34	0,28	0,21	0,38	0,31	0,23										
CS	0,06	-0,02	-0,06	-0,16	-0,19	-0,12	-0,21	-0,09	-0,07	-0,24	-0,17	-0,15	-0,54	-0,37	-0,29	-0,61	-0,48	-0,34										
CK	3,04	2,87	3,12	3,04	3,24	3,12	3,09	3,06	2,95	3,14	3,16	2,98	3,79	3,37	3,37	3,81	3,63	3,39										
VIÉS	0,00	0,01	0,00	-0,01	0,00	-0,01	-0,01	0,00	-0,01	-0,01	-0,02	-0,01	-0,01	-0,03	-0,03	-0,06	-0,06	-0,04	-0,06	-0,04	-0,04	-0,02						
VRA	0,00	0,01	0,00	0,02	0,01	0,00	0,01	0,01	0,00	0,14	0,08	0,06	0,05	0,05	0,05	0,07	0,04	0,02										
EQM	0,09	0,06	0,03	0,05	0,02	0,04	0,03	0,02	0,02	0,06	0,04	0,02	0,08	0,08	0,04	0,04	0,15	0,10	0,06									
REQM	0,30	0,24	0,18	0,21	0,17	0,13	0,21	0,16	0,13	0,24	0,20	0,15	0,35	0,28	0,21	0,38	0,31	0,24										

STAT.	$n$			$\widehat{\text{Var}}_N(\hat{\beta})$					$\widehat{\text{Var}}_N(\hat{f}(1))$					$\widehat{\text{Var}}_N(\hat{f}(2))$					$\widehat{\text{Var}}_N(\hat{f}(3))$					$\widehat{\text{Var}}_N(\hat{f}(4))$					$\widehat{\text{Var}}_N(\hat{f}(5))$				
	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50			
MED	0,09	0,06	0,03	0,05	0,03	0,02	0,04	0,03	0,02	0,06	0,04	0,02	0,11	0,07	0,04	0,14	0,09	0,05															
DP	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,03	0,02	0,01	0,05	0,02	0,01															
CS	0,38	0,34	0,28	0,46	0,46	0,31	0,42	0,38	0,27	0,99	0,71	0,55	2,47	1,43	1,07	3,21	1,99	1,31															
CK	3,28	3,31	3,11	3,46	3,70	3,14	3,32	3,47	3,16	5,17	4,13	3,56	16,14	7,12	5,29	27,86	11,49	6,66															
VIÉS	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,00	0,01	0,01	0,00	0,01	0,00					
VRA	0,01	0,00	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,02	0,01	0,01	0,01	0,01	0,07	0,05	0,02	0,11	0,07	0,04													
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00					
REQM	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,03	0,02	0,01	0,05	0,02	0,01	0,05	0,02	0,01	0,05	0,02	0,01	0,05	0,02	0,01	0,05	0,01				

STAT.	$n$			$\widehat{\text{Var}}_R(\hat{\beta})$					$\widehat{\text{Var}}_R(\hat{f}(1))$					$\widehat{\text{Var}}_R(\hat{f}(2))$					$\widehat{\text{Var}}_R(\hat{f}(3))$					$\widehat{\text{Var}}_R(\hat{f}(4))$					$\widehat{\text{Var}}_R(\hat{f}(5))$				
	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50			
MED	0,09	0,06	0,03	0,05	0,03	0,02	0,05	0,03	0,02	0,06	0,04	0,02	0,10	0,07	0,04	0,12	0,08	0,04															
DP	0,02	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,02	0,01	0,00	0,04	0,02	0,01	0,05	0,03	0,01															
CS	0,64	0,49	0,42	0,87	0,87	0,69	0,50	0,95	0,73	0,62	0,94	0,77	0,55	2,20	1,27	1,07	3,05	2,10	1,18														
CK	3,66	3,42	3,38	4,20	3,76	3,33	4,84	4,00	3,67	4,57	4,26	3,47	14,54	6,12	5,41	23,69	13,80	5,81															
VIÉS	-0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00					
VRA	0,05	0,03	0,02	0,04	0,03	0,02	0,04	0,02	0,01	0,02	0,01	0,00	0,09	0,06	0,03	0,19	0,11	0,07															
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00					
REQM	0,02	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,02	0,01	0,00	0,04	0,02	0,01	0,05	0,03	0,01	0,05	0,02	0,01	0,05	0,02	0,01	0,05	0,01	0,05	0,01					

Fonte: O autor (2016).

**Tabela 4.11** Estatísticas para as observações de  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,49	0,50	0,50	0,92	0,91	0,89	0,75	0,77	0,81	0,20	0,19	0,18	-0,53	-0,56	-0,56	-1,13	-1,13	-1,11
DP	0,30	0,24	0,18	0,20	0,16	0,13	0,19	0,15	0,12	0,19	0,16	0,12	0,21	0,18	0,14	0,31	0,27	0,22
CS	0,05	-0,02	-0,06	-0,13	-0,18	-0,11	-0,18	-0,09	-0,06	-0,16	-0,09	-0,06	-0,21	-0,18	-0,07	-0,27	-0,27	-0,19
CK	3,04	2,87	3,13	3,02	3,10	3,21	3,10	3,09	3,03	3,00	2,99	3,00	3,05	3,06	3,12	3,15	3,20	3,15
VIÉS	-0,01	0,00	0,00	0,08	0,07	0,05	-0,16	-0,14	-0,10	0,06	0,05	0,04	0,26	0,23	0,20	-0,18	-0,17	-0,15
VRA	0,02	0,00	0,01	0,09	0,08	0,06	0,18	0,15	0,11	0,39	0,37	0,30	0,34	0,30	0,26	0,18	0,18	0,16
EQM	0,09	0,06	0,03	0,05	0,03	0,02	0,06	0,04	0,02	0,04	0,03	0,02	0,11	0,08	0,06	0,13	0,10	0,07
REQM	0,30	0,24	0,18	0,22	0,17	0,13	0,25	0,21	0,16	0,20	0,17	0,13	0,33	0,29	0,24	0,36	0,32	0,27

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,09	0,06	0,03	0,04	0,03	0,02	0,03	0,02	0,01	0,04	0,03	0,01	0,05	0,03	0,02	0,09	0,06	0,04	
DP	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,01	0,01	0,01	0,01	
CS	0,36	0,34	0,28	0,38	0,42	0,42	0,29	0,42	0,38	0,29	0,42	0,37	0,29	0,59	0,61	0,62	0,64	0,53	
CK	3,24	3,32	3,11	3,31	3,65	3,13	3,35	3,51	3,21	3,29	3,44	3,21	3,58	3,88	3,34	3,39	3,74	3,56	
VIÉS	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
VRA	0,01	0,01	0,00	0,03	0,01	0,01	0,01	0,02	0,02	0,01	0,00	0,01	0,01	0,01	0,04	0,06	0,06	0,07	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,01	0,01	0,01	

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,09	0,06	0,04	0,04	0,03	0,02	0,04	0,03	0,02	0,04	0,03	0,02	0,04	0,03	0,02	0,08	0,06	0,04	
DP	0,92	0,01	0,00	0,91	0,01	0,00	0,91	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,02	0,01	0,01	
CS	0,64	0,50	0,41	0,87	0,67	0,49	0,97	0,74	0,58	0,86	0,63	0,46	0,70	0,60	0,46	1,01	1,00	0,79	
CK	3,71	3,46	3,37	4,29	3,69	3,33	4,83	3,97	3,56	4,50	3,68	3,25	3,79	3,79	3,45	4,97	4,81	4,37	
VIÉS	-0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,00	
VRA	0,04	0,00	0,00	0,08	0,04	0,04	0,01	0,05	0,04	0,05	0,02	0,03	0,07	0,04	0,05	0,08	0,13	0,16	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,92	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,02	0,02	0,01	0,01	

Fonte: O autor (2016).

**Tabela 4.12** Estatísticas para as observações de  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10.000$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,48	0,50	0,48	1,05	1,04	1,05	0,57	0,58	0,58	0,10	0,09	0,11	-0,38	-0,37	-0,37	-0,86	-0,86	-0,85
DP	0,29	0,24	0,18	0,19	0,15	0,12	0,17	0,14	0,11	0,18	0,15	0,11	0,16	0,12	0,23	0,19	0,15	0,15
CS	0,05	-0,02	-0,06	-0,14	-0,16	-0,10	-0,18	-0,12	-0,09	-0,20	-0,12	-0,06	-0,20	-0,15	-0,06	-0,18	-0,18	-0,07
CK	3,05	2,87	3,12	3,08	3,16	3,10	3,08	3,05	3,06	2,99	3,03	3,03	3,03	3,06	3,01	3,09	3,09	3,09
VIÉS	-0,02	0,00	-0,03	0,20	0,20	0,21	-0,34	-0,34	-0,33	-0,04	-0,05	-0,04	0,38	0,38	0,39	0,11	0,10	0,11
VRA	0,04	0,01	0,05	0,24	0,24	0,25	0,37	0,38	0,36	0,30	0,34	0,25	0,50	0,50	0,51	0,11	0,12	0,12
EQM	0,08	0,06	0,03	0,08	0,06	0,06	0,14	0,14	0,12	0,03	0,02	0,01	0,18	0,17	0,17	0,06	0,05	0,03
REQM	0,29	0,24	0,18	0,28	0,25	0,24	0,38	0,37	0,35	0,18	0,15	0,12	0,43	0,41	0,41	0,25	0,22	0,18

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,09	0,06	0,03	0,04	0,02	0,01	0,03	0,02	0,01	0,03	0,01	0,04	0,03	0,02	0,03	0,02	0,04	0,02	
DP	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	
CS	0,35	0,33	0,29	0,40	0,40	0,30	0,43	0,40	0,30	0,43	0,39	0,29	0,45	0,43	0,31	0,50	0,49	0,35	
CK	3,20	3,31	3,13	3,33	3,58	3,22	3,36	3,54	3,22	3,30	3,46	3,18	3,26	3,50	3,16	3,34	3,60	3,17	
VIÉS	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,01	0,00	0,00	0,00	
VRA	0,04	0,01	0,01	0,05	0,03	0,04	0,03	0,00	0,01	0,04	0,02	0,02	0,07	0,05	0,06	0,10	0,09	0,09	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,01	0,01	0,00	

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,09	0,07	0,04	0,04	0,03	0,02	0,04	0,03	0,01	0,04	0,03	0,01	0,04	0,03	0,02	0,05	0,04	0,02	
DP	0,92	0,01	0,01	0,91	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,00	
CS	0,60	0,48	0,39	0,89	0,68	0,51	0,93	0,69	0,52	0,90	0,68	0,48	0,73	0,62	0,41	0,70	0,61	0,46	
CK	3,65	3,36	3,32	4,43	3,73	3,34	4,62	3,73	3,40	4,53	3,74	3,36	3,93	3,75	3,21	3,74	3,80	3,38	
VIÉS	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,01	0,00	0,00	-0,01	0,00	0,00	
VRA	0,02	0,11	0,07	0,02	0,01	0,03	0,08	0,07	0,04	0,05	0,05	0,10	0,03	0,17	0,11	0,12	0,11	0,12	
EQM	0,00	0,00	0,00	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,02	0,01	0,01	0,00	

Fonte: O autor (2016).

**Tabela 4.13** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 0, 01$ .

STAT.	n	$\hat{\beta}$	$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$			
			20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,52	0,50	0,50	0,82	0,83	0,84	0,89	0,90	0,91	0,11	0,13	0,13	-0,81	-0,78	-0,77	-1,03	-1,00	-0,98
DP	0,34	0,27	0,20	0,23	0,18	0,14	0,23	0,18	0,13	0,26	0,20	0,15	0,36	0,28	0,21	0,39	0,31	0,23
CS	0,02	0,02	-0,02	-0,22	-0,16	-0,10	-0,22	-0,18	-0,10	-0,23	-0,21	-0,13	-0,53	-0,41	-0,26	-0,59	-0,53	-0,36
CK	2,98	3,09	2,93	3,02	3,11	2,88	3,14	3,06	3,02	3,26	3,19	2,90	3,81	3,46	3,18	3,57	4,52	3,36
VIÉS	0,02	0,00	0,00	-0,02	-0,01	0,00	-0,02	-0,01	0,00	-0,03	-0,01	-0,01	-0,05	-0,02	-0,01	-0,07	-0,04	-0,02
VRA	0,03	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,01	0,22	0,08	0,06	0,07	0,03	0,02	0,07	0,04	0,03
EQM	0,12	0,07	0,04	0,05	0,03	0,02	0,05	0,03	0,02	0,07	0,04	0,02	0,13	0,08	0,05	0,16	0,10	0,05
REQM	0,34	0,27	0,20	0,23	0,18	0,14	0,23	0,18	0,13	0,26	0,20	0,15	0,37	0,28	0,21	0,39	0,31	0,23

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$	$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$			
			20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,09	0,06	0,03	0,05	0,03	0,02	0,04	0,03	0,02	0,06	0,04	0,02	0,11	0,07	0,04	0,14	0,09	0,05
DP	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,01	0,00	0,03	0,02	0,01	0,05	0,03	0,01
CS	0,53	0,48	0,31	0,61	0,48	0,35	0,59	0,48	0,37	0,89	0,73	0,47	2,67	1,59	0,95	2,37	8,42	1,37
CK	3,54	3,39	3,11	3,69	3,43	3,13	3,71	3,35	3,24	4,85	4,19	3,31	18,83	8,44	5,12	13,19	246,86	7,96
VIÉS	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,01	0,01	0,00	0,00
VRA	0,07	0,12	0,14	0,03	0,04	0,05	0,02	0,04	0,05	0,01	0,02	0,02	0,06	0,03	0,02	0,10	0,06	0,03
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,01	0,01	0,01	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,01	0,00	0,04	0,02	0,01	0,05	0,03	0,01

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$	$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$			
			20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,11	0,07	0,04	0,06	0,04	0,02	0,06	0,04	0,02	0,07	0,04	0,02	0,11	0,07	0,04	0,13	0,08	0,05
DP	0,03	0,01	0,01	0,02	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,01	0,04	0,02	0,01	0,05	0,03	0,01
CS	0,86	0,66	0,52	1,09	0,79	0,68	1,06	0,89	0,69	0,95	0,75	0,56	1,90	1,27	0,92	1,89	4,98	1,26
CK	4,39	3,83	3,49	4,88	3,99	3,93	4,97	4,33	3,83	4,42	3,99	3,51	11,42	6,40	5,05	9,30	94,93	6,31
VIÉS	0,02	0,01	0,01	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,01	0,00
VRA	0,28	0,25	0,27	0,14	0,13	0,14	0,12	0,13	0,12	0,12	0,10	0,09	0,18	0,12	0,10	0,24	0,17	0,13
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,04	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,04	0,02	0,01	0,05	0,03	0,01

Fonte: O autor (2016).

**Tabela 4.14** Estatísticas para as observações de  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10$ .

STAT.	$\hat{\beta}$	$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	
MED	0,51	0,50	0,50	0,91	0,91	0,89	0,74	0,77	0,80	0,18	0,19	0,18	-0,52	-0,53	-0,56	-1,13	-1,12
DP	0,33	0,27	0,20	0,17	0,13	0,22	0,17	0,13	0,23	0,18	0,13	0,25	0,20	0,15	0,34	0,29	0,22
CS	0,02	0,02	-0,02	-0,21	-0,16	-0,10	-0,20	-0,17	-0,11	-0,18	-0,16	-0,11	-0,24	-0,18	-0,12	-0,32	-0,24
CK	2,98	3,09	2,93	3,03	3,12	2,89	3,13	3,08	3,01	3,15	3,05	2,95	3,16	2,98	2,92	3,14	3,03
VIÉS	0,01	0,00	0,00	0,07	0,07	0,05	-0,17	-0,14	-0,11	0,04	0,05	0,04	0,24	0,23	0,19	-0,19	-0,17
VRA	0,01	0,00	0,01	0,09	0,08	0,05	0,19	0,15	0,12	0,30	0,38	0,30	0,32	0,31	0,26	0,20	0,18
EQM	0,11	0,07	0,04	0,05	0,03	0,02	0,08	0,05	0,03	0,05	0,04	0,02	0,12	0,10	0,06	0,15	0,11
REQM	0,33	0,27	0,20	0,23	0,19	0,14	0,28	0,22	0,17	0,23	0,19	0,14	0,35	0,31	0,25	0,39	0,27

STAT.	$\widehat{\text{Var}}_N(\hat{\beta})$	$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50		
MED	0,09	0,06	0,03	0,04	0,03	0,02	0,03	0,02	0,01	0,04	0,03	0,02	0,05	0,03	0,02	0,09	0,07	0,04
DP	0,01	0,01	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,02	0,01	0,01
CS	0,51	0,48	0,31	0,59	0,47	0,34	0,62	0,48	0,37	0,63	0,48	0,35	0,76	0,61	0,47	0,73	0,61	0,56
CK	3,50	3,40	3,11	3,70	3,40	3,14	3,84	3,38	3,21	3,87	3,36	3,19	4,14	3,57	3,44	3,94	3,53	3,64
VIÉS	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,01	-0,01	-0,01	-0,01	-0,01	0,00
VRA	0,05	0,12	0,14	0,01	0,02	0,03	0,08	0,04	0,03	0,17	0,14	0,14	0,22	0,21	0,23	0,12	0,09	0,06
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,01	0,01	0,01	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,01	0,00	0,02	0,01	0,01	0,01	0,01

STAT.	$\widehat{\text{Var}}_R(\hat{\beta})$	$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50		
MED	0,11	0,07	0,04	0,05	0,03	0,02	0,05	0,03	0,02	0,05	0,04	0,02	0,06	0,04	0,03	0,10	0,07	0,05
DP	0,93	0,01	0,02	0,01	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,03	0,02	0,01
CS	0,84	0,65	0,51	1,08	0,81	0,68	1,03	0,84	0,67	0,98	0,76	0,58	0,99	0,79	0,63	1,03	1,05	0,88
CK	4,32	3,80	3,46	4,85	4,03	3,94	4,79	4,16	3,74	4,65	3,97	3,44	4,82	4,01	3,73	4,78	5,40	4,66
VIÉS	0,02	0,02	0,01	0,00	0,00	0,00	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,01
VRA	0,27	0,29	0,29	0,10	0,12	0,12	0,18	0,19	0,18	0,09	0,08	0,06	0,06	0,05	0,03	0,15	0,18	0,20
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,04	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,03	0,02	0,01

Fonte: O autor (2016).

**Tabela 4.15** Estatísticas para as observações de  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10.000$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,49	0,50	0,47	1,04	1,04	1,05	0,56	0,57	0,58	0,09	0,10	-0,39	-0,38	-0,37	-0,87	-0,86	-0,85	
DP	0,32	0,26	0,19	0,21	0,17	0,13	0,21	0,17	0,12	0,22	0,18	0,13	0,24	0,19	0,14	0,27	0,22	0,16
CS	0,02	0,01	-0,02	-0,21	-0,17	-0,10	-0,21	-0,17	-0,11	-0,22	-0,17	-0,12	-0,23	-0,17	-0,12	-0,24	-0,17	-0,13
CK	2,98	3,09	2,93	3,07	3,13	2,93	3,12	3,09	2,94	3,15	3,02	2,96	3,15	2,97	2,97	3,14	2,96	2,97
VIÉS	-0,01	-0,01	-0,03	0,19	0,20	0,21	-0,35	-0,34	-0,33	-0,06	-0,05	-0,04	0,37	0,38	0,39	0,09	0,10	0,11
VRA	0,01	0,01	0,05	0,23	0,24	0,25	0,38	0,38	0,36	0,40	0,34	0,26	0,48	0,50	0,51	0,10	0,11	0,12
EQM	0,10	0,07	0,04	0,08	0,07	0,06	0,16	0,14	0,13	0,05	0,03	0,02	0,19	0,18	0,17	0,08	0,06	0,04
REQM	0,32	0,26	0,19	0,29	0,26	0,24	0,41	0,38	0,35	0,22	0,18	0,14	0,44	0,42	0,41	0,29	0,24	0,20

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$		$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,09	0,06	0,03	0,04	0,02	0,01	0,03	0,02	0,01	0,03	0,02	0,01	0,04	0,03	0,02	0,06	0,04	0,02
DP	0,01	0,01	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,01	0,01	0,01	0,00
CS	0,51	0,48	0,31	0,60	0,48	0,36	0,63	0,49	0,37	0,64	0,49	0,37	0,67	0,51	0,38	0,71	0,54	0,39
CK	3,49	3,40	3,10	3,77	3,39	3,19	3,87	3,40	3,20	3,92	3,37	3,22	3,96	3,38	3,25	4,03	3,42	3,27
VIÉS	0,00	0,01	0,00	0,00	0,00	0,00	-0,01	0,00	0,00	-0,01	-0,01	0,00	-0,01	-0,01	-0,02	-0,01	-0,01	-0,01
VRA	0,02	0,11	0,13	0,02	0,03	0,04	0,15	0,11	0,11	0,23	0,20	0,21	0,26	0,23	0,24	0,24	0,23	0,24
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,01	0,00	0,02	0,01	0,01	0,02	0,01	0,01

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$		$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,11	0,08	0,04	0,05	0,03	0,02	0,05	0,03	0,02	0,05	0,04	0,02	0,06	0,04	0,02	0,07	0,05	0,03
DP	0,93	0,02	0,01	0,92	0,01	0,00	0,92	0,01	0,00	0,92	0,01	0,00	0,92	0,01	0,00	0,92	0,01	0,01
CS	0,83	0,61	0,47	1,06	0,81	0,66	1,05	0,80	0,65	1,03	0,79	0,63	1,02	0,78	0,60	1,03	0,81	0,59
CK	4,32	3,72	3,37	4,86	4,04	3,81	4,84	4,04	3,74	4,88	4,03	3,66	5,01	4,03	3,56	5,24	4,13	3,54
VIÉS	0,02	0,02	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,00	0,00	0,00	0,00	0,00	-0,01	0,00	0,00
VRA	0,28	0,40	0,14	0,21	0,15	0,21	0,21	0,15	0,22	0,10	0,16	0,16	0,03	0,07	0,06	0,04	0,02	0,03
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,04	0,03	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01

Fonte: O autor (2016).

**Tabela 4.16** Estatísticas para as observações de  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 0, 01$ .

STAT.	$\hat{\beta}$	n		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,51	0,50	0,50	0,83	0,83	0,84	0,89	0,90	0,91	0,12	0,13	0,14	-0,81	-0,78	-0,77	-1,03	-0,99	-0,98
DP	0,32	0,25	0,19	0,22	0,18	0,14	0,22	0,17	0,13	0,25	0,20	0,15	0,36	0,28	0,21	0,39	0,31	0,23
CS	0,01	-0,04	0,04	-0,28	-0,08	-0,12	-0,21	-0,11	-0,12	-0,23	-0,16	-0,21	-0,45	-0,33	-0,30	-1,08	-0,49	-0,28
CK	3,10	2,91	2,88	3,22	2,92	3,09	2,92	2,92	3,16	3,05	3,18	3,73	3,37	3,26	9,60	3,71	3,06	
VIÉS	0,01	0,00	0,00	-0,02	-0,01	0,00	-0,02	-0,01	0,00	-0,02	-0,01	-0,05	-0,03	-0,01	-0,07	-0,03	-0,02	
VRA	0,02	0,00	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,16	0,10	0,04	0,07	0,03	0,01	0,08	0,04	0,02
EQM	0,10	0,06	0,04	0,05	0,03	0,02	0,05	0,03	0,02	0,06	0,04	0,02	0,13	0,08	0,05	0,16	0,10	0,05
REQM	0,32	0,25	0,19	0,22	0,18	0,14	0,22	0,17	0,13	0,25	0,20	0,15	0,36	0,28	0,21	0,40	0,31	0,23

STAT.	n		$\widehat{\text{Var}}_N(\hat{\beta})$			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50		
MED	0,09	0,06	0,03	0,05	0,03	0,02	0,04	0,03	0,02	0,06	0,04	0,02	0,11	0,07	0,04	0,14	0,09	0,05		
DP	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,03	0,02	0,01	0,18	0,02	0,01		
CS	0,48	0,32	0,30	0,60	0,32	0,34	0,56	0,36	0,33	0,86	0,56	0,61	3,25	1,41	0,98	61,78	2,17	1,10		
CK	3,43	3,16	3,16	3,67	3,15	3,15	3,60	3,16	3,18	4,91	3,52	3,84	39,39	7,13	4,84	4166,66	13,86	5,42		
VIÉS	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,02	0,01	0,00		
VRA	0,04	0,09	0,09	0,02	0,04	0,04	0,01	0,03	0,03	0,01	0,02	0,01	0,06	0,04	0,02	0,14	0,07	0,04		
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,00	0,00		
REQM	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,03	0,02	0,01	0,18	0,03	0,01		

STAT.	n		$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50		
MED	0,10	0,07	0,04	0,05	0,03	0,02	0,05	0,03	0,02	0,06	0,04	0,02	0,10	0,07	0,04	0,12	0,08	0,05		
DP	0,03	0,01	0,01	0,02	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,04	0,02	0,01	0,05	0,03	0,01		
CS	0,82	0,53	0,43	1,11	0,66	0,55	1,08	0,80	0,58	0,94	0,77	0,53	2,24	1,36	0,98	3,35	2,01	1,31		
CK	4,37	3,35	3,35	5,58	3,56	3,55	5,25	4,01	3,43	5,04	3,95	3,49	17,45	7,08	4,79	29,59	12,23	6,74		
VIÉS	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00		
VRA	0,11	0,14	0,15	0,06	0,07	0,08	0,05	0,06	0,07	0,05	0,06	0,05	0,13	0,10	0,07	0,23	0,15	0,09		
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00		
REQM	0,03	0,01	0,01	0,02	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,04	0,02	0,01	0,05	0,03	0,01		

Fonte: O autor (2016).

**Tabela 4.17** Estatísticas para as observações de  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 10$ .

STAT.	n	$\hat{f}(1)$					$\hat{f}(2)$					$\hat{f}(3)$					$\hat{f}(4)$					$\hat{f}(5)$									
		$\hat{\beta}$	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50					
MED	20	0,50	0,50	0,92	0,91	0,89	0,74	0,77	0,81	0,19	0,19	0,19	0,19	0,19	0,19	0,19	0,19	0,19	0,19	0,53	-0,51	-0,56	-1,13	-1,13	-1,11						
DP	20	0,32	0,25	0,19	0,21	0,17	0,13	0,21	0,17	0,13	0,21	0,18	0,13	0,24	0,20	0,20	0,20	0,15	0,34	0,34	0,29	0,29	0,23	0,23	0,23	0,23					
CS	20	0,01	-0,04	0,04	-0,27	-0,07	-0,11	-0,22	-0,10	-0,11	-0,15	-0,09	-0,15	-0,16	-0,13	-0,13	-0,15	-0,28	-0,28	-0,29	-0,29	-0,29	-0,29	-0,29	-0,29						
CK	20	3,10	2,91	2,88	3,21	2,93	2,92	3,08	2,95	2,92	3,04	2,96	3,04	3,03	3,03	3,03	3,07	2,99	3,07	3,28	3,28	2,99	2,99	2,99	2,99						
VIÉS	20	0,00	-0,01	0,01	0,08	0,06	0,05	-0,17	-0,14	-0,10	0,05	0,05	0,04	0,25	0,23	0,23	0,20	-0,19	-0,17	-0,17	-0,15	-0,15	-0,15	-0,15	-0,15						
VRA	20	0,00	0,01	0,01	0,09	0,08	0,05	0,19	0,15	0,11	0,34	0,36	0,31	0,33	0,31	0,31	0,26	0,20	0,18	0,18	0,16	0,16	0,16	0,16	0,16						
EQM	20	0,10	0,06	0,04	0,05	0,03	0,02	0,07	0,05	0,03	0,05	0,03	0,02	0,12	0,09	0,09	0,06	0,15	0,11	0,07	0,07	0,07	0,07	0,07	0,07						
REQM	20	0,32	0,25	0,19	0,23	0,18	0,14	0,27	0,22	0,16	0,22	0,18	0,14	0,34	0,31	0,31	0,25	0,39	0,34	0,27	0,27	0,27	0,27	0,27	0,27						
STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$					$\widehat{\text{Var}}_N(\hat{f}(1))$					$\widehat{\text{Var}}_N(\hat{f}(2))$					$\widehat{\text{Var}}_N(\hat{f}(3))$					$\widehat{\text{Var}}_N(\hat{f}(4))$					$\widehat{\text{Var}}_N(\hat{f}(5))$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50						
MED	20	0,09	0,06	0,03	0,04	0,03	0,03	0,02	0,03	0,02	0,01	0,04	0,03	0,02	0,05	0,03	0,02	0,05	0,03	0,02	0,09	0,07	0,04	0,04	0,04	0,04					
DP	20	0,01	0,01	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01					
CS	20	0,47	0,32	0,31	0,56	0,31	0,32	0,56	0,32	0,33	0,53	0,32	0,34	0,61	0,56	0,65	0,65	0,70	0,70	0,56	0,56	0,56	0,56	0,56	0,56						
CK	20	3,42	3,15	3,16	3,56	3,13	3,11	3,54	3,14	3,15	3,46	3,12	3,23	3,55	3,68	3,43	3,62	3,98	3,98	3,98	3,98	3,98	3,98	3,98	3,98						
VIÉS	20	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01						
VRA	20	0,02	0,09	0,09	0,05	0,01	0,01	0,08	0,04	0,05	0,13	0,11	0,13	0,13	0,18	0,16	0,16	0,19	0,19	0,19	0,11	0,11	0,08	0,08	0,06						
EQM	20	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00						
REQM	20	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,02	0,01	0,01	0,01	0,01						
STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$					$\widehat{\text{Var}}_R(\hat{f}(1))$					$\widehat{\text{Var}}_R(\hat{f}(2))$					$\widehat{\text{Var}}_R(\hat{f}(3))$					$\widehat{\text{Var}}_R(\hat{f}(4))$					$\widehat{\text{Var}}_R(\hat{f}(5))$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50						
MED	20	0,10	0,07	0,04	0,05	0,03	0,02	0,05	0,03	0,02	0,05	0,03	0,02	0,06	0,04	0,06	0,04	0,06	0,04	0,06	0,04	0,10	0,07	0,05	0,05	0,05					
DP	20	0,93	0,91	0,91	0,02	0,01	0,01	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,03	0,02	0,01	0,01	0,01					
CS	20	0,81	0,53	0,42	1,12	0,68	0,56	1,10	0,78	0,58	0,97	0,78	0,52	0,88	0,76	0,71	0,71	1,18	1,18	1,12	1,12	0,95	0,95	0,95	0,95						
CK	20	4,37	3,34	3,31	5,72	3,63	3,52	5,66	3,95	3,42	4,98	4,00	3,37	4,53	4,31	4,06	4,06	6,09	6,09	5,94	5,94	4,93	4,93	4,93	4,93						
VIÉS	20	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,01	0,01	0,01						
VRA	20	0,11	0,17	0,17	0,00	0,05	0,05	0,09	0,13	0,11	0,03	0,05	0,05	0,02	0,01	0,03	0,03	0,00	0,04	0,04	0,14	0,18	0,19	0,19	0,19						
EQM	20	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00						
REQM	20	0,93	0,02	0,01	0,02	0,01	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,03	0,02	0,02	0,02	0,02						

Fonte: O autor (2016).

**Tabela 4.18** Estatísticas para as observações de  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 10.000$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,49	0,49	0,47	1,04	1,04	1,05	0,57	0,58	0,09	0,11	-0,39	-0,38	-0,37	-0,86	-0,86	-0,84	-0,84	-0,84	-0,84
DP	0,31	0,25	0,19	0,21	0,17	0,13	0,19	0,16	0,12	0,20	0,16	0,12	0,22	0,19	0,14	0,26	0,22	0,22	0,16
CS	0,01	-0,04	0,03	-0,27	-0,09	-0,09	-0,23	-0,08	-0,12	-0,18	-0,08	-0,14	-0,16	-0,10	-0,14	-0,16	-0,11	-0,13	-0,13
CK	3,10	2,91	2,88	3,18	2,94	2,90	3,09	2,93	2,92	3,02	2,97	3,04	3,02	3,00	3,09	3,06	3,00	3,06	3,00
VIÉS	-0,01	-0,01	-0,03	0,20	0,20	0,21	-0,34	-0,34	-0,33	-0,05	-0,03	-0,37	0,38	0,39	0,10	0,10	0,12	0,12	
VRA	0,03	0,02	0,05	0,24	0,23	0,25	0,38	0,38	0,36	0,36	0,34	0,24	0,49	0,50	0,51	0,10	0,11	0,12	
EQM	0,09	0,06	0,04	0,08	0,07	0,06	0,16	0,14	0,12	0,04	0,03	0,02	0,19	0,18	0,17	0,08	0,06	0,04	
REQM	0,31	0,25	0,19	0,29	0,26	0,24	0,39	0,38	0,35	0,21	0,17	0,13	0,43	0,42	0,41	0,28	0,24	0,20	

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,09	0,06	0,03	0,04	0,02	0,01	0,03	0,02	0,01	0,03	0,01	0,04	0,03	0,02	0,04	0,02	0,04	0,02	0,02
DP	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00
CS	0,48	0,33	0,31	0,57	0,33	0,32	0,58	0,33	0,34	0,54	0,33	0,35	0,53	0,38	0,37	0,57	0,44	0,44	0,39
CK	3,43	3,15	3,16	3,57	3,14	3,14	3,57	3,15	3,15	3,47	3,15	3,20	3,48	3,22	3,28	3,60	3,32	3,36	3,36
VIÉS	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,01	0,00	0,00	-0,01	-0,01	-0,02	-0,01	-0,01	-0,01
VRA	0,01	0,08	0,08	0,10	0,06	0,08	0,11	0,06	0,07	0,16	0,12	0,14	0,22	0,19	0,21	0,26	0,24	0,26	0,26
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,01	0,02	0,01	0,01	0,01

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,10	0,07	0,04	0,05	0,03	0,02	0,04	0,03	0,02	0,04	0,03	0,02	0,05	0,04	0,02	0,07	0,05	0,03	0,03
DP	0,92	0,01	0,01	0,92	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,00	0,91	0,01	0,00	0,02	0,01	0,01	0,01
CS	0,79	0,49	0,41	1,11	0,71	0,57	1,11	0,72	0,57	1,04	0,73	0,55	0,92	0,73	0,58	0,91	0,78	0,70	0,70
CK	4,35	3,29	3,33	5,71	3,72	3,42	5,83	3,77	3,42	5,33	3,88	3,42	4,63	4,15	3,65	4,64	4,52	4,10	4,10
VIÉS	0,01	0,02	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,01	-0,01	0,00	0,00
VRA	0,13	0,28	0,27	0,02	0,11	0,10	0,07	0,17	0,17	0,04	0,13	0,12	0,04	0,03	0,02	0,11	0,07	0,08	0,08
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,03	0,02	0,01	0,02	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,02	0,01	0,01	0,01

Fonte: O autor (2016).

**Tabela 4.19** Estatísticas para as observações de  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização  $\alpha = 0,01$ .

STAT.	$\hat{\beta}$	n										$\hat{f}(5)$										
		$\hat{f}(1)$					$\hat{f}(2)$					$\hat{f}(3)$					$\hat{f}(4)$					
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,50	0,50	0,49	0,81	0,82	0,83	0,87	0,89	0,90	0,11	0,13	0,13	-0,79	-0,78	-0,76	-0,99	-0,98	-0,97	-0,98	-0,97	-0,98	-0,97
DP	0,41	0,33	0,24	0,31	0,25	0,19	0,31	0,25	0,19	0,30	0,25	0,25	0,17	0,30	0,24	0,19	0,29	0,24	0,18	0,24	0,18	0,18
CS	-0,17	-0,36	-0,76	-0,12	-0,03	-0,05	-0,13	-0,06	-0,01	-0,09	-0,06	-0,04	-0,19	-0,13	-0,04	-0,12	-0,06	-0,06	-0,02	-0,06	-0,02	-0,02
CK	4,50	6,59	14,52	3,10	3,19	3,54	3,14	3,10	3,67	3,14	3,33	3,98	3,24	3,29	3,64	3,23	3,16	3,16	3,58	3,16	3,58	3,58
VIES	0,00	0,00	-0,01	-0,03	-0,02	-0,01	-0,04	-0,02	-0,01	-0,03	-0,02	-0,01	-0,03	-0,02	-0,01	-0,03	-0,02	-0,01	-0,03	-0,02	-0,01	-0,01
VRA	0,01	0,00	0,01	0,04	0,02	0,01	0,04	0,02	0,01	0,04	0,02	0,01	0,12	0,07	0,04	0,03	0,01	0,04	0,02	0,01	0,02	0,01
EQM	0,17	0,11	0,06	0,10	0,06	0,04	0,10	0,06	0,04	0,09	0,06	0,03	0,09	0,06	0,03	0,09	0,06	0,03	0,09	0,06	0,03	0,03
REQM	0,41	0,33	0,24	0,31	0,25	0,19	0,31	0,25	0,19	0,30	0,25	0,17	0,30	0,24	0,19	0,30	0,24	0,18	0,30	0,24	0,18	0,18

STAT.	$\widehat{\text{Var}}_N(\hat{\beta})$	n										$\widehat{\text{Var}}_N(\hat{f}(5))$										
		$\widehat{\text{Var}}_N(\hat{f}(1))$					$\widehat{\text{Var}}_N(\hat{f}(2))$					$\widehat{\text{Var}}_N(\hat{f}(3))$					$\widehat{\text{Var}}_N(\hat{f}(4))$					
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,14	0,10	0,05	0,09	0,06	0,04	0,08	0,06	0,03	0,08	0,06	0,03	0,08	0,06	0,03	0,08	0,06	0,03	0,08	0,05	0,03	0,03
DP	0,03	0,02	0,01	0,02	0,01	0,02	0,01	0,00	0,02	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,00
CS	0,63	0,53	0,40	0,63	0,53	0,40	0,63	0,53	0,40	0,63	0,53	0,40	0,63	0,53	0,40	0,63	0,53	0,40	0,63	0,53	0,40	0,40
CK	3,88	3,88	4,21	3,88	3,88	4,21	3,88	3,88	4,21	3,88	3,88	4,21	3,88	3,88	4,21	3,88	3,88	4,21	3,88	3,88	3,88	4,21
VIES	-0,01	0,00	-0,01	0,00	0,00	-0,01	0,00	-0,01	0,00	0,00	-0,01	0,00	-0,01	0,00	-0,01	0,00	-0,01	0,00	0,00	0,00	0,00	0,00
VRA	0,05	0,04	0,02	0,05	0,05	0,04	0,02	0,05	0,04	0,02	0,05	0,04	0,02	0,05	0,04	0,02	0,05	0,04	0,02	0,05	0,04	0,02
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,03	0,02	0,01	0,02	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,01	0,00	0,01	0,00

STAT.	$\widehat{\text{Var}}_R(\hat{\beta})$	n										$\widehat{\text{Var}}_R(\hat{f}(5))$										
		$\widehat{\text{Var}}_R(\hat{f}(1))$					$\widehat{\text{Var}}_R(\hat{f}(2))$					$\widehat{\text{Var}}_R(\hat{f}(3))$					$\widehat{\text{Var}}_R(\hat{f}(4))$					
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,14	0,10	0,05	0,10	0,07	0,04	0,11	0,08	0,05	0,08	0,06	0,05	0,08	0,06	0,03	0,07	0,05	0,03	0,07	0,05	0,03	0,03
DP	0,04	0,02	0,01	0,04	0,02	0,01	0,04	0,02	0,01	0,03	0,02	0,01	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,01	0,01
CS	2,55	1,56	1,30	1,74	1,53	1,11	2,95	2,18	1,48	1,44	1,41	1,08	1,33	1,10	1,05	1,29	1,29	0,95	1,29	1,29	0,95	0,95
CK	25,28	9,64	12,62	8,22	7,25	5,34	22,55	12,60	7,21	7,54	7,17	5,39	6,69	6,00	5,65	6,08	6,93	6,93	4,62	6,93	4,62	4,62
VIES	-0,01	0,00	-0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,01	0,00	0,00	-0,01	0,00	-0,01	0,00	-0,01	0,00	-0,01	0,00	0,00
VRA	0,01	0,01	0,02	0,01	0,01	0,01	0,06	0,05	0,02	0,00	0,00	0,01	0,01	0,00	0,01	0,00	0,01	0,00	0,01	0,00	0,00	0,00
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,04	0,02	0,01	0,04	0,02	0,01	0,04	0,02	0,01	0,05	0,03	0,01	0,03	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,01

Fonte: O autor (2016).

**Tabela 4.20** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,50	0,48	0,48	0,98	0,95	0,65	0,69	0,73	0,10	0,12	0,13	-0,53	-0,54	-0,57	-1,07	-1,05	-1,03	
DP	0,41	0,33	0,24	0,29	0,23	0,18	0,25	0,20	0,15	0,24	0,20	0,15	0,24	0,19	0,14	0,27	0,22	0,17
CS	-0,17	-0,35	-0,76	-0,07	0,02	0,02	-0,05	0,02	0,11	-0,06	0,02	0,06	-0,07	0,01	0,08	-0,09	-0,03	0,00
CK	4,50	6,54	14,48	3,10	3,66	3,33	3,39	4,49	3,34	3,48	4,78	3,35	3,50	4,89	3,24	3,19	3,70	
VIES	0,00	-0,02	-0,02	0,14	0,11	-0,26	-0,22	-0,18	-0,04	-0,02	-0,01	0,22	0,22	0,19	-0,11	-0,09	-0,08	
VRA	0,00	0,03	0,03	0,17	0,16	0,13	0,28	0,24	0,20	0,28	0,13	0,08	0,30	0,29	0,25	0,12	0,10	0,08
EQM	0,17	0,11	0,06	0,10	0,07	0,04	0,13	0,09	0,06	0,06	0,04	0,02	0,11	0,09	0,06	0,06	0,03	0,03
REQM	0,41	0,33	0,24	0,32	0,27	0,21	0,36	0,30	0,23	0,25	0,20	0,15	0,33	0,29	0,24	0,24	0,19	0,19

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$		$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,15	0,11	0,06	0,08	0,05	0,03	0,06	0,04	0,02	0,06	0,04	0,02	0,05	0,04	0,02	0,07	0,05	0,03
DP	0,03	0,02	0,01	0,02	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,00
CS	0,84	0,71	0,50	0,84	0,71	0,50	0,84	0,71	0,50	0,84	0,71	0,50	0,84	0,71	0,50	0,84	0,71	0,50
CK	4,64	4,60	4,31	4,64	4,60	4,31	4,64	4,60	4,31	4,64	4,60	4,31	4,64	4,60	4,31	4,64	4,60	4,31
VIES	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,03	0,02	0,01	0,02	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$		$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,15	0,11	0,06	0,09	0,06	0,03	0,08	0,06	0,03	0,07	0,05	0,03	0,05	0,04	0,05	0,04	0,07	0,05	0,03
DP	0,05	0,03	0,01	0,03	0,02	0,01	0,04	0,02	0,01	0,02	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,01
CS	3,78	2,40	1,55	2,44	1,80	1,03	3,60	2,51	1,34	3,40	2,12	1,08	2,51	1,66	0,68	1,32	1,24	0,87	
CK	48,59	19,82	15,08	17,42	10,18	5,15	41,10	19,31	6,46	41,43	14,49	5,86	26,57	10,94	3,90	6,83	6,65	4,31	
VIES	0,01	0,01	0,00	-0,01	-0,01	0,00	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
VRA	0,07	0,10	0,06	0,02	0,03	0,06	0,19	0,20	0,17	0,10	0,11	0,06	0,01	0,01	0,03	0,06	0,10	0,09	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,05	0,03	0,01	0,04	0,02	0,01	0,04	0,02	0,01	0,02	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,01	

Fonte: O autor (2016).

**Tabela 4.21** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10.000$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,50	0,49	0,47	1,12	1,13	1,14	0,58	0,60	0,61	0,05	0,06	0,07	-0,49	-0,48	-0,46	-1,03	-1,02	-1,00
DP	0,42	0,33	0,25	0,28	0,22	0,17	0,24	0,20	0,14	0,23	0,18	0,13	0,23	0,19	0,14	0,26	0,21	0,16
CS	-0,17	-0,34	-0,71	-0,03	0,03	0,09	-0,04	0,03	0,13	-0,04	0,04	0,14	-0,05	0,02	0,10	-0,08	-0,02	0,04
CK	4,45	6,34	13,82	3,23	3,25	3,88	3,35	3,45	4,62	3,42	3,60	5,24	3,38	3,50	4,97	3,29	3,27	4,17
VIÉS	0,00	-0,02	-0,04	0,28	0,29	0,30	-0,33	-0,31	-0,30	-0,10	-0,08	-0,07	0,26	0,28	0,29	-0,07	-0,06	-0,04
VRA	0,01	0,03	0,07	0,33	0,35	0,36	0,34	0,33	0,33	0,68	0,58	0,48	0,35	0,37	0,39	0,07	0,06	0,04
EQM	0,17	0,11	0,06	0,16	0,14	0,12	0,17	0,14	0,11	0,06	0,04	0,02	0,12	0,11	0,11	0,07	0,05	0,03
REQM	0,42	0,33	0,25	0,39	0,37	0,35	0,41	0,37	0,33	0,25	0,20	0,15	0,35	0,34	0,32	0,27	0,22	0,16

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$		$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,16	0,11	0,06	0,08	0,05	0,03	0,06	0,04	0,02	0,05	0,04	0,02	0,05	0,04	0,02	0,07	0,05	0,03
DP	0,03	0,02	0,01	0,02	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,00
CS	0,98	0,88	0,68	0,98	0,88	0,68	0,98	0,88	0,68	0,98	0,88	0,68	0,98	0,88	0,68	0,98	0,88	0,68
CK	5,26	5,31	4,54	5,26	5,31	4,54	5,26	5,31	4,54	5,26	5,31	4,54	5,26	5,31	4,54	5,26	5,31	4,54
VIÉS	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00
VRA	0,07	0,08	0,09	0,07	0,08	0,09	0,07	0,08	0,07	0,08	0,07	0,08	0,07	0,08	0,09	0,07	0,08	0,09
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,04	0,02	0,01	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,02	0,01	0,00

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$		$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,16	0,12	0,06	0,09	0,07	0,04	0,07	0,05	0,03	0,06	0,04	0,02	0,06	0,04	0,02	0,06	0,05	0,03
DP	0,95	0,03	0,01	0,04	0,02	0,01	0,03	0,02	0,01	0,02	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,00
CS	4,48	2,62	1,57	3,85	2,54	1,34	3,99	2,56	1,29	3,92	2,47	1,16	3,36	2,14	0,90	1,91	1,42	0,63
CK	68,92	22,67	11,83	48,30	19,80	6,54	52,77	20,41	6,26	53,81	19,86	5,65	44,90	16,62	4,62	18,31	9,13	3,72
VIÉS	0,01	0,02	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,13	0,20	0,17	0,12	0,15	0,11	0,13	0,18	0,14	0,12	0,18	0,14	0,08	0,15	0,11	0,02	0,09	0,06
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,95	0,04	0,01	0,04	0,03	0,01	0,03	0,02	0,01	0,02	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,00

Fonte: O autor (2016).

**Tabela 4.22** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 0, 01$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,50	0,50	0,50	0,83	0,83	0,83	0,89	0,90	0,90	0,13	0,13	0,14	-0,76	-0,76	-0,97	-0,96	-0,96	-0,96
DP	0,24	0,20	0,15	0,20	0,16	0,12	0,20	0,16	0,12	0,18	0,14	0,10	0,16	0,13	0,10	0,16	0,13	0,10
CS	-0,03	-0,05	0,03	-0,04	0,01	-0,05	-0,02	0,02	-0,02	-0,02	0,00	0,00	-0,03	0,02	0,00	-0,03	0,02	-0,02
CK	2,85	3,02	2,90	2,94	2,99	2,88	2,99	2,95	2,97	2,95	2,92	3,02	2,90	3,04	2,97	2,96	2,98	3,04
VIÉS	0,00	0,00	-0,01	-0,01	-0,01	-0,01	-0,02	-0,01	-0,01	-0,01	-0,01	-0,01	0,00	0,00	-0,01	0,00	0,00	0,00
VRA	0,00	0,01	0,00	0,02	0,01	0,01	0,02	0,01	0,01	0,09	0,05	0,04	0,01	0,00	0,01	0,01	0,00	0,00
EQM	0,06	0,04	0,02	0,04	0,03	0,02	0,04	0,03	0,02	0,03	0,02	0,01	0,03	0,02	0,01	0,02	0,01	0,01
REQM	0,24	0,20	0,15	0,20	0,16	0,12	0,20	0,16	0,12	0,18	0,14	0,10	0,16	0,13	0,10	0,16	0,13	0,10

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,05	0,04	0,02	0,03	0,02	0,01	0,03	0,02	0,01	0,03	0,02	0,01	0,03	0,02	0,01	0,03	0,02	0,01	
DP	0,01	0,01	0,00	0,01	0,00	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,01	0,00	0,01	0,00	0,00	0,00	
CS	0,64	0,59	0,62	0,64	0,59	0,62	0,64	0,59	0,62	0,64	0,59	0,62	0,64	0,59	0,62	0,59	0,62	0,62	
CK	3,75	3,88	4,03	3,75	3,88	4,03	3,75	3,88	4,03	3,75	3,88	4,03	3,75	3,88	4,03	3,75	3,88	4,03	
VIÉS	-0,09	-0,06	-0,03	-0,06	-0,04	-0,02	-0,06	-0,04	-0,02	-0,06	-0,04	-0,02	-0,06	-0,04	-0,02	-0,05	-0,03	-0,02	
VRA	0,64	0,62	0,60	0,65	0,64	0,63	0,65	0,64	0,63	0,65	0,64	0,63	0,65	0,64	0,63	0,65	0,64	0,63	
EQM	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,09	0,06	0,03	0,06	0,04	0,02	0,06	0,04	0,02	0,06	0,04	0,02	0,06	0,04	0,02	0,05	0,03	0,02	

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,06	0,04	0,02	0,05	0,03	0,02	0,05	0,04	0,02	0,03	0,02	0,01	0,03	0,02	0,01	0,02	0,02	0,01	
DP	0,91	0,91	0,90	0,92	0,91	0,90	0,92	0,90	0,91	0,91	0,90	0,91	0,91	0,90	0,91	0,90	0,90	0,90	
CS	0,86	0,78	0,71	1,28	1,16	1,01	1,47	1,21	1,11	1,15	0,99	0,91	0,82	0,73	0,65	0,83	0,79	0,64	
CK	4,18	4,35	4,15	5,57	5,72	4,91	6,85	5,52	5,33	5,70	5,18	4,70	4,65	4,19	4,00	4,32	4,32	3,90	
VIÉS	-0,01	-0,01	0,00	-0,01	0,00	0,00	-0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
VRA	0,08	0,09	0,05	0,05	0,05	0,05	0,03	0,04	0,02	0,07	0,06	0,02	0,07	0,07	0,03	0,07	0,07	0,03	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,92	0,91	0,90	0,92	0,91	0,90	0,92	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	

Fonte: O autor (2016).

**Tabela 4.23** Estatísticas para as observações de  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,50	0,48	0,49	1,00	0,98	0,95	0,67	0,70	0,73	0,12	0,13	0,13	-0,52	-0,53	-0,57	-1,04	-1,04	-1,03
DP	0,25	0,21	0,15	0,18	0,15	0,12	0,16	0,13	0,10	0,15	0,12	0,09	0,14	0,12	0,09	0,15	0,13	0,10
CS	-0,03	-0,04	0,03	-0,04	-0,01	-0,05	-0,01	0,03	-0,02	-0,01	0,03	0,00	-0,02	0,02	0,00	-0,03	0,01	-0,01
CK	2,86	2,95	2,90	2,93	2,95	2,87	2,95	2,95	2,93	2,96	3,02	2,98	2,91	2,96	2,93	2,95	3,03	
VIÉS	0,00	-0,02	-0,01	0,16	0,14	0,11	-0,24	-0,21	-0,18	-0,03	-0,01	-0,01	0,24	0,23	0,19	-0,09	-0,08	-0,07
VRA	0,01	0,03	0,02	0,19	0,17	0,13	0,27	0,23	0,20	0,18	0,08	0,07	0,32	0,30	0,25	0,09	0,08	0,08
EQM	0,06	0,04	0,02	0,06	0,04	0,03	0,08	0,06	0,04	0,02	0,01	0,08	0,07	0,04	0,03	0,02	0,02	0,02
REQM	0,25	0,21	0,15	0,24	0,21	0,16	0,29	0,25	0,20	0,15	0,13	0,09	0,28	0,26	0,21	0,18	0,15	0,12

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$		$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,06	0,04	0,02	0,03	0,02	0,01	0,02	0,02	0,01	0,02	0,01	0,02	0,02	0,01	0,02	0,01	0,03	0,02	0,01
DP	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,01	0,00	0,00	0,00	0,00
CS	0,99	0,81	0,70	0,99	0,81	0,70	0,99	0,81	0,70	0,99	0,81	0,70	0,99	0,81	0,70	0,99	0,81	0,70	
CK	5,10	4,69	4,33	5,10	4,68	4,33	5,10	4,68	4,33	5,10	4,68	4,33	5,10	4,68	4,33	5,10	4,68	4,33	
VIÉS	-0,09	-0,06	-0,03	-0,05	-0,03	-0,02	-0,04	-0,03	-0,02	-0,04	-0,03	-0,02	-0,04	-0,03	-0,02	-0,05	-0,03	-0,02	
VRA	0,59	0,57	0,56	0,62	0,61	0,61	0,65	0,65	0,65	0,66	0,65	0,65	0,66	0,65	0,66	0,62	0,61	0,61	
EQM	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,09	0,06	0,03	0,05	0,03	0,02	0,04	0,03	0,02	0,04	0,03	0,02	0,04	0,03	0,02	0,05	0,03	0,02	

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$		$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,06	0,05	0,02	0,04	0,03	0,02	0,04	0,03	0,02	0,03	0,02	0,01	0,02	0,02	0,01	0,02	0,02	0,01
DP	0,92	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,00	0,01	0,00	0,00	0,00
CS	1,27	1,05	0,78	1,27	1,02	0,88	1,61	1,21	0,98	1,40	1,02	0,74	1,04	0,80	0,59	0,85	0,72	0,60
CK	6,26	5,33	4,28	5,66	5,12	4,39	7,83	5,57	4,67	6,88	4,88	3,87	5,25	4,16	3,53	4,44	3,92	3,70
VIÉS	0,00	0,00	-0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,04	0,05	0,06	0,09	0,08	0,11	0,12	0,13	0,05	0,06	0,06	0,02	0,01	0,02	0,01	0,04	0,06	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,02	0,01	0,00	0,02	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,00	0,00	0,01	0,00	0,00	

Fonte: O autor (2016).

**Tabela 4.24** Estatísticas para as observações de  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10.000$ .

n		$\widehat{f}(2)$						$\widehat{f}(3)$						$\widehat{f}(4)$					
		STAT.	$\hat{\beta}$	$\widehat{\text{Var}}_N(\hat{\beta})$	$\widehat{\text{Var}}_R(\hat{\beta})$	$\widehat{\text{Var}}_N(\hat{f}(1))$	$\widehat{\text{Var}}_R(\hat{f}(1))$	$\widehat{\text{Var}}_N(\hat{f}(2))$	$\widehat{\text{Var}}_R(\hat{f}(2))$	$\widehat{\text{Var}}_N(\hat{f}(3))$	$\widehat{\text{Var}}_R(\hat{f}(3))$	$\widehat{\text{Var}}_N(\hat{f}(4))$	$\widehat{\text{Var}}_R(\hat{f}(4))$	$\widehat{\text{Var}}_N(\hat{f}(5))$	$\widehat{\text{Var}}_R(\hat{f}(5))$				
MED	20	0,48	0,47	1,13	1,14	0,59	0,60	0,61	0,06	0,07	0,07	0,48	-0,47	-0,46	-1,02	-1,01	-1,00		
DP	20	0,25	0,21	0,15	0,18	0,14	0,11	0,16	0,13	0,09	0,14	0,12	0,09	0,15	0,13	0,10			
CS	20	-0,03	-0,03	0,03	0,01	-0,04	0,01	-0,04	0,02	-0,02	-0,01	0,02	0,00	-0,01	0,02	0,00	-0,01		
CK	2,88	2,93	2,92	2,97	2,91	2,95	2,91	2,92	2,92	2,94	2,95	2,91	2,96	3,00	2,92	2,98	3,03		
VIÉS	0,00	-0,02	-0,03	0,29	0,29	0,30	-0,30	-0,32	-0,31	-0,30	-0,08	-0,08	-0,07	0,28	0,29	-0,06	-0,05	-0,04	
VRA	0,01	0,03	0,06	0,34	0,35	0,36	0,35	0,34	0,33	0,60	0,53	0,48	0,37	0,38	0,39	0,06	0,05	0,04	
EQM	0,06	0,04	0,02	0,11	0,11	0,10	0,12	0,11	0,10	0,03	0,02	0,01	0,10	0,10	0,09	0,03	0,02	0,01	
REQM	0,25	0,21	0,15	0,34	0,33	0,33	0,35	0,33	0,32	0,17	0,14	0,11	0,31	0,31	0,16	0,14	0,10		
n		STAT.	$\widehat{\text{Var}}_N(\hat{\beta})$	$\widehat{\text{Var}}_R(\hat{\beta})$	$\widehat{\text{Var}}_N(\hat{f}(1))$	$\widehat{\text{Var}}_R(\hat{f}(1))$	$\widehat{\text{Var}}_N(\hat{f}(2))$	$\widehat{\text{Var}}_R(\hat{f}(2))$	$\widehat{\text{Var}}_N(\hat{f}(3))$	$\widehat{\text{Var}}_R(\hat{f}(3))$	$\widehat{\text{Var}}_N(\hat{f}(4))$	$\widehat{\text{Var}}_R(\hat{f}(4))$	$\widehat{\text{Var}}_N(\hat{f}(5))$	$\widehat{\text{Var}}_R(\hat{f}(5))$					
		MED	0,07	0,05	0,03	0,03	0,02	0,01	0,02	0,02	0,01	0,01	0,02	0,02	0,01	0,03	0,02	0,01	
DP	20	0,02	0,01	0,00	0,01	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	
CS	20	1,10	0,93	0,76	1,10	0,93	0,76	1,10	0,93	0,76	1,10	0,93	0,76	1,10	0,93	0,76			
CK	20	5,37	4,96	4,19	5,37	4,96	4,19	5,37	4,96	4,19	5,37	4,96	4,19	5,37	4,96	4,19			
VIÉS	20	-0,08	-0,05	-0,02	-0,04	-0,03	-0,02	-0,04	-0,03	-0,01	-0,04	-0,02	-0,01	-0,04	-0,02	-0,03	-0,01		
VRA	20	0,54	0,52	0,49	0,58	0,57	0,56	0,62	0,61	0,60	0,64	0,62	0,62	0,63	0,61	0,59	0,58	0,57	
EQM	20	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	20	0,08	0,05	0,02	0,05	0,03	0,02	0,04	0,03	0,01	0,04	0,02	0,01	0,04	0,02	0,01	0,03	0,01	

Fonte: O autor (2016).

**Tabela 4.25** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_R(\hat{\xi})$  e  $\widehat{\text{Var}}_N(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 0, 01$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$			
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,50	0,50	0,50	0,83	0,83	0,90	0,90	0,90	0,90	0,90	0,13	0,14	0,14	-0,76	-0,76	-0,98	-0,97	-0,97	-0,97
DP	0,25	0,21	0,15	0,21	0,17	0,13	0,18	0,15	0,12	0,17	0,14	0,14	0,10	0,13	0,10	0,19	0,16	0,12	0,12
CS	-0,03	-0,01	0,03	-0,05	-0,09	-0,01	-0,03	0,00	-0,04	0,04	-0,07	-0,04	-0,02	-0,01	-0,08	-0,06	-0,09	-0,05	-0,05
CK	3,06	3,18	2,91	3,03	3,03	2,88	2,96	2,97	3,00	2,92	3,12	3,00	2,92	3,08	2,99	3,02	2,91	2,91	2,91
VIÉS	0,00	0,00	-0,02	-0,02	-0,01	-0,01	-0,01	-0,01	-0,01	-0,01	0,00	-0,01	0,00	0,00	0,00	-0,02	-0,01	-0,01	-0,01
VRA	0,00	0,01	0,01	0,02	0,01	0,01	0,01	0,01	0,01	0,05	0,03	0,03	0,00	0,00	0,01	0,02	0,01	0,01	0,01
EQM	0,06	0,04	0,02	0,04	0,03	0,02	0,03	0,02	0,01	0,03	0,02	0,01	0,03	0,02	0,01	0,04	0,02	0,02	0,02
REQM	0,25	0,21	0,15	0,21	0,17	0,13	0,18	0,15	0,12	0,17	0,14	0,10	0,16	0,13	0,10	0,19	0,16	0,12	0,12

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,06	0,04	0,02	0,03	0,02	0,01	0,03	0,02	0,01	0,03	0,02	0,01	0,03	0,02	0,01	0,03	0,02	0,01	0,01
DP	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,01	0,00	0,00	0,00
CS	0,65	0,63	0,53	0,65	0,63	0,53	0,65	0,63	0,53	0,65	0,63	0,53	0,65	0,63	0,53	0,63	0,63	0,63	0,53
CK	3,87	3,77	3,61	3,87	3,77	3,61	3,87	3,77	3,61	3,87	3,77	3,61	3,87	3,77	3,61	3,87	3,77	3,61	3,61
VIÉS	-0,09	-0,06	-0,03	-0,06	-0,04	-0,02	-0,06	-0,04	-0,02	-0,05	-0,04	-0,02	-0,05	-0,04	-0,02	-0,05	-0,03	-0,02	-0,02
VRA	0,62	0,60	0,59	0,63	0,62	0,61	0,63	0,62	0,61	0,63	0,62	0,61	0,63	0,62	0,61	0,63	0,62	0,61	0,61
EQM	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,09	0,06	0,03	0,06	0,04	0,02	0,06	0,04	0,02	0,05	0,04	0,02	0,05	0,04	0,02	0,05	0,03	0,02	0,02

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,06	0,04	0,02	0,05	0,03	0,02	0,04	0,03	0,02	0,03	0,02	0,01	0,02	0,02	0,01	0,03	0,02	0,01	0,01
DP	0,91	0,91	0,90	0,92	0,91	0,90	0,92	0,91	0,90	0,91	0,90	0,91	0,90	0,91	0,90	0,91	0,90	0,90	0,90
CS	1,00	0,75	0,57	1,46	1,11	0,97	1,66	1,30	1,04	1,05	1,02	0,85	1,01	0,82	0,61	1,34	1,24	0,95	0,95
CK	5,51	4,02	3,69	7,53	5,09	4,53	8,47	6,11	5,08	5,42	5,22	4,69	5,38	4,85	3,98	6,58	6,15	5,13	5,13
VIÉS	-0,01	-0,01	0,00	-0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
VRA	0,08	0,08	0,05	0,04	0,04	0,01	0,04	0,04	0,02	0,07	0,06	0,03	0,08	0,07	0,04	0,06	0,05	0,03	0,03
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,92	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,01	0,00	0,01	0,00	0,01	0,01	0,01	0,01

Fonte: O autor (2016).

**Tabela 4.26** Estatísticas para as observações de  $\hat{\boldsymbol{\xi}}$ ,  $\widehat{\text{Var}}_R(\hat{\boldsymbol{\xi}})$  e  $\widehat{\text{Var}}_N(\hat{\boldsymbol{\xi}})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 0, 01$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,49	0,48	0,49	1,00	0,98	0,95	0,67	0,70	0,73	0,12	0,13	0,13	-0,52	-0,53	-0,57	-1,04	-1,03	
DP	0,25	0,21	0,15	0,19	0,16	0,12	0,13	0,10	0,14	0,12	0,09	0,14	0,12	0,09	0,18	0,15	0,12	
CS	-0,01	0,00	0,03	-0,04	-0,09	0,00	0,03	-0,04	-0,01	0,03	-0,05	-0,06	-0,01	-0,07	-0,08	-0,05	-0,09	-0,05
CK	3,05	3,15	2,90	3,04	3,00	2,88	2,94	3,00	2,90	3,17	3,07	3,01	3,12	3,01	3,04	2,94	2,93	
VIÉS	-0,01	-0,02	-0,01	0,16	0,14	0,11	-0,24	-0,21	-0,18	-0,02	-0,01	-0,01	0,24	0,23	0,19	-0,09	-0,08	-0,08
VRA	0,01	0,03	0,02	0,19	0,17	0,13	0,26	0,23	0,20	0,15	0,07	0,06	0,32	0,30	0,25	0,10	0,09	0,08
EQM	0,06	0,05	0,02	0,06	0,05	0,03	0,08	0,06	0,04	0,02	0,01	0,08	0,07	0,04	0,04	0,03	0,02	0,02
REQM	0,25	0,21	0,15	0,25	0,21	0,17	0,29	0,25	0,20	0,15	0,12	0,09	0,28	0,26	0,21	0,20	0,17	0,14

STAT.	n	$\widehat{\text{Var}}_N(\hat{\beta})$			$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	
MED	0,06	0,04	0,02	0,03	0,02	0,01	0,02	0,02	0,01	0,02	0,01	0,02	0,01	0,02	0,01	0,03	0,02	0,01	
DP	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	
CS	0,82	0,74	0,57	0,82	0,74	0,57	0,82	0,74	0,57	0,82	0,74	0,57	0,82	0,74	0,57	0,74	0,57	0,57	
CK	4,47	4,13	3,73	4,47	4,13	3,73	4,47	4,13	3,73	4,47	4,13	3,73	4,47	4,13	3,73	4,47	4,13	3,73	
VIÉS	-0,08	-0,05	-0,03	-0,05	-0,03	-0,02	-0,04	-0,03	-0,02	-0,04	-0,03	-0,02	-0,04	-0,03	-0,02	-0,05	-0,03	-0,02	
VRA	0,57	0,56	0,56	0,62	0,61	0,60	0,63	0,63	0,64	0,63	0,62	0,63	0,64	0,63	0,64	0,62	0,61	0,61	
EQM	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,08	0,06	0,03	0,05	0,03	0,02	0,04	0,03	0,02	0,04	0,03	0,02	0,04	0,03	0,02	0,05	0,03	0,02	

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	
MED	0,06	0,05	0,02	0,04	0,03	0,02	0,03	0,01	0,03	0,02	0,01	0,02	0,02	0,01	0,02	0,03	0,02	0,01	
DP	0,92	0,01	0,00	0,91	0,01	0,00	0,91	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,00	
CS	1,25	1,05	0,63	1,37	0,98	0,83	1,77	1,36	0,94	1,68	1,22	0,80	1,09	0,91	0,50	1,29	1,20	0,95	
CK	6,58	5,61	3,80	6,52	4,51	4,12	9,45	6,87	4,68	9,60	6,40	4,42	5,67	4,85	3,48	6,38	5,95	5,20	
VIÉS	0,00	0,00	0,00	-0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
VRA	0,02	0,04	0,05	0,11	0,10	0,10	0,13	0,14	0,06	0,08	0,07	0,02	0,00	0,01	0,00	0,04	0,05	0,05	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,02	0,01	0,00	0,02	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,00	0,01	0,01	0,01	0,00	

Fonte: O autor (2016).

**Tabela 4.27** Estatísticas para as observações de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_R(\hat{\xi})$  e  $\widehat{\text{Var}}_N(\hat{\xi})$  obtidas no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 10.000$ .

STAT.	n	$\hat{\beta}$		$\hat{f}(1)$			$\hat{f}(2)$			$\hat{f}(3)$			$\hat{f}(4)$			$\hat{f}(5)$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30
MED	0,49	0,48	0,47	1,13	1,14	1,14	0,60	0,60	0,61	0,06	0,07	0,07	-0,48	-0,47	-0,46	-1,02	-1,01	-1,00
DP	0,25	0,21	0,15	0,18	0,15	0,11	0,13	0,09	0,14	0,12	0,08	0,14	0,12	0,09	0,17	0,14	0,10	0,10
CS	0,00	0,01	0,04	0,01	-0,07	-0,01	0,02	-0,06	-0,01	0,01	-0,06	-0,05	-0,01	-0,07	-0,02	-0,07	-0,09	-0,07
CK	3,06	3,12	2,89	2,99	2,97	2,95	2,98	3,01	2,98	3,02	3,05	2,98	3,06	3,04	2,96	3,06	3,02	2,95
VIÉS	-0,01	-0,02	-0,03	0,29	0,30	0,30	-0,31	-0,31	-0,30	-0,08	-0,08	-0,07	0,28	0,29	-0,06	-0,05	-0,04	-0,04
VRA	0,01	0,03	0,05	0,34	0,35	0,36	0,35	0,34	0,33	0,59	0,54	0,49	0,37	0,38	0,39	0,06	0,05	0,04
EQM	0,06	0,05	0,02	0,12	0,11	0,10	0,12	0,11	0,10	0,03	0,02	0,01	0,10	0,10	0,09	0,03	0,02	0,01
REQM	0,25	0,21	0,16	0,34	0,33	0,33	0,35	0,33	0,32	0,16	0,14	0,11	0,31	0,31	0,17	0,15	0,11	0,11

STAT.	n	$\widehat{\text{Var}}_N(\hat{f}(1))$			$\widehat{\text{Var}}_N(\hat{f}(2))$			$\widehat{\text{Var}}_N(\hat{f}(3))$			$\widehat{\text{Var}}_N(\hat{f}(4))$			$\widehat{\text{Var}}_N(\hat{f}(5))$				
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50		
MED	0,07	0,05	0,03	0,03	0,02	0,01	0,02	0,02	0,01	0,01	0,02	0,02	0,01	0,02	0,01	0,03	0,02	0,01
DP	0,01	0,01	0,00	0,01	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,01	0,00	0,01	0,00	0,00	0,00
CS	0,92	0,86	0,64	0,92	0,86	0,64	0,92	0,86	0,64	0,92	0,86	0,64	0,92	0,86	0,64	0,86	0,86	0,64
CK	4,85	4,77	3,84	4,84	4,78	3,84	4,84	4,78	3,84	4,84	4,78	3,84	4,84	4,78	3,84	4,84	4,78	3,84
VIÉS	-0,08	-0,05	-0,03	-0,05	-0,03	-0,02	-0,04	-0,02	-0,01	-0,03	-0,02	-0,01	-0,03	-0,02	-0,01	-0,04	-0,03	-0,02
VRA	0,54	0,52	0,51	0,60	0,59	0,59	0,60	0,58	0,58	0,60	0,58	0,60	0,58	0,60	0,58	0,61	0,59	0,59
EQM	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
REQM	0,08	0,05	0,03	0,05	0,03	0,02	0,04	0,02	0,01	0,03	0,02	0,01	0,03	0,02	0,01	0,04	0,03	0,02

STAT.	n	$\widehat{\text{Var}}_R(\hat{\beta})$			$\widehat{\text{Var}}_R(\hat{f}(1))$			$\widehat{\text{Var}}_R(\hat{f}(2))$			$\widehat{\text{Var}}_R(\hat{f}(3))$			$\widehat{\text{Var}}_R(\hat{f}(4))$			$\widehat{\text{Var}}_R(\hat{f}(5))$		
		20	30	50	20	30	50	20	30	50	20	30	50	20	30	50	20	30	50
MED	0,07	0,05	0,03	0,04	0,03	0,02	0,03	0,02	0,01	0,03	0,02	0,01	0,02	0,02	0,01	0,03	0,02	0,01	
DP	0,92	0,91	0,90	0,91	0,91	0,90	0,91	0,91	0,90	0,91	0,90	0,91	0,90	0,91	0,90	0,91	0,90	0,90	
CS	1,47	1,34	0,77	1,64	1,32	0,85	1,70	1,37	0,86	1,61	1,33	0,79	1,29	1,15	0,67	1,11	1,06	0,74	
CK	7,91	7,77	4,14	8,38	6,88	4,34	8,92	7,33	4,36	8,54	7,23	4,15	6,68	6,18	3,87	5,57	5,41	4,34	
VIÉS	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
VRA	0,07	0,15	0,17	0,00	0,05	0,06	0,02	0,09	0,10	0,03	0,11	0,13	0,01	0,09	0,10	0,04	0,03	0,03	
EQM	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	
REQM	0,92	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	

Fonte: O autor (2016).

## 4.2 Simulação dos Resíduos

As tabelas 4.28 a 4.54 contêm algumas medidas descritivas dos três tipos de resíduos estudados. Em todos os cenários os resíduos de Person, resíduos “naive” e resíduos “robustos” apresentaram média próxima de zero, contudo esta medida se distancia um pouco deste valor para alguns resíduos sob as distribuições Poisson e gama, como pode ser observado a partir dos valores de MED nas tabelas 4.37 a 4.54. Em geral o desvio-padrão apresentou valor próximo de um para os três resíduos, sob todas as configurações do MPLAG para dados correlacionados utilizado neste estudo, como evidenciado nos valores de DP nas respectivas tabelas.

Considerando a distribuição marginal normal, para os três tipos de resíduos temos que os valores de seus respectivos coeficientes de assimetria CS ficaram próximos de zero, como evidenciado nos valores de CS nas tabelas 4.28 a 4.36. Contudo, para as distribuições Poisson e gama os valores de CS tendem a se distanciar um pouco do 0, como pode ser observado nos valores de CS nas tabelas 4.37 a 4.54. Sendo assim, sob a distribuição normal os três tipos de resíduos apresentam distribuições aproximadamente simétricas, enquanto que sob as distribuições Poisson e gama os resíduos de Pearson, “naive” e “robustos” apresentam distribuições com alguma assimetria.

Sob distribuição normal, os coeficientes de curtose CK apresentaram valores próximos de 3 (valor do coeficiente de curtose da distribuição normal padrão) para os três tipos de resíduos considerados, como pode ser observado nas tabelas 4.28 a 4.36. Sob as distribuições Poisson e gama, alguns valores dos coeficientes de curtose se distanciam um pouco de 3 para os três tipos de resíduos (ver os valores de CK nas tabelas 4.37 a 4.54), sob todas as configurações consideradas para estas respectivas distribuições. Portanto, em geral os três tipos de resíduos apresentam distribuições com algumas características da distribuição marginal considerada para a simulação dos dados e ajustes dos respectivos modelos.

**Tabela 4.28** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização  $\alpha = 0,01$ .

$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5	
MED	$r_P$	0,00	-0,01	0,00	0,00	-0,01	0,01	0,02	0,01	0,00	-0,01
	$r_N$	0,00	-0,01	0,00	-0,01	-0,01	0,01	0,02	0,01	0,01	-0,01
	$r_R$	0,00	-0,01	0,00	0,00	-0,02	0,01	0,02	0,01	0,01	-0,02
	$r_P$	0,99	1,02	0,99	0,95	0,98	0,97	1,01	1,00	1,00	0,99
DP	$r_N$	1,01	1,04	1,02	1,01	1,01	1,00	1,02	1,02	1,02	1,03
	$r_R$	1,06	1,08	1,07	1,06	1,07	1,05	1,07	1,07	1,06	1,08
	$r_P$	0,03	0,11	-0,03	-0,01	0,16	-0,04	-0,02	-0,04	-0,10	0,03
CS	$r_N$	0,02	-0,02	-0,03	-0,03	0,02	-0,02	-0,02	-0,03	-0,06	0,03
	$r_R$	0,01	0,00	-0,04	0,01	0,00	-0,01	-0,04	-0,02	-0,04	0,00
	$r_P$	3,01	4,00	2,90	2,98	4,19	2,98	3,01	3,00	3,02	2,93
CK	$r_N$	2,87	2,90	2,82	2,82	2,90	2,85	2,92	2,91	2,89	2,85
	$r_R$	2,43	2,45	2,43	2,48	2,49	2,45	2,41	2,46	2,39	2,41
$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5	
MED	$r_P$	0,02	-0,02	0,01	-0,01	-0,01	-0,02	0,00	-0,01	0,00	0,00
	$r_N$	0,01	-0,02	0,00	-0,02	-0,01	-0,02	0,00	-0,01	0,00	0,00
	$r_R$	0,01	-0,02	0,00	-0,02	0,00	-0,02	0,00	-0,01	0,00	0,01
	$r_P$	1,00	0,98	0,98	1,00	0,99	0,97	0,92	1,01	0,96	0,98
DP	$r_N$	1,02	1,01	1,00	1,02	1,02	1,01	0,99	1,03	1,00	1,02
	$r_R$	1,07	1,06	1,05	1,08	1,07	1,06	1,05	1,07	1,06	1,07
	$r_P$	0,00	0,00	0,10	0,06	-0,05	0,06	-0,04	0,01	-0,05	-0,04
CS	$r_N$	-0,03	-0,01	0,08	0,03	-0,04	0,05	-0,03	0,02	-0,01	0,00
	$r_R$	-0,04	0,01	0,05	0,02	-0,01	0,04	-0,03	0,01	-0,03	0,04
	$r_P$	3,14	2,91	3,02	3,02	3,14	2,99	2,99	3,07	3,15	3,07
CK	$r_N$	2,90	2,80	2,93	2,84	3,03	2,85	2,89	2,88	2,85	2,88
	$r_R$	2,45	2,42	2,46	2,42	2,51	2,48	2,57	2,41	2,47	2,50
$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5	
MED	$r_P$	-0,03	0,01	-0,01	-0,02	0,00	-0,01	0,01	-0,01	-0,01	-0,01
	$r_N$	-0,03	0,01	-0,01	-0,02	0,00	-0,01	0,01	-0,01	-0,01	-0,01
	$r_R$	-0,04	0,00	-0,01	-0,02	0,00	-0,01	0,01	-0,01	-0,01	-0,01
	$r_P$	0,99	1,00	0,98	0,98	1,00	0,95	0,98	0,97	0,95	0,99
DP	$r_N$	1,03	1,02	1,02	1,00	1,01	0,99	1,00	1,01	1,01	1,01
	$r_R$	1,08	1,06	1,07	1,05	1,07	1,05	1,05	1,06	1,06	1,06
	$r_P$	-0,03	0,04	0,02	0,02	-0,02	0,02	0,03	-0,04	0,03	-0,04
CS	$r_N$	-0,05	0,02	0,01	0,05	-0,03	0,03	0,02	0,02	0,02	-0,04
	$r_R$	-0,02	0,00	0,03	0,04	-0,02	0,01	0,00	-0,01	0,02	0,00
	$r_P$	3,07	3,05	2,98	3,01	3,02	2,94	2,99	3,48	2,95	3,08
CK	$r_N$	2,86	2,87	2,84	2,89	2,85	2,84	2,89	2,85	2,85	2,92
	$r_R$	2,43	2,42	2,42	2,44	2,45	2,45	2,46	2,44	2,48	2,49
$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5	
MED	$r_P$	-0,01	0,02	0,00	0,01	0,01	0,01	-0,01	0,00	0,00	0,01
	$r_N$	0,00	0,02	0,00	0,01	0,01	0,01	-0,01	0,00	0,00	0,01
	$r_R$	0,00	0,02	0,00	0,01	0,01	0,01	-0,01	0,00	0,00	0,02
	$r_P$	0,97	0,99	0,98	0,99	0,95	0,97	0,97	0,96	0,99	1,00
DP	$r_N$	1,00	1,02	1,00	1,01	0,98	1,00	1,00	1,01	1,01	1,01
	$r_R$	1,06	1,07	1,06	1,06	1,04	1,06	1,05	1,07	1,07	1,05
	$r_P$	-0,07	0,06	0,00	0,02	0,00	-0,01	-0,01	-0,01	-0,01	0,00
CS	$r_N$	-0,04	0,03	0,00	0,03	-0,01	-0,02	-0,01	-0,02	-0,02	0,02
	$r_R$	-0,04	0,03	0,01	0,01	0,00	-0,03	-0,01	-0,02	-0,01	0,02
	$r_P$	3,04	3,14	2,83	3,01	3,08	2,99	2,91	3,01	2,99	3,11
CK	$r_N$	2,88	2,86	2,69	2,87	2,88	2,82	2,75	2,84	2,85	2,94
	$r_R$	2,46	2,44	2,37	2,45	2,50	2,46	2,41	2,47	2,42	2,49
$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5	
MED	$r_P$	0,00	-0,01	0,02	0,02	0,02	0,02	0,01	0,00	-0,01	-0,01
	$r_N$	0,00	-0,01	0,03	0,02	0,02	0,02	0,01	0,00	-0,01	-0,01
	$r_R$	0,00	-0,01	0,03	0,02	0,03	0,02	0,01	0,00	-0,01	-0,02
	$r_P$	1,01	0,98	0,96	0,99	0,99	0,97	0,99	0,99	0,99	0,98
DP	$r_N$	1,02	1,00	1,00	1,02	1,02	0,99	1,01	1,01	1,01	1,01
	$r_R$	1,08	1,06	1,06	1,07	1,06	1,05	1,07	1,06	1,07	1,07
	$r_P$	-0,03	-0,02	-0,04	-0,02	-0,03	0,01	0,01	0,00	-0,05	-0,01
CS	$r_N$	0,03	0,00	-0,02	-0,03	-0,04	0,00	-0,04	-0,01	-0,05	0,01
	$r_R$	0,03	0,02	-0,03	-0,04	-0,03	0,01	-0,02	0,00	-0,02	-0,02
	$r_P$	3,38	3,04	3,22	2,96	2,93	2,84	3,06	2,97	3,16	3,11
CK	$r_N$	2,89	2,88	2,88	2,85	2,86	2,69	2,88	2,87	2,89	2,93
	$r_R$	2,45	2,49	2,45	2,44	2,41	2,35	2,42	2,46	2,46	2,52

Fonte: O autor (2016).

**Tabela 4.29** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10$ .

$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5	
MED	$r_P$	-0,18	0,29	0,03	-0,28	0,04	-0,19	0,29	0,04	-0,24	0,10
	$r_N$	-0,19	0,30	0,04	-0,30	0,04	-0,21	0,31	0,05	-0,24	0,11
	$r_R$	-0,21	0,31	0,04	-0,30	0,05	-0,23	0,32	0,05	-0,25	0,12
	$r_P$	0,92	0,97	0,94	0,92	0,90	0,90	0,95	0,95	0,94	0,92
DP	$r_N$	0,97	1,00	0,98	0,97	0,97	0,96	0,98	0,98	0,97	0,99
	$r_R$	1,03	1,01	1,04	1,00	1,04	1,02	0,99	1,04	1,00	1,06
	$r_P$	0,02	0,09	-0,03	-0,01	0,03	-0,04	-0,04	-0,05	-0,08	0,02
	$r_N$	0,03	-0,02	-0,03	-0,01	0,00	-0,01	-0,05	-0,05	-0,03	0,02
CS	$r_R$	0,04	-0,11	-0,05	0,11	-0,01	0,04	-0,14	-0,04	0,05	-0,02
	$r_P$	3,02	3,66	2,96	2,90	3,27	3,01	3,00	2,97	2,99	2,94
	$r_N$	2,89	2,93	2,85	2,81	2,92	2,89	2,93	2,90	2,87	2,86
	$r_R$	2,46	2,55	2,46	2,52	2,52	2,49	2,52	2,50	2,46	2,43
$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5	
MED	$r_P$	-0,16	0,23	0,07	-0,22	0,09	-0,22	0,22	0,05	-0,27	0,05
	$r_N$	-0,18	0,24	0,07	-0,24	0,10	-0,24	0,24	0,05	-0,29	0,06
	$r_R$	-0,20	0,25	0,08	-0,25	0,12	-0,26	0,25	0,06	-0,29	0,07
	$r_P$	0,92	0,92	0,93	0,94	0,92	0,90	0,88	0,95	0,92	0,91
DP	$r_N$	0,98	0,96	0,96	0,98	0,98	0,97	0,95	0,98	0,96	0,98
	$r_R$	1,04	0,99	1,02	1,01	1,05	1,03	0,97	1,03	0,98	1,05
	$r_P$	0,00	-0,02	0,09	0,08	-0,05	0,07	-0,09	0,00	-0,03	-0,04
	$r_N$	-0,02	-0,04	0,07	0,06	-0,05	0,08	-0,08	0,02	0,01	-0,02
CS	$r_R$	-0,01	-0,07	0,02	0,09	-0,04	0,10	-0,13	0,00	0,09	0,03
	$r_P$	3,11	2,89	3,01	3,05	3,15	3,01	3,03	3,01	3,15	3,05
	$r_N$	2,89	2,80	2,91	2,87	3,03	2,88	2,90	2,91	2,91	2,90
	$r_R$	2,46	2,49	2,47	2,51	2,53	2,52	2,67	2,46	2,56	2,54
$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5	
MED	$r_P$	-0,17	0,29	0,01	-0,24	0,08	-0,14	0,27	0,08	-0,20	0,08
	$r_N$	-0,18	0,30	0,01	-0,25	0,09	-0,16	0,28	0,09	-0,22	0,08
	$r_R$	-0,21	0,31	0,01	-0,26	0,10	-0,18	0,29	0,09	-0,23	0,10
	$r_P$	0,92	0,95	0,91	0,92	0,92	0,89	0,94	0,91	0,90	0,92
DP	$r_N$	0,99	0,98	0,96	0,96	0,97	0,95	0,97	0,97	0,97	0,97
	$r_R$	1,05	0,99	1,03	0,99	1,05	1,02	0,98	1,03	1,00	1,04
	$r_P$	-0,05	0,00	0,01	0,01	-0,01	0,02	-0,01	0,03	0,06	-0,06
	$r_N$	-0,03	-0,03	0,00	0,05	-0,03	0,03	-0,02	0,02	0,04	-0,06
CS	$r_R$	0,00	-0,13	0,02	0,10	-0,03	0,02	-0,11	-0,05	0,07	-0,02
	$r_P$	2,95	3,08	2,99	3,01	2,99	2,96	3,01	2,98	3,14	
	$r_N$	2,87	2,90	2,89	2,90	2,87	2,87	2,86	2,83	2,86	2,95
	$r_R$	2,48	2,54	2,50	2,52	2,46	2,47	2,54	2,46	2,56	2,51
$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5	
MED	$r_P$	-0,15	0,33	0,03	-0,22	0,13	-0,18	0,28	0,00	-0,24	0,09
	$r_N$	-0,16	0,34	0,04	-0,22	0,14	-0,20	0,30	0,00	-0,25	0,10
	$r_R$	-0,17	0,35	0,04	-0,24	0,16	-0,22	0,31	0,00	-0,26	0,12
	$r_P$	0,90	0,93	0,93	0,93	0,88	0,90	0,93	0,90	0,94	0,92
DP	$r_N$	0,96	0,97	0,96	0,96	0,94	0,96	0,96	0,97	0,97	0,97
	$r_R$	1,02	0,99	1,03	0,99	1,02	1,02	0,98	1,03	1,00	1,04
	$r_P$	-0,07	0,05	0,02	0,02	-0,01	-0,02	0,00	0,01	0,03	0,02
	$r_N$	-0,03	-0,01	0,02	0,05	-0,02	-0,02	-0,03	-0,01	0,03	0,02
CS	$r_R$	-0,02	-0,09	0,00	0,09	-0,03	0,01	-0,10	-0,01	0,09	0,01
	$r_P$	3,06	3,17	2,90	3,05	2,96	2,98	2,97	2,97	3,07	3,09
	$r_N$	2,89	2,87	2,76	2,91	2,83	2,83	2,81	2,84	2,92	2,94
	$r_R$	2,47	2,56	2,47	2,55	2,50	2,48	2,52	2,54	2,56	2,50
$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5	
MED	$r_P$	-0,15	0,27	0,10	-0,23	0,12	-0,16	0,28	0,05	-0,22	0,05
	$r_N$	-0,16	0,28	0,11	-0,24	0,13	-0,17	0,29	0,05	-0,23	0,05
	$r_R$	-0,18	0,29	0,12	-0,25	0,15	-0,19	0,30	0,05	-0,24	0,06
	$r_P$	0,93	0,92	0,92	0,94	0,92	0,90	0,94	0,93	0,93	0,90
DP	$r_N$	0,98	0,95	0,97	0,98	0,98	0,95	0,97	0,97	0,97	0,97
	$r_R$	1,04	0,97	1,02	1,00	1,05	1,02	0,99	1,02	1,00	1,05
	$r_P$	0,01	-0,02	0,00	0,00	-0,05	0,00	0,00	0,00	-0,04	-0,01
	$r_N$	0,05	-0,02	-0,02	-0,01	-0,05	0,01	-0,06	-0,02	-0,04	0,00
CS	$r_R$	0,07	-0,06	-0,05	0,06	-0,06	0,04	-0,12	-0,03	0,05	-0,01
	$r_P$	3,17	3,07	3,08	3,01	2,93	2,78	3,08	2,99	3,03	3,06
	$r_N$	2,89	2,92	2,90	2,90	2,86	2,68	2,90	2,91	2,88	2,95
	$r_R$	2,49	2,60	2,51	2,54	2,43	2,39	2,54	2,52	2,54	2,54

Fonte: O autor (2016).

**Tabela 4.30** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10.000$ .

$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5	
MED	$r_P$	-0,23	0,33	0,08	-0,28	0,00	-0,25	0,33	0,09	-0,24	0,07
	$r_N$	-0,25	0,35	0,08	-0,31	0,00	-0,27	0,35	0,10	-0,25	0,08
	$r_R$	-0,27	0,35	0,09	-0,31	0,00	-0,29	0,36	0,10	-0,26	0,08
	$r_P$	0,89	0,94	0,92	0,89	0,88	0,88	0,92	0,93	0,92	0,90
DP	$r_N$	0,95	0,99	0,96	0,95	0,95	0,94	0,96	0,97	0,95	0,97
	$r_R$	1,00	0,98	1,02	0,99	1,03	0,99	0,97	1,02	0,99	1,05
	$r_P$	0,04	0,06	-0,04	0,00	0,03	-0,02	-0,06	-0,07	-0,07	0,02
	$r_N$	0,04	-0,03	-0,04	-0,01	0,00	0,00	-0,07	-0,06	-0,02	0,02
CS	$r_R$	0,07	-0,15	-0,08	0,12	-0,01	0,08	-0,17	-0,07	0,07	-0,03
	$r_P$	3,03	3,55	2,98	2,91	3,21	3,02	2,99	2,98	3,01	2,96
	$r_N$	2,89	2,94	2,86	2,81	2,93	2,89	2,92	2,90	2,87	2,87
	$r_R$	2,49	2,59	2,47	2,53	2,53	2,53	2,55	2,52	2,47	2,45
$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5	
MED	$r_P$	-0,22	0,27	0,12	-0,22	0,06	-0,27	0,25	0,09	-0,27	0,02
	$r_N$	-0,24	0,29	0,12	-0,24	0,07	-0,30	0,29	0,10	-0,29	0,02
	$r_R$	-0,26	0,29	0,13	-0,25	0,08	-0,32	0,29	0,11	-0,30	0,02
	$r_P$	0,90	0,89	0,91	0,91	0,90	0,88	0,85	0,92	0,89	0,88
DP	$r_N$	0,96	0,95	0,95	0,96	0,96	0,95	0,94	0,96	0,95	0,96
	$r_R$	1,00	0,96	1,01	1,01	1,03	1,00	0,95	1,01	0,97	1,04
	$r_P$	0,02	-0,04	0,07	0,09	-0,05	0,09	-0,12	-0,01	-0,01	-0,04
	$r_N$	0,00	-0,06	0,06	0,07	-0,05	0,09	-0,10	0,01	0,02	-0,02
CS	$r_R$	0,02	-0,11	-0,02	0,10	-0,05	0,13	-0,16	-0,03	0,11	0,02
	$r_P$	3,11	2,92	3,00	3,06	3,14	3,00	3,06	3,02	3,15	3,08
	$r_N$	2,87	2,82	2,90	2,88	3,02	2,87	2,92	2,92	2,92	2,91
	$r_R$	2,49	2,53	2,47	2,52	2,54	2,56	2,71	2,49	2,58	2,56
$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5	
MED	$r_P$	-0,22	0,33	0,05	-0,24	0,05	-0,19	0,31	0,13	-0,20	0,05
	$r_N$	-0,24	0,35	0,05	-0,25	0,05	-0,21	0,33	0,14	-0,22	0,05
	$r_R$	-0,26	0,35	0,06	-0,26	0,05	-0,24	0,33	0,14	-0,23	0,06
	$r_P$	0,90	0,92	0,89	0,90	0,90	0,87	0,91	0,89	0,87	0,90
DP	$r_N$	0,97	0,96	0,94	0,94	0,96	0,94	0,95	0,95	0,95	0,95
	$r_R$	1,02	0,96	1,01	0,98	1,04	0,99	0,96	1,00	0,99	1,03
	$r_P$	-0,03	-0,01	0,00	0,02	0,00	0,04	-0,05	0,01	0,07	-0,04
	$r_N$	-0,02	-0,05	-0,01	0,05	-0,02	0,04	-0,04	0,01	0,04	-0,04
CS	$r_R$	0,04	-0,17	-0,01	0,12	-0,03	0,06	-0,14	-0,08	0,09	-0,03
	$r_P$	2,96	3,10	3,03	3,02	3,02	2,98	2,96	2,99	2,99	3,18
	$r_N$	2,88	2,91	2,92	2,90	2,89	2,89	2,87	2,85	2,86	2,97
	$r_R$	2,52	2,58	2,53	2,53	2,48	2,52	2,57	2,49	2,57	2,53
$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5	
MED	$r_P$	-0,20	0,37	0,08	-0,22	0,10	-0,24	0,32	0,04	-0,24	0,06
	$r_N$	-0,21	0,39	0,08	-0,23	0,11	-0,26	0,35	0,04	-0,26	0,07
	$r_R$	-0,23	0,40	0,09	-0,24	0,12	-0,28	0,35	0,04	-0,27	0,07
	$r_P$	0,88	0,91	0,91	0,90	0,86	0,88	0,90	0,88	0,91	0,90
DP	$r_N$	0,95	0,95	0,95	0,94	0,93	0,94	0,94	0,95	0,95	0,95
	$r_R$	1,00	0,96	1,02	0,97	1,01	0,99	1,01	0,99	1,01	0,99
	$r_P$	-0,06	0,02	0,02	0,03	0,00	0,01	-0,03	0,00	0,04	0,04
	$r_N$	-0,02	-0,03	0,01	0,06	-0,01	0,00	-0,04	-0,01	0,04	0,04
CS	$r_R$	0,01	-0,13	-0,03	0,11	-0,03	0,06	-0,13	-0,04	0,11	0,01
	$r_P$	3,08	3,17	2,91	3,09	2,95	2,98	2,97	2,98	3,10	3,12
	$r_N$	2,89	2,88	2,78	2,93	2,82	2,83	2,82	2,85	2,93	2,95
	$r_R$	2,50	2,60	2,48	2,57	2,51	2,50	2,55	2,54	2,56	2,52
$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5	
MED	$r_P$	-0,21	0,31	0,15	-0,23	0,09	-0,21	0,32	0,09	-0,22	0,01
	$r_N$	-0,22	0,33	0,16	-0,25	0,10	-0,23	0,33	0,10	-0,23	0,01
	$r_R$	-0,24	0,34	0,17	-0,25	0,11	-0,24	0,34	0,10	-0,25	0,01
	$r_P$	0,91	0,89	0,90	0,92	0,90	0,88	0,91	0,91	0,90	0,88
DP	$r_N$	0,97	0,93	0,95	0,96	0,96	0,93	0,95	0,95	0,95	0,95
	$r_R$	1,01	0,94	1,00	0,99	1,04	0,99	0,96	1,00	0,99	1,03
	$r_P$	0,04	-0,02	-0,03	0,01	-0,05	0,02	-0,02	-0,01	-0,02	0,00
	$r_N$	0,07	-0,02	-0,04	0,00	-0,05	0,03	-0,07	-0,02	-0,03	0,00
CS	$r_R$	0,12	-0,09	-0,08	0,08	-0,07	0,09	-0,15	-0,06	0,06	-0,02
	$r_P$	3,17	3,05	3,11	3,00	2,94	2,78	3,08	3,03	3,03	3,07
	$r_N$	2,90	2,92	2,93	2,91	2,87	2,69	2,91	2,93	2,88	2,95
	$r_R$	2,54	2,63	2,54	2,56	2,45	2,45	2,57	2,54	2,56	2,56

Fonte: O autor (2016).

**Tabela 4.31** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 0,01$ .

$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	0,00	-0,01	0,00	-0,01	-0,01	0,01	0,02	0,01	0,01
	$r_N$	0,00	-0,01	0,00	-0,01	-0,01	0,01	0,02	0,01	0,01
	$r_R$	0,00	-0,01	0,00	0,00	-0,01	0,00	0,02	0,01	0,01
	$r_P$	1,00	1,02	1,00	0,96	0,98	0,98	1,02	1,01	1,00
DP	$r_N$	1,03	1,05	1,04	1,03	1,03	1,02	1,04	1,04	1,04
	$r_R$	1,06	1,08	1,07	1,06	1,06	1,05	1,07	1,07	1,06
	$r_P$	0,05	0,00	-0,02	-0,02	0,09	-0,04	-0,04	-0,07	-0,09
	$r_N$	-0,02	-0,02	-0,03	-0,06	0,06	0,01	-0,03	-0,02	-0,06
CS	$r_R$	0,01	-0,01	-0,03	0,02	0,01	0,00	-0,04	-0,02	-0,04
	$r_P$	3,03	3,08	2,95	3,04	3,34	3,04	3,05	3,04	3,12
	$r_N$	3,00	3,01	3,25	3,05	3,10	3,24	3,02	3,01	3,21
	$r_R$	2,42	2,46	2,41	2,48	2,51	2,44	2,40	2,45	2,40
$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	0,01	-0,02	0,00	-0,01	-0,01	-0,02	0,00	-0,01	0,00
	$r_N$	0,01	-0,02	0,00	-0,02	-0,01	-0,02	0,00	-0,01	0,00
	$r_R$	0,01	-0,02	0,00	-0,02	0,00	-0,02	0,00	-0,01	0,00
	$r_P$	1,00	0,99	0,99	1,01	1,00	0,97	0,94	1,02	0,98
DP	$r_N$	1,03	1,03	1,02	1,04	1,04	1,01	1,01	1,04	1,02
	$r_R$	1,06	1,06	1,06	1,07	1,07	1,06	1,05	1,08	1,06
	$r_P$	0,02	-0,01	0,11	0,06	-0,04	0,05	-0,05	-0,03	-0,07
	$r_N$	0,01	-0,01	0,08	0,00	-0,01	0,06	-0,04	0,01	-0,01
CS	$r_R$	-0,04	0,00	0,06	0,02	-0,01	0,05	-0,03	0,00	-0,03
	$r_P$	3,09	2,92	3,03	2,98	3,19	3,01	2,99	3,06	3,45
	$r_N$	3,18	3,31	3,22	3,29	3,27	3,01	3,08	2,92	2,99
	$r_R$	2,46	2,43	2,47	2,42	2,52	2,47	2,56	2,39	2,48
$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,04	0,00	-0,02	-0,03	-0,01	-0,01	0,01	0,00	-0,01
	$r_N$	-0,03	0,00	-0,02	-0,02	0,00	-0,01	0,01	0,00	-0,01
	$r_R$	-0,04	0,00	-0,02	-0,02	-0,01	-0,01	0,01	0,00	-0,01
	$r_P$	1,00	1,00	0,99	0,98	1,00	0,96	0,99	0,97	1,00
DP	$r_N$	1,04	1,03	1,03	1,01	1,03	1,00	1,02	1,02	1,02
	$r_R$	1,08	1,06	1,07	1,05	1,06	1,05	1,05	1,06	1,06
	$r_P$	-0,06	0,04	0,06	0,00	-0,02	0,01	0,04	0,06	0,01
	$r_N$	-0,04	-0,01	0,05	0,06	-0,05	0,01	0,00	0,04	0,00
CS	$r_R$	-0,02	0,01	0,03	0,03	-0,02	0,00	-0,01	-0,01	0,00
	$r_P$	2,96	3,07	3,03	3,04	3,02	2,93	3,06	2,96	3,01
	$r_N$	2,98	3,15	3,10	3,08	3,04	2,99	3,03	2,96	3,00
	$r_R$	2,46	2,44	2,43	2,45	2,45	2,45	2,42	2,48	2,49
$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	0,00	0,03	0,01	0,01	0,01	0,01	-0,01	0,00	0,00
	$r_N$	0,00	0,02	0,00	0,01	0,01	0,00	-0,01	0,00	0,02
	$r_R$	0,00	0,02	0,00	0,01	0,01	0,01	-0,01	0,00	0,02
	$r_P$	0,98	1,00	0,99	0,99	0,96	0,97	0,98	0,96	0,99
DP	$r_N$	1,02	1,04	1,02	1,02	0,99	1,02	1,02	1,03	1,02
	$r_R$	1,06	1,07	1,06	1,06	1,04	1,06	1,05	1,06	1,07
	$r_P$	-0,07	0,05	0,01	0,01	0,00	-0,01	-0,01	0,02	0,02
	$r_N$	-0,01	0,03	-0,03	0,05	0,00	-0,08	-0,03	-0,09	0,01
CS	$r_R$	-0,03	0,03	0,00	0,00	0,00	-0,02	-0,01	-0,02	-0,01
	$r_P$	3,11	3,18	3,06	2,99	3,17	3,00	2,98	2,95	3,08
	$r_N$	2,94	3,10	2,89	3,23	2,96	3,27	3,01	3,07	3,09
	$r_R$	2,45	2,44	2,39	2,46	2,50	2,47	2,42	2,44	2,42
$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	0,01	0,00	0,03	0,02	0,03	0,02	0,01	0,00	-0,01
	$r_N$	0,00	0,00	0,02	0,02	0,03	0,02	0,00	0,00	-0,01
	$r_R$	0,00	-0,01	0,03	0,02	0,03	0,02	0,01	0,00	-0,01
	$r_P$	1,01	0,99	0,98	1,01	1,00	0,98	1,00	1,00	0,98
DP	$r_N$	1,04	1,01	1,03	1,04	1,03	1,01	1,03	1,03	1,03
	$r_R$	1,08	1,06	1,06	1,07	1,07	1,05	1,07	1,06	1,06
	$r_P$	0,02	-0,03	0,00	-0,01	-0,06	-0,01	0,03	-0,01	-0,06
	$r_N$	0,05	-0,01	-0,05	-0,03	-0,05	0,04	-0,18	0,06	-0,08
CS	$r_R$	0,04	0,01	-0,03	-0,04	-0,04	0,02	-0,01	0,01	-0,02
	$r_P$	3,03	3,06	3,09	3,00	2,96	2,90	3,08	2,96	3,20
	$r_N$	3,01	2,90	3,25	3,03	2,94	3,24	3,95	3,18	3,38
	$r_R$	2,44	2,47	2,43	2,45	2,40	2,34	2,41	2,45	2,50

Fonte: O autor (2016).

**Tabela 4.32** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10$ .

$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5	
MED	$r_P$	-0,18	0,29	0,02	-0,29	0,03	-0,19	0,29	0,04	-0,24	0,12
	$r_N$	-0,20	0,36	0,04	-0,35	0,05	-0,24	0,34	0,05	-0,28	0,14
	$r_R$	-0,22	0,36	0,04	-0,35	0,06	-0,26	0,35	0,05	-0,29	0,15
	$r_P$	0,93	0,98	0,95	0,92	0,91	0,92	0,97	0,96	0,96	0,95
DP	$r_N$	0,99	1,02	1,01	0,99	0,99	0,98	1,00	1,00	0,99	1,01
	$r_R$	1,03	1,00	1,04	0,99	1,04	1,02	0,98	1,04	0,99	1,06
	$r_P$	0,03	0,05	-0,01	-0,04	0,06	-0,06	-0,01	-0,06	-0,11	0,01
	$r_N$	-0,01	-0,03	-0,05	-0,04	0,04	0,03	-0,07	-0,03	-0,02	-0,01
CS	$r_R$	0,03	-0,13	-0,06	0,12	0,01	0,05	-0,14	-0,03	0,06	-0,03
	$r_P$	2,98	3,08	2,97	2,96	3,15	3,04	3,00	3,02	3,07	2,93
	$r_N$	3,01	3,05	3,31	3,10	3,16	3,34	3,05	3,07	3,20	2,94
	$r_R$	2,44	2,57	2,44	2,54	2,55	2,48	2,52	2,49	2,46	2,43
$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5	
MED	$r_P$	-0,17	0,22	0,07	-0,21	0,10	-0,23	0,20	0,04	-0,28	0,04
	$r_N$	-0,20	0,26	0,08	-0,26	0,13	-0,25	0,27	0,08	-0,31	0,07
	$r_R$	-0,23	0,27	0,08	-0,28	0,15	-0,28	0,27	0,08	-0,32	0,09
	$r_P$	0,94	0,94	0,94	0,95	0,94	0,91	0,89	0,97	0,94	0,92
DP	$r_N$	0,99	0,99	0,99	1,00	1,00	0,98	0,97	1,00	0,98	0,99
	$r_R$	1,03	0,98	1,03	1,00	1,05	1,02	0,97	1,04	0,98	1,05
	$r_P$	0,00	0,01	0,11	0,05	-0,03	0,06	-0,04	0,00	-0,05	-0,02
	$r_N$	0,02	-0,06	0,07	0,04	-0,01	0,09	-0,10	0,01	0,03	-0,02
CS	$r_R$	-0,01	-0,08	0,02	0,09	-0,04	0,10	-0,12	-0,03	0,09	0,04
	$r_P$	3,04	2,89	3,00	2,99	3,14	3,03	2,92	3,03	3,31	3,03
	$r_N$	3,16	3,31	3,24	3,31	3,29	3,09	3,18	2,98	3,10	3,02
	$r_R$	2,47	2,52	2,49	2,51	2,53	2,53	2,65	2,44	2,58	2,53
$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5	
MED	$r_P$	-0,16	0,28	-0,01	-0,24	0,07	-0,13	0,27	0,09	-0,19	0,08
	$r_N$	-0,18	0,33	-0,01	-0,28	0,09	-0,17	0,30	0,10	-0,24	0,09
	$r_R$	-0,21	0,33	-0,01	-0,29	0,10	-0,19	0,31	0,10	-0,25	0,11
	$r_P$	0,94	0,96	0,93	0,94	0,94	0,90	0,95	0,93	0,91	0,94
DP	$r_N$	1,00	1,00	0,99	0,98	0,99	0,97	0,98	0,98	0,99	0,99
	$r_R$	1,05	0,98	1,03	0,98	1,05	1,02	0,98	1,03	1,00	1,04
	$r_P$	-0,06	0,05	0,04	-0,03	-0,02	0,00	0,02	0,06	0,01	-0,02
	$r_N$	-0,03	-0,07	0,03	0,07	-0,05	0,01	-0,04	0,06	-0,02	-0,01
CS	$r_R$	0,00	-0,12	0,02	0,10	-0,02	0,01	-0,11	-0,04	0,06	-0,01
	$r_P$	2,96	3,07	2,98	3,02	2,98	2,92	3,03	2,90	3,01	3,16
	$r_N$	3,02	3,26	3,21	3,12	3,06	3,04	3,04	2,99	3,06	3,13
	$r_R$	2,50	2,57	2,50	2,52	2,47	2,48	2,54	2,44	2,56	2,51
$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5	
MED	$r_P$	-0,13	0,34	0,03	-0,21	0,14	-0,19	0,29	-0,02	-0,24	0,10
	$r_N$	-0,17	0,38	0,02	-0,26	0,16	-0,22	0,35	-0,03	-0,28	0,13
	$r_R$	-0,19	0,39	0,02	-0,28	0,18	-0,24	0,36	-0,02	-0,29	0,15
	$r_P$	0,92	0,95	0,94	0,94	0,90	0,91	0,94	0,91	0,95	0,93
DP	$r_N$	0,98	0,99	0,99	0,98	0,96	0,98	0,98	0,99	0,99	0,98
	$r_R$	1,02	0,98	1,04	0,98	1,02	1,02	0,97	1,03	1,00	1,04
	$r_P$	-0,09	0,07	0,00	-0,02	-0,01	-0,03	0,04	0,03	0,02	0,05
	$r_N$	0,00	-0,01	0,00	0,07	0,00	-0,09	-0,05	-0,09	0,05	0,04
CS	$r_R$	-0,02	-0,09	0,01	0,09	-0,03	0,02	-0,11	-0,01	0,10	0,01
	$r_P$	3,10	3,24	2,91	2,98	3,03	2,97	2,98	2,93	3,08	3,09
	$r_N$	2,97	3,09	2,94	3,35	2,93	3,43	3,11	3,14	3,17	3,17
	$r_R$	2,47	2,58	2,48	2,56	2,50	2,49	2,52	2,50	2,55	2,51
$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5	
MED	$r_P$	-0,14	0,27	0,11	-0,23	0,14	-0,15	0,28	0,04	-0,21	0,05
	$r_N$	-0,18	0,31	0,12	-0,29	0,16	-0,18	0,32	0,05	-0,25	0,06
	$r_R$	-0,21	0,32	0,13	-0,30	0,17	-0,20	0,33	0,05	-0,26	0,07
	$r_P$	0,95	0,94	0,93	0,96	0,94	0,92	0,95	0,95	0,95	0,92
DP	$r_N$	1,00	0,97	0,99	1,00	0,99	0,98	0,99	0,99	0,99	0,99
	$r_R$	1,04	0,97	1,03	1,00	1,05	1,02	0,98	1,03	1,00	1,05
	$r_P$	0,01	0,01	0,02	-0,02	-0,07	-0,03	0,05	-0,01	-0,07	0,00
	$r_N$	0,07	-0,01	-0,07	-0,01	-0,05	0,05	-0,17	0,04	-0,07	-0,07
CS	$r_R$	0,08	-0,07	-0,06	0,07	-0,08	0,04	-0,12	-0,03	0,05	0,00
	$r_P$	3,01	3,05	3,06	3,01	2,91	2,84	3,04	2,95	3,05	3,03
	$r_N$	3,03	2,95	3,23	3,08	2,94	3,20	3,77	3,14	3,16	3,46
	$r_R$	2,48	2,59	2,48	2,54	2,42	2,38	2,55	2,51	2,55	2,50

Fonte: O autor (2016).

**Tabela 4.33** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10.000$ .

$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5	
MED	$r_P$	-0,24	0,35	0,08	-0,31	-0,01	-0,26	0,35	0,09	-0,25	0,09
	$r_N$	-0,29	0,44	0,11	-0,37	0,00	-0,33	0,42	0,11	-0,30	0,11
	$r_R$	-0,30	0,43	0,11	-0,36	0,00	-0,35	0,41	0,12	-0,30	0,11
	$r_P$	0,91	0,95	0,93	0,90	0,89	0,89	0,94	0,94	0,93	0,93
DP	$r_N$	0,96	1,00	1,00	0,97	0,97	0,97	0,99	0,98	0,98	1,00
	$r_R$	0,99	0,96	1,02	0,97	1,03	0,98	0,95	1,02	0,97	1,05
	$r_P$	0,05	0,03	-0,02	-0,02	0,05	-0,04	-0,03	-0,07	-0,10	0,01
	$r_N$	0,00	0,00	-0,07	-0,06	0,01	-0,11	0,13	-0,02	-0,19	0,16
CS	$r_R$	0,08	-0,17	-0,09	0,15	0,00	0,10	-0,18	-0,07	0,09	-0,04
	$r_P$	3,00	3,10	2,99	2,97	3,15	3,05	3,00	3,03	3,09	2,96
	$r_N$	2,97	3,45	4,69	3,12	3,46	4,01	5,04	3,03	4,72	5,10
	$r_R$	2,48	2,62	2,47	2,56	2,56	2,53	2,56	2,51	2,48	2,46
$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5	
MED	$r_P$	-0,24	0,27	0,13	-0,22	0,07	-0,30	0,25	0,10	-0,29	0,00
	$r_N$	-0,29	0,33	0,15	-0,27	0,09	-0,34	0,34	0,15	-0,34	0,02
	$r_R$	-0,31	0,33	0,16	-0,28	0,10	-0,36	0,33	0,16	-0,34	0,03
	$r_P$	0,91	0,91	0,92	0,92	0,91	0,89	0,86	0,94	0,91	0,89
DP	$r_N$	0,97	0,97	0,97	0,98	0,98	0,97	0,95	1,01	0,98	0,97
	$r_R$	0,98	0,95	1,01	0,99	1,04	0,98	0,93	1,02	0,97	1,04
	$r_P$	0,01	-0,01	0,08	0,05	-0,03	0,08	-0,06	-0,01	-0,02	-0,02
	$r_N$	-0,06	-0,14	0,11	-0,04	-0,03	0,41	-0,05	1,01	-0,34	-0,04
CS	$r_R$	0,03	-0,12	-0,03	0,11	-0,05	0,15	-0,16	-0,06	0,12	0,02
	$r_P$	3,06	2,92	3,02	3,01	3,15	3,03	2,95	3,04	3,28	3,06
	$r_N$	3,37	3,99	3,32	3,63	3,20	7,03	3,91	20,12	6,46	3,27
	$r_R$	2,50	2,56	2,50	2,53	2,55	2,59	2,71	2,48	2,60	2,55
$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5	
MED	$r_P$	-0,22	0,33	0,04	-0,25	0,04	-0,19	0,32	0,15	-0,19	0,05
	$r_N$	-0,27	0,41	0,05	-0,29	0,05	-0,25	0,37	0,17	-0,25	0,05
	$r_R$	-0,29	0,40	0,06	-0,30	0,05	-0,27	0,37	0,17	-0,26	0,06
	$r_P$	0,91	0,93	0,91	0,91	0,92	0,88	0,92	0,90	0,89	0,92
DP	$r_N$	0,98	0,98	0,96	0,96	0,97	0,95	0,97	0,96	0,97	0,98
	$r_R$	1,01	0,94	1,01	0,97	1,04	0,98	0,94	1,00	0,98	1,03
	$r_P$	-0,05	0,03	0,02	-0,03	-0,01	0,01	-0,01	0,04	0,03	-0,01
	$r_N$	-0,05	-0,03	0,03	0,03	-0,04	0,02	-0,34	0,05	-0,05	0,12
CS	$r_R$	0,05	-0,17	-0,01	0,12	-0,02	0,06	-0,15	-0,08	0,08	-0,01
	$r_P$	2,98	3,09	3,02	3,05	3,02	2,95	3,01	2,92	3,01	3,20
	$r_N$	3,12	3,44	3,18	3,22	3,07	3,23	6,42	3,03	3,24	3,89
	$r_R$	2,55	2,63	2,55	2,54	2,49	2,53	2,60	2,48	2,58	2,53
$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5	
MED	$r_P$	-0,19	0,39	0,08	-0,22	0,11	-0,26	0,35	0,03	-0,25	0,06
	$r_N$	-0,25	0,46	0,08	-0,28	0,12	-0,31	0,43	0,04	-0,30	0,08
	$r_R$	-0,27	0,45	0,08	-0,29	0,13	-0,33	0,42	0,04	-0,31	0,09
	$r_P$	0,90	0,92	0,92	0,91	0,88	0,89	0,91	0,89	0,92	0,91
DP	$r_N$	0,97	0,97	0,97	0,96	0,95	0,96	0,97	0,97	0,97	0,97
	$r_R$	0,99	0,94	1,02	0,97	1,01	0,98	0,94	1,00	0,98	1,03
	$r_P$	-0,08	0,04	-0,01	-0,02	-0,01	0,00	0,02	0,03	0,04	0,07
	$r_N$	-0,18	0,03	0,02	0,14	-0,22	-0,09	0,06	-0,10	0,06	0,03
CS	$r_R$	0,02	-0,14	-0,03	0,12	-0,04	0,08	-0,16	-0,04	0,12	0,01
	$r_P$	3,12	3,23	2,93	3,01	3,02	2,98	2,98	2,95	3,09	3,13
	$r_N$	4,56	3,26	2,97	3,86	5,09	3,49	3,55	3,23	3,28	3,19
	$r_R$	2,51	2,65	2,50	2,58	2,51	2,53	2,56	2,52	2,58	2,54
$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5	
MED	$r_P$	-0,20	0,33	0,17	-0,24	0,10	-0,22	0,33	0,10	-0,22	0,01
	$r_N$	-0,27	0,39	0,19	-0,31	0,12	-0,27	0,39	0,12	-0,26	0,01
	$r_R$	-0,28	0,38	0,20	-0,31	0,13	-0,29	0,39	0,12	-0,27	0,01
	$r_P$	0,93	0,91	0,91	0,93	0,92	0,90	0,93	0,92	0,92	0,89
DP	$r_N$	0,98	0,95	0,97	0,98	0,98	0,95	0,97	0,97	0,97	0,97
	$r_R$	1,00	0,93	1,01	0,98	1,04	0,98	0,95	1,00	0,98	1,03
	$r_P$	0,03	0,00	0,00	-0,01	-0,06	-0,01	0,03	-0,02	-0,05	0,00
	$r_N$	0,06	0,13	-0,08	-0,05	0,06	-0,01	-0,07	-0,10	-0,09	0,05
CS	$r_R$	0,14	-0,11	-0,10	0,10	-0,08	0,10	-0,16	-0,07	0,07	-0,01
	$r_P$	3,03	3,04	3,09	3,02	2,92	2,84	3,04	2,97	3,05	3,03
	$r_N$	3,06	3,95	3,27	3,20	3,73	3,14	3,32	4,21	3,22	4,16
	$r_R$	2,55	2,63	2,52	2,58	2,44	2,45	2,60	2,54	2,57	2,53

Fonte: O autor (2016).

**Tabela 4.34** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 0,01$ .

	$r(\cdot)i,j$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	0,00	-0,01	0,00	0,00	-0,01	0,01	0,02	0,01	0,00	-0,01
	$r_N$	0,00	0,00	0,01	-0,01	-0,01	0,01	0,02	0,01	0,01	-0,01
	$r_R$	0,00	-0,01	0,00	0,00	-0,01	0,00	0,02	0,01	0,01	-0,02
	$r_P$	1,00	1,01	0,99	0,95	0,98	0,97	1,01	1,00	0,99	1,00
DP	$r_N$	1,07	1,09	1,07	1,05	1,02	1,05	1,04	1,05	1,05	1,05
	$r_R$	1,06	1,08	1,07	1,06	1,06	1,05	1,07	1,07	1,06	1,08
	$r_P$	0,05	0,04	-0,03	-0,01	0,08	-0,04	-0,03	-0,06	-0,09	0,01
CS	$r_N$	-1,58	1,10	0,83	-0,88	0,07	0,79	-0,09	-0,18	0,06	-0,14
	$r_R$	0,01	-0,01	-0,03	0,01	0,00	0,00	-0,03	-0,02	-0,05	0,01
	$r_P$	3,04	3,32	2,94	2,97	3,34	3,06	3,00	2,99	3,08	2,98
CK	$r_N$	2,42	2,44	2,42	2,48	2,50	2,44	2,41	2,43	2,41	2,41
	$r_R$	34,50	22,99	14,05	14,81	3,46	17,06	3,44	5,07	5,60	4,20
	$r(\cdot)i,j$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	0,01	-0,02	0,00	-0,01	-0,01	-0,02	-0,01	-0,01	0,00	0,00
	$r_N$	0,01	-0,02	0,00	-0,01	-0,01	-0,02	0,00	0,00	0,00	0,00
	$r_R$	0,01	-0,02	0,00	-0,02	0,00	-0,02	0,00	0,00	0,00	0,01
	$r_P$	1,00	0,98	0,98	1,00	0,99	0,97	0,93	1,01	0,97	0,99
DP	$r_N$	1,04	1,03	1,03	1,05	1,05	1,01	1,02	1,07	1,05	1,03
	$r_R$	1,07	1,06	1,06	1,08	1,06	1,06	1,05	1,07	1,06	1,07
	$r_P$	0,01	0,01	0,10	0,05	-0,04	0,05	-0,02	-0,03	-0,08	-0,06
CS	$r_N$	-0,28	-0,06	-0,06	0,35	0,32	0,08	0,05	0,22	-0,32	-0,03
	$r_R$	-0,04	0,01	0,06	0,02	-0,01	0,05	-0,03	0,01	-0,03	0,04
	$r_P$	3,17	2,88	3,02	2,97	3,21	3,01	2,94	2,98	3,38	3,28
CK	$r_N$	2,45	2,43	2,47	2,40	2,51	2,48	2,55	2,41	2,48	2,48
	$r_R$	5,11	4,03	3,97	5,92	6,79	3,10	3,51	11,77	8,80	2,96
	$r(\cdot)i,j$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,03	0,00	-0,02	-0,02	0,00	-0,01	0,01	0,00	-0,01	-0,01
	$r_N$	-0,03	0,01	-0,02	-0,02	0,00	0,00	0,01	0,00	-0,01	-0,01
	$r_R$	-0,04	0,00	-0,02	-0,02	-0,01	-0,01	0,01	0,00	-0,01	0,00
	$r_P$	1,00	1,00	0,99	0,98	1,00	0,96	0,98	0,97	0,96	1,00
DP	$r_N$	1,06	1,08	1,04	1,07	1,03	1,01	1,02	1,03	1,02	1,02
	$r_R$	1,08	1,06	1,08	1,05	1,07	1,05	1,05	1,06	1,06	1,06
	$r_P$	-0,04	0,04	0,06	0,01	-0,02	0,03	0,03	0,04	0,02	-0,03
CS	$r_N$	0,52	1,45	-0,02	-1,97	-0,19	0,02	-0,07	0,13	-0,04	0,01
	$r_R$	-0,01	-0,01	0,03	0,03	-0,02	0,00	-0,01	-0,01	0,01	0,00
	$r_P$	3,03	3,04	3,06	2,98	3,06	2,96	3,01	3,02	2,96	3,08
CK	$r_N$	2,43	2,42	2,42	2,44	2,45	2,45	2,46	2,42	2,49	2,49
	$r_R$	10,86	33,28	3,84	48,84	4,54	3,04	3,75	5,18	3,04	3,19
	$r(\cdot)i,j$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	0,00	0,02	0,01	0,01	0,01	0,01	-0,01	0,00	0,00	0,01
	$r_N$	0,00	0,01	0,00	0,01	0,01	0,01	-0,01	-0,01	0,00	0,01
	$r_R$	0,00	0,02	0,00	0,01	0,01	0,01	-0,01	-0,01	0,00	0,02
	$r_P$	0,98	0,99	0,98	0,98	0,95	0,97	0,98	0,96	0,98	1,00
SD	$r_N$	1,06	1,17	1,02	1,08	1,00	1,01	1,04	1,03	1,04	1,05
	$r_R$	1,06	1,07	1,06	1,06	1,03	1,06	1,05	1,06	1,07	1,05
	$r_P$	-0,06	0,04	0,01	0,00	0,02	0,00	-0,01	0,02	0,00	0,01
CS	$r_N$	1,38	-7,07	-0,06	1,52	0,13	0,06	0,29	0,03	0,14	-0,96
	$r_R$	-0,04	0,03	0,00	0,01	0,01	-0,02	-0,01	-0,02	0,00	0,02
	$r_P$	3,09	3,16	3,04	2,99	3,13	3,04	2,96	2,96	3,01	3,13
CK	$r_N$	2,46	2,44	2,38	2,46	2,51	2,47	2,41	2,44	2,43	2,49
	$r_R$	27,07	234,36	3,15	37,04	3,52	3,39	8,80	3,47	4,57	19,30
	$r(\cdot)i,j$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	0,00	0,00	0,03	0,02	0,03	0,02	0,01	0,00	-0,01	-0,01
	$r_N$	0,00	0,00	0,02	0,02	0,03	0,02	0,01	0,00	-0,01	-0,01
	$r_R$	0,00	0,00	0,02	0,02	0,03	0,03	0,01	0,00	-0,01	-0,01
	$r_P$	1,01	0,98	0,97	1,00	1,00	0,98	0,99	1,00	0,98	1,00
DP	$r_N$	1,04	1,02	1,04	1,03	1,04	1,01	1,04	1,03	1,07	1,02
	$r_R$	1,08	1,06	1,06	1,07	1,06	1,05	1,07	1,06	1,07	1,06
	$r_P$	-0,03	-0,03	-0,03	0,00	-0,03	0,00	0,02	0,01	-0,04	-0,01
CS	$r_N$	-0,06	0,07	-0,65	0,02	0,22	-0,06	-0,27	-0,07	0,50	-0,01
	$r_R$	0,03	0,01	-0,02	-0,04	-0,02	0,01	-0,01	0,01	-0,02	-0,01
	$r_P$	3,25	3,02	3,28	2,98	2,94	2,89	3,02	2,95	3,15	3,10
CK	$r_N$	2,45	2,46	2,45	2,45	2,42	2,35	2,41	2,45	2,46	2,51
	$r_R$	3,49	3,42	11,63	3,22	5,92	3,15	5,26	4,16	18,87	3,02

Fonte: O autor (2016).

**Tabela 4.35** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 10$ .

$r(\cdot)i,j$		1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,14	0,31	0,03	-0,29	0,00	-0,16	0,31	0,05	-0,25	0,09
	$r_N$	-0,19	0,36	0,05	-0,35	0,04	-0,21	0,35	0,05	-0,28	0,12
	$r_R$	-0,21	0,36	0,05	-0,34	0,05	-0,23	0,36	0,05	-0,30	0,13
	$r_P$	0,93	0,97	0,95	0,91	0,91	0,91	0,96	0,96	0,95	0,94
DP	$r_N$	1,02	1,05	1,03	1,01	0,99	1,01	1,00	1,01	1,01	1,01
	$r_R$	1,03	1,00	1,05	0,99	1,04	1,02	0,98	1,04	0,99	1,06
	$r_P$	0,01	0,06	-0,03	-0,01	0,05	-0,07	-0,01	-0,06	-0,10	0,03
CS	$r_N$	-1,16	0,80	0,80	-0,70	0,04	0,57	-0,10	-0,13	0,07	-0,12
	$r_R$	0,03	-0,13	-0,06	0,12	-0,01	0,04	-0,14	-0,03	0,05	-0,02
	$r_P$	3,00	3,24	2,97	2,93	3,10	3,06	2,97	2,97	3,06	2,96
CK	$r_N$	24,24	16,08	13,91	11,16	3,33	14,12	3,42	4,71	5,35	3,87
	$r_R$	2,44	2,55	2,45	2,54	2,52	2,48	2,52	2,47	2,47	2,43
$r(\cdot)i,j$		3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,13	0,24	0,08	-0,22	0,07	-0,19	0,22	0,05	-0,28	0,01
	$r_N$	-0,18	0,27	0,08	-0,26	0,10	-0,23	0,27	0,08	-0,33	0,05
	$r_R$	-0,20	0,28	0,09	-0,28	0,12	-0,26	0,28	0,08	-0,33	0,06
	$r_P$	0,94	0,93	0,93	0,94	0,93	0,91	0,88	0,96	0,93	0,92
DP	$r_N$	1,01	0,99	0,99	1,02	1,02	0,98	0,97	1,03	1,01	0,99
	$r_R$	1,04	0,98	1,03	1,01	1,05	1,03	0,96	1,04	0,98	1,06
	$r_P$	-0,02	0,01	0,10	0,05	-0,03	0,05	-0,05	-0,01	-0,05	-0,01
CS	$r_N$	-0,32	-0,17	-0,07	0,50	0,51	0,15	-0,02	-0,10	-0,08	-0,05
	$r_R$	-0,02	-0,07	0,02	0,09	-0,03	0,10	-0,12	-0,02	0,09	0,04
	$r_P$	3,12	2,86	3,00	2,98	3,16	3,01	2,95	2,98	3,21	3,03
CK	$r_N$	5,69	4,79	3,87	7,66	10,07	3,39	3,50	13,07	8,01	3,08
	$r_R$	2,46	2,51	2,49	2,49	2,52	2,53	2,65	2,45	2,58	2,51
$r(\cdot)i,j$		5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,12	0,30	0,00	-0,24	0,05	-0,10	0,29	0,09	-0,20	0,05
	$r_N$	-0,17	0,34	-0,01	-0,28	0,08	-0,14	0,31	0,10	-0,25	0,08
	$r_R$	-0,19	0,34	-0,01	-0,29	0,09	-0,16	0,32	0,10	-0,26	0,09
	$r_P$	0,93	0,95	0,93	0,93	0,94	0,90	0,94	0,92	0,91	0,94
DP	$r_N$	1,03	1,03	1,00	1,02	1,00	0,97	0,98	0,99	0,98	0,99
	$r_R$	1,05	0,98	1,03	0,98	1,05	1,02	0,97	1,02	1,00	1,05
	$r_P$	-0,08	0,03	0,03	-0,01	0,00	0,00	0,00	0,06	0,03	-0,03
CS	$r_N$	0,96	0,92	-0,09	-1,45	-0,22	0,02	-0,10	0,10	-0,02	0,00
	$r_R$	0,00	-0,14	0,02	0,09	-0,02	0,00	-0,11	-0,04	0,06	-0,02
	$r_P$	2,95	3,07	2,99	2,98	3,02	2,95	3,00	2,93	2,96	3,11
CK	$r_N$	19,54	24,12	4,43	34,84	4,91	3,10	3,60	4,87	3,10	3,21
	$r_R$	2,47	2,56	2,49	2,51	2,46	2,47	2,55	2,45	2,57	2,51
$r(\cdot)i,j$		7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,10	0,35	0,03	-0,22	0,11	-0,16	0,30	-0,01	-0,25	0,07
	$r_N$	-0,14	0,38	0,02	-0,26	0,15	-0,21	0,36	-0,02	-0,28	0,10
	$r_R$	-0,16	0,40	0,02	-0,27	0,16	-0,23	0,37	-0,02	-0,30	0,12
	$r_P$	0,92	0,95	0,94	0,93	0,89	0,91	0,94	0,91	0,94	0,93
DP	$r_N$	1,02	1,10	0,98	1,03	0,97	0,98	1,00	0,99	1,00	1,01
	$r_R$	1,03	0,98	1,03	0,98	1,02	1,03	0,97	1,03	0,99	1,04
	$r_P$	-0,09	0,05	0,00	-0,01	0,02	-0,03	0,03	0,03	0,01	0,05
CS	$r_N$	1,19	-5,88	-0,05	1,10	0,16	0,05	0,15	0,08	0,21	-0,73
	$r_R$	-0,03	-0,10	0,00	0,09	-0,02	0,01	-0,11	0,00	0,10	0,02
	$r_P$	3,11	3,19	2,92	2,99	3,01	2,99	2,96	2,94	3,05	3,10
CK	$r_N$	21,39	182,58	3,27	29,76	3,86	3,28	7,24	3,94	5,09	14,33
	$r_R$	2,48	2,58	2,47	2,56	2,50	2,49	2,51	2,50	2,56	2,52
$r(\cdot)i,j$		9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,11	0,29	0,12	-0,23	0,10	-0,12	0,30	0,05	-0,22	0,01
	$r_N$	-0,16	0,32	0,12	-0,29	0,14	-0,16	0,33	0,05	-0,26	0,04
	$r_R$	-0,18	0,33	0,13	-0,30	0,16	-0,18	0,34	0,05	-0,27	0,04
	$r_P$	0,95	0,93	0,92	0,95	0,94	0,92	0,95	0,94	0,94	0,92
DP	$r_N$	1,00	0,97	1,00	1,00	1,01	0,97	1,00	0,99	1,03	0,98
	$r_R$	1,05	0,96	1,03	0,99	1,05	1,02	0,98	1,03	1,00	1,05
	$r_P$	-0,01	-0,01	0,02	-0,01	-0,03	-0,03	0,03	0,00	-0,05	0,00
CS	$r_N$	-0,10	0,12	-0,53	0,06	0,12	-0,05	-0,25	-0,02	0,14	-0,01
	$r_R$	0,06	-0,07	-0,05	0,07	-0,06	0,04	-0,11	-0,03	0,05	0,00
	$r_P$	3,08	3,02	3,04	3,00	2,91	2,82	3,02	2,95	3,02	3,05
CK	$r_N$	4,04	3,89	9,25	3,40	5,06	3,18	4,96	4,40	18,40	3,03
	$r_R$	2,48	2,58	2,50	2,56	2,44	2,39	2,54	2,52	2,54	2,52

Fonte: O autor (2016).

**Tabela 4.36** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal normal, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 10.000$ .

$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5	
MED	$r_P$	-0,20	0,37	0,08	-0,31	-0,03	-0,21	0,37	0,10	-0,26	0,06
	$r_N$	-0,26	0,44	0,10	-0,37	0,01	-0,29	0,43	0,10	-0,31	0,09
	$r_R$	-0,28	0,43	0,10	-0,36	0,00	-0,31	0,42	0,11	-0,31	0,10
	$r_P$	0,91	0,94	0,92	0,89	0,88	0,89	0,93	0,94	0,92	0,91
DP	$r_N$	0,97	1,01	1,00	1,02	0,97	0,96	0,97	0,98	0,98	0,99
	$r_R$	1,00	0,96	1,02	0,97	1,03	0,99	0,94	1,02	0,97	1,05
	$r_P$	0,02	0,03	-0,04	0,00	0,05	-0,06	-0,04	-0,08	-0,09	0,04
CS	$r_N$	0,19	0,07	-0,23	-2,48	0,10	0,01	-0,04	-0,07	0,04	0,00
	$r_R$	0,07	-0,17	-0,09	0,14	-0,01	0,08	-0,18	-0,07	0,08	-0,03
	$r_P$	3,02	3,21	2,98	2,95	3,11	3,07	2,98	2,98	3,08	2,99
CK	$r_N$	4,66	3,55	6,57	57,29	3,63	3,08	3,20	3,20	5,72	3,05
	$r_R$	2,48	2,61	2,48	2,55	2,54	2,51	2,57	2,49	2,50	2,45
	$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,19	0,29	0,13	-0,23	0,04	-0,25	0,27	0,11	-0,29	-0,02
	$r_N$	-0,25	0,34	0,14	-0,28	0,07	-0,31	0,34	0,14	-0,35	0,02
	$r_R$	-0,27	0,34	0,14	-0,29	0,09	-0,33	0,33	0,14	-0,35	0,02
	$r_P$	0,91	0,90	0,92	0,92	0,90	0,89	0,86	0,93	0,90	0,89
DP	$r_N$	0,98	0,98	0,98	0,98	0,97	0,96	0,96	0,97	0,97	0,98
	$r_R$	1,00	0,94	1,01	0,99	1,04	1,00	0,93	1,01	0,96	1,04
	$r_P$	-0,01	-0,02	0,07	0,06	-0,02	0,06	-0,07	-0,02	-0,02	0,00
CS	$r_N$	-0,13	0,06	0,02	0,12	-0,03	0,02	0,09	0,04	0,14	-0,09
	$r_R$	0,01	-0,11	-0,02	0,12	-0,04	0,14	-0,16	-0,05	0,13	0,03
	$r_P$	3,13	2,89	3,00	3,00	3,16	3,01	2,98	3,00	3,19	3,07
CK	$r_N$	4,17	5,26	3,61	3,52	3,18	3,35	4,75	3,09	4,97	3,74
	$r_R$	2,48	2,55	2,49	2,52	2,54	2,57	2,71	2,49	2,61	2,53
	$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,17	0,36	0,05	-0,25	0,02	-0,14	0,34	0,15	-0,20	0,02
	$r_N$	-0,23	0,41	0,04	-0,29	0,05	-0,20	0,38	0,16	-0,26	0,04
	$r_R$	-0,26	0,40	0,05	-0,30	0,05	-0,22	0,38	0,16	-0,27	0,05
	$r_P$	0,91	0,92	0,90	0,90	0,91	0,88	0,91	0,90	0,88	0,91
DP	$r_N$	0,98	0,98	0,97	1,00	0,98	0,96	0,97	0,96	0,97	0,97
	$r_R$	1,02	0,94	1,01	0,96	1,04	0,99	0,94	1,00	0,98	1,03
	$r_P$	-0,07	0,01	0,01	0,00	0,01	0,00	-0,04	0,03	0,04	-0,02
CS	$r_N$	-0,02	0,16	-0,09	-1,27	0,15	0,02	0,07	0,09	-0,14	0,00
	$r_R$	0,03	-0,18	-0,01	0,11	-0,02	0,04	-0,16	-0,08	0,08	-0,02
	$r_P$	2,97	3,09	3,04	3,00	3,06	2,98	2,99	2,95	2,97	3,16
CK	$r_N$	2,89	4,83	3,73	34,28	4,37	3,47	3,53	3,46	4,20	3,21
	$r_R$	2,51	2,62	2,53	2,53	2,48	2,52	2,60	2,49	2,59	2,53
	$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,14	0,41	0,09	-0,22	0,09	-0,21	0,37	0,04	-0,26	0,04
	$r_N$	-0,21	0,47	0,08	-0,28	0,12	-0,28	0,44	0,03	-0,30	0,07
	$r_R$	-0,23	0,46	0,08	-0,29	0,13	-0,30	0,43	0,03	-0,31	0,08
	$r_P$	0,89	0,92	0,92	0,90	0,87	0,89	0,91	0,89	0,91	0,91
DP	$r_N$	0,96	0,97	0,97	0,96	0,94	0,96	0,97	0,97	0,99	0,98
	$r_R$	1,00	0,94	1,01	0,96	1,01	0,99	0,93	1,00	0,98	1,03
	$r_P$	-0,09	0,01	-0,02	0,00	0,03	-0,01	0,00	0,01	0,03	0,07
CS	$r_N$	-0,06	0,04	0,03	-0,05	0,07	-0,04	0,02	-0,20	0,42	-0,04
	$r_R$	0,00	-0,15	-0,03	0,12	-0,03	0,06	-0,15	-0,03	0,12	0,01
	$r_P$	3,14	3,19	2,93	3,02	3,00	3,00	2,96	2,96	3,07	3,14
CK	$r_N$	3,07	3,27	3,13	3,56	3,17	3,13	3,02	4,65	7,53	4,54
	$r_R$	2,51	2,65	2,48	2,58	2,51	2,51	2,55	2,52	2,58	2,52
	$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,16	0,35	0,18	-0,24	0,08	-0,17	0,35	0,11	-0,22	-0,02
	$r_N$	-0,23	0,40	0,18	-0,31	0,11	-0,23	0,41	0,10	-0,27	0,00
	$r_R$	-0,25	0,39	0,19	-0,31	0,12	-0,25	0,40	0,11	-0,28	0,00
	$r_P$	0,92	0,90	0,90	0,92	0,91	0,89	0,92	0,92	0,91	0,89
DP	$r_N$	0,99	0,96	0,97	0,98	0,97	0,95	0,98	0,96	1,00	0,97
	$r_R$	1,02	0,92	1,00	0,98	1,04	0,99	0,94	1,00	0,98	1,03
	$r_P$	0,00	-0,02	0,00	0,00	-0,03	-0,02	0,01	-0,01	-0,04	0,01
CS	$r_N$	0,08	0,22	-0,21	-0,02	-0,03	0,00	0,24	-0,04	-1,17	0,05
	$r_R$	0,12	-0,11	-0,09	0,11	-0,06	0,09	-0,15	-0,07	0,07	0,00
	$r_P$	3,09	3,01	3,06	3,00	2,92	2,83	3,03	2,99	3,03	3,06
CK	$r_N$	4,04	4,43	4,36	4,75	2,91	2,84	5,76	3,11	26,38	3,74
	$r_R$	2,53	2,62	2,53	2,61	2,45	2,45	2,59	2,55	2,57	2,54

Fonte: O autor (2016).

**Tabela 4.37** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização  $\alpha = 0,01$ .

$r_{(\cdot)i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5	
MED	$r_P$	0,00	-0,01	-0,01	-0,03	-0,02	0,00	0,00	-0,01	0,00	-0,01
	$r_N$	0,00	-0,01	-0,01	-0,03	-0,02	0,00	0,00	-0,01	0,00	-0,02
	$r_R$	0,00	-0,01	-0,02	-0,05	-0,05	0,00	0,00	-0,02	0,00	-0,02
DP	$r_P$	0,93	0,94	0,93	0,91	0,91	0,93	0,98	0,94	0,95	0,91
	$r_N$	0,98	1,01	0,98	0,96	0,96	1,00	1,03	0,99	1,00	0,98
	$r_R$	1,05	1,07	1,05	1,03	1,02	1,02	1,03	1,06	1,15	1,25
CS	$r_P$	0,49	0,45	0,73	1,27	1,52	0,50	0,54	0,74	1,18	1,17
	$r_N$	0,49	0,45	0,73	1,27	1,52	0,50	0,54	0,74	1,18	1,16
	$r_R$	0,28	0,29	0,45	0,91	1,13	0,29	0,31	0,46	0,81	0,92
CK	$r_P$	3,31	3,10	3,46	4,26	4,99	3,34	3,37	3,40	4,09	3,83
	$r_N$	3,31	3,10	3,45	4,24	4,97	3,33	3,37	3,40	4,09	3,81
	$r_R$	2,48	2,46	2,53	2,76	3,13	2,53	2,50	2,54	2,65	3,01
$r_{(\cdot)i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5	
MED	$r_P$	0,01	0,00	0,02	-0,01	0,00	-0,02	-0,03	0,02	0,00	0,01
	$r_N$	0,01	0,00	0,02	-0,01	0,00	-0,02	-0,04	0,02	0,00	0,01
	$r_R$	0,01	-0,01	0,03	-0,01	0,00	-0,02	-0,04	0,03	-0,02	-0,01
DP	$r_P$	0,95	0,93	0,94	0,92	0,93	0,91	0,87	0,96	0,94	0,95
	$r_N$	1,01	1,00	1,00	0,98	0,99	0,99	0,99	1,01	0,99	1,00
	$r_R$	1,08	0,97	1,15	1,25	1,23	1,00	0,92	1,13	1,07	1,04
CS	$r_P$	0,46	0,48	0,59	1,03	1,19	0,51	0,51	0,63	1,19	1,51
	$r_N$	0,46	0,48	0,59	1,03	1,19	0,50	0,50	0,63	1,19	1,50
	$r_R$	0,26	0,27	0,35	0,72	0,91	0,34	0,29	0,39	0,84	1,08
CK	$r_P$	3,10	3,09	3,14	3,78	3,90	3,19	3,30	3,10	3,88	5,08
	$r_N$	3,10	3,09	3,14	3,77	3,89	3,19	3,29	3,10	3,87	5,03
	$r_R$	2,40	2,55	2,46	2,77	2,90	2,55	2,76	2,43	2,59	2,98
$r_{(\cdot)i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5	
MED	$r_P$	0,00	0,01	0,00	0,00	0,01	-0,03	0,02	-0,03	-0,03	0,00
	$r_N$	0,00	0,01	0,00	0,00	0,01	-0,03	0,02	-0,04	-0,03	0,00
	$r_R$	0,00	0,01	0,00	0,00	-0,01	-0,03	0,02	-0,03	-0,01	-0,01
DP	$r_P$	0,90	0,94	0,97	0,96	0,95	0,90	0,96	0,92	0,91	0,93
	$r_N$	0,99	0,99	1,03	1,02	1,00	1,00	1,02	1,00	0,98	0,98
	$r_R$	1,17	1,02	1,04	1,25	1,15	1,18	1,01	1,19	1,31	1,16
CS	$r_P$	0,34	0,50	0,79	1,10	1,36	0,39	0,49	0,62	1,01	1,34
	$r_N$	0,34	0,50	0,79	1,10	1,36	0,38	0,49	0,61	1,00	1,34
	$r_R$	0,21	0,28	0,48	0,76	1,01	0,26	0,28	0,43	0,76	0,99
CK	$r_P$	2,98	3,31	3,46	3,77	4,44	3,01	3,16	3,29	3,80	4,53
	$r_N$	2,97	3,31	3,46	3,77	4,44	3,01	3,16	3,27	3,80	4,53
	$r_R$	2,53	2,52	2,49	2,64	2,93	2,53	2,51	2,60	3,03	2,91
$r_{(\cdot)i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5	
MED	$r_P$	0,01	0,00	-0,02	-0,01	-0,02	0,01	0,01	0,02	0,00	0,03
	$r_N$	0,01	0,00	-0,02	-0,01	-0,02	0,01	0,01	0,02	0,00	0,03
	$r_R$	0,01	0,00	-0,02	-0,01	-0,02	0,01	0,02	0,01	-0,01	0,02
DP	$r_P$	0,92	0,90	0,94	0,94	0,92	0,95	0,93	0,94	0,94	0,96
	$r_N$	1,00	1,00	0,99	0,99	0,98	1,01	1,00	1,01	0,99	1,01
	$r_R$	1,17	1,08	1,04	1,22	1,28	1,05	1,06	0,99	1,15	1,16
CS	$r_P$	0,42	0,44	0,75	1,10	1,19	0,47	0,39	0,79	1,12	1,32
	$r_N$	0,42	0,44	0,75	1,10	1,18	0,47	0,40	0,78	1,12	1,32
	$r_R$	0,25	0,28	0,47	0,75	0,96	0,28	0,26	0,47	0,79	0,96
CK	$r_P$	3,22	3,14	3,44	3,96	3,97	3,08	3,06	3,49	3,79	4,40
	$r_N$	3,21	3,13	3,44	3,96	3,96	3,08	3,06	3,46	3,79	4,40
	$r_R$	2,51	2,53	2,53	2,67	3,22	2,40	2,43	2,56	2,62	2,82
$r_{(\cdot)i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5	
MED	$r_P$	0,01	0,01	0,00	0,01	0,00	0,00	0,00	0,01	0,01	0,03
	$r_N$	0,01	0,01	0,00	0,01	0,00	0,00	0,00	0,01	0,01	0,03
	$r_R$	0,01	0,01	0,01	0,00	-0,01	0,00	-0,01	0,00	0,02	0,01
DP	$r_P$	0,93	0,95	0,92	0,96	0,93	0,95	0,94	0,94	0,95	0,97
	$r_N$	0,98	1,00	1,00	1,01	0,99	1,00	0,99	0,99	1,00	1,01
	$r_R$	1,12	1,02	1,19	1,15	1,23	1,08	1,00	1,09	1,27	1,08
CS	$r_P$	0,46	0,45	0,58	1,23	1,23	0,47	0,47	0,69	1,03	1,49
	$r_N$	0,46	0,45	0,58	1,23	1,23	0,47	0,47	0,69	1,03	1,49
	$r_R$	0,29	0,28	0,41	0,82	0,94	0,30	0,28	0,41	0,73	1,05
CK	$r_P$	3,05	3,16	3,13	4,32	4,05	3,06	3,07	3,31	3,63	5,11
	$r_N$	3,05	3,16	3,13	4,32	4,04	3,06	3,07	3,30	3,62	5,07
	$r_R$	2,47	2,50	2,58	2,66	2,98	2,40	2,48	2,51	2,74	2,96

Fonte: O autor (2016).

**Tabela 4.38** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10$ .

	$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,21	0,42	-0,09	-0,25	0,01	-0,22	0,37	-0,08	-0,22	0,06
	$r_N$	-0,22	0,44	-0,09	-0,26	0,01	-0,24	0,38	-0,08	-0,23	0,06
	$r_R$	-0,26	0,40	-0,12	-0,33	-0,02	-0,27	0,33	-0,11	-0,31	0,06
	$r_P$	0,88	1,07	0,92	0,80	0,94	0,87	1,10	0,94	0,85	0,97
DP	$r_N$	0,93	1,12	0,95	0,82	0,98	0,94	1,13	0,97	0,87	1,02
	$r_R$	1,01	1,00	1,00	0,94	0,99	0,98	0,96	1,02	1,05	1,21
	$r_P$	0,49	0,48	0,78	1,29	1,50	0,50	0,57	0,79	1,26	1,15
	$r_N$	0,49	0,48	0,78	1,28	1,50	0,50	0,57	0,79	1,26	1,15
CS	$r_R$	0,31	0,21	0,47	0,93	1,11	0,34	0,27	0,48	0,85	0,85
	$r_P$	3,33	3,12	3,57	4,41	4,91	3,30	3,42	3,55	4,59	3,69
	$r_N$	3,33	3,12	3,57	4,40	4,91	3,31	3,43	3,55	4,59	3,68
	$r_R$	2,55	2,43	2,60	2,90	2,93	2,63	2,47	2,57	2,84	2,66
	$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,20	0,31	-0,03	-0,24	0,07	-0,25	0,22	-0,04	-0,22	0,04
	$r_N$	-0,21	0,32	-0,03	-0,25	0,07	-0,27	0,24	-0,04	-0,23	0,04
	$r_R$	-0,24	0,27	-0,05	-0,36	0,06	-0,29	0,20	-0,07	-0,30	0,01
	$r_P$	0,91	1,03	0,95	0,83	0,98	0,85	0,96	0,96	0,83	0,99
DP	$r_N$	0,95	1,09	0,99	0,86	1,02	0,93	1,06	0,98	0,85	1,02
	$r_R$	1,04	0,90	1,11	1,14	1,18	0,94	0,84	1,09	0,97	1,02
	$r_P$	0,47	0,50	0,68	1,12	1,21	0,51	0,56	0,69	1,22	1,49
	$r_N$	0,47	0,50	0,68	1,12	1,21	0,51	0,56	0,69	1,22	1,49
CS	$r_R$	0,30	0,27	0,39	0,72	0,86	0,39	0,35	0,43	0,89	1,06
	$r_P$	3,13	3,15	3,32	4,32	4,02	3,15	3,45	3,18	4,06	5,00
	$r_N$	3,13	3,16	3,32	4,31	4,01	3,15	3,44	3,18	4,06	4,98
	$r_R$	2,50	2,57	2,51	2,91	2,61	2,67	2,84	2,50	2,81	2,82
	$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,17	0,40	-0,09	-0,23	0,06	-0,20	0,38	-0,06	-0,25	0,05
	$r_N$	-0,18	0,42	-0,09	-0,23	0,06	-0,22	0,39	-0,07	-0,26	0,06
	$r_R$	-0,23	0,37	-0,11	-0,34	0,03	-0,27	0,33	-0,09	-0,38	0,03
	$r_P$	0,86	1,06	0,95	0,86	1,00	0,87	1,08	0,94	0,82	0,98
DP	$r_N$	0,95	1,10	0,99	0,88	1,04	0,96	1,12	0,99	0,87	1,02
	$r_R$	1,12	0,95	1,00	1,13	1,12	1,14	0,94	1,17	1,19	1,13
	$r_P$	0,34	0,53	0,82	1,16	1,37	0,40	0,51	0,65	1,05	1,33
	$r_N$	0,34	0,53	0,82	1,16	1,37	0,40	0,51	0,65	1,05	1,33
CS	$r_R$	0,22	0,21	0,52	0,76	0,97	0,26	0,24	0,42	0,68	0,93
	$r_P$	2,95	3,38	3,50	4,15	4,58	3,02	3,20	3,24	4,00	4,59
	$r_N$	2,94	3,39	3,50	4,15	4,58	3,03	3,20	3,25	3,99	4,59
	$r_R$	2,56	2,50	2,60	2,81	2,70	2,59	2,52	2,63	3,06	2,64
	$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,17	0,46	-0,10	-0,24	0,05	-0,21	0,43	-0,09	-0,23	0,08
	$r_N$	-0,18	0,49	-0,10	-0,24	0,06	-0,23	0,45	-0,09	-0,23	0,08
	$r_R$	-0,22	0,45	-0,12	-0,33	0,06	-0,26	0,41	-0,11	-0,32	0,06
	$r_P$	0,88	1,04	0,92	0,85	0,98	0,89	1,07	0,91	0,83	1,00
DP	$r_N$	0,96	1,11	0,95	0,87	1,02	0,95	1,12	0,96	0,85	1,04
	$r_R$	1,11	1,01	1,00	1,10	1,24	1,02	0,99	0,95	1,04	1,13
	$r_P$	0,42	0,45	0,76	1,20	1,20	0,48	0,45	0,79	1,17	1,31
	$r_N$	0,42	0,45	0,76	1,20	1,20	0,49	0,45	0,78	1,17	1,30
CS	$r_R$	0,27	0,19	0,49	0,80	0,88	0,33	0,17	0,47	0,82	0,91
	$r_P$	3,24	3,07	3,38	4,43	4,02	3,05	3,19	3,46	4,04	4,34
	$r_N$	3,23	3,07	3,39	4,44	4,02	3,06	3,19	3,45	4,04	4,34
	$r_R$	2,57	2,47	2,57	2,95	2,85	2,50	2,41	2,64	2,80	2,59
	$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,18	0,38	-0,04	-0,22	0,07	-0,21	0,35	-0,06	-0,22	0,06
	$r_N$	-0,19	0,40	-0,04	-0,22	0,07	-0,22	0,37	-0,06	-0,23	0,06
	$r_R$	-0,24	0,35	-0,06	-0,30	0,05	-0,26	0,31	-0,09	-0,32	0,03
	$r_P$	0,88	1,07	0,94	0,86	0,99	0,90	1,05	0,94	0,86	1,00
DP	$r_N$	0,93	1,11	0,99	0,88	1,03	0,95	1,09	0,96	0,88	1,03
	$r_R$	1,08	0,95	1,15	1,05	1,19	1,04	0,93	1,04	1,15	1,05
	$r_P$	0,46	0,48	0,62	1,24	1,21	0,48	0,47	0,75	1,14	1,44
	$r_N$	0,46	0,48	0,63	1,24	1,21	0,48	0,47	0,75	1,14	1,43
CS	$r_R$	0,30	0,23	0,40	0,85	0,88	0,35	0,23	0,44	0,74	1,01
	$r_P$	3,04	3,21	3,21	4,28	3,90	3,11	3,03	3,49	4,22	4,79
	$r_N$	3,04	3,21	3,22	4,28	3,91	3,11	3,03	3,49	4,21	4,77
	$r_R$	2,51	2,48	2,62	2,83	2,67	2,51	2,46	2,59	2,89	2,72

Fonte: O autor (2016).

**Tabela 4.39** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10.000$ .

	$r_{(\cdot)i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,36	0,71	0,02	-0,32	-0,14	-0,38	0,63	0,03	-0,29	-0,09
	$r_N$	-0,38	0,72	0,02	-0,33	-0,14	-0,41	0,64	0,03	-0,29	-0,10
	$r_R$	-0,42	0,55	-0,01	-0,40	-0,20	-0,43	0,47	0,00	-0,38	-0,15
	$r_P$	0,85	1,19	0,98	0,77	0,86	0,85	1,20	1,00	0,82	0,89
DP	$r_N$	0,89	1,21	0,99	0,79	0,88	0,90	1,22	1,02	0,83	0,92
	$r_R$	0,94	0,91	0,99	0,90	0,96	0,91	0,88	1,01	1,00	1,15
	$r_P$	0,50	0,51	0,78	1,28	1,56	0,51	0,60	0,83	1,27	1,19
	$r_N$	0,50	0,51	0,78	1,28	1,56	0,51	0,60	0,83	1,27	1,19
CS	$r_R$	0,39	0,14	0,42	0,96	1,08	0,43	0,22	0,45	0,88	0,81
	$r_P$	3,37	3,16	3,52	4,39	5,50	3,34	3,48	3,68	4,71	3,93
	$r_N$	3,37	3,16	3,52	4,39	5,49	3,34	3,48	3,68	4,71	3,93
	$r_R$	2,69	2,47	2,53	3,05	2,96	2,79	2,53	2,52	2,97	2,67
	$r_{(\cdot)i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,35	0,53	0,11	-0,29	-0,09	-0,41	0,41	0,09	-0,29	-0,10
	$r_N$	-0,37	0,54	0,12	-0,30	-0,09	-0,44	0,44	0,09	-0,30	-0,11
	$r_R$	-0,40	0,38	0,09	-0,42	-0,15	-0,44	0,30	0,07	-0,37	-0,16
	$r_P$	0,88	1,12	1,02	0,81	0,90	0,82	1,03	1,02	0,80	0,90
DP	$r_N$	0,92	1,15	1,04	0,83	0,92	0,89	1,11	1,03	0,82	0,92
	$r_R$	0,96	0,83	1,10	1,09	1,13	0,86	0,77	1,07	0,94	0,98
	$r_P$	0,50	0,52	0,71	1,13	1,26	0,52	0,57	0,71	1,24	1,53
	$r_N$	0,50	0,52	0,71	1,13	1,26	0,52	0,57	0,71	1,24	1,53
CS	$r_R$	0,40	0,25	0,34	0,75	0,83	0,47	0,33	0,38	0,93	1,05
	$r_P$	3,21	3,23	3,37	4,35	4,28	3,15	3,49	3,26	4,13	5,31
	$r_N$	3,21	3,23	3,37	4,35	4,28	3,16	3,48	3,26	4,13	5,30
	$r_R$	2,68	2,63	2,45	3,01	2,68	2,84	2,94	2,45	2,97	2,88
	$r_{(\cdot)i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,31	0,67	0,01	-0,29	-0,09	-0,33	0,62	0,09	-0,30	-0,10
	$r_N$	-0,34	0,68	0,01	-0,29	-0,10	-0,37	0,63	0,10	-0,32	-0,10
	$r_R$	-0,39	0,50	-0,01	-0,41	-0,16	-0,44	0,46	0,08	-0,45	-0,16
	$r_P$	0,84	1,17	1,00	0,83	0,92	0,85	1,18	1,01	0,80	0,90
DP	$r_N$	0,93	1,18	1,03	0,85	0,93	0,93	1,19	1,05	0,84	0,92
	$r_R$	1,05	0,87	0,99	1,08	1,07	1,07	0,87	1,15	1,14	1,08
	$r_P$	0,35	0,57	0,84	1,18	1,45	0,41	0,54	0,66	1,06	1,36
	$r_N$	0,34	0,57	0,84	1,18	1,45	0,41	0,54	0,66	1,06	1,35
CS	$r_R$	0,27	0,15	0,49	0,80	0,96	0,32	0,19	0,34	0,70	0,91
	$r_P$	2,93	3,51	3,52	4,21	5,02	3,05	3,26	3,29	4,07	4,72
	$r_N$	2,93	3,51	3,53	4,21	5,01	3,05	3,26	3,29	4,06	4,72
	$r_R$	2,67	2,57	2,55	2,92	2,80	2,72	2,60	2,54	3,13	2,70
	$r_{(\cdot)i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,31	0,76	0,01	-0,29	-0,10	-0,37	0,72	0,00	-0,29	-0,07
	$r_N$	-0,33	0,79	0,01	-0,30	-0,10	-0,40	0,73	0,00	-0,29	-0,07
	$r_R$	-0,38	0,61	-0,01	-0,40	-0,16	-0,42	0,56	-0,02	-0,39	-0,13
	$r_P$	0,86	1,15	0,98	0,82	0,91	0,86	1,18	0,96	0,81	0,92
DP	$r_N$	0,93	1,19	0,99	0,84	0,93	0,91	1,20	0,99	0,82	0,94
	$r_R$	1,03	0,91	0,99	1,06	1,18	0,95	0,90	0,94	1,00	1,08
	$r_P$	0,44	0,48	0,79	1,20	1,26	0,51	0,49	0,80	1,18	1,39
	$r_N$	0,44	0,48	0,79	1,20	1,25	0,51	0,49	0,80	1,18	1,39
CS	$r_R$	0,33	0,12	0,45	0,84	0,85	0,42	0,09	0,45	0,86	0,91
	$r_P$	3,28	3,09	3,44	4,40	4,29	3,07	3,27	3,47	4,08	4,82
	$r_N$	3,27	3,09	3,44	4,40	4,29	3,07	3,27	3,47	4,08	4,82
	$r_R$	2,71	2,52	2,54	3,08	2,89	2,66	2,47	2,60	2,95	2,70
	$r_{(\cdot)i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,33	0,64	0,11	-0,28	-0,09	-0,36	0,60	0,06	-0,28	-0,09
	$r_N$	-0,34	0,65	0,11	-0,29	-0,09	-0,38	0,61	0,06	-0,28	-0,09
	$r_R$	-0,40	0,48	0,10	-0,37	-0,16	-0,42	0,44	0,03	-0,39	-0,14
	$r_P$	0,86	1,17	1,01	0,83	0,91	0,87	1,15	1,00	0,83	0,90
DP	$r_N$	0,90	1,19	1,04	0,84	0,93	0,91	1,17	1,01	0,86	0,92
	$r_R$	0,99	0,87	1,14	1,01	1,14	0,96	0,85	1,03	1,11	1,01
	$r_P$	0,47	0,51	0,65	1,24	1,29	0,50	0,49	0,77	1,15	1,45
	$r_N$	0,47	0,51	0,65	1,24	1,29	0,50	0,49	0,77	1,15	1,45
CS	$r_R$	0,37	0,18	0,35	0,89	0,86	0,43	0,19	0,38	0,77	1,00
	$r_P$	3,05	3,23	3,28	4,33	4,32	3,16	3,09	3,55	4,28	4,91
	$r_N$	3,05	3,23	3,28	4,33	4,32	3,17	3,09	3,56	4,28	4,90
	$r_R$	2,62	2,55	2,55	2,97	2,72	2,69	2,51	2,52	2,99	2,79

Fonte: O autor (2016).

**Tabela 4.40** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 0,01$ .

$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5	
MED	$r_P$	-0,01	-0,01	0,01	-0,03	-0,03	-0,02	0,00	0,00	0,01	-0,02
	$r_N$	0,00	0,00	0,02	-0,03	-0,03	-0,02	0,01	0,00	0,02	-0,03
	$r_R$	0,00	0,00	0,02	-0,05	-0,06	-0,02	0,00	0,00	0,01	-0,03
	$r_P$	0,95	0,92	0,96	0,91	0,92	0,91	0,95	0,94	0,96	0,92
DP	$r_N$	1,02	1,01	1,04	0,97	0,97	1,00	1,03	1,02	1,03	0,99
	$r_R$	1,08	1,07	1,09	1,03	1,02	1,01	1,02	1,07	1,17	1,26
	$r_P$	0,48	0,38	0,70	1,26	1,52	0,45	0,50	0,73	1,18	1,20
	$r_N$	0,45	0,44	0,71	1,24	1,46	0,46	0,59	0,81	1,19	1,13
CS	$r_R$	0,33	0,27	0,38	0,89	1,10	0,32	0,34	0,42	0,78	0,91
	$r_P$	3,03	2,99	3,23	4,16	4,91	3,00	3,08	3,46	4,10	3,93
	$r_N$	3,29	3,38	3,72	4,58	5,17	3,49	3,64	4,88	4,62	4,25
	$r_R$	2,45	2,45	2,43	2,80	3,19	2,58	2,47	2,46	2,66	3,15
$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5	
MED	$r_P$	0,02	-0,01	0,02	-0,01	0,00	0,00	-0,03	0,01	-0,03	-0,01
	$r_N$	0,03	-0,02	0,02	-0,01	0,00	0,01	-0,04	0,02	-0,02	-0,01
	$r_R$	0,03	-0,02	0,03	-0,01	-0,01	0,01	-0,03	0,03	-0,04	-0,03
	$r_P$	0,96	0,94	0,95	0,94	0,93	0,92	0,89	0,94	0,93	0,93
DP	$r_N$	1,03	1,03	1,03	1,00	0,99	1,03	1,02	1,01	0,99	1,00
	$r_R$	1,07	0,97	1,17	1,27	1,21	1,01	0,93	1,13	1,06	1,03
	$r_P$	0,47	0,47	0,61	1,03	1,28	0,49	0,50	0,63	1,31	1,56
	$r_N$	0,48	0,49	0,60	1,01	1,26	0,54	0,50	0,59	1,32	1,54
CS	$r_R$	0,25	0,31	0,36	0,72	0,91	0,28	0,35	0,36	0,89	1,06
	$r_P$	3,15	3,08	3,18	3,66	4,30	3,27	3,17	3,13	4,42	5,25
	$r_N$	3,54	4,06	3,84	4,12	4,49	3,97	3,57	3,34	5,05	5,92
	$r_R$	2,44	2,62	2,51	2,80	3,02	2,53	2,76	2,46	2,81	3,13
$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5	
MED	$r_P$	-0,03	0,03	-0,01	0,01	0,01	-0,01	0,02	-0,01	-0,02	0,00
	$r_N$	-0,03	0,04	-0,01	0,01	0,01	-0,01	0,03	-0,01	-0,02	0,01
	$r_R$	-0,04	0,04	-0,02	0,01	0,00	-0,01	0,03	-0,01	-0,01	0,00
	$r_P$	0,90	0,96	0,94	0,94	0,95	0,90	0,95	0,90	0,91	0,94
DP	$r_N$	1,03	1,05	1,01	1,00	1,01	1,00	1,03	1,00	0,99	1,00
	$r_R$	1,17	1,04	1,02	1,24	1,15	1,15	0,99	1,18	1,32	1,17
	$r_P$	0,38	0,47	0,71	1,02	1,35	0,39	0,49	0,52	0,96	1,30
	$r_N$	0,30	0,92	0,71	0,99	1,32	0,40	0,50	0,49	0,94	1,27
CS	$r_R$	0,24	0,26	0,44	0,73	0,94	0,25	0,26	0,35	0,70	0,93
	$r_P$	3,05	3,21	3,20	3,55	4,48	3,05	3,23	3,03	3,62	4,29
	$r_N$	5,09	9,46	3,63	3,74	4,81	3,45	3,71	3,32	3,97	4,59
	$r_R$	2,57	2,46	2,49	2,73	2,85	2,49	2,45	2,55	2,93	2,91
$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5	
MED	$r_P$	0,00	-0,01	-0,01	0,01	0,01	-0,01	-0,01	-0,01	-0,01	0,02
	$r_N$	0,00	-0,02	-0,02	0,01	0,01	-0,01	-0,01	-0,02	-0,01	0,02
	$r_R$	0,00	-0,01	-0,03	0,02	0,03	-0,01	-0,01	-0,02	-0,02	0,00
	$r_P$	0,92	0,91	0,94	0,93	0,95	0,92	0,92	0,91	0,95	0,96
DP	$r_N$	1,02	1,03	1,01	1,00	1,02	1,01	1,01	0,99	1,01	1,02
	$r_R$	1,17	1,09	1,03	1,22	1,30	1,03	1,05	0,97	1,16	1,18
	$r_P$	0,35	0,33	0,77	1,05	1,17	0,44	0,42	0,72	1,20	1,33
	$r_N$	0,32	0,31	0,78	1,06	1,22	0,47	0,47	0,95	1,11	1,28
CS	$r_R$	0,25	0,21	0,46	0,73	0,87	0,26	0,26	0,44	0,82	0,94
	$r_P$	2,92	3,01	3,41	3,60	3,91	3,03	3,19	3,17	4,09	4,35
	$r_N$	3,80	4,29	4,07	4,11	4,89	3,56	3,96	7,06	4,61	4,69
	$r_R$	2,48	2,41	2,58	2,77	2,98	2,46	2,51	2,59	2,76	2,93
$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5	
MED	$r_P$	0,01	0,00	-0,02	0,01	0,02	0,03	0,02	0,03	0,01	0,00
	$r_N$	0,01	0,00	-0,03	0,00	0,02	0,03	0,01	0,02	0,01	-0,01
	$r_R$	0,00	0,00	-0,03	-0,01	0,04	0,03	0,01	0,02	0,01	-0,03
	$r_P$	0,95	0,93	0,92	0,96	0,94	0,95	0,95	0,96	0,95	0,93
DP	$r_N$	1,03	1,00	0,99	1,03	1,01	1,04	1,02	1,02	1,01	0,98
	$r_R$	1,14	1,00	1,17	1,15	1,25	1,08	1,00	1,10	1,28	1,05
	$r_P$	0,39	0,46	0,56	1,19	1,15	0,49	0,46	0,66	1,02	1,44
	$r_N$	0,51	0,56	0,54	1,21	1,12	0,70	0,49	0,68	0,98	1,40
CS	$r_R$	0,24	0,28	0,39	0,78	0,86	0,26	0,27	0,39	0,71	1,02
	$r_P$	2,93	3,14	3,01	4,10	3,69	3,25	3,08	3,21	3,59	4,81
	$r_N$	3,68	4,35	3,33	4,81	3,97	5,59	4,54	3,60	3,82	5,00
	$r_R$	2,42	2,52	2,61	2,66	2,79	2,41	2,51	2,43	2,77	2,99

Fonte: O autor (2016).

**Tabela 4.41** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10$ .

	$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,22	0,35	-0,09	-0,27	0,00	-0,25	0,32	-0,10	-0,23	0,05
	$r_N$	-0,23	0,46	-0,08	-0,29	0,02	-0,28	0,40	-0,10	-0,25	0,07
	$r_R$	-0,27	0,43	-0,11	-0,37	-0,01	-0,31	0,36	-0,12	-0,34	0,08
	$r_P$	0,90	1,04	0,94	0,79	0,95	0,86	1,05	0,92	0,84	0,97
DP	$r_N$	0,94	1,09	0,98	0,81	0,99	0,92	1,11	0,96	0,87	1,02
	$r_R$	1,04	0,99	1,05	0,93	1,00	0,97	0,95	1,02	1,05	1,21
	$r_P$	0,49	0,38	0,74	1,29	1,48	0,46	0,50	0,76	1,22	1,20
	$r_N$	0,47	0,41	0,73	1,19	1,49	0,39	0,55	0,82	1,18	1,17
CS	$r_R$	0,36	0,18	0,42	0,91	1,10	0,34	0,28	0,45	0,84	0,87
	$r_P$	3,03	2,98	3,34	4,39	4,69	3,03	3,07	3,59	4,24	3,90
	$r_N$	3,13	3,23	3,67	4,57	5,12	3,50	3,32	4,23	4,68	4,15
	$r_R$	2,53	2,42	2,53	3,04	3,03	2,65	2,46	2,57	2,97	2,85
	$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,18	0,24	-0,05	-0,24	0,06	-0,23	0,16	-0,07	-0,26	0,02
	$r_N$	-0,20	0,31	-0,04	-0,27	0,09	-0,24	0,24	-0,04	-0,27	0,06
	$r_R$	-0,24	0,27	-0,06	-0,39	0,08	-0,27	0,21	-0,07	-0,34	0,03
	$r_P$	0,91	1,02	0,94	0,84	0,98	0,86	0,96	0,93	0,80	0,96
DP	$r_N$	0,96	1,08	0,99	0,86	1,02	0,94	1,05	0,96	0,83	1,02
	$r_R$	1,03	0,91	1,12	1,13	1,17	0,96	0,86	1,08	0,95	1,01
	$r_P$	0,48	0,45	0,64	1,08	1,25	0,50	0,46	0,67	1,28	1,55
	$r_N$	0,52	0,50	0,63	1,02	1,22	0,49	0,48	0,65	1,20	1,63
CS	$r_R$	0,30	0,32	0,38	0,71	0,86	0,33	0,39	0,37	0,91	1,05
	$r_P$	3,15	2,97	3,19	3,84	4,17	3,28	3,06	3,23	4,32	5,35
	$r_N$	3,55	3,31	3,43	4,11	4,40	3,58	3,26	3,38	4,53	6,33
	$r_R$	2,53	2,63	2,56	2,93	2,75	2,66	2,86	2,52	3,02	2,96
	$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,18	0,37	-0,13	-0,23	0,05	-0,17	0,31	-0,06	-0,26	0,05
	$r_N$	-0,21	0,46	-0,14	-0,26	0,08	-0,19	0,39	-0,06	-0,30	0,08
	$r_R$	-0,26	0,41	-0,16	-0,37	0,06	-0,25	0,34	-0,09	-0,43	0,07
	$r_P$	0,87	1,07	0,90	0,83	0,99	0,87	1,04	0,90	0,81	0,98
DP	$r_N$	0,97	1,12	0,94	0,85	1,04	0,95	1,10	0,96	0,85	1,03
	$r_R$	1,12	0,96	0,97	1,11	1,12	1,11	0,93	1,14	1,17	1,13
	$r_P$	0,41	0,47	0,70	1,07	1,32	0,42	0,48	0,56	1,01	1,29
	$r_N$	0,48	0,54	0,67	1,03	1,35	0,40	0,51	0,57	0,92	1,29
CS	$r_R$	0,26	0,19	0,47	0,77	0,93	0,25	0,25	0,34	0,63	0,91
	$r_P$	3,10	3,19	3,20	3,81	4,28	3,08	3,16	3,12	3,77	4,22
	$r_N$	3,81	3,55	3,49	4,08	4,92	3,21	3,43	3,44	4,01	4,45
	$r_R$	2,62	2,44	2,60	2,99	2,68	2,52	2,45	2,59	3,01	2,69
	$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,16	0,38	-0,12	-0,23	0,09	-0,23	0,35	-0,14	-0,25	0,06
	$r_N$	-0,20	0,48	-0,13	-0,27	0,11	-0,26	0,45	-0,15	-0,27	0,09
	$r_R$	-0,24	0,47	-0,16	-0,36	0,13	-0,30	0,42	-0,16	-0,36	0,08
	$r_P$	0,88	1,01	0,93	0,83	1,00	0,87	1,03	0,87	0,82	0,99
DP	$r_N$	0,96	1,09	0,96	0,85	1,05	0,93	1,09	0,92	0,85	1,04
	$r_R$	1,11	1,01	1,00	1,09	1,26	0,99	0,98	0,93	1,03	1,13
	$r_P$	0,35	0,30	0,82	1,12	1,15	0,45	0,41	0,72	1,20	1,29
	$r_N$	0,32	0,37	0,80	1,04	1,18	0,43	0,49	0,69	1,17	1,28
CS	$r_R$	0,24	0,15	0,51	0,75	0,82	0,29	0,18	0,46	0,84	0,91
	$r_P$	2,91	2,86	3,54	3,94	3,86	3,02	3,12	3,17	4,21	4,22
	$r_N$	3,02	3,15	3,77	4,22	4,26	3,26	3,68	3,34	4,73	4,43
	$r_R$	2,49	2,37	2,68	3,02	2,73	2,55	2,50	2,70	2,99	2,71
	$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,17	0,32	-0,08	-0,24	0,08	-0,17	0,33	-0,06	-0,22	0,03
	$r_N$	-0,20	0,39	-0,09	-0,27	0,11	-0,20	0,40	-0,06	-0,25	0,05
	$r_R$	-0,26	0,35	-0,12	-0,36	0,12	-0,24	0,35	-0,09	-0,36	0,03
	$r_P$	0,91	1,03	0,92	0,83	1,00	0,90	1,04	0,94	0,85	0,96
DP	$r_N$	0,96	1,07	0,96	0,85	1,04	0,96	1,09	0,97	0,87	1,01
	$r_R$	1,09	0,93	1,14	1,02	1,21	1,03	0,93	1,06	1,14	1,03
	$r_P$	0,40	0,42	0,61	1,21	1,15	0,50	0,44	0,69	1,05	1,42
	$r_N$	0,48	0,47	0,63	1,16	1,14	0,51	0,50	0,70	1,03	1,39
CS	$r_R$	0,26	0,24	0,43	0,81	0,81	0,29	0,23	0,42	0,68	1,00
	$r_P$	2,95	3,02	3,07	4,17	3,71	3,30	3,07	3,26	3,76	4,71
	$r_N$	3,41	3,33	3,36	4,69	3,92	3,68	3,45	3,65	4,31	4,98
	$r_R$	2,49	2,49	2,66	2,90	2,58	2,50	2,49	2,52	2,86	2,83

Fonte: O autor (2016).

**Tabela 4.42** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10.000$ .

	$r_{(\cdot)i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,39	0,68	0,02	-0,35	-0,15	-0,42	0,61	0,02	-0,30	-0,10
	$r_N$	-0,43	0,82	0,05	-0,38	-0,15	-0,49	0,73	0,04	-0,32	-0,10
	$r_R$	-0,47	0,62	0,03	-0,46	-0,21	-0,51	0,52	0,02	-0,42	-0,16
	$r_P$	0,86	1,15	0,99	0,75	0,86	0,82	1,16	0,98	0,81	0,90
DP	$r_N$	0,89	1,18	1,02	0,76	0,88	0,87	1,20	1,00	0,83	0,92
	$r_R$	0,94	0,88	1,03	0,88	0,98	0,87	0,85	1,01	1,00	1,16
	$r_P$	0,50	0,42	0,75	1,29	1,51	0,47	0,55	0,78	1,23	1,26
	$r_N$	0,46	0,49	0,77	1,15	1,49	0,39	0,63	0,84	1,16	1,23
CS	$r_R$	0,45	0,10	0,38	0,96	1,05	0,41	0,23	0,39	0,90	0,82
	$r_P$	3,05	3,08	3,35	4,41	4,94	3,01	3,16	3,63	4,31	4,23
	$r_N$	3,12	3,34	3,67	4,52	5,37	3,47	3,53	4,26	4,65	4,67
	$r_R$	2,71	2,47	2,48	3,22	3,05	2,79	2,54	2,51	3,14	2,89
	$r_{(\cdot)i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,35	0,49	0,11	-0,30	-0,09	-0,41	0,37	0,07	-0,33	-0,13
	$r_N$	-0,40	0,59	0,14	-0,34	-0,09	-0,45	0,49	0,12	-0,35	-0,12
	$r_R$	-0,43	0,42	0,12	-0,47	-0,16	-0,46	0,34	0,10	-0,42	-0,17
	$r_P$	0,87	1,11	1,01	0,81	0,90	0,82	1,03	0,99	0,76	0,86
DP	$r_N$	0,91	1,15	1,04	0,82	0,92	0,88	1,11	1,01	0,77	0,88
	$r_R$	0,93	0,81	1,11	1,07	1,13	0,86	0,77	1,06	0,89	0,97
	$r_P$	0,48	0,47	0,67	1,09	1,30	0,50	0,48	0,70	1,28	1,57
	$r_N$	0,45	0,53	0,66	1,00	1,27	0,47	0,54	0,69	1,18	1,60
CS	$r_R$	0,39	0,31	0,31	0,74	0,83	0,42	0,43	0,31	0,96	1,02
	$r_P$	3,15	3,01	3,25	3,90	4,44	3,29	3,10	3,35	4,36	5,60
	$r_N$	3,35	3,29	3,45	4,10	4,66	3,46	3,35	3,50	4,42	6,50
	$r_R$	2,72	2,73	2,49	3,02	2,82	2,86	3,00	2,46	3,19	3,05
	$r_{(\cdot)i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,33	0,68	-0,02	-0,30	-0,10	-0,31	0,60	0,11	-0,32	-0,10
	$r_N$	-0,39	0,80	-0,02	-0,34	-0,10	-0,38	0,69	0,13	-0,37	-0,10
	$r_R$	-0,46	0,58	-0,03	-0,45	-0,16	-0,45	0,50	0,12	-0,51	-0,16
	$r_P$	0,85	1,18	0,95	0,81	0,90	0,84	1,14	0,98	0,79	0,89
DP	$r_N$	0,93	1,21	0,98	0,81	0,91	0,91	1,18	1,02	0,82	0,91
	$r_R$	1,02	0,86	0,96	1,05	1,07	1,02	0,83	1,12	1,11	1,08
	$r_P$	0,41	0,50	0,74	1,08	1,34	0,44	0,52	0,60	1,01	1,34
	$r_N$	0,41	0,60	0,72	1,02	1,34	0,39	0,58	0,62	0,91	1,33
CS	$r_R$	0,30	0,14	0,43	0,81	0,91	0,32	0,21	0,28	0,66	0,90
	$r_P$	3,05	3,26	3,31	3,86	4,44	3,12	3,25	3,18	3,82	4,49
	$r_N$	3,53	3,68	3,50	4,07	4,96	3,16	3,50	3,44	4,05	4,82
	$r_R$	2,72	2,49	2,56	3,11	2,77	2,64	2,50	2,52	3,07	2,79
	$r_{(\cdot)i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,31	0,74	0,00	-0,30	-0,07	-0,41	0,68	-0,05	-0,32	-0,10
	$r_N$	-0,39	0,86	0,00	-0,34	-0,07	-0,47	0,82	-0,04	-0,35	-0,09
	$r_R$	-0,44	0,67	-0,03	-0,45	-0,12	-0,50	0,62	-0,06	-0,44	-0,15
	$r_P$	0,85	1,13	0,98	0,80	0,92	0,83	1,14	0,91	0,79	0,90
DP	$r_N$	0,92	1,19	1,00	0,81	0,95	0,88	1,18	0,95	0,80	0,92
	$r_R$	1,00	0,88	0,99	1,02	1,20	0,90	0,86	0,92	0,97	1,08
	$r_P$	0,35	0,36	0,85	1,12	1,24	0,45	0,46	0,75	1,19	1,34
	$r_N$	0,27	0,48	0,81	1,00	1,33	0,40	0,60	0,73	1,08	1,31
CS	$r_R$	0,30	0,07	0,47	0,81	0,80	0,37	0,12	0,43	0,88	0,89
	$r_P$	2,89	2,97	3,65	3,95	4,33	3,04	3,24	3,28	4,18	4,46
	$r_N$	3,09	3,39	4,03	4,20	5,57	3,21	3,79	3,41	4,44	4,67
	$r_R$	2,61	2,42	2,61	3,19	2,85	2,72	2,54	2,68	3,12	2,78
	$r_{(\cdot)i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,33	0,61	0,09	-0,31	-0,07	-0,34	0,62	0,07	-0,28	-0,12
	$r_N$	-0,39	0,71	0,10	-0,35	-0,07	-0,40	0,72	0,08	-0,32	-0,13
	$r_R$	-0,45	0,52	0,09	-0,45	-0,12	-0,44	0,52	0,07	-0,44	-0,18
	$r_P$	0,87	1,13	0,99	0,80	0,92	0,87	1,14	1,00	0,82	0,87
DP	$r_N$	0,92	1,17	1,02	0,81	0,93	0,91	1,18	1,02	0,84	0,89
	$r_R$	0,99	0,83	1,12	0,97	1,16	0,93	0,83	1,05	1,08	0,99
	$r_P$	0,41	0,47	0,65	1,20	1,22	0,50	0,49	0,72	1,06	1,47
	$r_N$	0,47	0,63	0,69	1,10	1,20	0,48	0,61	0,73	1,00	1,42
CS	$r_R$	0,34	0,18	0,36	0,87	0,79	0,38	0,21	0,37	0,74	0,98
	$r_P$	2,98	3,16	3,19	4,15	4,18	3,30	3,16	3,36	3,79	5,08
	$r_N$	3,46	4,29	3,49	4,50	4,49	3,66	3,74	3,64	4,12	5,38
	$r_R$	2,66	2,57	2,57	3,08	2,66	2,69	2,55	2,46	3,09	2,94

Fonte: O autor (2016).

**Tabela 4.43** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 0,01$ .

$r(\cdot)i,j$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5	
MED	$r_P$	0,02	0,01	-0,01	0,00	-0,01	0,01	-0,02	-0,01	0,00	-0,02
	$r_N$	0,02	0,01	-0,01	0,00	-0,01	0,02	-0,02	-0,01	0,01	-0,02
	$r_R$	0,02	0,00	-0,02	-0,01	-0,03	0,02	-0,01	-0,01	0,00	-0,03
	$r_P$	0,96	0,95	0,95	0,95	0,95	0,94	0,95	0,96	0,95	0,92
DP	$r_N$	1,02	1,04	1,01	1,01	1,00	1,02	1,02	1,02	1,01	0,99
	$r_R$	1,09	1,09	1,06	1,05	1,04	1,03	1,03	1,08	1,15	1,24
	$r_P$	0,54	0,49	0,71	1,26	1,54	0,49	0,46	0,71	1,18	1,22
	$r_N$	0,53	0,55	0,74	1,26	1,51	0,49	0,42	0,68	1,17	1,21
CS	$r_R$	0,26	0,27	0,42	0,86	1,11	0,27	0,27	0,39	0,79	0,91
	$r_P$	3,41	3,15	3,31	4,16	5,12	3,19	3,10	3,21	4,08	4,15
	$r_N$	3,56	4,33	3,94	4,67	5,15	3,34	3,27	3,57	4,57	4,42
	$r_R$	2,49	2,46	2,46	2,68	3,12	2,48	2,42	2,45	2,70	3,07
$r(\cdot)i,j$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5	
MED	$r_P$	-0,01	-0,01	0,01	0,01	0,00	0,00	-0,01	0,02	-0,04	-0,02
	$r_N$	-0,01	-0,02	0,01	0,01	0,00	0,01	-0,02	0,03	-0,04	-0,01
	$r_R$	-0,01	-0,01	0,02	0,03	-0,01	0,01	-0,02	0,03	-0,06	-0,03
	$r_P$	0,94	0,93	0,94	0,93	0,95	0,92	0,87	0,94	0,92	0,93
DP	$r_N$	1,01	1,01	1,03	1,00	1,01	1,00	0,99	1,01	0,99	0,99
	$r_R$	1,07	0,96	1,16	1,27	1,22	1,02	0,90	1,13	1,05	1,03
	$r_P$	0,54	0,47	0,69	1,00	1,25	0,49	0,44	0,62	1,27	1,54
	$r_N$	0,55	0,44	0,73	0,98	1,24	0,47	0,45	0,64	1,31	1,49
CS	$r_R$	0,32	0,26	0,41	0,70	0,93	0,31	0,26	0,35	0,91	1,08
	$r_P$	3,32	3,16	3,35	3,64	4,06	3,11	3,14	3,12	4,09	5,14
	$r_N$	3,47	3,38	4,33	4,07	4,23	3,27	3,50	3,64	5,01	5,22
	$r_R$	2,47	2,55	2,56	2,81	2,95	2,49	2,71	2,49	2,84	3,07
$r(\cdot)i,j$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5	
MED	$r_P$	-0,01	0,02	0,01	0,01	0,02	-0,02	0,02	0,00	-0,01	-0,01
	$r_N$	-0,02	0,02	0,01	0,00	0,02	-0,02	0,02	0,00	-0,01	-0,01
	$r_R$	-0,02	0,02	0,00	0,00	0,01	-0,02	0,02	0,02	0,00	-0,02
	$r_P$	0,90	0,94	0,95	0,95	0,96	0,90	0,94	0,92	0,93	0,94
DP	$r_N$	1,00	1,02	1,03	1,01	1,01	0,99	1,01	1,01	1,01	0,99
	$r_R$	1,17	1,04	1,03	1,24	1,15	1,16	0,98	1,18	1,32	1,15
	$r_P$	0,43	0,45	0,78	1,03	1,31	0,39	0,40	0,64	0,99	1,33
	$r_N$	0,38	0,43	0,89	1,01	1,28	0,35	0,35	0,62	0,93	1,30
CS	$r_R$	0,28	0,24	0,43	0,71	0,98	0,26	0,24	0,41	0,69	0,98
	$r_P$	3,13	3,09	3,52	3,56	4,26	3,06	3,04	3,35	3,61	4,39
	$r_N$	3,12	3,55	4,72	3,94	4,32	3,12	3,48	3,85	4,00	4,42
	$r_R$	2,59	2,43	2,54	2,69	2,95	2,57	2,51	2,64	2,90	2,97
$r(\cdot)i,j$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5	
MED	$r_P$	-0,01	0,00	-0,01	-0,01	0,02	-0,02	-0,01	0,00	0,00	0,00
	$r_N$	-0,01	0,01	-0,01	-0,01	0,02	-0,02	0,00	0,00	-0,01	0,00
	$r_R$	0,00	0,01	-0,01	-0,01	0,03	-0,03	0,00	-0,01	-0,01	-0,01
	$r_P$	0,91	0,89	0,93	0,95	0,92	0,91	0,92	0,94	0,95	0,95
DP	$r_N$	1,00	1,01	1,00	1,03	0,99	0,98	1,01	1,02	1,00	1,00
	$r_R$	1,16	1,09	1,03	1,24	1,27	1,01	1,06	0,99	1,14	1,15
	$r_P$	0,44	0,38	0,69	1,17	1,10	0,50	0,38	0,76	1,17	1,37
	$r_N$	0,41	0,37	0,72	1,26	1,06	0,47	0,38	0,79	1,17	1,32
CS	$r_R$	0,26	0,21	0,45	0,77	0,84	0,30	0,22	0,44	0,79	0,97
	$r_P$	3,22	3,08	3,21	4,35	3,73	3,15	3,03	3,35	4,07	4,58
	$r_N$	3,28	3,43	4,02	5,53	3,83	3,22	3,74	3,91	4,37	4,70
	$r_R$	2,53	2,47	2,54	2,84	2,96	2,49	2,42	2,52	2,71	2,93
$r(\cdot)i,j$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5	
MED	$r_P$	0,01	0,03	-0,01	0,00	0,02	0,01	-0,02	-0,01	-0,01	0,00
	$r_N$	0,00	0,03	-0,02	0,00	0,02	0,01	-0,02	-0,01	-0,01	0,00
	$r_R$	0,00	0,03	-0,03	-0,01	0,03	0,01	-0,03	-0,01	-0,02	-0,02
	$r_P$	0,95	0,94	0,92	0,96	0,95	0,96	0,94	0,95	0,95	0,96
DP	$r_N$	1,02	1,02	1,01	1,02	1,02	1,01	1,01	1,01	1,02	1,01
	$r_R$	1,14	1,01	1,19	1,16	1,25	1,08	1,00	1,09	1,26	1,07
	$r_P$	0,53	0,46	0,60	1,20	1,19	0,53	0,48	0,74	1,12	1,50
	$r_N$	0,46	0,48	0,60	1,23	1,16	0,53	0,47	0,71	1,18	1,48
CS	$r_R$	0,31	0,23	0,37	0,82	0,89	0,31	0,27	0,42	0,74	1,08
	$r_P$	3,23	3,16	3,13	4,03	3,94	3,23	3,15	3,49	4,01	4,90
	$r_N$	3,38	3,59	3,53	4,72	4,08	3,30	3,70	3,75	4,89	5,01
	$r_R$	2,51	2,48	2,56	2,72	2,95	2,49	2,53	2,51	2,87	3,06

Fonte: O autor (2016).

**Tabela 4.44** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 10$ .

	$r(\cdot)i,j$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,14	0,41	-0,10	-0,25	0,00	-0,17	0,33	-0,09	-0,25	0,03
	$r_N$	-0,19	0,48	-0,11	-0,26	0,03	-0,22	0,39	-0,10	-0,26	0,06
	$r_R$	-0,23	0,45	-0,14	-0,33	0,00	-0,25	0,36	-0,12	-0,35	0,06
	$r_P$	0,93	1,07	0,92	0,81	0,96	0,89	1,06	0,93	0,82	0,97
DP	$r_N$	0,97	1,13	0,95	0,84	1,01	0,95	1,11	0,97	0,85	1,03
	$r_R$	1,05	1,01	1,02	0,95	1,02	1,00	0,95	1,04	1,03	1,21
	$r_P$	0,54	0,47	0,73	1,29	1,50	0,50	0,46	0,74	1,21	1,25
	$r_N$	0,51	0,49	0,69	1,31	1,48	0,48	0,46	0,70	1,20	1,23
CS	$r_R$	0,28	0,21	0,46	0,90	1,10	0,31	0,23	0,41	0,82	0,88
	$r_P$	3,43	3,04	3,30	4,48	4,83	3,22	3,07	3,29	4,26	4,25
	$r_N$	3,53	3,34	3,85	5,38	4,85	3,29	3,21	3,69	4,94	4,52
	$r_R$	2,55	2,41	2,56	2,94	2,99	2,59	2,44	2,55	2,96	2,84
	$r(\cdot)i,j$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,17	0,27	-0,05	-0,25	0,04	-0,19	0,21	-0,05	-0,28	-0,01
	$r_N$	-0,21	0,32	-0,04	-0,26	0,07	-0,22	0,28	-0,04	-0,29	0,02
	$r_R$	-0,25	0,28	-0,06	-0,37	0,06	-0,24	0,24	-0,06	-0,37	0,00
	$r_P$	0,90	1,02	0,94	0,82	0,98	0,86	0,94	0,94	0,80	0,95
DP	$r_N$	0,95	1,07	0,98	0,84	1,03	0,93	1,04	0,98	0,83	0,99
	$r_R$	1,03	0,89	1,12	1,13	1,18	0,97	0,83	1,09	0,95	1,01
	$r_P$	0,57	0,46	0,70	1,03	1,24	0,50	0,42	0,68	1,30	1,52
	$r_N$	0,57	0,47	0,71	0,97	1,24	0,47	0,46	0,69	1,31	1,49
CS	$r_R$	0,36	0,29	0,42	0,69	0,88	0,34	0,31	0,38	0,96	1,08
	$r_P$	3,39	3,07	3,26	3,80	4,03	3,13	3,08	3,29	4,27	5,09
	$r_N$	3,49	3,26	3,63	4,09	4,12	3,14	3,43	3,59	4,99	5,03
	$r_R$	2,57	2,61	2,55	2,98	2,70	2,61	2,82	2,55	3,10	2,95
	$r(\cdot)i,j$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,12	0,38	-0,10	-0,25	0,05	-0,13	0,35	-0,04	-0,26	0,02
	$r_N$	-0,18	0,44	-0,11	-0,27	0,07	-0,18	0,40	-0,04	-0,29	0,04
	$r_R$	-0,23	0,40	-0,13	-0,38	0,06	-0,23	0,35	-0,06	-0,42	0,03
	$r_P$	0,88	1,05	0,92	0,83	0,98	0,88	1,04	0,92	0,82	0,97
DP	$r_N$	0,96	1,10	0,96	0,85	1,02	0,97	1,09	0,98	0,86	1,01
	$r_R$	1,12	0,95	0,98	1,11	1,12	1,13	0,92	1,15	1,19	1,12
	$r_P$	0,43	0,42	0,80	1,08	1,28	0,44	0,40	0,66	1,01	1,33
	$r_N$	0,37	0,45	0,78	1,07	1,27	0,40	0,52	0,65	0,93	1,30
CS	$r_R$	0,26	0,19	0,48	0,72	0,94	0,25	0,22	0,39	0,66	0,94
	$r_P$	3,14	2,99	3,54	3,80	4,15	3,15	3,05	3,40	3,66	4,50
	$r_N$	3,12	3,25	3,81	4,33	4,16	3,48	4,06	4,11	3,88	4,49
	$r_R$	2,61	2,41	2,68	2,86	2,70	2,57	2,52	2,63	3,09	2,72
	$r(\cdot)i,j$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,13	0,43	-0,10	-0,26	0,08	-0,20	0,38	-0,12	-0,26	0,03
	$r_N$	-0,19	0,52	-0,11	-0,28	0,11	-0,25	0,47	-0,12	-0,27	0,06
	$r_R$	-0,23	0,49	-0,13	-0,39	0,12	-0,29	0,44	-0,15	-0,36	0,04
	$r_P$	0,88	1,01	0,91	0,82	0,97	0,87	1,04	0,90	0,82	0,97
DP	$r_N$	0,95	1,10	0,94	0,85	1,02	0,93	1,10	0,95	0,84	1,02
	$r_R$	1,11	1,00	1,00	1,09	1,24	0,98	0,98	0,95	1,02	1,11
	$r_P$	0,44	0,39	0,71	1,24	1,10	0,52	0,39	0,76	1,23	1,36
	$r_N$	0,41	0,56	0,71	1,17	1,09	0,50	0,36	0,79	1,22	1,34
CS	$r_R$	0,28	0,14	0,48	0,78	0,78	0,32	0,16	0,46	0,85	0,96
	$r_P$	3,22	3,03	3,24	4,68	3,74	3,22	2,99	3,32	4,35	4,50
	$r_N$	3,35	4,62	3,50	5,10	3,81	3,26	3,39	3,77	4,83	4,54
	$r_R$	2,59	2,45	2,63	3,05	2,68	2,55	2,41	2,63	3,01	2,76
	$r(\cdot)i,j$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,13	0,38	-0,06	-0,25	0,07	-0,15	0,31	-0,09	-0,26	0,01
	$r_N$	-0,18	0,43	-0,07	-0,27	0,10	-0,19	0,36	-0,09	-0,27	0,04
	$r_R$	-0,23	0,39	-0,10	-0,36	0,10	-0,23	0,32	-0,12	-0,39	0,01
	$r_P$	0,92	1,04	0,93	0,83	0,99	0,92	1,04	0,93	0,83	0,98
DP	$r_N$	0,97	1,10	0,98	0,85	1,04	0,96	1,09	0,96	0,86	1,02
	$r_R$	1,10	0,93	1,15	1,03	1,21	1,05	0,92	1,05	1,13	1,05
	$r_P$	0,55	0,44	0,62	1,25	1,18	0,55	0,47	0,78	1,14	1,47
	$r_N$	0,50	0,42	0,63	1,21	1,18	0,55	0,36	0,82	1,21	1,45
CS	$r_R$	0,32	0,18	0,37	0,88	0,85	0,35	0,25	0,46	0,72	1,07
	$r_P$	3,26	3,10	3,15	4,35	3,88	3,26	3,11	3,65	4,18	4,66
	$r_N$	3,42	3,50	3,39	4,96	4,04	3,36	4,33	4,25	5,18	4,71
	$r_R$	2,53	2,47	2,58	3,05	2,70	2,58	2,52	2,56	2,94	2,90

Fonte: O autor (2016).

**Tabela 4.45** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal Poisson, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 10.000$ .

	$r_{(\cdot)i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,25	0,78	0,03	-0,32	-0,15	-0,30	0,66	0,04	-0,32	-0,13
	$r_N$	-0,38	0,88	0,00	-0,35	-0,13	-0,41	0,75	0,02	-0,34	-0,10
	$r_R$	-0,42	0,63	-0,02	-0,42	-0,19	-0,42	0,52	0,00	-0,42	-0,16
	$r_P$	0,91	1,21	0,99	0,78	0,87	0,87	1,18	1,00	0,79	0,89
DP	$r_N$	0,96	1,32	1,03	0,82	0,91	0,93	1,26	1,05	0,83	0,94
	$r_R$	0,97	0,90	1,00	0,91	0,99	0,92	0,85	1,03	0,98	1,16
	$r_P$	0,58	0,57	0,77	1,29	1,50	0,53	0,55	0,78	1,22	1,32
	$r_N$	0,32	1,11	0,81	1,18	1,43	0,37	0,73	0,78	0,92	1,36
CS	$r_R$	0,36	0,12	0,41	0,93	1,06	0,37	0,15	0,36	0,87	0,85
	$r_P$	3,55	3,35	3,43	4,57	4,83	3,33	3,34	3,41	4,29	4,63
	$r_N$	4,23	7,42	4,61	5,73	5,03	3,43	4,44	4,53	5,14	5,73
	$r_R$	2,66	2,48	2,52	3,09	3,05	2,72	2,52	2,50	3,15	2,92
	$r_{(\cdot)i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,29	0,55	0,11	-0,31	-0,12	-0,31	0,45	0,10	-0,35	-0,16
	$r_N$	-0,39	0,63	0,12	-0,34	-0,10	-0,41	0,55	0,11	-0,37	-0,14
	$r_R$	-0,41	0,43	0,10	-0,45	-0,16	-0,40	0,37	0,08	-0,44	-0,19
	$r_P$	0,89	1,12	1,02	0,79	0,90	0,84	1,02	1,01	0,76	0,85
DP	$r_N$	0,94	1,20	1,07	0,84	0,94	0,92	1,14	1,06	0,81	0,89
	$r_R$	0,95	0,80	1,11	1,07	1,13	0,88	0,74	1,07	0,90	0,96
	$r_P$	0,61	0,51	0,74	1,05	1,32	0,54	0,51	0,74	1,30	1,57
	$r_N$	0,52	0,66	0,75	0,85	1,28	0,35	0,81	0,82	1,18	1,50
CS	$r_R$	0,44	0,25	0,36	0,71	0,85	0,41	0,30	0,32	1,00	1,07
	$r_P$	3,47	3,17	3,34	3,89	4,46	3,23	3,40	3,45	4,32	5,55
	$r_N$	3,62	3,92	3,77	5,06	4,71	4,17	5,81	4,57	5,46	5,42
	$r_R$	2,73	2,71	2,48	3,10	2,80	2,79	2,93	2,48	3,29	3,05
	$r_{(\cdot)i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,21	0,72	0,02	-0,31	-0,11	-0,22	0,66	0,14	-0,32	-0,13
	$r_N$	-0,35	0,80	-0,01	-0,34	-0,09	-0,34	0,72	0,13	-0,36	-0,12
	$r_R$	-0,39	0,57	-0,03	-0,45	-0,14	-0,40	0,51	0,12	-0,50	-0,17
	$r_P$	0,87	1,16	0,98	0,80	0,89	0,88	1,15	1,00	0,80	0,89
DP	$r_N$	0,96	1,23	1,03	0,85	0,92	0,96	1,21	1,07	0,87	0,92
	$r_R$	1,04	0,85	0,97	1,05	1,06	1,05	0,82	1,13	1,14	1,08
	$r_P$	0,48	0,48	0,84	1,09	1,35	0,50	0,45	0,68	1,01	1,40
	$r_N$	0,26	0,59	0,90	0,92	1,28	0,37	0,63	0,79	0,71	1,34
CS	$r_R$	0,31	0,13	0,45	0,74	0,92	0,28	0,18	0,32	0,68	0,94
	$r_P$	3,25	3,16	3,68	3,88	4,64	3,31	3,15	3,50	3,68	4,98
	$r_N$	3,51	3,71	4,47	4,83	4,58	3,91	3,91	4,95	5,27	4,98
	$r_R$	2,72	2,50	2,63	2,94	2,79	2,65	2,63	2,54	3,20	2,83
	$r_{(\cdot)i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,22	0,82	0,03	-0,33	-0,08	-0,32	0,74	-0,02	-0,32	-0,13
	$r_N$	-0,36	0,93	0,00	-0,36	-0,06	-0,44	0,85	-0,04	-0,34	-0,11
	$r_R$	-0,40	0,68	-0,02	-0,46	-0,11	-0,47	0,62	-0,06	-0,43	-0,16
	$r_P$	0,87	1,15	0,97	0,80	0,90	0,85	1,16	0,96	0,79	0,89
DP	$r_N$	0,95	1,25	1,02	0,84	0,94	0,92	1,23	1,03	0,82	0,92
	$r_R$	1,02	0,88	0,99	1,03	1,18	0,91	0,87	0,93	0,97	1,07
	$r_P$	0,48	0,47	0,74	1,23	1,16	0,56	0,46	0,83	1,25	1,38
	$r_N$	0,32	0,73	0,73	1,05	1,13	0,35	0,56	1,01	1,11	1,29
CS	$r_R$	0,33	0,05	0,44	0,82	0,75	0,39	0,08	0,43	0,89	0,94
	$r_P$	3,27	3,22	3,32	4,63	4,08	3,33	3,12	3,59	4,45	4,61
	$r_N$	3,47	4,74	3,91	4,95	4,13	3,75	3,63	5,57	5,15	4,64
	$r_R$	2,72	2,53	2,60	3,19	2,76	2,71	2,49	2,61	3,19	2,84
	$r_{(\cdot)i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,23	0,71	0,11	-0,32	-0,09	-0,26	0,63	0,05	-0,32	-0,14
	$r_N$	-0,35	0,78	0,10	-0,36	-0,08	-0,37	0,70	0,03	-0,34	-0,12
	$r_R$	-0,40	0,55	0,07	-0,44	-0,12	-0,40	0,49	0,01	-0,46	-0,17
	$r_P$	0,91	1,16	1,01	0,80	0,90	0,91	1,15	0,99	0,81	0,89
DP	$r_N$	0,97	1,23	1,08	0,84	0,94	0,95	1,23	1,03	0,85	0,92
	$r_R$	1,01	0,83	1,13	0,98	1,15	0,97	0,82	1,03	1,07	1,01
	$r_P$	0,57	0,52	0,67	1,26	1,23	0,59	0,54	0,81	1,13	1,47
	$r_N$	0,35	0,71	0,85	1,00	1,18	0,50	0,75	0,84	1,08	1,40
CS	$r_R$	0,37	0,14	0,31	0,93	0,82	0,43	0,21	0,41	0,74	1,05
	$r_P$	3,36	3,35	3,34	4,39	4,20	3,35	3,30	3,77	4,10	4,75
	$r_N$	3,93	4,29	4,72	5,11	4,22	3,40	4,56	4,42	4,93	4,84
	$r_R$	2,63	2,55	2,51	3,25	2,77	2,73	2,59	2,50	3,06	2,98

Fonte: O autor (2016).

**Tabela 4.46** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização  $\alpha = 0,01$ .

$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5	
MED	$r_P$	-0,02	-0,01	0,00	-0,03	0,02	-0,01	-0,02	0,01	0,01	-0,02
	$r_N$	-0,02	-0,01	0,01	-0,03	0,02	-0,01	-0,01	0,01	0,01	-0,02
	$r_R$	-0,02	-0,01	0,00	-0,03	0,02	-0,01	-0,01	0,01	0,00	-0,02
DP	$r_P$	1,05	1,04	1,07	1,00	1,03	1,02	1,03	1,07	1,07	1,02
	$r_N$	1,02	1,01	1,04	0,99	1,01	0,99	1,00	1,03	1,04	0,99
	$r_R$	1,07	1,04	1,07	1,05	1,07	0,96	0,95	1,09	1,31	1,49
CS	$r_P$	1,26	1,22	1,29	1,17	1,12	1,21	1,21	1,25	1,25	1,17
	$r_N$	1,35	1,33	1,40	1,24	1,19	1,26	1,33	1,33	1,34	1,22
	$r_R$	0,99	0,97	0,98	0,97	0,91	0,94	0,99	0,95	1,01	1,03
CK	$r_P$	4,43	4,36	4,64	4,26	4,06	4,51	4,42	4,51	4,44	4,32
	$r_N$	4,70	4,74	4,99	4,42	4,18	4,51	4,80	4,73	4,72	4,32
	$r_R$	3,17	3,21	3,17	3,24	3,02	3,26	3,44	3,09	3,65	4,06
$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5	
MED	$r_P$	0,03	0,01	0,02	0,01	0,00	0,00	-0,04	0,00	-0,01	-0,01
	$r_N$	0,03	0,01	0,02	0,01	0,00	0,00	-0,04	0,00	-0,01	-0,01
	$r_R$	0,03	0,00	0,03	0,01	0,00	0,00	-0,04	0,00	0,00	-0,01
DP	$r_P$	1,06	1,04	1,05	1,05	1,06	1,03	0,98	1,03	1,00	1,01
	$r_N$	1,01	1,02	1,02	1,03	1,02	1,02	0,99	1,00	0,99	1,00
	$r_R$	1,06	0,91	1,27	1,59	1,48	0,96	0,84	1,16	1,08	1,04
CS	$r_P$	1,16	1,24	1,19	1,20	1,24	1,21	1,15	1,21	1,16	1,13
	$r_N$	1,20	1,32	1,27	1,31	1,33	1,31	1,22	1,32	1,22	1,22
	$r_R$	0,89	1,09	1,01	1,16	1,09	1,01	1,08	0,98	0,93	0,94
CK	$r_P$	4,20	4,37	4,20	4,29	4,42	4,32	4,22	4,41	4,30	4,15
	$r_N$	4,20	4,58	4,46	4,61	4,62	4,60	4,29	4,73	4,40	4,32
	$r_R$	2,98	4,14	3,47	4,71	4,27	3,44	4,64	3,33	3,16	3,17
$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5	
MED	$r_P$	0,01	0,01	0,01	-0,01	0,03	-0,03	0,01	-0,02	-0,02	0,03
	$r_N$	0,01	0,00	0,01	-0,01	0,02	-0,03	0,01	-0,02	-0,02	0,03
	$r_R$	0,01	0,01	0,01	-0,01	0,02	-0,03	0,00	-0,02	-0,02	0,04
DP	$r_P$	1,03	1,03	1,06	1,04	1,04	1,06	1,02	1,06	1,00	1,06
	$r_N$	1,00	0,99	1,03	1,01	1,02	0,99	1,03	1,00	1,00	1,02
	$r_R$	1,28	0,98	1,00	1,50	1,28	1,28	0,96	1,34	1,55	1,33
CS	$r_P$	1,01	1,20	1,25	1,25	1,21	1,02	1,24	1,13	0,66	1,20
	$r_N$	1,21	1,28	1,32	1,33	1,29	1,26	1,32	1,23	1,22	1,27
	$r_R$	1,01	0,96	0,98	1,14	0,98	1,03	1,01	1,00	1,04	0,99
CK	$r_P$	5,09	4,33	4,49	4,56	4,32	5,56	4,37	4,24	10,09	4,31
	$r_N$	4,20	4,50	4,63	4,76	4,51	4,43	4,56	4,41	4,35	4,44
	$r_R$	3,62	3,28	3,24	4,54	3,50	3,64	3,61	3,67	4,09	3,63
$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5	
MED	$r_P$	-0,01	0,00	0,00	0,01	-0,01	0,01	0,00	-0,01	0,01	0,00
	$r_N$	-0,01	0,00	0,00	0,01	-0,01	0,01	0,01	-0,02	0,01	0,00
	$r_R$	-0,01	0,01	-0,01	0,01	-0,01	0,02	0,01	-0,01	0,00	-0,01
DP	$r_P$	1,03	1,01	1,04	1,05	1,03	1,04	1,04	1,02	1,07	1,06
	$r_N$	1,01	0,99	1,01	1,01	1,01	1,01	1,01	1,01	1,03	1,01
	$r_R$	1,28	1,08	1,03	1,49	1,55	0,99	1,05	0,94	1,30	1,28
CS	$r_P$	1,21	1,15	1,22	1,18	1,16	1,16	1,16	1,19	1,22	1,25
	$r_N$	1,29	1,21	1,31	1,23	1,24	1,25	1,27	1,25	1,32	1,32
	$r_R$	1,06	0,94	0,95	1,03	1,13	0,94	0,94	1,01	1,03	1,01
CK	$r_P$	4,30	4,23	4,35	4,20	4,21	4,21	4,17	4,32	4,31	4,37
	$r_N$	4,50	4,32	4,63	4,32	4,37	4,48	4,45	4,37	4,63	4,55
	$r_R$	3,65	3,16	3,13	4,22	4,47	3,18	3,10	3,61	3,65	3,60
$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5	
MED	$r_P$	0,01	0,03	-0,01	0,00	-0,01	0,00	0,04	0,02	0,00	-0,01
	$r_N$	0,00	0,03	-0,01	0,00	-0,01	0,00	0,03	0,02	-0,01	-0,01
	$r_R$	-0,01	0,03	-0,01	0,01	-0,02	-0,01	0,03	0,01	-0,02	-0,01
DP	$r_P$	1,07	1,06	1,00	1,05	1,03	1,07	1,09	1,06	1,05	1,02
	$r_N$	1,03	1,02	0,98	1,01	1,00	1,02	1,05	1,02	1,01	1,00
	$r_R$	1,20	0,98	1,29	1,28	1,45	1,08	0,98	1,13	1,56	1,10
CS	$r_P$	1,24	1,19	1,16	1,15	1,16	1,28	1,23	1,21	1,24	1,10
	$r_N$	1,31	1,28	1,23	1,24	1,26	1,35	1,29	1,31	1,29	1,21
	$r_R$	0,95	0,94	1,00	1,00	1,05	0,99	0,96	0,93	1,13	0,92
CK	$r_P$	4,41	4,21	4,31	4,11	4,16	4,58	4,27	4,34	4,45	4,07
	$r_N$	4,57	4,49	4,43	4,38	4,44	4,74	4,44	4,64	4,54	4,28
	$r_R$	3,24	3,17	3,69	3,57	4,17	3,18	3,24	3,12	4,71	3,10

Fonte: O autor (2016).

**Tabela 4.47** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10$ .

	$r_{(\cdot)i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,20	0,30	0,03	-0,26	0,05	-0,21	0,27	0,04	-0,22	0,08
	$r_N$	-0,21	0,31	0,03	-0,27	0,05	-0,22	0,29	0,04	-0,22	0,09
	$r_R$	-0,30	0,24	-0,02	-0,38	0,05	-0,29	0,20	-0,01	-0,39	0,12
	$r_P$	0,80	1,18	1,01	0,75	0,94	0,77	1,17	1,01	0,81	0,97
DP	$r_N$	0,80	1,21	1,01	0,75	0,98	0,78	1,20	1,00	0,80	1,00
	$r_R$	0,99	1,02	1,02	0,91	1,03	0,89	0,94	1,03	1,14	1,44
	$r_P$	1,52	1,18	1,45	1,52	1,16	1,54	1,19	1,45	1,67	1,17
	$r_N$	1,60	1,33	1,59	1,65	1,21	1,52	1,40	1,53	1,78	1,21
CS	$r_R$	1,11	0,86	0,97	1,18	0,93	1,05	0,93	0,94	1,12	1,05
	$r_P$	6,00	4,01	5,26	6,24	4,15	6,67	4,03	5,32	6,92	4,29
	$r_N$	6,10	4,64	5,87	6,46	4,25	5,92	4,92	5,64	7,23	4,24
	$r_R$	3,66	3,05	3,28	4,00	3,11	3,75	3,36	3,23	4,24	4,11
	$r_{(\cdot)i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,17	0,26	0,08	-0,20	0,10	-0,20	0,17	0,05	-0,25	0,02
	$r_N$	-0,18	0,27	0,08	-0,20	0,10	-0,21	0,17	0,05	-0,25	0,02
	$r_R$	-0,25	0,19	0,04	-0,42	0,12	-0,27	0,12	0,00	-0,36	0,02
	$r_P$	0,80	1,14	1,02	0,81	1,02	0,78	1,02	1,00	0,75	0,91
DP	$r_N$	0,80	1,17	1,02	0,81	1,04	0,80	1,07	1,01	0,75	0,96
	$r_R$	0,98	0,90	1,23	1,35	1,42	0,88	0,84	1,12	0,92	1,00
	$r_P$	1,41	1,22	1,36	1,51	1,26	1,43	1,14	1,41	1,54	1,16
	$r_N$	1,45	1,36	1,44	1,61	1,34	1,54	1,19	1,57	1,67	1,25
CS	$r_R$	1,01	1,16	0,97	1,04	1,11	1,08	1,26	0,94	1,16	0,95
	$r_P$	5,73	4,12	4,91	5,88	4,36	5,50	3,98	5,20	6,48	4,26
	$r_N$	5,45	4,68	5,22	6,03	4,62	5,77	4,07	5,94	6,79	4,45
	$r_R$	3,44	4,46	3,53	4,58	4,30	3,85	5,32	3,38	4,04	3,26
	$r_{(\cdot)i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,14	0,31	0,02	-0,22	0,09	-0,17	0,28	0,06	-0,20	0,11
	$r_N$	-0,15	0,31	0,02	-0,22	0,09	-0,18	0,29	0,06	-0,21	0,11
	$r_R$	-0,27	0,23	-0,02	-0,43	0,10	-0,31	0,20	0,03	-0,40	0,13
	$r_P$	0,81	1,17	0,98	0,78	1,00	0,81	1,18	0,99	0,80	1,00
DP	$r_N$	0,83	1,20	0,99	0,77	1,02	0,82	1,20	1,02	0,81	1,03
	$r_R$	1,19	0,96	0,96	1,27	1,23	1,19	0,94	1,33	1,31	1,28
	$r_P$	1,30	1,16	1,43	1,59	1,23	1,31	1,20	1,32	1,29	1,21
	$r_N$	1,42	1,29	1,51	1,68	1,32	1,45	1,32	1,41	1,56	1,29
CS	$r_R$	1,03	0,87	0,99	1,06	0,98	1,04	0,98	1,01	1,09	0,99
	$r_P$	5,60	3,89	5,21	6,62	4,40	5,86	4,04	4,88	7,48	4,34
	$r_N$	5,15	4,41	5,50	6,74	4,71	5,34	4,44	5,18	5,91	4,58
	$r_R$	3,77	3,09	3,45	4,79	3,52	3,79	3,58	3,95	4,60	3,63
	$r_{(\cdot)i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,16	0,32	0,02	-0,21	0,10	-0,19	0,32	-0,02	-0,21	0,06
	$r_N$	-0,17	0,33	0,02	-0,21	0,10	-0,20	0,33	-0,02	-0,22	0,07
	$r_R$	-0,29	0,28	-0,03	-0,41	0,15	-0,26	0,25	-0,05	-0,38	0,07
	$r_P$	0,81	1,15	0,98	0,79	0,99	0,78	1,18	0,93	0,82	0,99
DP	$r_N$	0,82	1,18	0,98	0,78	1,03	0,79	1,22	0,95	0,81	1,01
	$r_R$	1,17	1,05	0,99	1,28	1,50	0,93	1,02	0,91	1,14	1,23
	$r_P$	1,42	1,12	1,42	1,54	1,15	1,40	1,11	1,34	1,67	1,30
	$r_N$	1,47	1,22	1,51	1,62	1,22	1,45	1,26	1,39	1,81	1,36
CS	$r_R$	1,07	0,85	0,94	1,08	1,11	1,02	0,82	1,02	1,19	1,02
	$r_P$	5,48	3,90	5,18	6,13	4,12	5,57	3,76	4,91	6,73	4,57
	$r_N$	5,37	4,26	5,56	6,29	4,27	5,45	4,34	4,94	7,32	4,71
	$r_R$	3,87	3,03	3,26	4,84	4,32	3,56	2,90	3,88	4,33	3,63
	$r_{(\cdot)i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,17	0,33	0,07	-0,23	0,08	-0,19	0,32	0,05	-0,20	0,03
	$r_N$	-0,18	0,33	0,07	-0,23	0,09	-0,20	0,32	0,05	-0,21	0,04
	$r_R$	-0,30	0,24	0,04	-0,38	0,11	-0,29	0,23	0,01	-0,44	0,04
	$r_P$	0,81	1,21	0,98	0,78	0,99	0,81	1,20	1,01	0,80	0,94
DP	$r_N$	0,81	1,23	0,99	0,77	1,02	0,81	1,23	1,01	0,79	0,97
	$r_R$	1,10	0,96	1,27	1,09	1,39	1,00	0,95	1,08	1,31	1,06
	$r_P$	1,44	1,15	1,27	1,55	1,20	1,56	1,17	1,40	1,55	1,16
	$r_N$	1,50	1,28	1,37	1,69	1,30	1,60	1,33	1,53	1,63	1,24
CS	$r_R$	1,00	0,88	0,98	1,13	1,08	1,10	0,94	0,93	1,00	0,92
	$r_P$	5,67	3,79	4,65	6,36	4,32	6,23	3,85	5,00	6,10	4,26
	$r_N$	5,61	4,26	5,02	6,74	4,60	6,06	4,53	5,60	6,30	4,43
	$r_R$	3,54	3,05	3,79	4,20	4,26	3,71	3,24	3,26	4,53	3,14

Fonte: O autor (2016).

**Tabela 4.48** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação independente e parâmetro de suavização  $\alpha = 10.000$ .

	$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,25	0,33	0,08	-0,25	0,02	-0,25	0,30	0,08	-0,21	0,05
	$r_N$	-0,26	0,35	0,08	-0,27	0,01	-0,27	0,32	0,09	-0,22	0,05
	$r_R$	-0,38	0,26	0,01	-0,39	-0,01	-0,37	0,22	0,03	-0,40	0,05
	$r_P$	0,73	1,16	1,01	0,72	0,89	0,72	1,15	1,01	0,78	0,91
DP	$r_N$	0,74	1,21	1,04	0,73	0,93	0,72	1,21	1,03	0,77	0,95
	$r_R$	0,92	1,01	1,01	0,89	1,01	0,84	0,93	1,02	1,12	1,41
	$r_P$	1,69	1,18	1,47	1,61	1,25	1,77	1,19	1,46	1,74	1,23
	$r_N$	1,79	1,33	1,63	1,73	1,30	1,72	1,40	1,58	1,85	1,27
CS	$r_R$	1,24	0,85	0,94	1,21	0,93	1,19	0,92	0,90	1,16	1,03
	$r_P$	6,98	3,98	5,26	6,67	4,48	8,12	3,99	5,32	7,36	4,55
	$r_N$	7,26	4,62	6,06	6,92	4,58	6,90	4,91	5,85	7,69	4,48
	$r_R$	4,14	3,03	3,24	4,13	3,18	4,24	3,37	3,18	4,36	4,19
	$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,22	0,28	0,13	-0,19	0,07	-0,25	0,19	0,09	-0,24	-0,02
	$r_N$	-0,23	0,30	0,13	-0,20	0,07	-0,27	0,20	0,10	-0,25	-0,02
	$r_R$	-0,34	0,21	0,09	-0,42	0,05	-0,35	0,14	0,03	-0,37	-0,04
	$r_P$	0,74	1,11	1,02	0,77	0,97	0,72	0,99	1,00	0,72	0,86
DP	$r_N$	0,74	1,17	1,05	0,78	1,00	0,74	1,07	1,04	0,73	0,91
	$r_R$	0,91	0,89	1,21	1,32	1,41	0,82	0,83	1,11	0,90	0,97
	$r_P$	1,65	1,21	1,38	1,57	1,36	1,63	1,14	1,43	1,62	1,26
	$r_N$	1,68	1,36	1,49	1,66	1,43	1,74	1,19	1,63	1,75	1,35
CS	$r_R$	1,15	1,16	0,94	1,08	1,09	1,19	1,29	0,91	1,20	0,98
	$r_P$	7,13	4,09	4,91	6,25	4,77	6,62	3,98	5,16	6,92	4,70
	$r_N$	6,72	4,68	5,41	6,33	4,98	6,88	4,07	6,17	7,27	4,90
	$r_R$	3,93	4,52	3,52	4,74	4,36	4,29	5,43	3,36	4,19	3,38
	$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,19	0,34	0,07	-0,22	0,05	-0,22	0,31	0,11	-0,19	0,07
	$r_N$	-0,21	0,35	0,07	-0,22	0,06	-0,24	0,33	0,12	-0,21	0,07
	$r_R$	-0,37	0,25	0,01	-0,44	0,03	-0,41	0,22	0,09	-0,40	0,06
	$r_P$	0,76	1,16	0,98	0,74	0,94	0,75	1,16	1,00	0,76	0,94
DP	$r_N$	0,78	1,20	1,01	0,75	0,97	0,76	1,21	1,04	0,79	0,98
	$r_R$	1,13	0,95	0,95	1,25	1,20	1,12	0,93	1,32	1,29	1,26
	$r_P$	1,52	1,15	1,43	1,64	1,32	1,50	1,20	1,34	1,41	1,31
	$r_N$	1,63	1,30	1,54	1,73	1,42	1,63	1,32	1,44	1,61	1,38
CS	$r_R$	1,15	0,86	0,96	1,09	0,98	1,15	0,98	1,00	1,12	0,97
	$r_P$	6,50	3,85	5,16	6,92	4,84	6,57	4,05	4,84	7,08	4,81
	$r_N$	6,21	4,42	5,59	7,04	5,15	6,24	4,45	5,19	6,13	5,00
	$r_R$	4,20	3,08	3,40	4,91	3,57	4,22	3,60	3,99	4,70	3,67
	$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,21	0,35	0,07	-0,20	0,07	-0,24	0,35	0,03	-0,21	0,03
	$r_N$	-0,23	0,37	0,07	-0,21	0,07	-0,25	0,37	0,02	-0,22	0,03
	$r_R$	-0,39	0,31	0,01	-0,42	0,07	-0,35	0,28	-0,02	-0,39	0,00
	$r_P$	0,75	1,13	0,98	0,76	0,94	0,72	1,16	0,92	0,79	0,94
DP	$r_N$	0,77	1,19	1,00	0,76	0,98	0,73	1,22	0,96	0,79	0,97
	$r_R$	1,10	1,04	0,98	1,26	1,48	0,86	1,01	0,89	1,12	1,20
	$r_P$	1,61	1,11	1,44	1,61	1,24	1,58	1,10	1,36	1,74	1,41
	$r_N$	1,65	1,22	1,54	1,69	1,29	1,62	1,26	1,42	1,89	1,47
CS	$r_R$	1,17	0,84	0,90	1,11	1,10	1,14	0,80	0,99	1,22	1,02
	$r_P$	6,52	3,86	5,21	6,51	4,52	6,55	3,72	4,99	7,15	5,10
	$r_N$	6,24	4,24	5,64	6,67	4,57	6,33	4,32	5,10	7,77	5,22
	$r_R$	4,26	3,02	3,21	4,98	4,48	4,00	2,89	3,85	4,43	3,72
	$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,22	0,36	0,12	-0,23	0,05	-0,24	0,35	0,10	-0,20	0,00
	$r_N$	-0,23	0,37	0,12	-0,23	0,05	-0,25	0,36	0,11	-0,21	0,00
	$r_R$	-0,39	0,26	0,09	-0,40	0,03	-0,38	0,25	0,04	-0,45	-0,02
	$r_P$	0,75	1,19	0,98	0,75	0,93	0,75	1,18	1,02	0,76	0,88
DP	$r_N$	0,75	1,23	1,02	0,75	0,97	0,75	1,23	1,04	0,77	0,92
	$r_R$	1,02	0,95	1,26	1,07	1,37	0,93	0,94	1,07	1,28	1,03
	$r_P$	1,63	1,15	1,28	1,63	1,32	1,76	1,17	1,42	1,61	1,26
	$r_N$	1,69	1,28	1,41	1,77	1,41	1,81	1,34	1,56	1,69	1,33
CS	$r_R$	1,13	0,87	0,96	1,16	1,07	1,26	0,93	0,89	1,03	0,93
	$r_P$	6,67	3,75	4,62	6,86	4,85	7,33	3,83	5,02	6,41	4,70
	$r_N$	6,65	4,26	5,13	7,23	5,10	7,14	4,55	5,75	6,65	4,83
	$r_R$	3,97	3,05	3,83	4,31	4,44	4,27	3,26	3,21	4,66	3,22

Fonte: O autor (2016).

**Tabela 4.49** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 0,01$ .

$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	0,08	0,04	-0,02	-0,05	-0,03	0,00	0,05	0,01	0,03
	$r_N$	0,05	0,02	-0,01	-0,03	-0,02	0,00	0,03	0,00	0,02
	$r_R$	0,04	0,02	-0,01	-0,03	-0,02	0,00	0,02	0,00	0,04
	$r_P$	1,96	1,97	1,64	1,38	1,44	1,87	1,96	1,70	1,49
	$r_N$	1,15	1,16	0,95	0,81	0,83	1,11	1,14	0,97	0,84
	$r_R$	1,06	1,07	1,03	1,03	1,04	0,97	0,97	1,07	1,25
DP	$r_P$	1,13	1,10	0,97	0,67	0,63	1,08	1,09	0,94	0,78
	$r_N$	1,28	1,19	1,06	0,69	0,70	1,19	1,19	1,03	0,78
	$r_R$	0,86	0,90	0,74	0,52	0,49	0,90	0,88	0,73	0,55
	$r_P$	4,24	4,01	4,14	3,57	3,75	4,16	4,01	3,97	3,93
	$r_N$	4,71	4,25	4,29	3,41	3,57	4,43	4,19	3,97	3,66
	$r_R$	3,05	3,04	2,98	2,70	2,69	3,25	3,09	2,87	3,06
$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,05	0,01	0,01	-0,04	0,03	-0,02	-0,03	-0,04	-0,05
	$r_N$	-0,03	0,01	0,01	-0,02	0,01	-0,01	-0,02	-0,02	-0,01
	$r_R$	-0,04	0,01	0,00	-0,04	0,01	-0,01	0,01	-0,03	-0,01
	$r_P$	1,94	1,95	1,74	1,51	1,54	1,91	1,80	1,79	1,45
	$r_N$	1,13	1,15	1,02	0,87	0,88	1,13	1,10	1,04	0,85
	$r_R$	1,05	0,90	1,28	1,51	1,41	0,96	0,83	1,22	1,11
CS	$r_P$	1,12	1,09	1,00	0,72	0,79	1,05	0,98	1,00	0,69
	$r_N$	1,25	1,21	1,09	0,77	0,82	1,14	1,07	1,09	0,74
	$r_R$	0,90	0,96	0,73	0,56	0,56	0,90	1,05	0,76	0,57
	$r_P$	4,16	4,06	4,04	3,73	3,89	4,00	3,89	3,98	3,65
	$r_N$	4,51	4,41	4,19	3,56	3,73	4,13	4,03	4,13	3,46
	$r_R$	3,15	3,55	2,96	3,11	2,95	3,21	4,27	2,91	2,75
$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,01	-0,03	0,03	0,01	0,00	-0,06	0,01	0,00	0,00
	$r_N$	-0,01	-0,02	0,02	0,00	0,00	-0,04	0,00	0,00	0,00
	$r_R$	0,00	-0,02	0,02	-0,01	-0,01	-0,03	0,00	0,00	-0,02
	$r_P$	1,92	1,94	1,64	1,50	1,56	1,85	1,92	1,69	1,44
	$r_N$	1,14	1,13	0,95	0,85	0,88	1,10	1,12	1,01	0,85
	$r_R$	1,30	0,99	0,96	1,40	1,26	1,26	0,92	1,34	1,48
CS	$r_P$	1,13	1,13	0,86	0,79	0,73	1,06	1,11	1,02	0,75
	$r_N$	1,25	1,26	0,92	0,79	0,79	1,17	1,22	1,13	0,75
	$r_R$	0,97	0,93	0,66	0,51	0,55	0,95	0,93	0,83	0,51
	$r_P$	4,20	4,19	3,88	4,14	3,74	3,97	4,09	4,18	3,86
	$r_N$	4,54	4,51	3,78	3,75	3,62	4,18	4,40	4,42	3,56
	$r_R$	3,39	3,17	2,90	2,96	2,79	3,34	3,31	3,34	3,05
$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,03	-0,02	0,05	0,02	0,01	0,02	0,02	0,01	-0,03
	$r_N$	-0,02	-0,01	0,03	0,01	0,00	0,01	0,01	0,00	0,01
	$r_R$	-0,02	-0,01	0,03	0,03	-0,01	0,01	0,01	0,00	-0,02
	$r_P$	1,89	1,91	1,68	1,51	1,50	1,90	1,95	1,54	1,48
	$r_N$	1,12	1,13	0,97	0,86	0,87	1,12	1,15	0,92	0,82
	$r_R$	1,26	1,10	1,02	1,43	1,46	0,99	1,04	0,88	1,22
CS	$r_P$	1,05	1,09	0,93	0,72	0,71	1,06	1,11	0,87	0,68
	$r_N$	1,15	1,21	1,01	0,73	0,74	1,21	1,27	0,93	0,75
	$r_R$	0,92	0,92	0,69	0,53	0,57	0,89	0,92	0,70	0,55
	$r_P$	3,86	4,06	4,04	3,77	3,65	4,02	4,08	4,00	3,62
	$r_N$	4,09	4,38	4,19	3,50	3,44	4,46	4,56	3,95	3,56
	$r_R$	3,28	3,21	2,86	2,89	3,05	3,14	3,13	3,16	2,84
$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	0,03	0,04	-0,06	0,00	0,02	0,01	-0,01	0,01	0,01
	$r_N$	0,02	0,02	-0,04	0,00	0,01	0,00	0,00	0,01	0,02
	$r_R$	0,03	0,02	-0,05	0,01	0,01	0,01	0,00	0,01	-0,02
	$r_P$	1,98	1,97	1,70	1,50	1,50	1,97	1,98	1,74	1,53
	$r_N$	1,16	1,14	1,00	0,85	0,87	1,15	1,16	1,01	0,88
	$r_R$	1,22	0,96	1,33	1,25	1,40	1,09	0,96	1,14	1,48
CS	$r_P$	1,03	1,11	0,98	0,67	0,73	1,05	1,09	0,98	0,73
	$r_N$	1,19	1,21	1,02	0,70	0,76	1,17	1,22	1,08	0,78
	$r_R$	0,86	0,89	0,75	0,53	0,53	0,87	0,92	0,73	0,51
	$r_P$	3,88	4,18	4,12	3,68	3,69	3,89	4,00	4,02	3,53
	$r_N$	4,33	4,42	4,04	3,45	3,59	4,20	4,29	4,24	3,44
	$r_R$	3,01	3,11	3,09	2,76	3,02	3,00	3,23	2,86	2,94

Fonte: O autor (2016).

**Tabela 4.50** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10$ .

	$r_{(\cdot)i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,40	0,81	0,05	-0,68	0,08	-0,51	0,76	0,10	-0,57	0,30
	$r_N$	-0,27	0,53	0,03	-0,44	0,06	-0,34	0,50	0,05	-0,37	0,20
	$r_R$	-0,35	0,40	0,00	-0,64	0,08	-0,39	0,34	0,02	-0,62	0,30
	$r_P$	1,40	2,02	1,43	0,92	1,22	1,31	1,99	1,49	0,98	1,33
DP	$r_N$	0,88	1,33	0,89	0,56	0,78	0,83	1,30	0,92	0,59	0,85
	$r_R$	0,96	1,01	0,98	0,78	0,97	0,86	0,91	1,02	0,95	1,34
	$r_P$	1,46	1,03	1,22	0,71	0,70	1,41	1,04	1,27	0,75	0,80
	$r_N$	1,56	1,18	1,27	0,88	0,72	1,50	1,21	1,30	0,90	0,76
CS	$r_R$	1,03	0,82	0,74	0,81	0,52	1,06	0,83	0,72	0,77	0,53
	$r_P$	6,19	3,46	5,04	4,67	4,01	6,24	3,59	5,08	4,69	3,96
	$r_N$	6,17	4,01	5,06	4,40	3,64	6,06	4,17	5,10	4,35	3,57
	$r_R$	3,68	2,88	3,11	3,54	2,76	3,97	3,04	2,97	3,57	3,05
	$r_{(\cdot)i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,49	0,63	0,18	-0,54	0,27	-0,52	0,50	0,10	-0,67	0,06
	$r_N$	-0,33	0,42	0,11	-0,35	0,18	-0,35	0,35	0,07	-0,43	0,05
	$r_R$	-0,41	0,28	0,08	-0,69	0,27	-0,38	0,24	0,02	-0,62	0,08
	$r_P$	1,37	1,92	1,58	1,04	1,37	1,34	1,71	1,60	0,96	1,24
DP	$r_N$	0,86	1,26	1,00	0,64	0,87	0,85	1,14	1,00	0,59	0,81
	$r_R$	0,94	0,86	1,23	1,18	1,33	0,85	0,79	1,17	0,82	1,01
	$r_P$	1,36	1,04	1,28	0,78	0,87	1,32	0,99	1,23	0,73	0,72
	$r_N$	1,47	1,20	1,31	0,93	0,85	1,40	1,05	1,30	0,92	0,76
CS	$r_R$	1,05	1,02	0,71	0,63	0,55	1,05	1,25	0,74	0,89	0,57
	$r_P$	5,66	3,70	5,01	4,51	4,18	5,57	3,80	4,71	4,77	3,87
	$r_N$	5,64	4,29	4,93	4,25	3,84	5,45	3,95	4,85	4,45	3,66
	$r_R$	3,72	3,87	3,03	3,54	2,89	3,86	5,15	2,98	3,74	2,74
	$r_{(\cdot)i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,37	0,70	0,05	-0,54	0,18	-0,42	0,69	0,21	-0,47	0,17
	$r_N$	-0,25	0,46	0,03	-0,35	0,12	-0,29	0,45	0,13	-0,32	0,11
	$r_R$	-0,38	0,32	0,00	-0,68	0,18	-0,42	0,30	0,13	-0,64	0,17
	$r_P$	1,43	1,98	1,39	1,01	1,35	1,36	1,94	1,53	1,01	1,30
DP	$r_N$	0,92	1,29	0,87	0,61	0,85	0,87	1,25	0,98	0,64	0,82
	$r_R$	1,17	0,93	0,91	1,08	1,19	1,14	0,87	1,30	1,16	1,20
	$r_P$	1,43	1,07	1,09	0,88	0,77	1,31	1,08	1,21	0,88	0,84
	$r_N$	1,52	1,24	1,10	0,95	0,81	1,39	1,24	1,31	0,94	0,84
CS	$r_R$	1,06	0,86	0,67	0,60	0,56	1,02	0,90	0,78	0,52	0,64
	$r_P$	5,87	3,65	4,75	5,35	3,96	5,44	3,74	4,82	5,06	4,06
	$r_N$	5,89	4,30	4,50	4,56	3,74	5,20	4,34	5,13	4,49	3,83
	$r_R$	3,81	3,06	3,11	3,47	2,77	3,70	3,31	3,39	3,32	3,02
	$r_{(\cdot)i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,40	0,78	0,10	-0,53	0,30	-0,48	0,79	-0,02	-0,62	0,20
	$r_N$	-0,28	0,52	0,06	-0,35	0,20	-0,32	0,53	-0,02	-0,39	0,14
	$r_R$	-0,40	0,40	0,03	-0,64	0,31	-0,38	0,38	-0,05	-0,66	0,21
	$r_P$	1,37	1,97	1,46	1,02	1,34	1,34	2,00	1,28	0,95	1,27
DP	$r_N$	0,88	1,30	0,91	0,62	0,86	0,85	1,32	0,83	0,57	0,80
	$r_R$	1,12	1,03	0,97	1,09	1,38	0,90	0,98	0,83	0,92	1,15
	$r_P$	1,30	1,03	1,20	0,84	0,77	1,33	1,04	1,04	0,75	0,81
	$r_N$	1,36	1,17	1,22	0,92	0,74	1,49	1,25	1,08	0,93	0,81
CS	$r_R$	1,00	0,84	0,68	0,67	0,57	1,05	0,84	0,69	0,78	0,54
	$r_P$	5,27	3,56	4,96	4,93	3,80	5,64	3,55	4,57	4,75	4,13
	$r_N$	5,12	4,07	4,95	4,41	3,46	5,91	4,34	4,50	4,54	3,86
	$r_R$	3,63	3,05	2,99	3,50	3,02	3,81	2,99	3,40	3,65	2,80
	$r_{(\cdot)i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,39	0,76	0,16	-0,60	0,27	-0,45	0,69	0,12	-0,51	0,14
	$r_N$	-0,26	0,50	0,09	-0,39	0,18	-0,30	0,46	0,07	-0,33	0,10
	$r_R$	-0,36	0,34	0,07	-0,64	0,27	-0,38	0,31	0,04	-0,66	0,14
	$r_P$	1,43	2,00	1,54	0,99	1,33	1,39	2,01	1,52	1,06	1,31
DP	$r_N$	0,91	1,30	0,98	0,59	0,85	0,87	1,31	0,96	0,65	0,84
	$r_R$	1,09	0,91	1,29	0,95	1,33	0,97	0,91	1,08	1,16	1,06
	$r_P$	1,33	1,03	1,20	0,69	0,78	1,31	1,05	1,23	0,90	0,78
	$r_N$	1,49	1,19	1,22	0,83	0,77	1,42	1,22	1,35	1,01	0,81
CS	$r_R$	1,01	0,81	0,72	0,78	0,53	1,02	0,88	0,73	0,59	0,59
	$r_P$	5,59	3,61	4,82	4,58	3,90	5,43	3,61	4,93	4,76	3,98
	$r_N$	5,97	4,21	4,76	4,14	3,67	5,45	4,17	5,38	4,44	3,73
	$r_R$	3,60	3,01	3,20	3,56	3,01	3,56	3,19	3,02	3,31	2,77

Fonte: O autor (2016).

**Tabela 4.51** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação uniforme e parâmetro de suavização  $\alpha = 10.000$ .

	$r_{(\cdot)i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,52	0,88	0,16	-0,66	0,00	-0,62	0,83	0,20	-0,55	0,21
	$r_N$	-0,36	0,60	0,11	-0,44	0,00	-0,43	0,56	0,13	-0,37	0,14
	$r_R$	-0,46	0,44	0,07	-0,66	-0,01	-0,49	0,38	0,09	-0,63	0,20
DP	$r_P$	1,26	1,96	1,41	0,85	1,12	1,18	1,92	1,47	0,92	1,23
	$r_N$	0,80	1,33	0,90	0,53	0,73	0,75	1,30	0,93	0,56	0,79
	$r_R$	0,88	0,98	0,97	0,76	0,96	0,79	0,89	1,00	0,93	1,33
CS	$r_P$	1,63	1,01	1,24	0,73	0,78	1,57	1,02	1,29	0,75	0,88
	$r_N$	1,70	1,17	1,29	0,91	0,77	1,67	1,20	1,34	0,91	0,81
	$r_R$	1,20	0,81	0,68	0,83	0,52	1,21	0,82	0,67	0,79	0,49
CK	$r_P$	7,20	3,42	5,06	4,98	4,47	7,38	3,55	5,07	4,86	4,37
	$r_N$	6,90	3,97	5,12	4,63	3,90	7,08	4,14	5,25	4,47	3,79
	$r_R$	4,22	2,88	3,05	3,64	2,80	4,59	3,05	2,92	3,65	3,06
	$r_{(\cdot)i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,60	0,70	0,30	-0,52	0,19	-0,63	0,56	0,22	-0,65	-0,02
	$r_N$	-0,41	0,48	0,19	-0,35	0,12	-0,44	0,40	0,15	-0,43	-0,01
	$r_R$	-0,51	0,31	0,16	-0,70	0,17	-0,48	0,27	0,10	-0,63	-0,01
DP	$r_P$	1,23	1,85	1,57	0,97	1,28	1,20	1,64	1,58	0,90	1,14
	$r_N$	0,78	1,25	1,01	0,61	0,82	0,77	1,13	1,02	0,56	0,75
	$r_R$	0,85	0,85	1,21	1,15	1,32	0,78	0,78	1,16	0,80	1,00
CS	$r_P$	1,51	1,03	1,29	0,80	0,97	1,46	0,98	1,25	0,76	0,78
	$r_N$	1,62	1,20	1,33	0,95	0,92	1,56	1,04	1,33	0,95	0,81
	$r_R$	1,21	1,03	0,66	0,64	0,52	1,18	1,28	0,69	0,93	0,57
CK	$r_P$	6,64	3,68	5,02	4,67	4,63	6,51	3,79	4,70	5,08	4,17
	$r_N$	6,49	4,25	5,00	4,37	4,14	6,30	3,91	4,93	4,63	3,83
	$r_R$	4,29	3,93	2,99	3,59	2,93	4,39	5,32	2,93	3,85	2,80
	$r_{(\cdot)i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,48	0,77	0,16	-0,52	0,10	-0,53	0,76	0,32	-0,45	0,08
	$r_N$	-0,34	0,52	0,10	-0,35	0,06	-0,37	0,51	0,22	-0,32	0,05
	$r_R$	-0,51	0,36	0,07	-0,69	0,08	-0,54	0,34	0,22	-0,64	0,08
DP	$r_P$	1,31	1,91	1,36	0,95	1,25	1,24	1,88	1,51	0,95	1,20
	$r_N$	0,85	1,29	0,87	0,58	0,80	0,80	1,25	0,99	0,61	0,77
	$r_R$	1,09	0,91	0,90	1,06	1,18	1,05	0,86	1,28	1,13	1,20
CS	$r_P$	1,63	1,05	1,11	0,91	0,84	1,47	1,07	1,20	0,89	0,90
	$r_N$	1,71	1,23	1,13	0,98	0,87	1,55	1,23	1,30	0,96	0,89
	$r_R$	1,21	0,86	0,63	0,60	0,55	1,16	0,90	0,74	0,54	0,63
CK	$r_P$	7,00	3,60	4,83	5,69	4,27	6,37	3,72	4,76	5,31	4,34
	$r_N$	6,89	4,26	4,62	4,67	3,96	5,96	4,30	5,09	4,64	4,03
	$r_R$	4,39	3,06	3,08	3,49	2,79	4,18	3,33	3,35	3,39	3,04
	$r_{(\cdot)i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,51	0,86	0,21	-0,51	0,22	-0,59	0,86	0,08	-0,60	0,11
	$r_N$	-0,36	0,59	0,13	-0,35	0,14	-0,40	0,59	0,05	-0,39	0,08
	$r_R$	-0,51	0,45	0,09	-0,65	0,21	-0,48	0,42	0,01	-0,67	0,11
DP	$r_P$	1,25	1,90	1,43	0,95	1,25	1,20	1,93	1,26	0,88	1,17
	$r_N$	0,80	1,29	0,91	0,59	0,81	0,77	1,32	0,83	0,54	0,75
	$r_R$	1,03	1,00	0,95	1,07	1,37	0,82	0,96	0,82	0,90	1,14
CS	$r_P$	1,47	1,01	1,22	0,87	0,85	1,47	1,02	1,06	0,77	0,87
	$r_N$	1,51	1,16	1,25	0,94	0,80	1,64	1,24	1,09	0,95	0,85
	$r_R$	1,13	0,83	0,64	0,70	0,54	1,21	0,82	0,65	0,81	0,52
CK	$r_P$	6,25	3,52	4,97	5,19	4,11	6,54	3,49	4,59	4,97	4,45
	$r_N$	5,87	4,01	5,05	4,56	3,66	6,75	4,28	4,54	4,66	4,04
	$r_R$	4,12	3,05	2,95	3,58	3,00	4,41	2,99	3,40	3,75	2,84
	$r_{(\cdot)i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,51	0,83	0,28	-0,58	0,18	-0,57	0,76	0,22	-0,49	0,05
	$r_N$	-0,35	0,56	0,18	-0,38	0,12	-0,39	0,52	0,15	-0,33	0,04
	$r_R$	-0,48	0,38	0,16	-0,65	0,17	-0,49	0,34	0,11	-0,67	0,05
DP	$r_P$	1,30	1,94	1,53	0,92	1,24	1,25	1,95	1,50	0,99	1,21
	$r_N$	0,83	1,30	0,99	0,56	0,80	0,79	1,31	0,97	0,62	0,78
	$r_R$	1,00	0,90	1,27	0,93	1,32	0,89	0,89	1,07	1,14	1,05
CS	$r_P$	1,54	1,01	1,20	0,70	0,86	1,47	1,04	1,24	0,93	0,83
	$r_N$	1,71	1,18	1,23	0,85	0,82	1,59	1,21	1,39	1,04	0,85
	$r_R$	1,19	0,81	0,69	0,81	0,51	1,19	0,87	0,68	0,61	0,60
CK	$r_P$	6,83	3,56	4,75	4,78	4,22	6,44	3,58	4,92	5,06	4,28
	$r_N$	7,23	4,16	4,77	4,23	3,86	6,39	4,14	5,54	4,62	3,90
	$r_R$	4,25	3,02	3,17	3,65	3,03	4,15	3,20	2,97	3,37	2,81

Fonte: O autor (2016).

**Tabela 4.52** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 0,01$ .

	$r(\cdot)i,j$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	0,07	0,02	0,01	-0,02	-0,04	-0,01	0,03	0,00	0,02	-0,02
	$r_N$	0,05	0,01	0,01	-0,01	-0,02	-0,01	0,02	0,00	0,01	-0,01
	$r_R$	0,04	0,01	0,00	-0,01	-0,02	0,00	0,02	0,00	0,03	0,01
	$r_P$	1,96	1,75	1,49	1,29	1,78	1,90	1,72	1,48	1,33	1,84
DP	$r_N$	1,19	1,04	0,88	0,78	1,09	1,16	1,03	0,88	0,78	1,12
	$r_R$	1,06	1,09	1,06	1,03	1,08	0,97	0,98	1,07	1,24	1,50
	$r_P$	0,95	0,95	0,90	0,86	0,93	0,96	0,99	0,93	0,85	0,98
CS	$r_N$	1,09	1,02	0,93	0,90	1,03	1,09	1,07	0,96	0,88	1,09
	$r_R$	0,79	0,72	0,65	0,62	0,80	0,84	0,75	0,66	0,62	0,95
	$r_P$	3,73	3,87	3,98	4,37	3,71	3,68	4,01	4,19	4,18	3,83
CK	$r_N$	4,12	3,92	3,88	4,25	3,91	4,08	4,08	3,99	3,98	4,09
	$r_R$	2,97	2,82	2,76	2,88	2,96	3,11	2,94	2,79	2,95	3,65
	$r(\cdot)i,j$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,04	0,01	0,01	0,00	0,00	-0,04	-0,02	-0,01	-0,02	-0,03
	$r_N$	-0,03	0,01	0,01	0,00	0,00	-0,03	-0,01	0,00	-0,01	-0,02
	$r_R$	-0,03	0,01	-0,01	-0,02	0,00	-0,01	0,00	-0,01	-0,01	-0,02
	$r_P$	1,96	1,65	1,52	1,34	1,84	1,90	1,53	1,55	1,30	1,76
DP	$r_N$	1,18	0,99	0,91	0,80	1,12	1,16	0,96	0,93	0,78	1,08
	$r_R$	1,06	0,86	1,25	1,45	1,41	0,96	0,80	1,21	1,06	1,04
	$r_P$	1,02	0,99	0,92	0,89	1,05	0,94	0,78	0,91	0,80	0,98
CS	$r_N$	1,13	1,07	0,96	0,93	1,17	1,03	0,84	1,03	0,86	1,05
	$r_R$	0,81	0,79	0,63	0,57	0,89	0,83	0,69	0,68	0,61	0,79
	$r_P$	3,95	4,26	4,07	4,21	4,02	3,68	3,80	3,92	4,11	3,98
CK	$r_N$	4,22	4,38	3,90	4,24	4,39	3,87	3,72	4,24	4,00	4,03
	$r_R$	3,01	3,38	2,78	3,19	3,39	3,11	3,70	2,80	2,88	3,03
	$r(\cdot)i,j$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	0,01	-0,01	0,00	0,00	0,01	-0,07	0,01	0,02	0,00	0,04
	$r_N$	0,00	-0,01	0,00	0,00	0,01	-0,05	0,00	0,01	0,00	0,03
	$r_R$	0,01	-0,01	0,00	-0,03	0,00	-0,04	0,00	0,00	-0,04	0,03
	$r_P$	1,94	1,69	1,43	1,40	1,84	1,90	1,65	1,50	1,35	1,83
DP	$r_N$	1,19	1,00	0,85	0,82	1,11	1,17	0,98	0,92	0,83	1,10
	$r_R$	1,32	0,98	0,95	1,42	1,23	1,30	0,91	1,34	1,50	1,27
	$r_P$	0,95	1,02	0,87	1,01	1,03	0,97	0,97	0,95	0,84	1,04
CS	$r_N$	1,04	1,10	0,91	1,01	1,14	1,06	1,05	1,02	0,87	1,10
	$r_R$	0,86	0,74	0,65	0,63	0,80	0,85	0,74	0,71	0,54	0,82
	$r_P$	3,59	4,36	3,97	4,67	4,03	3,75	4,09	4,14	4,10	4,10
CK	$r_N$	3,81	4,38	3,85	4,34	4,36	4,36	4,23	4,15	3,94	4,12
	$r_R$	3,18	2,97	2,88	3,18	3,12	3,21	3,06	3,12	3,04	3,17
	$r(\cdot)i,j$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,01	-0,02	-0,02	0,00	0,00	0,02	-0,01	-0,01	-0,04	0,03
	$r_N$	-0,01	-0,01	-0,01	0,00	0,00	0,01	0,00	-0,01	-0,02	0,02
	$r_R$	0,00	-0,01	-0,01	-0,01	0,01	0,01	-0,01	-0,01	-0,03	0,02
	$r_P$	1,92	1,70	1,44	1,40	1,81	1,93	1,76	1,39	1,38	1,89
DP	$r_N$	1,17	1,03	0,85	0,82	1,10	1,17	1,06	0,85	0,82	1,14
	$r_R$	1,26	1,13	1,01	1,43	1,52	1,00	1,08	0,89	1,26	1,28
	$r_P$	0,96	0,91	0,85	0,96	0,92	0,91	0,98	0,80	0,95	1,03
CS	$r_N$	1,07	0,96	0,89	1,00	1,00	1,05	1,10	0,83	1,04	1,11
	$r_R$	0,86	0,70	0,66	0,67	0,87	0,81	0,75	0,58	0,67	0,84
	$r_P$	3,75	3,82	3,90	4,23	3,63	3,62	4,00	3,93	4,57	4,02
CK	$r_N$	3,99	3,81	3,73	4,18	3,74	3,97	4,25	3,78	4,51	4,12
	$r_R$	3,24	2,76	2,84	3,13	3,52	3,03	2,89	2,93	2,95	3,06
	$r(\cdot)i,j$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	0,04	0,04	-0,04	0,02	0,00	0,01	0,02	0,04	-0,03	0,03
	$r_N$	0,03	0,02	-0,02	0,01	0,00	0,00	0,01	0,02	-0,02	0,02
	$r_R$	0,04	0,02	-0,04	0,03	0,00	0,00	0,01	0,02	-0,06	0,03
	$r_P$	1,97	1,67	1,50	1,31	1,85	1,96	1,66	1,49	1,38	1,75
DP	$r_N$	1,20	0,99	0,91	0,77	1,12	1,18	0,99	0,88	0,82	1,07
	$r_R$	1,22	0,95	1,31	1,19	1,43	1,08	0,93	1,12	1,46	1,07
	$r_P$	0,91	1,03	0,96	0,85	1,01	0,99	0,93	0,94	0,84	0,96
CS	$r_N$	1,06	1,08	0,97	0,86	1,11	1,09	1,03	0,95	0,90	1,06
	$r_R$	0,80	0,73	0,71	0,61	0,85	0,82	0,76	0,64	0,57	0,79
	$r_P$	3,50	4,36	4,20	4,33	3,81	3,74	3,84	4,17	4,01	3,92
CK	$r_N$	3,98	4,43	4,01	4,02	4,04	3,97	4,08	4,00	4,00	4,11
	$r_R$	2,93	2,97	3,05	2,96	3,34	2,97	3,04	2,77	2,94	3,03

Fonte: O autor (2016).

**Tabela 4.53** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 10$ .

	$r(\cdot)_{i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,42	0,80	0,09	-0,63	0,06	-0,51	0,75	0,08	-0,55	0,23
	$r_N$	-0,28	0,52	0,05	-0,42	0,04	-0,34	0,49	0,05	-0,36	0,16
	$r_R$	-0,34	0,43	0,03	-0,62	0,04	-0,38	0,38	0,03	-0,62	0,22
DP	$r_P$	1,41	1,86	1,33	0,88	1,53	1,34	1,81	1,31	0,92	1,66
	$r_N$	0,91	1,22	0,84	0,56	1,03	0,87	1,19	0,83	0,57	1,11
	$r_R$	0,97	1,01	1,02	0,78	1,03	0,88	0,91	1,02	0,93	1,45
CS	$r_P$	1,18	0,90	1,12	1,01	0,97	1,20	0,94	1,13	1,12	1,00
	$r_N$	1,31	1,02	1,15	1,14	1,06	1,34	1,08	1,14	1,19	1,10
	$r_R$	0,93	0,65	0,63	0,99	0,82	0,98	0,70	0,66	0,93	0,95
CK	$r_P$	4,99	3,36	4,65	5,88	3,83	5,15	3,55	4,81	5,94	3,86
	$r_N$	5,16	3,79	4,77	5,50	4,02	5,34	4,00	4,62	5,41	4,10
	$r_R$	3,48	2,69	2,85	4,15	3,05	3,73	2,92	2,91	3,95	3,67
	$r(\cdot)_{i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,50	0,64	0,17	-0,50	0,22	-0,55	0,53	0,12	-0,62	0,05
	$r_N$	-0,33	0,43	0,11	-0,33	0,15	-0,37	0,36	0,08	-0,41	0,04
	$r_R$	-0,40	0,31	0,09	-0,68	0,18	-0,39	0,26	0,05	-0,60	0,04
DP	$r_P$	1,39	1,68	1,40	0,96	1,65	1,33	1,51	1,41	0,89	1,50
	$r_N$	0,89	1,10	0,89	0,60	1,10	0,87	1,01	0,90	0,56	1,01
	$r_R$	0,95	0,81	1,21	1,14	1,34	0,86	0,74	1,17	0,78	1,00
CS	$r_P$	1,24	0,97	1,12	1,06	1,05	1,10	0,81	1,14	0,92	1,01
	$r_N$	1,34	1,08	1,13	1,15	1,18	1,24	0,82	1,22	1,09	1,07
	$r_R$	0,95	0,88	0,59	0,68	0,88	0,96	0,90	0,64	0,93	0,81
CK	$r_P$	5,27	3,83	4,57	5,43	4,01	4,79	3,72	4,55	5,33	4,11
	$r_N$	5,27	4,23	4,41	5,21	4,44	4,88	3,62	4,90	5,17	4,13
	$r_R$	3,52	3,65	2,82	3,77	3,33	3,70	4,31	2,82	3,94	3,13
	$r(\cdot)_{i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,38	0,73	0,03	-0,51	0,17	-0,43	0,71	0,22	-0,45	0,22
	$r_N$	-0,26	0,48	0,02	-0,34	0,12	-0,30	0,46	0,14	-0,31	0,15
	$r_R$	-0,37	0,37	0,00	-0,67	0,13	-0,42	0,34	0,15	-0,64	0,17
DP	$r_P$	1,46	1,79	1,23	1,01	1,63	1,42	1,74	1,39	0,99	1,61
	$r_N$	0,95	1,17	0,79	0,63	1,08	0,93	1,12	0,91	0,65	1,06
	$r_R$	1,19	0,91	0,90	1,12	1,18	1,18	0,84	1,30	1,19	1,22
CS	$r_P$	1,22	0,95	0,99	1,36	1,08	1,15	0,95	1,15	1,03	1,06
	$r_N$	1,30	1,08	1,03	1,39	1,20	1,24	1,03	1,19	1,11	1,13
	$r_R$	0,95	0,67	0,64	0,87	0,81	0,90	0,74	0,65	0,67	0,83
CK	$r_P$	4,93	3,69	4,28	6,96	4,17	4,67	3,67	4,73	4,99	4,15
	$r_N$	4,98	4,12	4,29	6,39	4,57	4,66	3,99	4,80	4,77	4,23
	$r_R$	3,56	2,88	3,02	4,22	3,11	3,45	3,10	3,12	3,60	3,19
	$r(\cdot)_{i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,41	0,79	0,04	-0,51	0,26	-0,48	0,77	-0,03	-0,58	0,19
	$r_N$	-0,28	0,53	0,02	-0,34	0,18	-0,32	0,52	-0,02	-0,38	0,13
	$r_R$	-0,38	0,46	0,01	-0,65	0,24	-0,36	0,41	-0,05	-0,65	0,14
DP	$r_P$	1,41	1,81	1,25	1,00	1,63	1,36	1,87	1,17	0,98	1,66
	$r_N$	0,92	1,20	0,79	0,62	1,10	0,88	1,25	0,77	0,61	1,10
	$r_R$	1,13	1,05	0,95	1,10	1,45	0,91	1,00	0,83	0,97	1,22
CS	$r_P$	1,14	0,83	1,07	1,24	0,94	1,12	0,91	0,92	1,26	1,05
	$r_N$	1,26	0,91	1,05	1,34	1,02	1,26	1,08	0,95	1,43	1,15
	$r_R$	0,93	0,60	0,67	0,87	0,89	0,93	0,66	0,61	1,03	0,83
CK	$r_P$	4,78	3,25	4,62	6,12	3,65	4,87	3,42	4,33	6,48	4,06
	$r_N$	4,96	3,51	4,27	6,12	3,79	5,07	4,01	4,16	6,72	4,25
	$r_R$	3,59	2,62	3,00	3,85	3,54	3,55	2,74	3,18	4,21	3,07
	$r(\cdot)_{i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,40	0,77	0,16	-0,56	0,22	-0,46	0,73	0,14	-0,51	0,13
	$r_N$	-0,26	0,50	0,10	-0,37	0,15	-0,30	0,48	0,08	-0,34	0,09
	$r_R$	-0,35	0,39	0,10	-0,62	0,18	-0,37	0,36	0,07	-0,69	0,10
DP	$r_P$	1,44	1,76	1,38	0,88	1,66	1,40	1,75	1,33	1,00	1,50
	$r_N$	0,94	1,14	0,88	0,55	1,11	0,90	1,15	0,84	0,63	1,00
	$r_R$	1,10	0,88	1,27	0,89	1,37	0,98	0,87	1,07	1,14	1,03
CS	$r_P$	1,17	0,94	1,16	0,96	1,03	1,20	0,90	1,13	1,10	0,99
	$r_N$	1,33	1,06	1,14	1,08	1,13	1,29	1,05	1,12	1,25	1,07
	$r_R$	0,90	0,69	0,67	0,90	0,85	0,95	0,73	0,62	0,72	0,81
CK	$r_P$	4,98	3,69	4,88	5,38	3,81	4,94	3,48	4,77	5,69	4,00
	$r_N$	5,34	4,18	4,61	5,14	4,11	4,90	4,02	4,60	5,82	4,15
	$r_R$	3,39	2,93	3,16	4,03	3,27	3,45	3,03	2,84	3,68	3,08

Fonte: O autor (2016).

**Tabela 4.54** Estatísticas para os resíduos obtidos no estudo de simulação segundo o MPLAG para dados correlacionados com distribuição marginal gama, estrutura de correlação AR-1 e parâmetro de suavização  $\alpha = 10.000$ .

	$r_{(\cdot)i,j}$	1,1	1,2	1,3	1,4	1,5	2,1	2,2	2,3	2,4	2,5
MED	$r_P$	-0,56	0,88	0,21	-0,62	-0,03	-0,64	0,84	0,20	-0,54	0,14
	$r_N$	-0,38	0,59	0,14	-0,42	-0,02	-0,44	0,56	0,13	-0,36	0,10
	$r_R$	-0,45	0,47	0,11	-0,63	-0,04	-0,49	0,42	0,11	-0,62	0,13
	$r_P$	1,27	1,82	1,34	0,83	1,41	1,20	1,77	1,31	0,87	1,55
DP	$r_N$	0,82	1,23	0,86	0,53	0,96	0,79	1,20	0,85	0,55	1,05
	$r_R$	0,89	0,98	1,00	0,77	1,01	0,80	0,89	1,00	0,91	1,43
	$r_P$	1,28	0,88	1,13	1,04	1,04	1,34	0,93	1,17	1,18	1,08
	$r_N$	1,41	1,01	1,19	1,17	1,13	1,50	1,07	1,19	1,23	1,18
CS	$r_R$	1,08	0,64	0,57	1,03	0,81	1,15	0,70	0,61	0,98	0,93
	$r_P$	5,53	3,27	4,59	6,08	4,14	6,06	3,49	4,84	6,28	4,24
	$r_N$	5,60	3,72	4,89	5,67	4,29	6,29	3,96	4,80	5,61	4,43
	$r_R$	3,94	2,69	2,80	4,30	3,10	4,36	2,94	2,88	4,13	3,72
	$r_{(\cdot)i,j}$	3,1	3,2	3,3	3,4	3,5	4,1	4,2	4,3	4,4	4,5
MED	$r_P$	-0,63	0,71	0,30	-0,48	0,13	-0,67	0,60	0,25	-0,61	-0,04
	$r_N$	-0,43	0,49	0,20	-0,33	0,09	-0,46	0,42	0,17	-0,41	-0,03
	$r_R$	-0,51	0,34	0,19	-0,67	0,09	-0,48	0,29	0,14	-0,61	-0,04
	$r_P$	1,24	1,64	1,41	0,91	1,53	1,19	1,46	1,42	0,84	1,38
DP	$r_N$	0,80	1,10	0,92	0,58	1,04	0,78	1,01	0,93	0,54	0,94
	$r_R$	0,86	0,79	1,19	1,11	1,33	0,78	0,72	1,14	0,76	0,98
	$r_P$	1,34	0,95	1,14	1,09	1,12	1,21	0,80	1,16	0,96	1,06
	$r_N$	1,45	1,06	1,16	1,17	1,25	1,37	0,81	1,25	1,12	1,13
CS	$r_R$	1,09	0,89	0,54	0,71	0,86	1,10	0,94	0,58	0,98	0,81
	$r_P$	5,93	3,75	4,50	5,57	4,33	5,46	3,71	4,52	5,50	4,43
	$r_N$	5,90	4,16	4,48	5,30	4,75	5,56	3,59	4,93	5,30	4,39
	$r_R$	3,98	3,70	2,79	3,82	3,37	4,22	4,44	2,77	4,08	3,21
	$r_{(\cdot)i,j}$	5,1	5,2	5,3	5,4	5,5	6,1	6,2	6,3	6,4	6,5
MED	$r_P$	-0,51	0,81	0,15	-0,49	0,08	-0,56	0,79	0,35	-0,43	0,12
	$r_N$	-0,36	0,55	0,09	-0,33	0,06	-0,39	0,53	0,23	-0,30	0,08
	$r_R$	-0,50	0,41	0,07	-0,67	0,04	-0,55	0,38	0,26	-0,63	0,08
	$r_P$	1,32	1,75	1,22	0,96	1,52	1,28	1,70	1,39	0,94	1,49
DP	$r_N$	0,88	1,17	0,80	0,61	1,02	0,85	1,13	0,93	0,62	1,00
	$r_R$	1,10	0,89	0,89	1,10	1,17	1,09	0,82	1,27	1,17	1,20
	$r_P$	1,39	0,93	1,02	1,43	1,17	1,25	0,93	1,16	1,05	1,14
	$r_N$	1,47	1,07	1,07	1,45	1,28	1,34	1,02	1,21	1,13	1,20
CS	$r_R$	1,10	0,67	0,59	0,91	0,81	1,03	0,73	0,61	0,70	0,81
	$r_P$	5,81	3,58	4,33	7,39	4,57	5,20	3,61	4,63	5,11	4,48
	$r_N$	5,79	4,05	4,45	6,71	4,97	5,10	3,93	4,83	4,86	4,50
	$r_R$	4,09	2,89	3,00	4,37	3,18	3,83	3,07	3,11	3,69	3,26
	$r_{(\cdot)i,j}$	7,1	7,2	7,3	7,4	7,5	8,1	8,2	8,3	8,4	8,5
MED	$r_P$	-0,54	0,88	0,16	-0,49	0,17	-0,61	0,86	0,08	-0,56	0,09
	$r_N$	-0,37	0,60	0,10	-0,33	0,12	-0,41	0,59	0,05	-0,37	0,07
	$r_R$	-0,50	0,51	0,09	-0,65	0,15	-0,47	0,45	0,02	-0,65	0,06
	$r_P$	1,27	1,78	1,25	0,95	1,53	1,22	1,83	1,17	0,92	1,55
DP	$r_N$	0,84	1,20	0,80	0,60	1,04	0,80	1,25	0,78	0,59	1,04
	$r_R$	1,04	1,01	0,93	1,08	1,44	0,83	0,97	0,81	0,95	1,21
	$r_P$	1,27	0,80	1,10	1,31	1,02	1,25	0,88	0,95	1,33	1,13
	$r_N$	1,40	0,89	1,08	1,40	1,09	1,39	1,07	0,97	1,50	1,22
CS	$r_R$	1,07	0,59	0,61	0,92	0,88	1,08	0,66	0,59	1,08	0,83
	$r_P$	5,47	3,16	4,66	6,50	3,92	5,60	3,34	4,33	6,91	4,42
	$r_N$	5,65	3,44	4,39	6,49	4,05	5,71	3,96	4,15	7,18	4,57
	$r_R$	4,07	2,63	2,94	3,99	3,61	4,04	2,75	3,19	4,38	3,15
	$r_{(\cdot)i,j}$	9,1	9,2	9,3	9,4	9,5	10,1	10,2	10,3	10,4	10,5
MED	$r_P$	-0,53	0,85	0,29	-0,55	0,13	-0,59	0,81	0,26	-0,49	0,03
	$r_N$	-0,36	0,57	0,19	-0,37	0,09	-0,40	0,54	0,17	-0,34	0,02
	$r_R$	-0,47	0,42	0,21	-0,63	0,09	-0,48	0,40	0,16	-0,69	0,02
	$r_P$	1,31	1,72	1,38	0,83	1,55	1,26	1,71	1,34	0,94	1,39
DP	$r_N$	0,86	1,15	0,90	0,53	1,05	0,82	1,15	0,86	0,61	0,94
	$r_R$	1,01	0,86	1,24	0,87	1,36	0,89	0,85	1,04	1,12	1,01
	$r_P$	1,36	0,91	1,18	1,00	1,09	1,33	0,88	1,15	1,17	1,03
	$r_N$	1,51	1,05	1,17	1,12	1,20	1,42	1,04	1,16	1,30	1,12
CS	$r_R$	1,08	0,69	0,64	0,94	0,82	1,12	0,73	0,57	0,76	0,79
	$r_P$	5,97	3,57	4,86	5,62	4,09	5,67	3,41	4,75	6,08	4,20
	$r_N$	6,28	4,13	4,68	5,32	4,41	5,54	3,99	4,72	6,13	4,35
	$r_R$	3,94	2,94	3,15	4,17	3,30	3,96	3,06	2,82	3,80	3,11

Fonte: O autor (2016).

## Capítulo 5

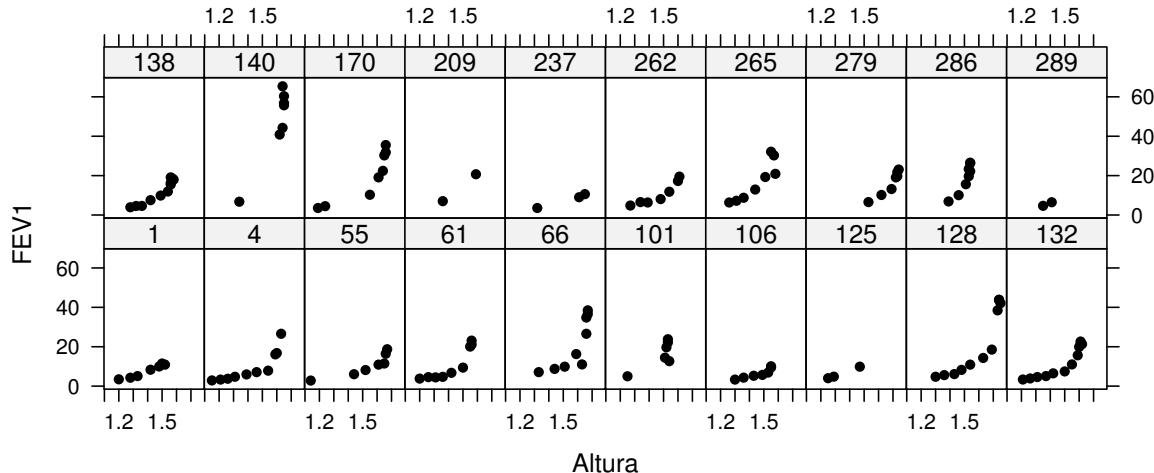
# Exemplos de Aplicações

### 5.1 Aplicação 1: Estudo de Poluição do Ar

Para o primeiro exemplo de aplicação dos MPLAG para dados correlacionados, consideramos uma amostra ( $n=20$ ) dos dados referentes ao estudo longitudinal executado para caracterizar o crescimento do pulmão segundo medidas de função pulmonar em crianças e adolescentes, segundo fatores como a idade e a altura (DOCKERY et al., 1983). Para tanto, o estudo foi realizado considerando 13.379 crianças nascidas em 1967 ou após este ano, segundo seis comunidades dos Estados Unidos: Watertown (Massachusetts), Kingston e Harriman (Tennessee), uma parte de St. Louis (Missouri), Steubenville (Ohio), Portage (Wisconsin), e Topeka (Kansas). A maioria das crianças se encontravam no início do estudo na primeira ou segunda séries do ensino fundamental e apresentavam idades entre seis e sete anos. Os valores das variáveis consideradas foram coletadas anualmente até o término do ensino médio ou até a impossibilidade de contato com o aluno. Em cada registro dos dados, uma medida de função pulmonar (FEV1) foi obtida (assim como a altura e o peso) e um questionário sobre aspectos relacionados à saúde respiratória dos jovens foi preenchido por um respectivo responsável.

Considerando a altura dos jovens, temos a partir do gráfico da Figura 5.1 que a variável FEV1 apresenta uma relação não linear com esta covariada segundo os vinte indivíduos

**Figura 5.1** Valores da medida de função pulmonar FEV1 versus altura para os vinte indivíduos considerados no Estudo de Poluição do Ar.



Fonte: O autor (2016).

considerado neste exemplo e portanto, o MPLAG para dados correlacionados pode ser utilizado para o ajuste destes dados.

Consideramos então o preditor linear da forma

$$\eta_{ij} = \beta_1 x_{1ij} + f(t_{ij}),$$

em que  $x_{1ij}$  é a idade (em anos) do  $i$ -ésimo indivíduo na  $j$ -ésima observação e  $t_{ij}$  é a altura (em metros) do  $i$ -ésimo indivíduo na  $j$ -ésima observação, para  $i = 1, \dots, 20$  e  $j = 1, \dots, m_i$ . Aqui, assumimos que a variável resposta  $\text{FEV1}_{ij}$  segue uma distribuição marginal gama com média  $\mu_{ij} = \exp\{\eta_{ij}\}$ , para  $i = 1, \dots, 20$  e  $j = 1, \dots, m_i$ . Uma estrutura de correlação autorregressiva de ordem 1 (AR-1) foi utilizada na matriz de “trabalho” para observações referentes a um mesmo indivíduo, segundo os vinte jovens considerados. A estrutura de correlação AR-1 é muito utilizada para modelagem de dados correlacionados, por depender apenas de um único parâmetro e remeter à uma estrutura de correlação encontrada em muitos fenômenos. Aqui, utilizamos o estimador de momentos definido na Seção 2.2 do Capítulo 2 para estimar o parâmetro  $\rho$  sob a

referida estrutura de correlação.

**Tabela 5.1** Estimativas dos parâmetros sob o MPLAG para dados correlacionados ajustado aos dados referentes ao Estudo de Poluição do Ar.

Efeito	Estim.	e.p. <sub>N</sub>	e.p. <sub>R</sub>	Efeito	Estim.	e.p. <sub>N</sub>	e.p. <sub>R</sub>
$\beta_1$	0,130	0,018	0,025	$f(1, 31)$	0,423	0,179	0,252
$f(1, 14)$	0,172	0,241	0,284	$f(1, 32)$	0,439	0,181	0,257
$f(1, 15)$	0,189	0,218	0,264	$f(1, 33)$	0,453	0,184	0,263
$f(1, 19)$	0,258	0,175	0,230	$f(1, 34)$	0,463	0,187	0,270
$f(1, 20)$	0,277	0,173	0,231	$f(1, 35)$	0,466	0,190	0,279
$f(1, 21)$	0,296	0,172	0,233	$f(1, 36)$	0,466	0,193	0,287
$f(1, 24)$	0,351	0,171	0,236	$f(1, 37)$	0,467	0,196	0,293
$f(1, 25)$	0,365	0,172	0,236	$f(1, 39)$	0,476	0,202	0,302
$f(1, 26)$	0,374	0,173	0,236	$f(1, 41)$	0,503	0,208	0,308
$f(1, 27)$	0,381	0,173	0,237	$f(1, 42)$	0,525	0,211	0,311
$f(1, 28)$	0,388	0,174	0,240	$f(1, 43)$	0,551	0,214	0,314
$f(1, 29)$	0,397	0,176	0,243	$f(1, 44)$	0,578	0,217	0,316
$f(1, 30)$	0,409	0,177	0,248	$f(1, 46)$	0,628	0,224	0,322
Efeito	Estim.	e.p. <sub>N</sub>	e.p. <sub>R</sub>	Efeito	Estim.	e.p. <sub>N</sub>	e.p. <sub>R</sub>
$f(1, 47)$	0,653	0,228	0,326	$f(1, 60)$	1,055	0,277	0,384
$f(1, 48)$	0,681	0,232	0,331	$f(1, 61)$	1,113	0,278	0,384
$f(1, 49)$	0,713	0,237	0,335	$f(1, 62)$	1,181	0,280	0,386
$f(1, 50)$	0,749	0,241	0,340	$f(1, 63)$	1,248	0,281	0,390
$f(1, 51)$	0,787	0,246	0,346	$f(1, 64)$	1,304	0,282	0,394
$f(1, 52)$	0,819	0,252	0,354	$f(1, 65)$	1,338	0,284	0,398
$f(1, 53)$	0,847	0,257	0,364	$f(1, 66)$	1,353	0,286	0,401
$f(1, 54)$	0,869	0,262	0,373	$f(1, 67)$	1,355	0,288	0,402
$f(1, 55)$	0,889	0,266	0,380	$f(1, 69)$	1,348	0,291	0,401
$f(1, 56)$	0,911	0,270	0,385	$f(1, 72)$	1,363	0,297	0,401
$f(1, 57)$	0,937	0,272	0,386	$f(1, 73)$	1,378	0,301	0,403
$f(1, 58)$	0,968	0,275	0,386	$f(1, 74)$	1,396	0,308	0,407
$f(1, 59)$	1,007	0,276	0,384	$f(1, 75)$	1,415	0,318	0,410

Fonte: O autor (2016).

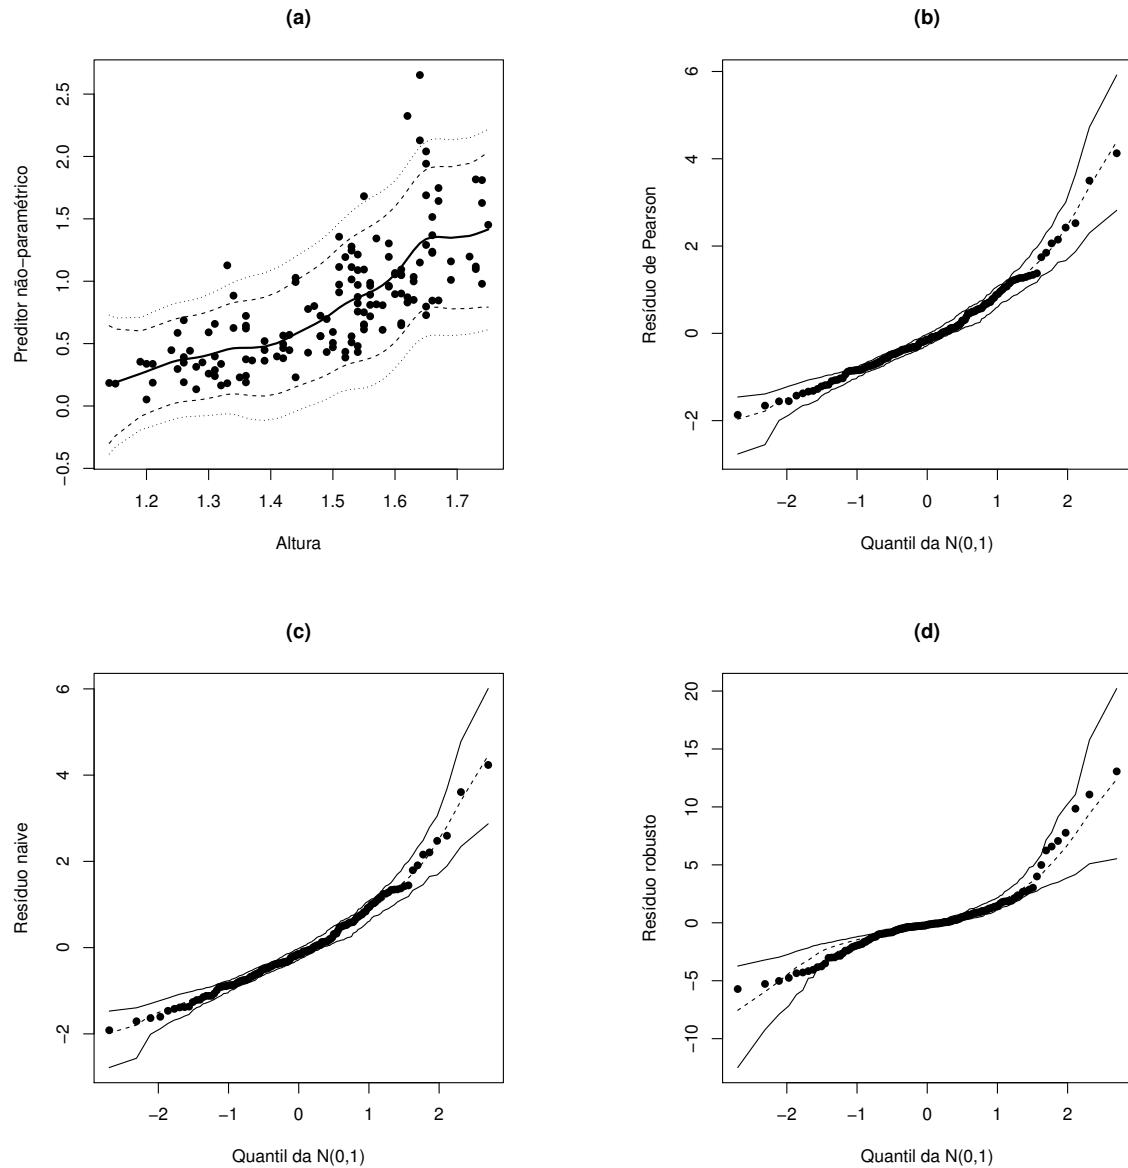
Pode ser observado a partir da Tabela 5.1 que as estimativas “robustas” para os erros-padrão das estimativas das componentes paramétricas e não-paramétricas do preditor apresentam valores maiores que as respectivas estimativas “naive”. A idade e as funções não-paramétricas para todos os valores distintos da altura são marginalmente

significativas segundo testes de hipóteses aproximados do tipo z (assumindo 5% de significância), realizados a partir das estimativas e dos erros-padrão “naive” e “robustos” estimados. A estimativa do parâmetro de correlação foi de  $\hat{\rho} = 0,814$  e a estimativa do parâmetro de dispersão foi de  $\hat{\phi} = 9,358$ . Ainda, a estimativa do parâmetro de suavização foi de  $\hat{\alpha} = 9,135 \times 10^{-5}$ , selecionado através do método de validação cruzada generalizada dentre um conjunto de 20 valores compreendidos entre  $9,135 \times 10^{-5}$  e  $1,179 \times 10^6$ . Sendo assim, o valor selecionado pode ser considerado baixo, indicando desta forma um comportamento não linear para a função não-paramétrica.

A função não-paramétrica estimada é ilustrada no gráfico (a) da Figura 5.2 (curva em negrito), com bandas de confiança aproximadas utilizando estimativas “naive” (curvas tracejadas) e “robustas” (curvas pontilhadas) dos erros-padrão das estimativas. Os limites inferior e superior da banda de confiança utilizando as estimativas “naive” dos erros-padrão são dados por  $\hat{f}(t_{ij}) - 1,96\sqrt{\widehat{\text{Var}}_N(\hat{f}(t_{ij}))}$  e  $\hat{f}(t_{ij}) + 1,96\sqrt{\widehat{\text{Var}}_N(\hat{f}(t_{ij}))}$  respectivamente, enquanto os limites inferior e superior da banda de confiança utilizando as estimativas “robustas” dos erros-padrão são dados por  $\hat{f}(t_{ij}) - 1,96\sqrt{\widehat{\text{Var}}_R(\hat{f}(t_{ij}))}$  e  $\hat{f}(t_{ij}) + 1,96\sqrt{\widehat{\text{Var}}_R(\hat{f}(t_{ij}))}$  respectivamente, para  $i = 1, \dots, 20$  e  $j = 1, \dots, m_i$ . A partir deste gráfico podemos notar o comportamento não linear da relação entre a idade e a medida de desempenho pulmonar FEV1.

Considerando os gráficos (b), (c) e (d) da Figura 5.2, em cada um deles a grande maioria dos pontos se apresenta dentro dos respectivos envelopes simulados. Desta forma, consideramos que a suposição de uma distribuição marginal gama para a medida de desempenho pulmonar FEV1 observada nos dados referentes ao Estudo de Poluição do Ar é apropriada sob o MPLAG para dados correlacionados ajustado neste exemplo de aplicação. Os comportamentos dos pontos nos gráficos de quantis referentes aos resíduos de Pearson e resíduos “naive” (gráficos (b) e (c), respectivamente) indicam que os respectivos resíduos apresentam distribuições assimétricas, enquanto que o comportamento dos pontos no gráfico de quantis para os resíduos “robustos” (gráfico (d)) indica uma

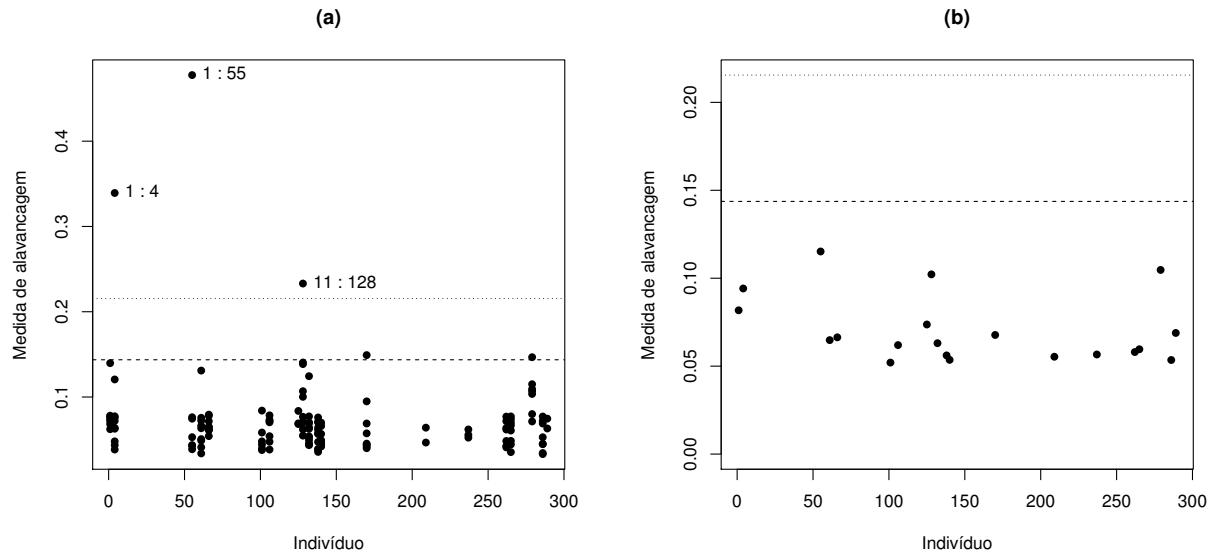
**Figura 5.2** Gráfico da função não-paramétrica estimada (a) e gráficos de quantis normais com envelopes simulados (95% de confiança) para os resíduos de Pearson (b) “naive” (c) e “robustos” (d) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 1 para os dados referentes ao Estudo de Poluição do Ar.



Fonte: O autor (2016).

distribuição aproximadamente simétrica para estes respectivos resíduos.

**Figura 5.3** Gráficos das medidas de alavancagem por período observado para cada observação (a) e para cada indivíduo (b) considerado sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 1 para os dados referentes ao Estudo de Poluição do Ar.

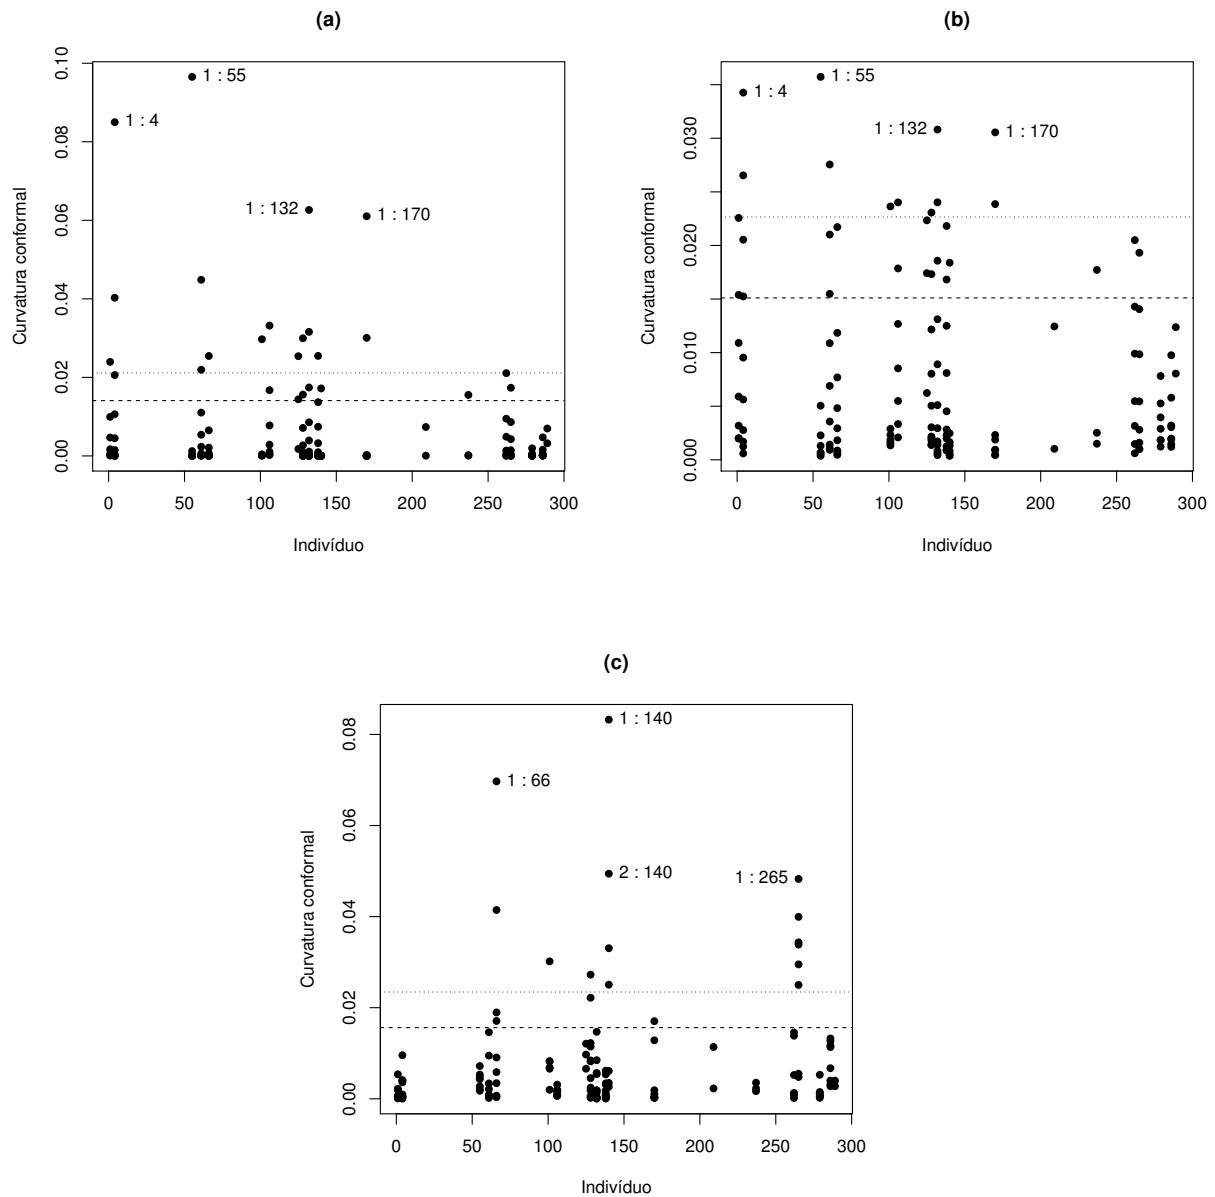


Fonte: O autor (2016).

Observando o gráfico (a) da Figura 5.3, podemos notar que a observação 1 para o indivíduo de número 4, a observação 1 para o indivíduo de número 55 e a obsevação 11 para o indivíduo de número 128 apresentam alta alavancagem. O indivíduo de número 4 apresentou altura de  $1,15m$  e 6,76 anos na observação destacada; o indivíduo de número 55 teve altura registrada de  $1,14m$  e 6,56 anos de idade em sua primeira observação e o indivíduo de número 128 registrou valor da altura de  $1,75m$  e 17,56 anos de idade na observação destacada no respectivo gráfico. A média geral das alturas para todos os indivíduos foi de  $1,49m$ , com desvio-padrão de  $0.14m$  e a média geral das idades para todos os jovens considerados neste exemplo foi de 12,73 anos, com desvio-padrão de 3,12 anos. Temos ainda que, de acordo com o gráfico (b) desta mesma figura, nenhum indivíduo apresenta alta alavancagem.

Segundo a perturbação de casos (gráfico (a) da Figura 5.4), as observações potencial-

**Figura 5.4** Gráficos das medidas de influência local segundo a perturbação de casos (a), perturbação na variável resposta (b) e perturbação em uma variável explicativa (c) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 1 para os dados referentes ao Estudo de Poluição do Ar.



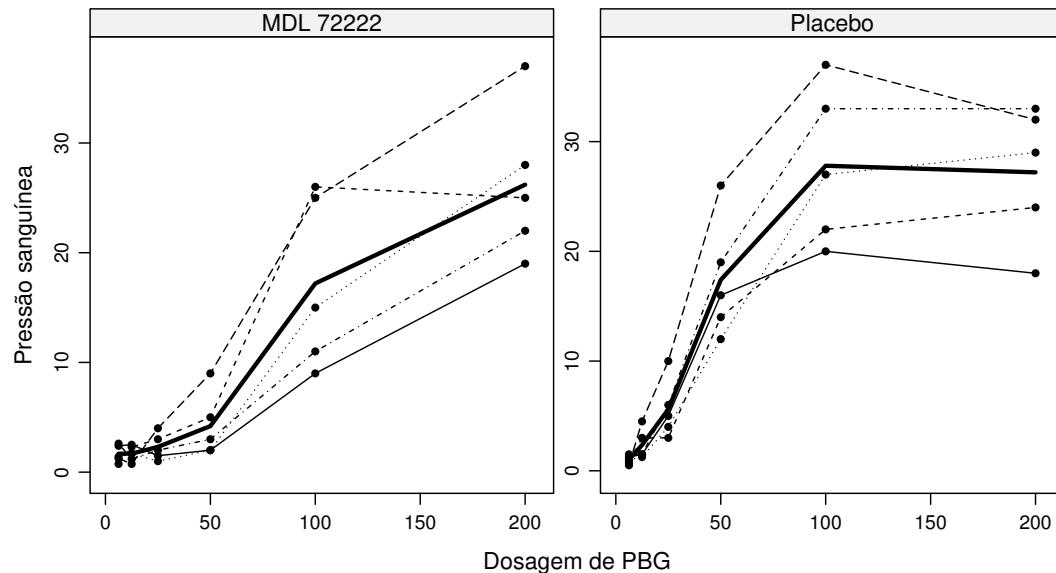
Fonte: O autor (2016).

mente influentes nas estimativas dos parâmetros foram as observações 1 para o indivíduo 4, 1 para o indivíduo 55, 1 para o indivíduo 132 e 1 para o indivíduo 170. Os valores da altura para estas observações foram  $1,15m$ ,  $1,14m$ ,  $1,21m$  e  $1,19m$ , respectivamente. Considerando as idades para estas observações, temos os valores observados 6,76, 6,56, 6,70 e 7,06 anos, respectivamente. Ainda, os valores da variável resposta FEV1 registrados foram 2,89, 2,83, 3,35 e 3,56, respectivamente. A média geral da variável FEV1 para todos os indivíduos foi de 15,33, com desvio-padrão de 12,61. Considerando o gráfico (b) desta mesma Figura, temos que as mesmas observações detectadas no gráfico (a) como potencialmente influentes, segundo a perturbação na variável resposta. De acordo com o gráfico (c), a observação 1 referente ao indivíduo 66, as observações 1 e 2 referentes ao indivíduo 140 e a observação 1 para o indivíduo de número 265 foram consideradas como potencialmente influentes sob a perturbação na variável explicativa idade. Para estas observações, temos os valores das alturas  $1,33m$ ,  $1,34m$ ,  $1,62m$  e  $1,26m$ , respectivamente, enquanto que as idades registradas segundo estas observações foram 7,61, 8,40, 13,56 e 9,23 anos, respectivamente. Ainda, para as referidas observações, os valores da variável resposta FEV1 foram 7,10, 6,75, 40,85 e 6,36, respectivamente.

## 5.2 Aplicação 2: Dados de Pressão Sanguínea

Os dados referentes a este exemplo de aplicação dos MPLAG para dados correlacionados são provenientes de um experimento, descrito em Ludbrook (1994) e analisado em Venables e Ripley (2002), com o objetivo de examinar o efeito da droga MDL 72222 no controle da pressão sanguínea, segundo dosagens crescentes da substância **phenylbiguanide** (PBG). Cinco coelhos foram estudados sob dois cenários: após o tratamento com uma substância salina (placebo) e após o tratamento com a MDL 72222. Após cada tratamento, doses crescentes de PBG foram injetadas de forma intravenosa a cada 10 minutos nos coelhos, em um total de seis aplicações, e a pressão sanguínea média, em  $mm\ Hg$  (considerando as pressões sistólica e diastólica) foi registrada.

**Figura 5.5** Dosagem de PBG versus pressão sanguínea média segundo os dois tratamentos considerados nos Dados de Pressão Sanguínea.



Fonte: O autor (2016).

A partir da Figura 5.5 pode ser observado que a pressão sanguínea média cresce à medida que a concentração da dosagem de PBG cresce, considerando os dois tratamentos utilizados neste estudo. Contudo, a droga MDL 72222 parece retardar a velocidade de crescimento da pressão média. Nota-se, ainda, que existe uma relação não-linear entre a dosagem de PBG e a pressão sanguínea média tanto no grupo placebo quanto no grupo que recebeu o tratamento investigado. Além disto, observações realizadas para um mesmo indivíduo podem apresentar correlação. Sendo assim, podemos considerar o ajuste do MPLAG para dados correlacionados para este exemplo de aplicação.

Consideramos portanto para o ajuste do MPLAG para dados correlacionados o seguinte preditor

$$\eta_{ij} = \beta_1 x_{1ij} + f(t_{ij}),$$

em que  $x_{1ij}$  (1, se o  $i$ -ésimo coelho recebeu a droga MDL 72222 no  $j$ -ésimo período e 0, caso contrário) é uma variável dicotômica referente ao tratamento utilizado e  $t_{ij}$  é a  $j$ -

ésima dosagem de PBG aplicada no  $i$ -ésimo coelho, para  $i = 1, 2, \dots, 10$  e  $j = 1, 2, \dots, 6$ . Aqui, assumimos que a pressão sanguínea  $y_{ij}$  segue uma distribuição marginal gama com média  $\mu_{ij} = \exp\{\eta_{ij}\}$ , para  $i = 1, 2, \dots, 10$  e  $j = 1, 2, \dots, 6$ . Ainda, utilizamos a função de ligação  $\log(\mu_{ij}) = \eta_{ij}$ . Assim como no primeiro exemplo de aplicação, foi considerada uma estrutura de correlação AR-1 para observações da pressão sanguínea pertencentes a um determinado indivíduo utilizado neste estudo. Utilizamos o estimador de momentos definido na Seção 2.2 do Capítulo 2 para estimar o parâmetro  $\rho$ .

**Tabela 5.2** Estimativas dos parâmetros sob o MPLAG para dados correlacionados ajustado aos Dados de Pressão Sanguínea.

Efeito	Estim.	e.p. <sub>N</sub>	e.p. <sub>R</sub>
$\beta_1$	-0,459	0,132	0,167
$f(6, 25)$	0,650	0,133	0,188
$f(12, 5)$	0,939	0,115	0,125
$f(25)$	1,499	0,111	0,136
$f(50)$	2,432	0,138	0,243
$f(100)$	3,333	0,163	0,143
$f(200)$	3,542	0,174	0,144

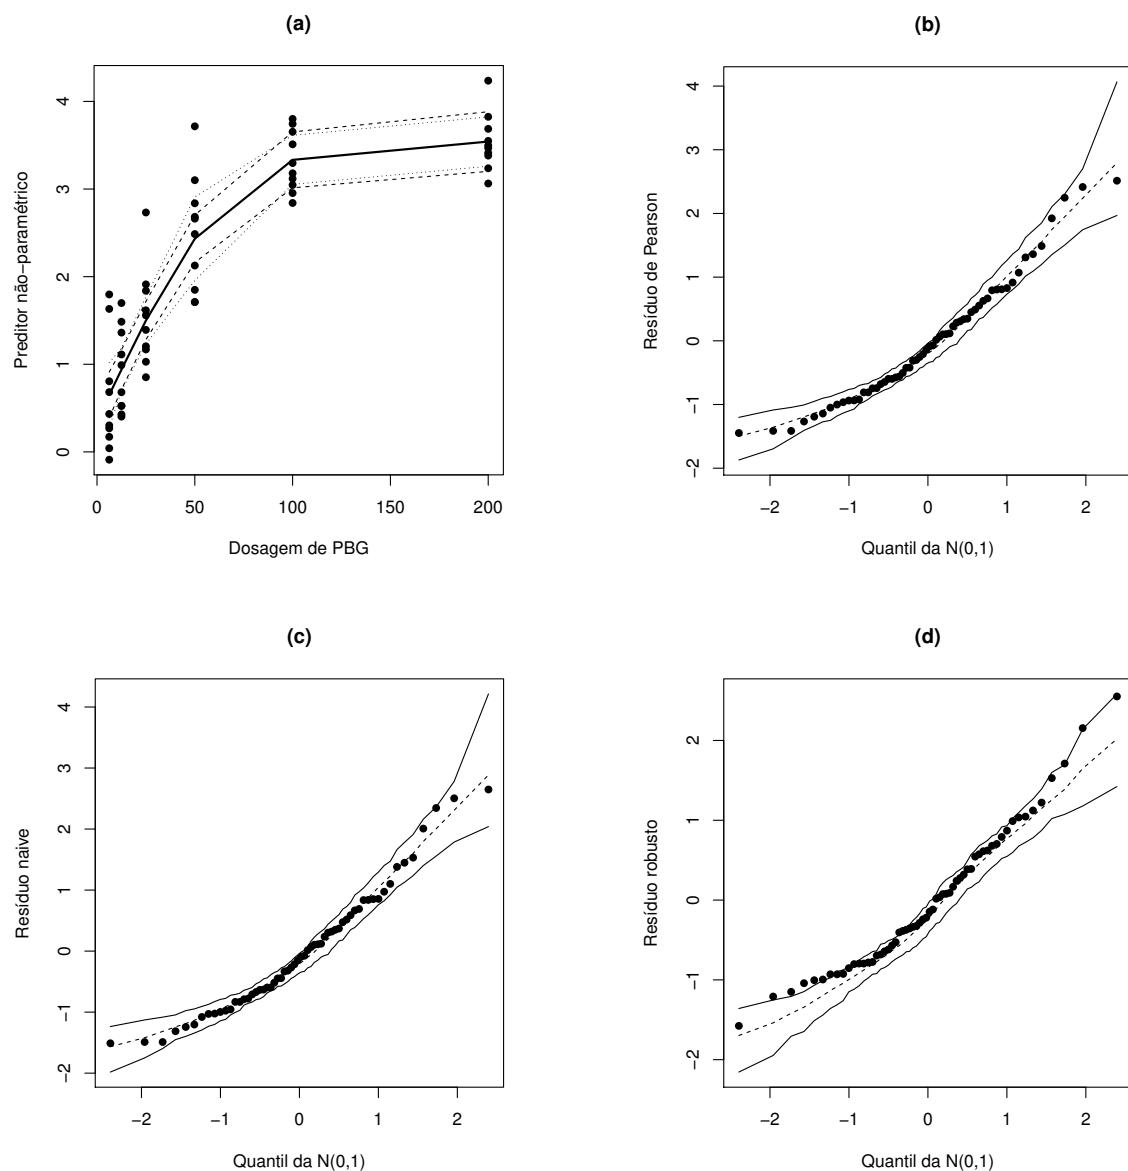
Fonte: O autor (2016).

Segundo a Tabela 5.2, temos que o tratamento segundo a droga MDL 72222 é significativo para retardar o crescimento da pressão sanguínea média, segundo testes marginais do tipo z (assumindo, por exemplo, 5% de significância), considerando tanto a estimativa “naive” quanto a estimativa “robusta” do erro-padrão referente à estimativa de  $\beta_1$ . Temos ainda que as funções não-paramétricas referentes aos valores das dosagens de PBG também são significativas segundo testes de hipóteses similares.

O valor estimado para o parâmetro de correlação foi de  $\hat{\rho} = 0,354$  e a estimativa do parâmetro  $\phi$  foi de  $\hat{\phi} = 3,835$ . Ainda, o valor da estimativa do parâmetro de suavização foi de  $\hat{\alpha} = 29.023,745$ , selecionado dentre 20 valores compreendidos entre  $4,753 \times 10^{-4}$  e  $2,312 \times 10^6$ . Sendo assim, o valor selecionado do parâmetro de suavização pode ser considerado baixo, indicando desta forma um comportamento não linear para a função

não-paramétrica. As análises de alavancagem e de influência local não foram realizadas pelo fato de que existe apenas uma variável dicotômica referente a parte paramétrica do preditor considerado no MPLAG para dados correlacionados ajustado para os Dados de Pressão Sanguínea considerados neste exemplo de aplicação.

**Figura 5.6** Gráfico da função não-paramétrica estimada (a) e gráficos de quantis normais com envelopes simulados (95% de confiança) para os resíduos de Pearson (b) “naive” (c) e “robustos” (d) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 1 para os Dados de Pressão Sanguínea.



Fonte: O autor (2016).

A função não-paramétrica estimada é ilustrada no gráfico (a) da Figura 5.6 (curva em negrito), com bandas de confiança aproximadas utilizando estimativas “naive” (curvas tracejadas) e “robustas” (curvas pontilhadas) dos erros-padrão das estimativas. A partir deste gráfico podemos notar o comportamento não linear da relação entre a dosagem de PBG e a pressão sanguínea.

Considerando os gráficos de quantis normais com envelopes simulados para os resíduos de Pearson (b), resíduos “naive” (c) e resíduos “robustos” (d) da Figura 5.6, podemos observar evidências de que a distribuição marginal gama assumida para a pressão sanguínea média está corretamente especificada sob o MPLAG para dados correlacionados ajustado aos Dados de Pressão Sanguínea, uma vez que em cada um destes gráficos a maioria dos pontos encontra-se dentro dos respectivos envelopes simulados. Finalmente, os comportamentos dos pontos nos gráficos de quantis referentes aos resíduos de Pearson, resíduos “naive” e resíduos “robustos” (gráficos (b), (c) e (d), respectivamente) indicam que os três resíduos considerados apresentam distribuições com certa assimetria.

## **PARTE II**

# **MPLAG PARA DADOS CORRELACIONADOS - CASO 2**

Nesta parte estudamos os MPLAG para dados correlacionados sob a proposta de equações de estimação semiparamétricas definidas para a estimação conjunta dos efeitos fixos e dos parâmetros de correlação. No caso unicamente paramétrico estas equações de estimação são conhecidas na literatura como EEG-2. Uma das principais vantagens do uso das EEG-2 em relação às EEG-1 reside no fato de que sob as EEG-2 os estimadores dos efeitos fixos são em geral mais eficientes que aqueles obtidos sob as EEG-1, desde que a estrutura de correlação esteja corretamente especificada. Além disso, nas EEG-2 podemos em geral garantir que os valores estimados dos parâmetros de correlação encontrem-se entre -1 e 1 (LIANG; ZEGER; QAQISH, 1992).

## Capítulo 6

# Definição do Modelo, Estimação e Inferência

Antes da definição do modelo sob a abordagem similar àquela utilizada sob EEG-2 no caso paramétrico, vale observar que a maioria dos estimadores de  $\boldsymbol{\rho}$  utilizados na Parte I podem ser obtidos através de equações de estimação (CROWDER, 1995; ZIEGLER; KASTNER; BLETTNER, 1998). Para tanto, um segundo conjunto de equações de estimação pode ser definido. Considerando  $\phi$  fixado, seja,

$$s_{ijk} = \phi \frac{(y_{ij} - \mu_{ij})(y_{ik} - \mu_{ik})}{V_{ij}^{1/2} V_{ik}^{1/2}},$$

para  $i = 1, \dots, n$  e  $j, k = 1, \dots, m_i$ , com  $j < k$  e seja  $\boldsymbol{\rho} = (\boldsymbol{\rho}_1^\top, \dots, \boldsymbol{\rho}_n^\top)^\top$ , em que  $\boldsymbol{\rho}_i = (\rho_{i1}, \dots, \rho_{ia_i})^\top$ , representando o vetor com os parâmetros de correlação distintos para o vetor de respostas  $\mathbf{y}_i$ , de tal forma que  $a_i = m_i(m_i - 1)/2$ . Assumindo que  $\boldsymbol{\rho}$  é função de um vetor de parâmetros  $\mathbf{v}$  de dimensão  $a \times 1$  e que  $\boldsymbol{\xi}$  e  $\boldsymbol{\alpha}$  estão fixados, temos a forma geral das equações de estimação para  $\mathbf{v}$  (PRENTICE, 1988) dada por

$$\Psi_{\boldsymbol{\alpha}}(\mathbf{v}) = \sum_{i=1}^n \mathbf{E}_{(22)i}^{*\top} \mathbf{V}_{(22)i}^{*-1} (\mathbf{s}_i - \boldsymbol{\rho}_i) = \mathbf{0}, \quad (14)$$

em que  $\mathbf{E}_{(22)i}^* = \partial \boldsymbol{\rho}_i / \partial \mathbf{v}$ ,  $\mathbf{V}_{(22)i}^*$  é uma matriz de variância e covariância de “trabalho” que faz o papel da matriz  $\text{Var}(\mathbf{s}_i)$  e  $\mathbf{s}_i = (s_{i1}, \dots, s_{ia_i})^\top$  representa um vetor com as

variáveis  $s_{ijk}$  ordenadas sob a mesma ordem do vetor de parâmetros de correlação  $\rho_i$ . Sob o caso 1,  $\mathbf{V}_{(22)i}$  é uma matriz identidade e  $\boldsymbol{\rho}$  é uma função linear de  $\boldsymbol{v}$  (ZIEGLER; KASTNER; BLETTNER, 1998). Sendo assim, podemos considerar os MPLAG para dados correlacionados sob o caso 1, reescrevendo (7) como

$$\Psi_{\alpha}(\boldsymbol{\xi}) = \sum_{i=1}^n \mathbf{E}_{(11)i}^{*\top} \mathbf{V}_{(11)i}^{*-1} (\mathbf{y}_i - \boldsymbol{\mu}_i) - \mathbf{P}(\boldsymbol{\alpha}) = \mathbf{0}, \quad (15)$$

em que  $\mathbf{E}_{(11)i}^* = \partial \boldsymbol{\mu}_i / \partial \boldsymbol{\xi} = \mathbf{D}_i \mathbf{X}_i^*$  e  $\mathbf{V}_{(11)i}^* = \mathbf{V}_i^*$ , e combinar as equações (15) e (14) em um único sistema de equações, da forma

$$\Psi_{\alpha}(\boldsymbol{\delta}) = \sum_{i=1}^n \mathbf{E}_{(\boldsymbol{\delta})i}^{*\top} \mathbf{V}_{(\boldsymbol{\delta})i}^{*-1} (\boldsymbol{\gamma}_i - \boldsymbol{\tau}_i) - \mathbf{P}(\boldsymbol{\delta})(\boldsymbol{\alpha}) = \mathbf{0}, \quad (16)$$

em que

$$\boldsymbol{\delta} = (\boldsymbol{\xi}^\top, \boldsymbol{v}^\top)^\top, \quad \mathbf{E}_{(\boldsymbol{\delta})i}^* = \begin{bmatrix} \mathbf{E}_{(11)i}^* & \mathbf{0} \\ \mathbf{0} & \mathbf{E}_{(22)i}^* \end{bmatrix}, \quad \mathbf{V}_{(\boldsymbol{\delta})i}^* = \begin{bmatrix} \mathbf{V}_{(11)i}^* & \mathbf{0} \\ \mathbf{0} & \mathbf{V}_{(22)i}^{*-1} \end{bmatrix}, \quad \boldsymbol{\gamma}_i = (\mathbf{y}_i^\top, \mathbf{s}_i^\top)^\top,$$

$\boldsymbol{\tau}_i = (\boldsymbol{\mu}_i^\top, \boldsymbol{\rho}_i^\top)^\top$  e  $\mathbf{P}(\boldsymbol{\delta})(\boldsymbol{\alpha}) = (\mathbf{P}(\boldsymbol{\alpha})^\top, \mathbf{0}^\top)^\top$ . Outra forma de obter (14) é definir um preditor linear da forma

$$h(\rho_{il}) = \eta_{(2)il} = \mathbf{u}_{il} \boldsymbol{v},$$

para  $i = 1, \dots, n$  e  $l = 1, \dots, a_i$ , em que  $h$  é uma função invertível duas vezes diferenciável que faz o papel de uma “função de ligação” e  $\mathbf{u}_{il}$  é um vetor de variáveis preditoras associados aos parâmetros em  $\boldsymbol{v}$  (LIPSITZ; LAIRD; HARRINGTON, 1991). Como  $-1 \leq \rho_{il} \leq 1$ , algumas funções específicas são geralmente utilizadas, como por exemplo uma modificação da função arco-tangente hiperbólica, dada por  $h(\rho) = \log[(1 + \rho)/(1 - \rho)]$ .

Desta forma, as equações de estimação para  $\boldsymbol{v}$  podem ser definidas da forma

$$\boldsymbol{\Psi}_{\alpha}(\boldsymbol{v}) = \sum_{i=1}^n \mathbf{X}_{(22)i}^{*\top} \mathbf{W}_{(22)i}^* \mathbf{D}_{(22)i}^{-1} (\mathbf{s}_i - \boldsymbol{\rho}_i) = \mathbf{0}, \quad (17)$$

em que  $\mathbf{X}_{(22)i}^* = (\mathbf{u}_{1i}, \dots, \mathbf{u}_{ai})$ ,  $\mathbf{u}_{bi} = (u_{bi1}, \dots, u_{bia_i})^\top$ , para  $b = 1, \dots, a$ ,  $\mathbf{W}_{(22)i}^* = \mathbf{D}_{(22)i} \mathbf{V}_{(22)i}^{*-1} \mathbf{D}_{(22)i}$  e  $\mathbf{D}_{(22)i} = \text{diag}\{\partial\rho_{i1}/\partial\eta_{(2)i1}, \dots, \partial\rho_{ia_i}/\partial\eta_{(2)ia_i}\}$ . Portanto, sob o caso 1 temos as equações de estimação dadas por

$$\boldsymbol{\Psi}_{\alpha}(\boldsymbol{\delta}) = \sum_{i=1}^n \mathbf{X}_{(\boldsymbol{\delta})i}^{*\top} \mathbf{W}_{(\boldsymbol{\delta})i}^* \mathbf{D}_{(\boldsymbol{\delta})i}^{-1} (\boldsymbol{\gamma}_i - \boldsymbol{\tau}_i) - \mathbf{P}_{(\boldsymbol{\delta})}(\boldsymbol{\alpha}) = \mathbf{0}, \quad (18)$$

em que

$$\mathbf{X}_{(\boldsymbol{\delta})i}^* = \begin{bmatrix} \mathbf{X}_{(11)i}^* & \mathbf{0} \\ \mathbf{0} & \mathbf{X}_{(22)i}^* \end{bmatrix}, \quad \mathbf{W}_{(\boldsymbol{\delta})i}^* = \begin{bmatrix} \mathbf{W}_{(11)i}^* & \mathbf{0} \\ \mathbf{0} & \mathbf{W}_{(22)i}^* \end{bmatrix}, \quad \mathbf{D}_{(\boldsymbol{\delta})i} = \begin{bmatrix} \mathbf{D}_{(11)i} & \mathbf{0} \\ \mathbf{0} & \mathbf{D}_{(22)i} \end{bmatrix},$$

$\mathbf{X}_{(11)i}^* = \mathbf{X}_i^*$ ,  $\mathbf{D}_{(11)i} = \mathbf{D}_i$  e  $\mathbf{W}_{(11)i}^* = \mathbf{W}_i^*$ , com  $\mathbf{X}_i^*$ ,  $\mathbf{D}_i$  e  $\mathbf{W}_i^*$  sendo as matrizes definidas no Capítulo 2.

A partir de uma nova abordagem em analogia às equações de estimação conhecidas como EEG-2 no caso paramétrico (ZHAO; PRETICE, 1990; PRENTICE; ZHAO, 1991), permite-se que o vetor de médias  $\boldsymbol{\mu}$  possa depender não somente do vetor de efeitos fixos como também do vetor de parâmetros de correlação, ou seja, podemos considerar  $\boldsymbol{\mu} = \boldsymbol{\mu}(\boldsymbol{\xi}, \boldsymbol{v})$ . Analogamente, permitimos que o vetor de parâmetros de correlação dependa não somente do vetor de parâmetros  $\boldsymbol{v}$  como também do vetor de parâmetros referentes aos efeitos fixos, ou seja,  $\boldsymbol{\rho} = \boldsymbol{\rho}(\boldsymbol{v}, \boldsymbol{\xi})$ . A partir destas definições, podemos generalizar as equações dadas em (16) de tal forma que

$$\mathbf{E}_{(\boldsymbol{\delta})i}^* = \begin{bmatrix} \partial\boldsymbol{\mu}_i/\partial\boldsymbol{\xi} & \partial\boldsymbol{\mu}_i/\partial\boldsymbol{v} \\ \partial\boldsymbol{\rho}_i/\partial\boldsymbol{\xi} & \partial\boldsymbol{\rho}_i/\partial\boldsymbol{v} \end{bmatrix} = \begin{bmatrix} \mathbf{E}_{(11)i}^* & \mathbf{E}_{(12)i}^* \\ \mathbf{E}_{(21)i}^* & \mathbf{E}_{(22)i}^* \end{bmatrix}$$

e

$$\mathbf{V}_{(\delta)i}^* = \begin{bmatrix} \text{Var}(\mathbf{y}_i) & \text{Cov}(\mathbf{y}_i, \mathbf{s}_i) \\ \text{Cov}(\mathbf{s}_i, \mathbf{y}_i) & \text{Var}(\mathbf{s}_i) \end{bmatrix} = \begin{bmatrix} \mathbf{V}_{(11)i}^* & \mathbf{V}_{(12)i}^* \\ \mathbf{V}_{(21)i}^* & \mathbf{V}_{(22)i}^* \end{bmatrix}.$$

Neste caso, além da definição de uma matriz de trabalho dada em  $\text{Var}(\mathbf{s}_i)$  é necessário admitir uma estrutura para a matriz  $\text{Cov}(\mathbf{y}_i, \mathbf{s}_i)$ . Estas matrizes dependem possivelmente de  $\boldsymbol{\mu}(\boldsymbol{\xi}, \boldsymbol{v})$  e  $\boldsymbol{\rho}(\boldsymbol{v}, \boldsymbol{\xi})$ . Analogamente, podemos generalizar as equações em (18) de tal forma que

$$\mathbf{X}_{(\delta)i}^* = \begin{bmatrix} \mathbf{X}_{(11)i}^* & \mathbf{X}_{(12)i}^* \\ \mathbf{X}_{(21)i}^* & \mathbf{X}_{(22)i}^* \end{bmatrix},$$

em que  $\mathbf{X}_{(11)i}^*$  é a matriz de variáveis associadas à  $\boldsymbol{\xi}$  em  $\boldsymbol{\eta}_{(1)i} = (\eta_{(1)i1}, \dots, \eta_{(1)im_i})^\top$ ,  $\mathbf{X}_{(12)i}^*$  é a matriz de variáveis preditoras associadas à  $\boldsymbol{v}$  em  $\boldsymbol{\eta}_{(1)i}$ ,  $\mathbf{X}_{(21)i}^*$  é a matriz de variáveis preditoras associadas à  $\boldsymbol{\xi}$  em  $\boldsymbol{\eta}_{(2)i} = (\eta_{(2)i1}, \dots, \eta_{(2)ia_i})^\top$  e  $\mathbf{X}_{(22)i}^*$  é a matriz de variáveis preditoras associadas à  $\boldsymbol{v}$  em  $\boldsymbol{\eta}_{(2)i}$ . Pode ser notado que as matrizes  $\mathbf{X}_{(11)i}^*$  e  $\mathbf{X}_{(21)i}^*$  não são necessariamente iguais, pois as variáveis referentes à  $\boldsymbol{\xi}$  em  $\boldsymbol{\eta}_{(1)i}$  podem não ser as mesmas utilizadas em  $\boldsymbol{\eta}_{(2)i}$ , o mesmo acontecendo no caso de  $\boldsymbol{v}$ . Ainda, a matriz  $\mathbf{W}_{(\delta)i}^*$  não é necessariamente bloco-diagonal, dada a generalização de  $\mathbf{V}_{(\delta)i}^*$ .

Nas próximas duas seções derivamos o processo de estimação dos parâmetros nos MPLAG para dados correlacionados sob o caso 2, mais especificamente um procedimento para a obtenção das estimativas de  $\boldsymbol{\delta}$  e  $\phi$ .

## 6.1 Estimação de $\boldsymbol{\delta}$

Para a estimação de  $\boldsymbol{\delta}$  nos MPLAG para dados correlacionados sob o caso 2, devemos considerar as equações de estimação dadas em (18). Sendo assim, temos o processo iterativo (assumindo  $\boldsymbol{\alpha}$  e  $\phi$  fixados) dado por

$$\boldsymbol{\delta}^{(b+1)} = \{\mathbf{X}_{(\delta)}^{*\top} \mathbf{W}_{(\delta)}^{*(b)} \mathbf{X}_{(\delta)}^* + \mathbf{K}_{(\delta)}^*(\boldsymbol{\alpha})\}^{-1} \{\mathbf{X}_{(\delta)}^{*\top} \mathbf{W}_{(\delta)}^{*(b)} \mathbf{z}_{(\delta)}^{(b)}\}, \quad b = 0, 1, 2, \dots \quad (19)$$

Em (19) temos  $\mathbf{X}_{(\delta)}^* = (\mathbf{X}_{(\delta)}^{*\top}, \dots, \mathbf{X}_{(\delta)}^{*\top})^\top$ ,  $\mathbf{W}_{(\delta)} = \text{diag}\{\mathbf{W}_{(\delta)1}, \dots, \mathbf{W}_{(\delta)n}\}$ ,  $\mathbf{K}_{(\delta)}^*(\boldsymbol{\alpha}) = \text{diag}\{\mathbf{0}, \mathbf{K}_{(11)}(\boldsymbol{\alpha}), \mathbf{K}_{(22)}(\boldsymbol{\alpha})\}$ ,  $\mathbf{K}_{(11)}(\boldsymbol{\alpha}) = \mathbf{K}(\boldsymbol{\alpha})$  e  $\mathbf{K}_{(22)}(\boldsymbol{\alpha})$  é uma matriz de penalização referente às possíveis funções não paramétricas em  $\boldsymbol{\rho}(\boldsymbol{v}, \boldsymbol{\xi})$ ,  $\mathbf{z}_{(\delta)} = (\mathbf{z}_{(\delta)1}^\top, \dots, \mathbf{z}_{(\delta)n}^\top)^\top$ ,  $\mathbf{z}_{(\delta)i} = \mathbf{D}_{(\delta)i}^{-1}(\boldsymbol{\gamma}_i - \boldsymbol{\tau}_i) + \boldsymbol{\eta}_{(\delta)i}$ ,  $\boldsymbol{\eta}_{(\delta)i} = (\boldsymbol{\eta}_{(1)i}^\top, \boldsymbol{\eta}_{(2)i}^\top)^\top$ ,  $\boldsymbol{\eta}_{(1)i} = \boldsymbol{\eta}_i$  e  $\boldsymbol{\eta}_{(2)i} = (\eta_{(2)i1}, \dots, \eta_{(2)i a_i})^\top$ .

Sob o caso 1 e considerando as equações de estimação para  $\boldsymbol{v}$ , podemos definir o processo iterativo

$$\begin{aligned}\boldsymbol{\xi}^{(b+1)} &= \{\mathbf{X}_{(11)}^{*\top} \mathbf{W}_{(11)}^{*(b)} \mathbf{X}_{(11)}^* + \mathbf{K}_{(11)}^*(\boldsymbol{\alpha})\}^{-1} \{\mathbf{X}_{(11)}^{*\top} \mathbf{W}_{(11)}^{*(b)} \mathbf{z}_{(1)}^{(b)}\}, \\ \boldsymbol{v}^{(b+1)} &= \{\mathbf{X}_{(22)}^{*\top} \mathbf{W}_{(22)}^{*(b)} \mathbf{X}_{(22)}^*\}^{-1} \{\mathbf{X}_{(22)}^{*\top} \mathbf{W}_{(22)}^{*(b)} \mathbf{z}_{(2)}^{(b)}\},\end{aligned}$$

para  $b = 0, 1, \dots$ , com  $\mathbf{X}_{(11)}^* = \mathbf{X}^*$ ,  $\mathbf{W}_{(11)}^* = \mathbf{W}^*$ ,  $\mathbf{z}_{(1)} = \mathbf{z}$ ,  $\mathbf{X}_{(22)}^* = (\mathbf{X}_{(22)1}^\top, \dots, \mathbf{X}_{(22)n}^\top)^\top$ ,  $\mathbf{W}_{(22)}^* = \text{diag}\{\mathbf{W}_{(22)1}^*, \dots, \mathbf{W}_{(22)n}^*\}$ ,  $\mathbf{z}_{(2)} = (\mathbf{z}_{(2)1}^\top, \dots, \mathbf{z}_{(2)n}^\top)^\top$  e  $\mathbf{z}_{(2)i} = \mathbf{D}_{(22)i}^{-1}(\mathbf{s}_i - \boldsymbol{\rho}_i) + \boldsymbol{\eta}_{(2)i}$ .

## 6.2 Estimação de $\phi$

Para estimar o parâmetro  $\phi$  sob o caso 1, utilizamos uma função dos resíduos  $r_{ij} = (y_{ij} - \mu_{ij})/V_{ij}^{1/2}$ . Usando o fato de que  $E(r_{ij}^2) = \phi^{-1}$ , no caso 2 podemos assumir que  $\phi$  depende de um vetor de parâmetros  $\boldsymbol{\kappa}$  e definir um sistema de equações de estimação

$$\boldsymbol{\Psi}_{\boldsymbol{\alpha}}(\boldsymbol{\kappa}) = \sum_{i=1}^n \mathbf{E}_{(33)i}^{*\top} \mathbf{V}_{(33)i}^{*-1} (\boldsymbol{\zeta}_i - \boldsymbol{\nu}_i) = \mathbf{0}, \quad (20)$$

em que  $\mathbf{E}_{(33)i}^* = \partial\phi/\partial\boldsymbol{\kappa}$ ,  $\mathbf{V}_{(33)i}^* = \text{Var}(\boldsymbol{\zeta}_i)$ ,  $\boldsymbol{\zeta}_i = (r_{i1}^2, \dots, r_{im_i}^2)^\top$  e  $\boldsymbol{\nu}_i = (\phi^{-1}, \dots, \phi^{-1})^\top$ .

Neste caso a estrutura de  $\mathbf{V}_{(33)i}^*$  deve ser especificada.

Outra forma de obter (20) é definir um preditor linear da forma

$$d(\phi) = \eta_{(3)il} = \mathbf{b}_{il}\boldsymbol{\kappa},$$

para  $i = 1, \dots, n$  e  $l = 1, \dots, m_i$ , em que  $d$  é uma função invertível duas vezes diferenciável que faz o papel de uma “função de ligação” e  $\mathbf{b}_{il}$  é um vetor de variáveis preditoras

associados aos parâmetros em  $\kappa$ . Como  $\phi > 0$ , algumas funções específicas podem ser utilizadas, como por exemplo  $d(\phi) = \log(\phi)$ . Desta forma, as equações de estimação para  $\kappa$  podem ser definidas da forma

$$\Psi_{\alpha}(\kappa) = \sum_{i=1}^n \mathbf{X}_{(33)i}^{*\top} \mathbf{W}_{(33)i}^* \mathbf{D}_{(33)i}^{-1} (\zeta_i - \nu_i) = 0, \quad (21)$$

em que  $\mathbf{X}_{(33)i}^* = (\mathbf{b}_{1i}, \dots, \mathbf{b}_{ki})$ , com  $\mathbf{b}_{li} = (b_{li1}, \dots, b_{lim_i})^\top$ ,  $\mathbf{W}_{(33)i}^* = \mathbf{D}_{(33)i} \mathbf{V}_{(33)i}^{*-1} \mathbf{D}_{(33)i}$  e  $\mathbf{D}_{(33)i} = \text{diag}\{\partial\phi/\partial\eta_{(3)i1}, \dots, \partial\phi/\partial\eta_{(3)im_i}\}$ , para  $l = 1, \dots, k$ . Desta forma, podemos definir o processo iterativo

$$\kappa^{(b+1)} = \{\mathbf{X}_{(33)}^{*T} \mathbf{W}_{(33)}^{*(b)} \mathbf{X}_{(33)}^*\}^{-1} \{\mathbf{X}_{(33)}^{*T} \mathbf{W}_{(33)}^{*(b)} \mathbf{z}_{(3)}^{(b)}\},$$

para  $b = 0, 1, \dots$ , em que  $\mathbf{z}_{(3)} = (\mathbf{z}_{(3)1}^\top, \dots, \mathbf{z}_{(3)n}^\top)^\top$ , com  $\mathbf{z}_{(3)i} = \mathbf{D}_{(3)i}^{-1} (\zeta_i - \nu_i) + \boldsymbol{\eta}_{(3)i}$ .

Nas próximas seções deste capítulo temos alguns aspectos a respeito da realização de inferência estatística nos MPLAG para dados correlacionados sob o caso 2, mais especificamente um procedimento para a obtenção de erros-padrão aproximados para  $\hat{\delta}$ , a obtenção dos graus de liberdade efetivos e a seleção dos parâmetros de suavização.

### 6.3 Erros-padrão Aproximados

Dadas as estimativas dos parâmetros nos MPLAG para dados correlacionados sob o caso 2, devemos investigar os valores estimados, por exemplo, através da realização de testes de hipóteses. Sendo assim, estimativas dos erros-padrão associados a estes valores devem ser obtidas. Sendo assim temos, na convergência do processo iterativo (considerando  $\alpha$  fixado), que

$$\hat{\delta} = \widehat{\mathbf{A}}_{(\delta)}^{-1} \mathbf{X}_{(\delta)}^{*\top} \widehat{\mathbf{W}}_{(\delta)}^* \hat{\mathbf{Z}}_{(\delta)},$$

em que  $\mathbf{A}_{(\delta)}^* = \mathbf{X}_{(\delta)}^{*\top} \mathbf{W}_{(\delta)}^* \mathbf{X}_{(\delta)}^* + \mathbf{K}_{(\delta)}^*(\boldsymbol{\alpha})$ . Assumindo que  $\boldsymbol{\delta} = \boldsymbol{\delta}_0$  é o vetor com os verdadeiros valores dos parâmetros, e que  $\hat{\boldsymbol{\delta}} \approx \boldsymbol{\delta}_0$ , temos que  $\hat{\boldsymbol{\delta}} \approx \mathbf{A}_{(\delta)}^{*-1} \mathbf{X}_{(\delta)}^{*\top} \mathbf{W}_{(\delta)}^* \mathbf{z}_{(\delta)}$ . Sendo assim,

$$\text{Var}(\hat{\boldsymbol{\delta}}) \approx \mathbf{A}_{(\delta)}^{-1} \mathbf{X}_{(\delta)}^{*\top} \mathbf{W}_{(\delta)}^* \mathbf{D}_{(\delta)}^{-1} \text{Var}(\boldsymbol{\gamma}) \mathbf{D}_{(\delta)}^{-1} \mathbf{W}_{(\delta)}^* \mathbf{X}_{(\delta)}^* \mathbf{A}_{(\delta)}^{-1},$$

em que  $\boldsymbol{\gamma} = (\boldsymbol{\gamma}_1^\top, \dots, \boldsymbol{\gamma}_n^\top)^\top$ . Se  $\mathbf{V}_{(\delta)i}^*$  é a verdadeira matriz de variância de  $\boldsymbol{\gamma}_i$ , para  $i = 1, 2, \dots, n$ , temos que  $\text{Var}(\boldsymbol{\gamma}) = \text{diag}\{\mathbf{V}_{(\delta)1}^*, \dots, \mathbf{V}_{(\delta)n}^*\}$ . Desta forma, estimamos  $\text{Var}(\hat{\boldsymbol{\delta}})$  por

$$\widehat{\text{Var}}_N(\hat{\boldsymbol{\delta}}) = \widehat{\mathbf{A}}_{(\delta)}^{*-1} \mathbf{X}_{(\delta)}^{*\top} \widehat{\mathbf{W}}_{(\delta)}^* \widehat{\mathbf{D}}_{(\delta)}^{-1} \widehat{\text{Var}}_N(\boldsymbol{\gamma}) \widehat{\mathbf{D}}_{(\delta)}^{-1} \widehat{\mathbf{W}}_{(\delta)}^* \mathbf{X}_{(\delta)}^* \widehat{\mathbf{A}}_{(\delta)}^{-1}, \quad (22)$$

em que  $\widehat{\text{Var}}_N(\boldsymbol{\gamma}) = \text{diag}\{\widehat{\text{Var}}_N(\boldsymbol{\gamma}_1), \dots, \widehat{\text{Var}}_N(\boldsymbol{\gamma}_n)\}$ , com  $\widehat{\text{Var}}_N(\boldsymbol{\gamma}_i) = \widehat{\mathbf{V}}_{(\delta)i}^*$ . Se  $\mathbf{V}_{(\delta)i}^*$  não é a verdadeira matriz de variância de  $\boldsymbol{\gamma}_i$ , para  $i = 1, 2, \dots, n$ , podemos estimar  $\text{Var}(\hat{\boldsymbol{\delta}})$  por

$$\widehat{\text{Var}}_R(\hat{\boldsymbol{\delta}}) = \widehat{\mathbf{A}}_{(\delta)}^{*-1} \mathbf{X}_{(\delta)}^{*\top} \widehat{\mathbf{W}}_{(\delta)}^* \widehat{\mathbf{D}}_{(\delta)}^{-1} \widehat{\text{Var}}_R(\boldsymbol{\gamma}) \widehat{\mathbf{D}}_{(\delta)}^{-1} \widehat{\mathbf{W}}_{(\delta)}^* \mathbf{X}_{(\delta)}^* \widehat{\mathbf{A}}_{(\delta)}^{-1}, \quad (23)$$

em que  $\widehat{\text{Var}}_R(\boldsymbol{\gamma}) = \text{diag}\{\widehat{\text{Var}}_R(\boldsymbol{\gamma}_1), \dots, \widehat{\text{Var}}_R(\boldsymbol{\gamma}_n)\}$  e  $\widehat{\text{Var}}_R(\boldsymbol{\gamma}_i) = (\hat{\boldsymbol{\gamma}}_i - \hat{\boldsymbol{\tau}}_i)(\hat{\boldsymbol{\gamma}}_i - \hat{\boldsymbol{\tau}}_i)^\top$ . Logo podemos obter estimativas do tipo “naive” e “robusta” para o erro-padrão de  $\hat{\boldsymbol{\delta}}$  a partir da diagonal de (22) e (23) respectivamente.

## 6.4 Graus de Liberdade Efetivos

Para a obtenção dos graus de liberdade efetivos a partir do ajuste do MPLAG para dados correlacionados sob o caso 2, devemos obter a matriz de projeção a partir do ajuste do modelo. Desta forma, ao estimarmos o preditor  $\boldsymbol{\eta}_{(\delta)}$  temos que, na convergência do processo iterativo,  $\hat{\boldsymbol{\eta}}_{(\delta)} = \mathbf{X}_{(\delta)}^* \hat{\boldsymbol{\delta}} = \widehat{\mathbf{H}}_{(\delta)}^* \mathbf{z}_{(\hat{\boldsymbol{\delta}})}$ , em que

$$\mathbf{H}_{(\delta)}^* = \mathbf{X}_{(\delta)}^* \mathbf{A}_{(\delta)}^{*-1} \mathbf{X}_{(\delta)}^{*\top} \mathbf{W}_{(\delta)}^*.$$

Sendo assim, podemos definir os graus de liberdade efetivos por

$$df(\boldsymbol{\alpha}) = \text{tr}(\widehat{\mathbf{H}}^*(\boldsymbol{\delta})).$$

Para a obtenção dos graus de liberdade efetivos associados a alguma componente não-paramétrica em  $\hat{\boldsymbol{\eta}}_{(\boldsymbol{\delta})}$ , devemos obter a matriz de projeção associada, a partir de  $\widehat{\mathbf{H}}^*(\boldsymbol{\delta})$ , em um procedimento similar àquele definido no caso 1.

## 6.5 Seleção do Parâmetro de Suavização

Analogamente ao caso 1, em situações práticas podemos considerar para a seleção do vetor de parâmetros de suavização os valores  $\alpha_k \in [\alpha_{k(\min)}, \alpha_{k(\max)}]$  tais que

$$df(\alpha_{k(\min)}) - df(\alpha_{k(\max)}) = \gamma_k(r_k - 2),$$

considerando um valor fixado de  $\gamma_k \in (0, 1)$ , para  $k = 1, 2, \dots, q$ . No caso do uso de splines cúbicas, podemos considerar o método de validação cruzada generalizada (assim como no caso 1) e selecionar o vetor de parâmetros de suavização como sendo o vetor  $\boldsymbol{\alpha}^* \in [\alpha_{1(\min)}, \alpha_{1(\max)}] \times [\alpha_{2(\min)}, \alpha_{2(\max)}] \times \dots \times [\alpha_{q(\min)}, \alpha_{q(\max)}]$  que minimiza

$$\text{GCV}(\boldsymbol{\alpha}) = \frac{(\sum_{i=1}^n n_i) \{(\hat{\boldsymbol{\gamma}} - \hat{\boldsymbol{\tau}})^\top \hat{\mathbf{V}}_{(\boldsymbol{\delta})}^{*-1} (\hat{\boldsymbol{\gamma}} - \hat{\boldsymbol{\tau}})\}}{\{\text{tr}(\mathbf{I} - \widehat{\mathbf{H}}^*(\boldsymbol{\delta}))\}^2}$$

em que  $n_i = m_i + a_i$ ,  $\boldsymbol{\gamma} = (\boldsymbol{\gamma}_1^\top, \dots, \boldsymbol{\gamma}_n^\top)^\top$ ,  $\boldsymbol{\tau} = (\boldsymbol{\tau}_1^\top, \dots, \boldsymbol{\tau}_n^\top)^\top$  e  $\mathbf{I}$  é a matriz identidade com a mesma dimensão de  $\widehat{\mathbf{H}}^*(\boldsymbol{\delta})$ .

## Capítulo 7

# Técnicas de Diagnóstico

Neste capítulo serão apresentadas algumas técnicas de diagnóstico nos MPLAG para dados correlacionados sob o caso 2. Assim como no caso 1, temos uma proposta de medidas de alavancagem baseadas na matriz de projeção resultante do ajuste do modelo, a análise de resíduos através do uso de três diferentes tipos de resíduos e a proposta da análise de influência local no intuito de investigar a presença de pontos potencialmente influentes nas estimativas dos parâmetros e das funções não paramétricas.

### 7.1 Medidas de Alavancagem

Considerando o MPLAG para dados correlacionados sob o caso 2, se  $\hat{h}_{(\delta)ijj}^*$  é o elemento  $(j, j)$  da diagonal da matriz  $\widehat{\mathbf{H}}^*(\delta)_i = \mathbf{X}_{(\delta)i}^* \widehat{\mathbf{A}}_{(\delta)}^{-1} \mathbf{X}_{(\delta)i}^{*\top} \widehat{\mathbf{W}}^*(\delta)_i$ , para  $i = 1, 2, \dots, n$ , sugerimos observar  $\hat{h}_{(\delta)ijj}^*$  como medida de alavancagem, considerando o respectivo vetor observado das variáveis independentes em  $\mathbf{X}_{(\delta)i}$ , para  $i = 1, 2, \dots, n$  e  $j = 1, 2, \dots, n_i$ . Para tanto, comparamos os valores de  $\hat{h}_{(\delta)ijj}^*$  com a média geral  $\bar{h}_{(\delta)}^* = \text{tr}(\widehat{\mathbf{H}}^*(\delta)) / \sum_{i=1}^n n_i$ . Portanto, um alto valor de  $\hat{h}_{(\delta)ijj}^*$  pode indicar que  $\gamma_i$  exerce alta influência sobre valor ajustado  $\hat{z}_{(\delta)ij}$ . Sendo assim, podemos por exemplo observar o gráfico de  $\hat{h}_{(\delta)ijj}^*$  versus  $i$ , para  $i = 1, 2, \dots, n$  e  $j = 1, 2, \dots, n_i$  no intuito de detectar pontos com alta alavancagem. Nestes pontos os valores preditos devem ser tratados com algum cuidado, uma vez que estes podem ser particularmente sensíveis a seus respectivos valores observados.

Para a detecção de grupos discrepantes, podemos utilizar a média das medidas de alavancagem  $\hat{h}_{(\delta)ij}^*$  dentro de cada grupo e investigar aqueles que apresentam alta alavancagem. Sendo assim, através das matrizes  $\widehat{\mathbf{H}}_{(\delta)i}^*$ , podemos considerar o  $i$ -ésimo grupo como apresentando potencialmente alta influência no valor predito se  $\bar{h}_{(\delta)i}^* > 2\bar{h}_{(\delta)}^*$  (ou se  $\bar{h}_{(\delta)i}^* > 3\bar{h}_{(\delta)}^*$ ), em que  $\bar{h}_{(\delta)i}^* = \text{tr}(\widehat{\mathbf{H}}_{(\delta)i}^*)/n_i$ . Neste caso devemos observar o gráfico de  $\bar{h}_{(\delta)i}^*$  versus  $i$ , para  $i = 1, 2, \dots, n$ .

## 7.2 Análise de Resíduos

Nesta seção temos a proposta de três tipos de resíduos a serem utilizados no ajuste dos MPLAG para dados correlacionados sob o caso 2. Estes resíduos devem ser considerados na investigação da presença de outliers nos dados, assim como para a investigação de suposições específicas feitas a respeito do modelo, por exemplo a suposição da distribuição marginal da variável resposta, de maneira análoga àquela considerada no caso 1.

### 7.2.1 Resíduos de Pearson

Os resíduos de Pearson podem ser utilizados nos MPLAG para dados correlacionados sob o caso 2 de maneira similar ao seu uso sob o caso 1. Para tanto, seja  $\hat{\mu}_{(\delta)ij}$  a média ajustada de  $y_{ij}$ . Dado  $\phi$ , o resíduo de Pearson neste caso é dado por

$$\hat{r}_{(1)Pij} = \phi^{1/2}(y_{ij} - \hat{\mu}_{(\delta)ij})/\hat{V}_{(11)ij}^{*1/2},$$

para  $i = 1, 2, \dots, n$  e  $j = 1, 2, \dots, m_i$ . Desta forma, observações com altos valores do resíduo de Pearson podem ser consideradas como *outliers* sob o MPLAG para dados correlacionados sob o caso 2.

### 7.2.2 Resíduos “Naive”

Seja a matriz  $\underline{\mathbf{H}}_{(\delta)}^* = \mathbf{W}_{(\delta)}^{*1/2} \mathbf{X}_{(\delta)}^* \mathbf{A}_{(\delta)}^{*-1} \mathbf{X}_{(\delta)}^{*\top} \mathbf{W}_{(\delta)}^{*1/2}$  particionada da forma

$$\underline{\mathbf{H}}_{(\delta)}^* = \begin{bmatrix} \underline{\mathbf{H}}_{(11)}^* & \underline{\mathbf{H}}_{(12)}^* \\ \underline{\mathbf{H}}_{(21)}^* & \underline{\mathbf{H}}_{(22)}^* \end{bmatrix}$$

e a matriz  $\mathbf{W}_{(\delta)}^*$  particionada da forma

$$\mathbf{W}_{(\delta)}^* = \begin{bmatrix} \mathbf{W}_{(11)}^* & \mathbf{W}_{(12)}^* \\ \mathbf{W}_{(21)}^* & \mathbf{W}_{(22)}^* \end{bmatrix}.$$

Considerando o processo iterativo de estimação dos parâmetros dado em (19) na convergência, seja

$$\hat{\boldsymbol{\epsilon}}_{(1)} = [\mathbf{I} - \widehat{\underline{\mathbf{H}}}^*_{(11)}] \widehat{\mathbf{W}}_{(11)}^{*1/2} \hat{\mathbf{z}}_{(1)}.$$

Assumindo que  $\hat{\boldsymbol{\mu}}_{(\delta)} \approx \boldsymbol{\mu}_{(\delta)} = (\boldsymbol{\mu}_{(\delta)1}^\top, \dots, \boldsymbol{\mu}_{(\delta)n}^\top)^\top$ , em que  $\boldsymbol{\mu}_{(\delta)i} = (\mu_{(\delta)i1}, \dots, \mu_{(\delta)i m_i})^\top$ , com  $\mu_{(\delta)ij}$  sendo a média verdadeira de  $y_{ij}$ , temos que  $\hat{\boldsymbol{\epsilon}}_{(1)} \approx \boldsymbol{\epsilon}_{(1)} = [\mathbf{I} - \underline{\mathbf{H}}_{(11)}^*] \mathbf{W}_{(11)}^{*1/2} \mathbf{z}_{(1)}$ .

Sendo assim, temos que

$$\text{Var}(\hat{\boldsymbol{\epsilon}}_{(1)}) \approx \text{Var}(\boldsymbol{\epsilon}_{(1)}) = [\mathbf{I} - \underline{\mathbf{H}}_{(11)}^*] \mathbf{W}_{(11)}^{*1/2} \mathbf{D}_{(11)}^{-1} \text{Var}(\mathbf{y}) \mathbf{D}_{(11)}^{-1} \mathbf{W}_{(11)}^{*1/2} [\mathbf{I} - \underline{\mathbf{H}}_{(11)}^*].$$

Se  $\mathbf{V}_{(11)i}^*$  é a verdadeira matriz de variância de  $\mathbf{y}_i$ , para  $i = 1, 2, \dots, n$ , podemos estimar  $\text{Var}(\hat{\boldsymbol{\epsilon}}_{(1)})$  por

$$\widehat{\text{Var}}_N(\hat{\boldsymbol{\epsilon}}_{(1)}) = [\mathbf{I} - \widehat{\underline{\mathbf{H}}}^*_{(11)}] \widehat{\mathbf{W}}_{(11)}^{*1/2} \hat{\mathbf{D}}_{(11)}^{-1} \widehat{\text{Var}}_N(\mathbf{y}) \hat{\mathbf{D}}_{(11)}^{-1} \widehat{\mathbf{W}}_{(11)}^{*1/2} [\mathbf{I} - \widehat{\underline{\mathbf{H}}}^*_{(11)}], \quad (24)$$

em que  $\widehat{\text{Var}}_N(\mathbf{y}) = \widehat{\mathbf{V}}_{(11)}^*$ . Portanto, definimos os resíduos “naive” para os MPLAG para

dados correlacionados sob o caso 2 por

$$\hat{r}_{(1)Nij} = \hat{\epsilon}_{(1)ij}/\hat{e}\hat{p}_N(\hat{\epsilon}_{(1)ij}),$$

para  $i = 1, 2, \dots, n$  e  $j = 1, 2, \dots, m_i$ , em que  $\hat{e}\hat{p}_N(\hat{\epsilon}_{(1)ij})$  é a estimativa “naive” do erro-padrão de  $\hat{\epsilon}_{(1)ij}$ , obtida a partir de (24).

### 7.2.3 Resíduos “Robustos”

Ainda na convergência do processo iterativo de estimação dos parâmetros dado em (19) e se  $\mathbf{V}_{(\xi\xi)_i}^*$  não é a verdadeira matriz de variância de  $\mathbf{y}_i$ , podemos estimar  $\text{Var}(\hat{\boldsymbol{\epsilon}}_{(1)})$  por

$$\widehat{\text{Var}}_R(\hat{\boldsymbol{\epsilon}}_{(1)}) = [\mathbf{I} - \widehat{\mathbf{H}}_{(11)}^*] \widehat{\mathbf{W}}_{(11)}^{*1/2} \widehat{\mathbf{D}}_{(11)}^{-1} \widehat{\text{Var}}_R(\mathbf{y}) \widehat{\mathbf{D}}_{(11)}^{-1} \widehat{\mathbf{W}}_{(11)}^{*1/2} [\mathbf{I} - \widehat{\mathbf{H}}_{(11)}^*], \quad (25)$$

com  $\widehat{\text{Var}}_R(\mathbf{y}) = \text{diag}\{\widehat{\text{Var}}_R(\mathbf{y}_1), \dots, \widehat{\text{Var}}_R(\mathbf{y}_n)\}$ ,  $\widehat{\text{Var}}_R(\mathbf{y}_i) = \widehat{\mathbf{V}}_{(11)i}^{1/2} \{ \frac{1}{n} \sum_{i=1}^n \widehat{\mathbf{r}}_{(1)i} \widehat{\mathbf{r}}_{(1)i}^\top \} \widehat{\mathbf{V}}_{(11)i}^{1/2}$ ,  $\mathbf{r}_{(1)i} = (r_{(1)i1}, \dots, r_{(1)i m_i})^\top$  e  $r_{(1)ij} = (y_{ij} - \mu_{(1)ij})/V_{(11)ij}$ . Sendo assim, definimos o resíduo robusto por

$$\hat{\epsilon}_{(1)Rij} = \hat{\epsilon}_{(1)ij}/\hat{e}\hat{p}_R(\hat{\epsilon}_{(1)ij}),$$

em que  $\hat{e}\hat{p}_R(\hat{\epsilon}_{(1)ij})$  é a estimativa “robusta” para o erro-padrão de  $\hat{\epsilon}_{(1)ij}$ , obtida via (25), para  $i = 1, 2, \dots, n$  e  $j = 1, 2, \dots, m_i$ .

## 7.3 Influência Local

Assumindo fixo o vetor de parâmetros de suavização  $\boldsymbol{\alpha}$ , seja  $\mathcal{F}_{\boldsymbol{\alpha}}(\boldsymbol{\delta})$  uma função (penalizada) de ajuste referente ao MPLAG para dados correlacionados sob o caso 2, sendo pelo menos duas vezes diferenciável em  $\boldsymbol{\delta}$  e que a estimativa de  $\boldsymbol{\delta}$  seja solução de

$$\frac{\partial \mathcal{F}_{\boldsymbol{\alpha}}(\boldsymbol{\delta})}{\partial \boldsymbol{\delta}} = \boldsymbol{\Psi}_{\boldsymbol{\alpha}}(\boldsymbol{\delta}) = \mathbf{0}.$$

Denotamos a função de afastamento em relação ao modelo perturbado como sendo

$$FD_{\boldsymbol{\omega}} = 2\{\mathcal{F}_{\boldsymbol{\alpha}}(\hat{\boldsymbol{\delta}}) - \mathcal{F}_{\boldsymbol{\alpha}}(\hat{\boldsymbol{\delta}}_{\boldsymbol{\omega}})\},$$

em que  $\boldsymbol{\omega} = (\omega_1, \dots, \omega_l)^{\top}$  é um vetor de perturbação de dimensão  $l \times 1$  em  $\Omega \in \mathbb{R}^l$ , representando um conjunto de perturbações. Temos ainda que  $\hat{\boldsymbol{\delta}}$  e  $\hat{\boldsymbol{\delta}}_{\boldsymbol{\omega}}$  são as estimativas de  $\boldsymbol{\delta}$  sob os modelos postulado e perturbado respectivamente. A medida  $FD_{\boldsymbol{\omega}}$  deve ser utilizada para investigar a influência na estimativa de  $\boldsymbol{\delta}$  para diferentes valores de  $\boldsymbol{\omega}$  em  $\Omega$ . Contudo, investigar o comportamento de  $FD_{\boldsymbol{\omega}}$  em  $\Omega \in \mathbb{R}^l$  não é viável devido a grande quantidade de valores distintos que o vetor  $\boldsymbol{\omega}$  em geral pode assumir. Sendo assim, Cook (1986) propõe estudar o comportamento de  $FD_{\boldsymbol{\omega}}$  localmente para qualquer valor de  $\boldsymbol{\omega}$  na vizinhança de um valor  $\boldsymbol{\omega}_0$ , em que  $\boldsymbol{\omega}_0$  representa a ausência de perturbação, i.e.,  $\boldsymbol{\omega}_0$  é tal que  $\mathcal{F}_{\boldsymbol{\alpha}}(\boldsymbol{\delta}|\boldsymbol{\omega}_0) = \mathcal{F}_{\boldsymbol{\alpha}}(\boldsymbol{\delta})$  o que implica em  $FD_{\boldsymbol{\omega}_0} = 0$ . Cook (1986) sugere investigar a curvatura normal do gráfico de  $FD_{\boldsymbol{\omega}_0+a\boldsymbol{d}}$  versus  $a$ , em que  $a \in \mathbb{R}$  e  $\boldsymbol{d}$  representa uma direção com norma unitária, i.e.,  $\|\boldsymbol{d}\| = 1$ . Esta curvatura pode ser expressa de forma geral como sendo

$$C_d(\boldsymbol{\delta}) = -2\{\boldsymbol{d}^{\top} \boldsymbol{\Delta}^{\top} \ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} \boldsymbol{\Delta} \boldsymbol{d}\}, \quad (26)$$

em que

$$\boldsymbol{\Delta} = \frac{\partial^2 \mathcal{F}_{\boldsymbol{\alpha}}(\boldsymbol{\delta}|\boldsymbol{\omega})}{\partial \boldsymbol{\delta} \partial \boldsymbol{\omega}^{\top}} = \frac{\partial \Psi_{\boldsymbol{\alpha}}(\boldsymbol{\delta}|\boldsymbol{\omega})}{\partial \boldsymbol{\omega}^{\top}}$$

e

$$\ddot{\mathcal{F}}_{\boldsymbol{\alpha}} = \frac{\partial^2 \mathcal{F}_{\boldsymbol{\alpha}}(\boldsymbol{\delta})}{\partial \boldsymbol{\delta} \partial \boldsymbol{\delta}^{\top}} = \frac{\partial \Psi_{\boldsymbol{\alpha}}(\boldsymbol{\delta})}{\partial \boldsymbol{\delta}^{\top}} = \mathbf{X}_{(\boldsymbol{\delta})}^{*\top} [\mathbf{M}_{(\boldsymbol{\delta})1} + \mathbf{M}_{(\boldsymbol{\delta})2}] \mathbf{X}_{(\boldsymbol{\delta})}^* - \mathbf{K}_{(\boldsymbol{\delta})}^*(\boldsymbol{\alpha}),$$

sendo

$$\mathbf{M}_{(\boldsymbol{\delta})1} = [\dot{\mathbf{D}}_{(\boldsymbol{\delta})} \mathbf{V}_{(\boldsymbol{\delta})}^{*-1} + \mathbf{D}_{(\boldsymbol{\delta})} \dot{\mathbf{V}}_{(\boldsymbol{\delta})}^{*-1}] \mathbf{C}_{(\boldsymbol{\delta})}, \quad \dot{\mathbf{D}}_{(\boldsymbol{\delta})} = \text{diag}\{\dot{\mathbf{D}}_{(\boldsymbol{\delta})1}, \dots, \dot{\mathbf{D}}_{(\boldsymbol{\delta})n}\},$$

$$\dot{\mathbf{D}}_{(\boldsymbol{\delta})i} = \text{diag}\{\partial^2 \tau_{i1}/\partial \eta_{(\boldsymbol{\delta})i1}^2, \dots, \partial^2 \tau_{in_i}/\partial \eta_{(\boldsymbol{\delta})in_i}^2\}, \quad \dot{\mathbf{V}}_{(\boldsymbol{\delta})}^{*-1} = \text{diag}\{\dot{\mathbf{V}}_{(\boldsymbol{\delta})1}^{*-1}, \dots, \dot{\mathbf{V}}_{(\boldsymbol{\delta})n}^{*-1}\},$$

$$\dot{\mathbf{V}}_{(\boldsymbol{\delta})i}^{*-1} = -\mathbf{V}_{(\boldsymbol{\delta})i}^{*-1}\dot{\mathbf{V}}_{(\boldsymbol{\delta})i}^*\mathbf{V}_{(\boldsymbol{\delta})i}^{*-1}, \quad \dot{\mathbf{V}}_{(\boldsymbol{\delta})i}^* = \{\partial\mathbf{V}_{(\boldsymbol{\delta})i}^*/\partial\boldsymbol{\tau}_i\}\mathbf{D}_{(\boldsymbol{\delta})i},$$

$$\mathbf{C}_{(\boldsymbol{\delta})} = \text{diag}\{\mathbf{C}_{(\boldsymbol{\delta})1}, \dots, \mathbf{C}_{(\boldsymbol{\delta})n}\}, \quad \mathbf{C}_{(\boldsymbol{\delta})i} = \text{diag}\{\gamma_{i1} - \tau_{i1}, \dots, \gamma_{in_i} - \tau_{in_i}\} \text{ e } \mathbf{M}_{(\boldsymbol{\delta})2} = -\mathbf{W}_{(\boldsymbol{\delta})}^*,$$

em que  $n_i = m_i + a_i$ . Aqui, estas quantidades são avaliadas em  $\boldsymbol{\delta} = \hat{\boldsymbol{\delta}}$  e  $\boldsymbol{\omega} = \boldsymbol{\omega}_0$ . Para identificar observações que exercem considerável influência em  $FD_{\boldsymbol{\omega}}$  sob pequenas perturbações devemos considerar, por exemplo, a direção  $\mathbf{d}_{max}$  referente à máxima curvatura, dada pelo autovetor correspondente ao maior autovalor da matriz  $-\boldsymbol{\Delta}^T \ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} \boldsymbol{\Delta}$ .

Assim como no caso 1, uma alternativa para definir a curvatura normal sob as EEG-2 é utilizar no lugar da informação observada a matriz esperada (negativa) da informação (PAULA; CYSNEIROS, 2009; VENEZUELA; SANDOVAL; BOTTER, 2011), dada por

$$\mathcal{I}_{\boldsymbol{\alpha}} = -E\left\{\ddot{\mathcal{F}}_{\boldsymbol{\alpha}}\right\} = -E\left\{\frac{\partial\Psi_{\boldsymbol{\alpha}}(\boldsymbol{\delta})}{\partial\boldsymbol{\delta}^T}\right\} = \mathbf{X}_{(\boldsymbol{\delta})}^{*\top} \mathbf{W}_{(\boldsymbol{\delta})}^* \mathbf{X}_{(\boldsymbol{\delta})}^* + \mathbf{K}_{(\boldsymbol{\delta})}^*(\boldsymbol{\alpha}).$$

Neste caso, utilizamos como medida de influência local baseada na curvatura normal a quantidade

$$C_d(\boldsymbol{\delta}) = 2\{\mathbf{d}^T \boldsymbol{\Delta}^T \mathcal{I}_{\boldsymbol{\alpha}}^{-1} \boldsymbol{\Delta} \mathbf{d}\}.$$

Considerando novamente (26) e no intuito de obter uma medida de curvatura invariante sob mudanças de escala derivamos, assim como na abordagem sob o caso 1 (EEG-1), a medida de curvatura normal conformal (POON; POON, 1999)

$$B_d(\boldsymbol{\delta}) = -\frac{\mathbf{d}^T \boldsymbol{\Delta}^T \ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} \boldsymbol{\Delta} \mathbf{d}}{\sqrt{\text{tr}(\boldsymbol{\Delta}^T \ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} \boldsymbol{\Delta})^2}},$$

sendo esta curvatura tal que, para toda direção unitária  $\mathbf{d}$ ,  $0 \leq B_d(\boldsymbol{\delta}) \leq 1$ . Uma forma de utilizar esta medida é investigá-la na direção  $\mathbf{d} = \mathbf{e}_{ij}$ , em que  $\mathbf{e}_{ij}$  é um vetor de dimensão  $\sum_{i=1}^n n_i \times 1$  com o valor 1 na  $ij$ -ésima posição e 0 nas demais posições e observar o gráfico de  $B_{\mathbf{e}_{ij}}(\boldsymbol{\delta})$  versus seus respectivos índices. Consideraremos a  $ij$ -ésima observação como potencialmente influente se  $B_{ij} > 2\bar{B}$  (ou se  $B_{ij} > 3\bar{B}$ ), em que  $\bar{B}$  é a média

de  $B = \{B_{ij} = B_{e_{ij}}(\boldsymbol{\delta}) : i = 1, \dots, n \text{ e } j = 1, \dots, n_i\}$  (VERBEKE; MOLENBERGHS, 2000).

Considerando a partição  $\boldsymbol{\delta} = (\boldsymbol{\delta}_1^\top, \boldsymbol{\delta}_2^\top)^\top$ , segundo Cook (1986) a curvatura normal referente ao subvetor  $\boldsymbol{\delta}_1$  segundo uma direção unitária  $\mathbf{d}$  é dada por

$$C_d(\boldsymbol{\delta}_1) = -2\{\mathbf{d}^\top \boldsymbol{\Delta}^\top (\ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} - \mathcal{G}_{22}) \boldsymbol{\Delta} \mathbf{d}\},$$

em que

$$\mathcal{G}_{22} = \begin{bmatrix} \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \ddot{\mathcal{F}}_{\boldsymbol{\alpha}22}^{-1} \end{bmatrix},$$

com  $\ddot{\mathcal{F}}_{\boldsymbol{\alpha}22}^{-1}$  a inversa da matriz  $\ddot{\mathcal{F}}_{\boldsymbol{\alpha}22}$  obtida a partir da matriz  $\ddot{\mathcal{F}}_{\boldsymbol{\alpha}}$  particionada da forma

$$\ddot{\mathcal{F}}_{\boldsymbol{\alpha}} = \begin{bmatrix} \ddot{\mathcal{F}}_{\boldsymbol{\alpha}11} & \ddot{\mathcal{F}}_{\boldsymbol{\alpha}12} \\ \ddot{\mathcal{F}}_{\boldsymbol{\alpha}21} & \ddot{\mathcal{F}}_{\boldsymbol{\alpha}22} \end{bmatrix}.$$

Neste caso, o gráfico dos valores em  $\mathbf{d}_{max}$ , referentes à máxima curvatura dada pelo autovetor correspondente ao maior autovalor da matriz  $-\boldsymbol{\Delta}^\top (\ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} - \mathcal{G}_{22}) \boldsymbol{\Delta}$  pode revelar observações que exercem alta influência nos valores ajustados de  $\boldsymbol{\delta}_1$ . Podemos ainda considerar a curvatura normal conformal

$$B_d(\boldsymbol{\delta}_1) = -\frac{\mathbf{d}^\top \boldsymbol{\Delta}^\top (\ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} - \mathcal{G}_{22}) \boldsymbol{\Delta} \mathbf{d}}{\sqrt{\text{tr}(\boldsymbol{\Delta}^\top (\ddot{\mathcal{F}}_{\boldsymbol{\alpha}}^{-1} - \mathcal{G}_{22}) \boldsymbol{\Delta})^2}}$$

e investigá-la, por exemplo, na direção  $\mathbf{d} = \mathbf{e}_{ij}$ , para  $i = 1, \dots, n$  e  $j = 1, \dots, m_i$ .

Aqui, apresentamos as expressões para a matriz  $\boldsymbol{\Delta}$  (já avaliadas em  $\boldsymbol{\omega} = \boldsymbol{\omega}_0$ ) segundo os cenários de perturbação de casos, perturbação na variável resposta e perturbação em uma das variáveis explicativas.

### 7.3.1 Perturbação de Casos

Para o cenário de perturbação de casos, temos a equação de estimação no modelo perturbado dada por

$$\Psi_{\alpha}(\delta|\omega) = \mathbf{X}_{(\delta)}^{*\top} \mathbf{W}_{(\delta)}^* \mathbf{D}_{(\delta)}^{-1} \text{diag}\{\omega\}(\gamma - \tau) - \mathbf{P}_{(\delta)}(\alpha),$$

em que  $\omega = (\omega_1^\top, \omega_2^\top, \dots, \omega_n^\top)^\top$ , com  $\omega_i = (\omega_{i1}, \omega_{i2}, \dots, \omega_{in_i})^\top$ , para  $i = 1, 2, \dots, n$  e  $\omega_0$  é um vetor de 1's de dimensão  $\sum_{i=1}^n n_i \times 1$ . Neste caso, a matriz  $\Delta$  é dada por

$$\Delta = \mathbf{X}_{(\delta)}^{*\top} \mathbf{W}_{(\delta)}^* \mathbf{D}_{(\delta)}^{-1} \mathbf{C}_{(\delta)}.$$

### 7.3.2 Perturbação na Variável Resposta

Seja a variável  $\gamma_{ij}$  perturbada de tal forma que  $\gamma_{\omega_{ij}} = \gamma_{ij} + \omega_{ij} V_{(\delta)ij}^{*1/2}$ , com a quantidade  $V_{(\delta)ij}^{*1/2}$  considerada fixa. Aqui,  $\omega_{ij} = 0$  representa  $\omega_{ij}$  na ausência de perturbação, para  $i = 1, \dots, n$  e  $j = 1, \dots, n_i$ . As equações de estimação sob o modelo perturbado são dadas, portanto, por

$$\Psi_{\alpha}(\delta|\omega) = \mathbf{X}_{(\delta)}^{*\top} \mathbf{W}_{(\delta)}^* \mathbf{D}_{(\delta)}^{-1} (\gamma - \tau_{\omega}) - \mathbf{P}_{(\delta)}(\alpha),$$

em que  $\tau_{\omega} = \tau - \mathbf{V}_{d(\delta)}^{*1/2} \omega$ ,  $\mathbf{V}_{d(\delta)} = \text{diag}\{\mathbf{V}_{d(\delta)1}, \dots, \mathbf{V}_{d(\delta)1}\}$  e  $\mathbf{V}_{d(\delta)i}$  é a matriz  $\mathbf{V}_{(\delta)i}^*$  com seus elementos iguais a zero fora da diagonal principal. Portanto, a matriz  $\Delta$  é dada por

$$\Delta = \mathbf{X}_{(\delta)}^{*\top} \mathbf{W}_{(\delta)}^* \mathbf{D}_{(\delta)}^{-1} \mathbf{V}_{d(\delta)}^{*1/2}.$$

### 7.3.3 Perturbação em Uma das Variáveis Explicativas

Para este cenário, perturbamos uma variável contínua  $\mathbf{x}_l = (\mathbf{x}_{l1}^\top, \dots, \mathbf{x}_{ln}^\top)^\top$ , para algum  $l$ , tal que  $x_{l\omega_{ij}} = x_{lij} + \sigma_l \omega_{ij}$ , em que  $\sigma_l$  é o desvio padrão observado de  $\mathbf{x}_l$ . Esta variável

pode estar relacionada a  $\boldsymbol{\beta}$  ou a  $\boldsymbol{v}$ , em  $\boldsymbol{\eta}_{(1)i}$ ,  $\boldsymbol{\eta}_{(2)i}$  ou em ambos preditores, caso esta variável apareça em ambos. Sendo assim, temos que  $\tau_{\omega_{ij}}$  é uma função de  $\eta_{(\delta)\omega_{ij}}$ , em que  $\eta_{(\delta)\omega_{ij}}$  representa o preditor  $\eta_{(\delta)ij}$  com a variável modificada  $x_{l\omega_{ij}}$ . Neste caso as equações de estimação sob o modelo perturbado são dadas por

$$\Psi_{\alpha}(\delta|\omega) = \mathbf{X}_{(\delta)\omega}^{*\top} \mathbf{W}_{(\delta)\omega}^* \mathbf{D}_{(\delta)\omega}^{-1} (\gamma - \boldsymbol{\tau}_{\omega}) - \mathbf{P}_{(\delta)}(\alpha) = \mathbf{X}_{(\delta)\omega}^{*\top} \mathbf{D}_{(\delta)\omega} \mathbf{V}_{(\delta)\omega}^{*-1} (\gamma - \boldsymbol{\tau}_{\omega}) - \mathbf{P}_{(\delta)}(\alpha),$$

em que  $\mathbf{X}_{(\delta)\omega}^* = (\mathbf{X}_{(\delta)\omega 1}^{*\top}, \dots, \mathbf{X}_{(\delta)\omega n}^{*\top})^\top$ ,  $\mathbf{X}_{(\delta)\omega i}^* = \mathbf{X}_{(\delta)i}^* + \mathbf{0}_{l\omega_i}$  e  $\mathbf{0}_{l\omega_i}$  é uma matriz com mesmas dimensões que  $\mathbf{X}_{(\delta)i}$ , com  $\sigma_l \omega_i$  na  $l$ -ésima coluna (associada a uma ou mais partições de  $\mathbf{X}_{(\delta)i}^*$ ) e 0's nas demais componentes. Temos ainda que

$$\mathbf{W}_{(\delta)\omega}^* = \mathbf{D}_{(\delta)\omega} \mathbf{V}_{(\delta)\omega}^{*-1} \mathbf{D}_{(\delta)\omega}, \quad \mathbf{D}_{(\delta)\omega} = \text{diag}\{\mathbf{D}_{(\delta)\omega_1}, \dots, \mathbf{D}_{(\delta)\omega_n}\},$$

$$\mathbf{D}_{(\delta)\omega_i} = \text{diag}\{\partial \boldsymbol{\tau}_{\omega_i} / \partial \boldsymbol{\eta}_{(\delta)\omega_i}\}, \quad \mathbf{V}_{(\delta)\omega}^* = \text{diag}\{\mathbf{V}_{(\delta)\omega_1}^*, \dots, \mathbf{V}_{(\delta)\omega_n}^*\},$$

em que cada elemento de  $\mathbf{V}_{(\delta)\omega_i}^*$  é possivelmente uma função de  $\tau_{\omega_{ij}}$ ,  $\boldsymbol{\tau}_{\omega} = (\boldsymbol{\tau}_{\omega_1}^\top, \dots, \boldsymbol{\tau}_{\omega_n}^\top)^\top$  e  $\boldsymbol{\tau}_{\omega_i}$  uma função de  $\boldsymbol{\delta}$  e  $\omega_i$ . Sendo assim, temos a matriz  $\Delta = (\Delta_1, \dots, \Delta_n)$ , em que  $\Delta_i = (\Delta_{i1}, \dots, \Delta_{ib_i})$ , com

$$\Delta_{ij} = \frac{\partial \Psi_{\alpha}(\xi|\omega)}{\partial \omega_{ij}} = \mathbf{T}_{1\omega_{ij}} + \mathbf{T}_{2\omega_{ij}},$$

$$\mathbf{T}_{1\omega_{ij}} = \mathbf{X}_{(\delta)\omega}^{*\top} \mathbf{D}_{(\delta)\omega} \left[ \frac{\partial \mathbf{V}_{(\delta)\omega}^{*-1}}{\partial \omega_{ij}} (\gamma - \boldsymbol{\tau}_{\omega}) + \mathbf{V}_{(\delta)\omega}^{*-1} \frac{\partial (\gamma - \boldsymbol{\tau}_{\omega})}{\partial \omega_{ij}} \right],$$

$$\mathbf{T}_{2\omega_{ij}} = \left[ \frac{\partial \mathbf{X}_{(\delta)\omega}^{*\top}}{\partial \omega_{ij}} \mathbf{D}_{(\delta)\omega} + \mathbf{X}_{(\delta)\omega}^{*\top} \frac{\partial \mathbf{D}_{(\delta)\omega}}{\partial \omega_{ij}} \right] \mathbf{V}_{(\delta)\omega}^{*-1} (\gamma - \boldsymbol{\tau}_{\omega}),$$

$$\frac{\partial \mathbf{V}_{(\delta)\omega}^{*-1}}{\partial \omega_{ij}} = -\mathbf{V}_{(\delta)\omega}^{*-1} \frac{\partial \mathbf{V}_{(\delta)\omega}^*}{\partial \omega_{ij}} \mathbf{V}_{(\delta)\omega}^{*-1},$$

$$\dot{\mathbf{X}}_{(\delta)\omega_{ij}}^* = (\dot{\mathbf{X}}_{(\delta)1\omega_{ij}}^{*\top}, \dots, \dot{\mathbf{X}}_{(\delta)n\omega_{ij}}^{*\top})^\top,$$

$$\frac{\partial \mathbf{D}_{(\delta)\omega}}{\partial \omega_{ij}} = \delta_l \sigma_l \text{diag}\{0, \dots, \partial^2 \tau_{\omega_{ij}} / \partial \eta_{(\delta)\omega_{ij}}^2, \dots, 0\}$$

e  $\dot{\mathbf{X}}_{(\delta)b\omega_{ij}}^*$  é uma matrix de dimensão  $n_b \times s^*$  com 1 sendo o elemento  $(j, l)$  e 0 nas demais componentes se  $b = i$  ou uma matriz de zeros de dimensão  $n_b \times s^*$  se  $b \neq i$ , para  $b = 1, \dots, n$  e  $j = 1, \dots, m_b$ , em que  $s^* = s + a$ . Aqui, a quantidade  $b_i$  (dimensão do vetor de perturbação  $\omega_i$ ) depende de onde está a variável  $\mathbf{x}_l$  a ser perturbada. Por exemplo, se estiver apenas no preditor linear referente à  $\mu_{(\delta)i}$ , temos  $b_i = m_i$ , para  $i = 1, \dots, n$ .

## Capítulo 8

# Exemplos de Aplicações

### 8.1 Aplicação 1: Estudo de Poluição do Ar

Para o primeiro exemplo de aplicação dos MPLAG para dados correlacionados já analisado sob o caso 1, consideramos as mesmas equações de estimação para  $\xi$ , contudo consideramos um caso particular das equações de estimação dadas em (17) para estimar  $\rho$ . Utilizamos a função  $h(\rho) = \log[(1+\rho)/(1-\rho)] = v$  e assumimos  $\mathbf{V}_{(22)i}$  como sendo uma matriz identidade, para  $i = 1, \dots, 20$ . Sendo assim,  $\mathbf{X}_{(22)i}$  é um vetor de 1's e  $\mathbf{W}_{(22)i}^* = \mathbf{D}_{(22)i}^2$ , em que  $\mathbf{D}_{(22)i} = \text{diag}\{2e^v/(e^v + 1)^2, \dots, 2e^v/(e^v + 1)^2\}$ . Ainda, consideramos equações de estimação da forma (21) para  $\phi$ , utilizando a função  $h(\phi) = \log(\phi) = \kappa$  e também considerando  $\mathbf{V}_{(33)i}$  como sendo uma matriz identidade, para  $i = 1, \dots, 20$ . Desta forma, temos que  $\mathbf{X}_{(33)i}$  é um vetor de 1's e  $\mathbf{W}_{(33)i}^* = \mathbf{D}_{(33)i}^2$ , em que  $\mathbf{D}_{(33)i} = \text{diag}\{e^v, \dots, e^v\}$ .

Considerando o parâmetro  $\beta_1$  e as funções não-paramétricas, através da Tabela 8.1 pode ser notado que os valores das estimativas são os mesmos em ambos os casos. Para as estimativas dos erros-padrão “naive” alguns valores diferem ligeiramente entre os dois casos considerados e em geral são maiores sob o caso 2. Considerando as estimativas dos erros-padrão “robustas”, os valores estimados sob os casos 1 e 2 são os mesmos, portanto o parâmetro  $\beta_1$  e as funções não-paramétricas são significativas segundo os

**Tabela 8.1** Estimativas dos parâmetros sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo os casos 1 e 2 para os dados referentes ao Estudo de Poluição do Ar.

Efeito	Estim.		e.p. $\cdot N$		e.p. $\cdot R$	
	EEG-1	EEG-2	EEG-1	EEG-2	EEG-1	EEG-2
$\beta_1$	0,130	0,130	0,018	0,018	0,025	0,025
$f(1, 14)$	0,172	0,172	0,241	0,242	0,284	0,284
$f(1, 15)$	0,189	0,189	0,218	0,220	0,264	0,264
$f(1, 19)$	0,258	0,258	0,175	0,176	0,230	0,230
$f(1, 20)$	0,277	0,277	0,173	0,174	0,231	0,231
$f(1, 21)$	0,296	0,296	0,172	0,173	0,233	0,233
$f(1, 24)$	0,351	0,351	0,171	0,173	0,236	0,236
$f(1, 25)$	0,365	0,365	0,172	0,173	0,236	0,236
$f(1, 26)$	0,374	0,374	0,173	0,174	0,236	0,236
$f(1, 27)$	0,381	0,381	0,173	0,175	0,237	0,237
$f(1, 28)$	0,388	0,388	0,174	0,175	0,240	0,240
$f(1, 29)$	0,397	0,397	0,176	0,177	0,243	0,243
$f(1, 30)$	0,409	0,409	0,177	0,179	0,248	0,248
$f(1, 31)$	0,423	0,423	0,179	0,181	0,252	0,252
$f(1, 32)$	0,439	0,439	0,181	0,183	0,257	0,257
$f(1, 33)$	0,453	0,453	0,184	0,185	0,263	0,263
$f(1, 34)$	0,463	0,463	0,187	0,188	0,270	0,270
$f(1, 35)$	0,466	0,466	0,190	0,191	0,279	0,279
$f(1, 36)$	0,466	0,466	0,193	0,194	0,287	0,287
$f(1, 37)$	0,467	0,467	0,196	0,197	0,293	0,293
$f(1, 39)$	0,476	0,476	0,202	0,203	0,302	0,302
$f(1, 41)$	0,503	0,503	0,208	0,209	0,308	0,308
$f(1, 42)$	0,525	0,525	0,211	0,212	0,311	0,311
$f(1, 43)$	0,551	0,551	0,214	0,215	0,314	0,314
$f(1, 44)$	0,578	0,578	0,217	0,218	0,316	0,316
$f(1, 46)$	0,628	0,628	0,224	0,225	0,322	0,322
$f(1, 47)$	0,653	0,653	0,228	0,229	0,326	0,326
$f(1, 48)$	0,681	0,681	0,232	0,234	0,331	0,331
$f(1, 49)$	0,713	0,713	0,237	0,238	0,335	0,335
$f(1, 50)$	0,749	0,749	0,241	0,243	0,340	0,340
$f(1, 51)$	0,787	0,787	0,246	0,248	0,346	0,346
$f(1, 52)$	0,819	0,819	0,252	0,253	0,354	0,354
$f(1, 53)$	0,847	0,847	0,257	0,259	0,364	0,364
$f(1, 54)$	0,869	0,869	0,262	0,263	0,373	0,373
$f(1, 55)$	0,889	0,889	0,266	0,268	0,380	0,380
$f(1, 56)$	0,911	0,911	0,270	0,271	0,385	0,385
$f(1, 57)$	0,937	0,937	0,272	0,274	0,386	0,386
$f(1, 58)$	0,968	0,968	0,275	0,276	0,386	0,386
$f(1, 59)$	1,007	1,007	0,276	0,278	0,384	0,384
$f(1, 60)$	1,055	1,055	0,277	0,279	0,384	0,384
$f(1, 61)$	1,113	1,113	0,278	0,280	0,384	0,384
$f(1, 62)$	1,181	1,181	0,280	0,281	0,386	0,386
$f(1, 63)$	1,248	1,248	0,281	0,283	0,390	0,390
$f(1, 64)$	1,304	1,304	0,282	0,284	0,394	0,394
$f(1, 65)$	1,338	1,338	0,284	0,286	0,398	0,398
$f(1, 66)$	1,353	1,353	0,286	0,288	0,401	0,401
$f(1, 67)$	1,355	1,355	0,288	0,290	0,402	0,402
$f(1, 69)$	1,348	1,348	0,291	0,293	0,401	0,401
$f(1, 72)$	1,363	1,363	0,297	0,299	0,401	0,401
$f(1, 73)$	1,378	1,378	0,301	0,303	0,403	0,403
$f(1, 74)$	1,396	1,396	0,308	0,310	0,407	0,407
$f(1, 75)$	1,415	1,415	0,318	0,320	0,410	0,410

Fonte: O autor (2016).

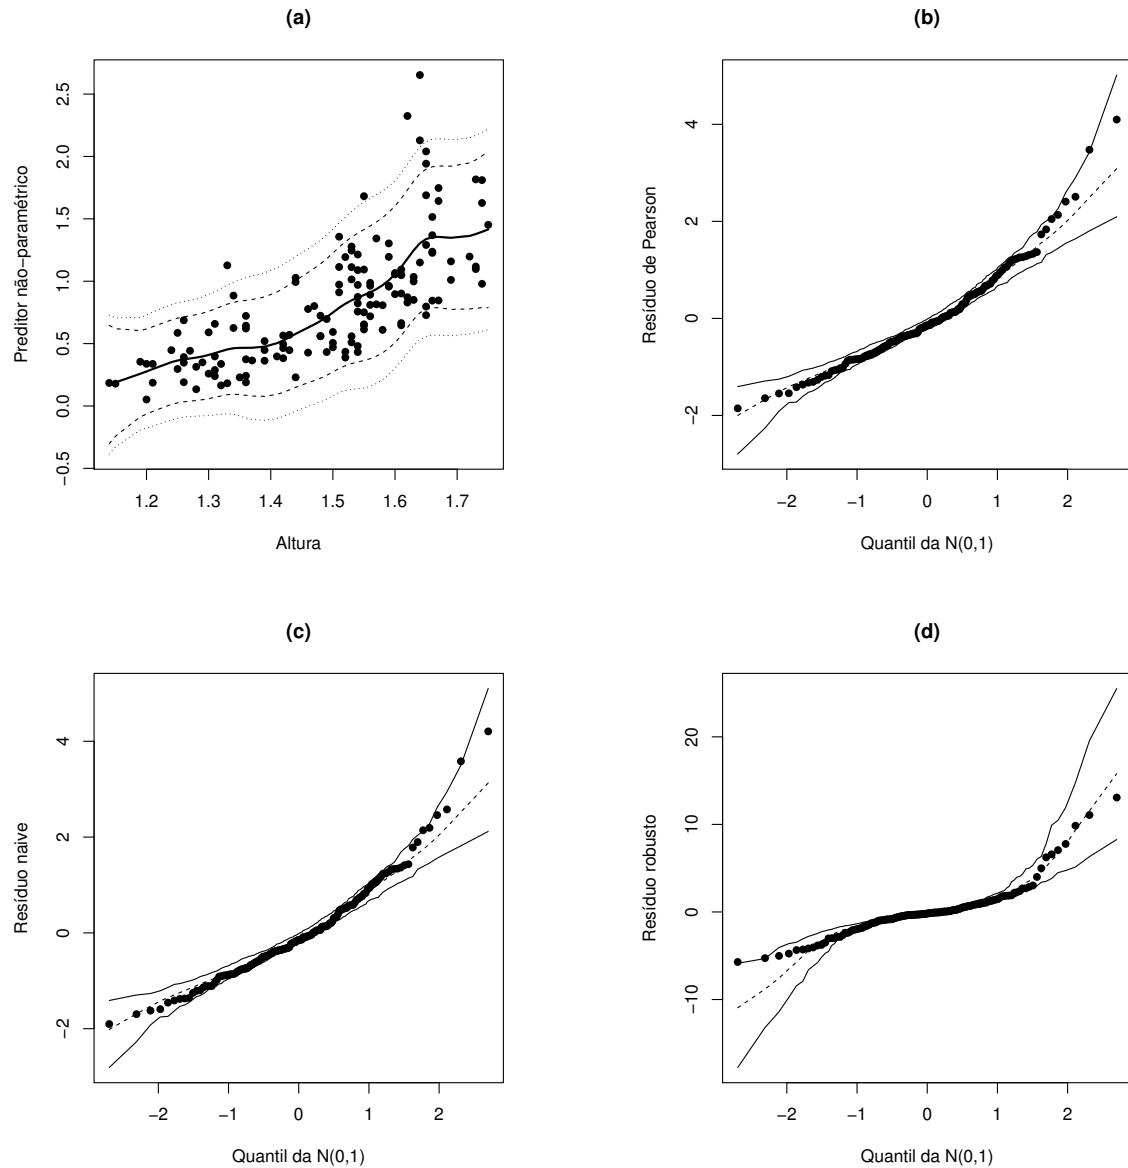
modelos ajustados tanto sob o caso 1 como sob o caso 2. Temos ainda que a estimativa do parâmetro de correlação sob o caso 2 foi de  $\hat{\rho} = 0,606$ , valor menor que aquele obtido sob o caso 1 ( $\hat{\rho} = 0,814$ ). Ainda, a estimativa do parâmetro de dispersão sob o caso 2 foi de  $\hat{\phi} = 9,230$ , ou seja, ligeiramente menor que a estimativa obtida sob o caso 1 ( $\hat{\phi} = 9,358$ ). Temos ainda que a estimativa do parâmetro de suavização sob o caso 2 foi de  $\hat{\alpha} = 9,135 \times 10^{-5}$ , mesmo valor obtido sob o caso 1, dentre o mesmo conjunto de 20 valores (mínimo igual a  $9,135 \times 10^{-5}$  e máximo igual a  $1,179 \times 10^6$ ). Sendo assim, assim como no caso 1, o valor selecionado pode ser considerado baixo, indicando desta forma um comportamento não linear para a função não-paramétrica.

A função não-paramétrica estimada sob o caso 2 é ilustrada no gráfico (a) da Figura 8.1 (curva em negrito), com bandas de confiança aproximadas utilizando estimativas “naive” (curvas tracejadas) e “robustas” (curvas pontilhadas) dos erros padrão das estimativas. O comportamento da curva estimada é similar àquele obtido sob o caso 1.

Considerando os gráficos (b), (c) e (d) da Figura 8.1, em cada um deles a grande maioria dos pontos se apresenta dentro dos respectivos envelopes simulados. Sendo assim, analogamente ao modelo ajustado sob o caso 1 (EEG-1), consideramos que a suposição de uma distribuição marginal gama para a medida de desempenho pulmonar FEV1 observada nos dados referentes ao Estudo de Poluição do Ar é apropriada sob o MPLAG para dados correlacionados ajustado segundo o caso 2 (EEG-2) neste exemplo de aplicação. Assim como no caso 1, sob as EEG-2 os comportamentos dos pontos nos gráficos de quantis referentes aos resíduos de Pearson e resíduos “naive” (gráficos (b) e (c), respectivamente) indicam que os respectivos resíduos apresentam distribuições assimétricas, enquanto que o comportamento dos pontos no gráfico de quantis para os resíduos “robustos” (gráfico (d)) indica uma distribuição aproximadamente simétrica para estes respectivos resíduos.

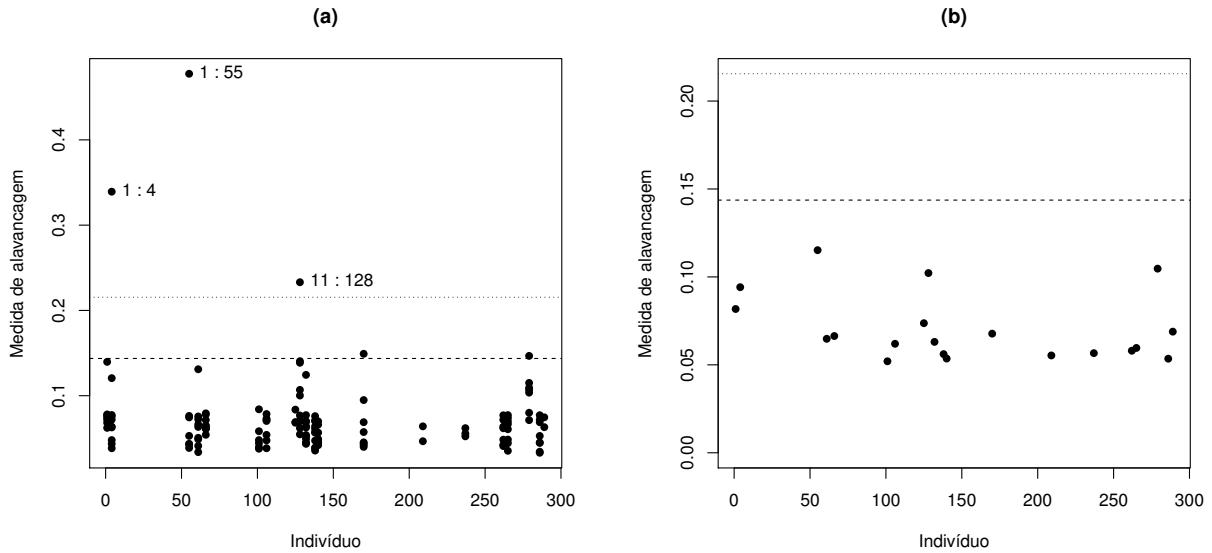
Observando o gráfico (a) da Figura 8.2, podemos notar que a observação 1 para o indivíduo de número 4, a observação 1 para o indivíduo de número 55 e a obsevação 11 para o indivíduo de número 128 apresentam alta alavancagem. Contudo, de acordo com

**Figura 8.1** Gráfico da função não-paramétrica estimada (a) e gráficos de quantis normais com envelopes simulados (95% de confiança) para os resíduos de Pearson (b) “naive” (c) e “robustos” (d) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 2 para os dados referentes ao Estudo de Poluição do Ar.



Fonte: O autor (2016).

**Figura 8.2** Gráficos das medidas de alavancagem por período observado para cada observação (a) e para cada indivíduo (b) considerado sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 2 para os dados referentes ao Estudo de Poluição do Ar.

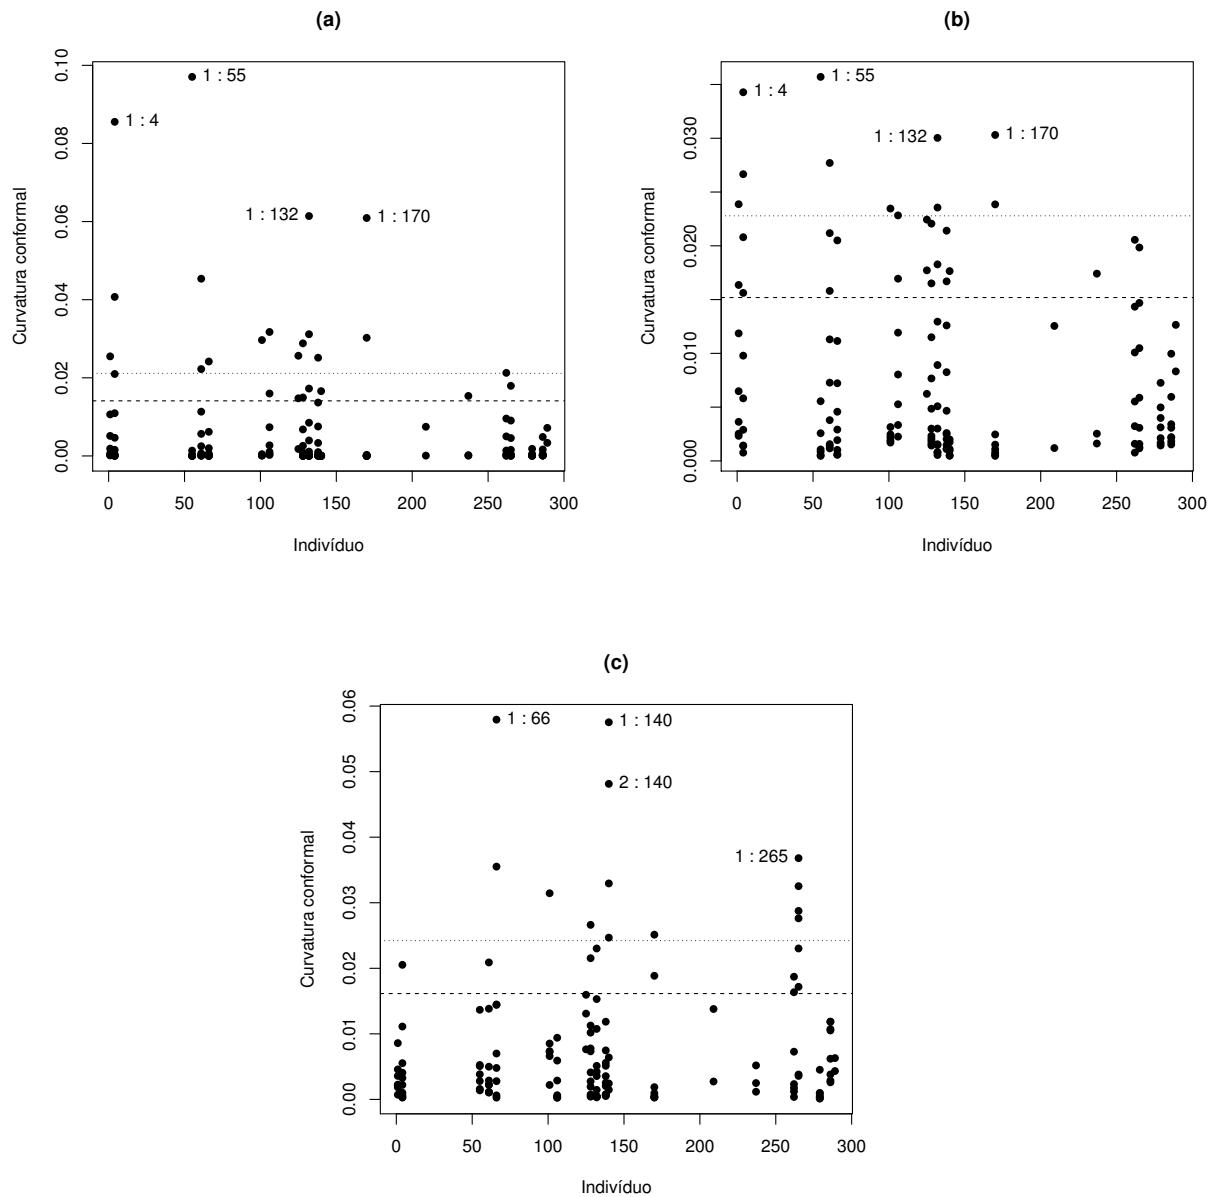


Fonte: O autor (2016).

o gráfico (b) desta mesma figura, nenhum indivíduo apresenta alta alavancagem. Este comportamento foi o mesmo observado no ajuste do MPLAG para dados correlacionados realizado neste exemplo sob o caso 1.

Segundo a perturbação de casos, as observações potencialmente influentes nas estimativas dos parâmetros foram as observações 1 para o indivíduo 55, 1 para o indivíduo 4, 1 para o indivíduo 132 e 1 para o indivíduo 170, como pode ser observado a partir do gráfico (a) da Figura 8.3. Estas mesmas observações foram detectadas como potencialmente influentes sob o ajuste do MPLAG para dados correlacionados sob o caso 1 para este exemplo. Considerando o gráfico (b) desta mesma Figura, temos que as mesmas observações detectadas no gráfico (a) como potencialmente influentes, segundo a perturbação na variável resposta. Finalmente, segundo o gráfico (c), as observações 1 e 2 referentes ao indivíduo 140, 1 referente ao indivíduo 66 e 1 para o indivíduo de número 265 foram consideradas como potencialmente influentes sob a perturbação na variável ex-

**Figura 8.3** Gráficos das medidas de influência local segundo a perturbação de casos (a), perturbação na variável resposta (b) e perturbação em uma variável explicativa (c) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 2 para os dados referentes ao Estudo de Poluição do Ar.



Fonte: O autor (2016).

plicativa idade. Sendo assim, os mesmos pontos detectados sob o caso 1 foram destacados como potencialmente influentes sob o caso 2.

Portanto, uma vez que os resultados obtidos sob o caso 1 (GEE-1) e sob o caso 2 (GEE-2) foram similares, podemos optar por qualquer das duas abordagens para a modelagem dos dados referentes ao Estudo de Poluição do Ar.

## 8.2 Aplicação 2: Dados de Pressão Sanguínea

Para o segundo exemplo de aplicação dos MPLAG para dados correlacionados já analisado sob o caso 1, consideramos sob o caso 2 as mesmas configurações do exemplo anterior, ou seja, utilizamos as mesmas equações de estimação para  $\xi$  e para  $\rho$  consideramos um caso particular das equações de estimação dadas em (17) através da função  $h(\rho) = \log[(1 + \rho)/(1 - \rho)] = v$  e assumimos  $\mathbf{V}_{(22)i}$  como sendo uma matriz identidade, para  $i = 1, \dots, 20$ . Sendo assim,  $\mathbf{X}_{(22)i}$  é um vetor de 1's e  $\mathbf{W}_{(22)i}^* = \mathbf{D}_{(22)i}^2$ , em que  $\mathbf{D}_{(22)i} = \text{diag}\{2e^v/(e^v + 1)^2, \dots, 2e^v/(e^v + 1)^2\}$ . Ainda, consideramos equações de estimação da forma (21) para  $\phi$ , utilizando a função  $h(\phi) = \log(\phi) = \kappa$  e também considerando  $\mathbf{V}_{(33)i}$  como sendo uma matriz identidade, para  $i = 1, \dots, 10$ . Desta forma, temos que  $\mathbf{X}_{(33)i}$  é um vetor de 1's e  $\mathbf{W}_{(33)i}^* = \mathbf{D}_{(33)i}^2$ , em que  $\mathbf{D}_{(33)i} = \text{diag}\{e^v, \dots, e^v\}$ .

**Tabela 8.2** Estimativas dos parâmetros sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo os casos 1 e 2 para os Dados de Pressão Sanguínea.

Efeito	Estim.		e.p. <sub>N</sub>		e.p. <sub>R</sub>	
	EEG-1	EEG-2	EEG-1	EEG-2	EEG-1	EEG-2
$\beta_1$	-0,459	-0,459	0,132	0,146	0,167	0,167
$f(6, 25)$	0,650	0,650	0,133	0,148	0,188	0,188
$f(12, 5)$	0,939	0,939	0,115	0,128	0,125	0,125
$f(25)$	1,499	1,499	0,111	0,123	0,136	0,137
$f(50)$	2,432	2,432	0,138	0,153	0,243	0,243
$f(100)$	3,333	3,333	0,163	0,18	0,143	0,143
$f(200)$	3,542	3,542	0,174	0,192	0,144	0,144

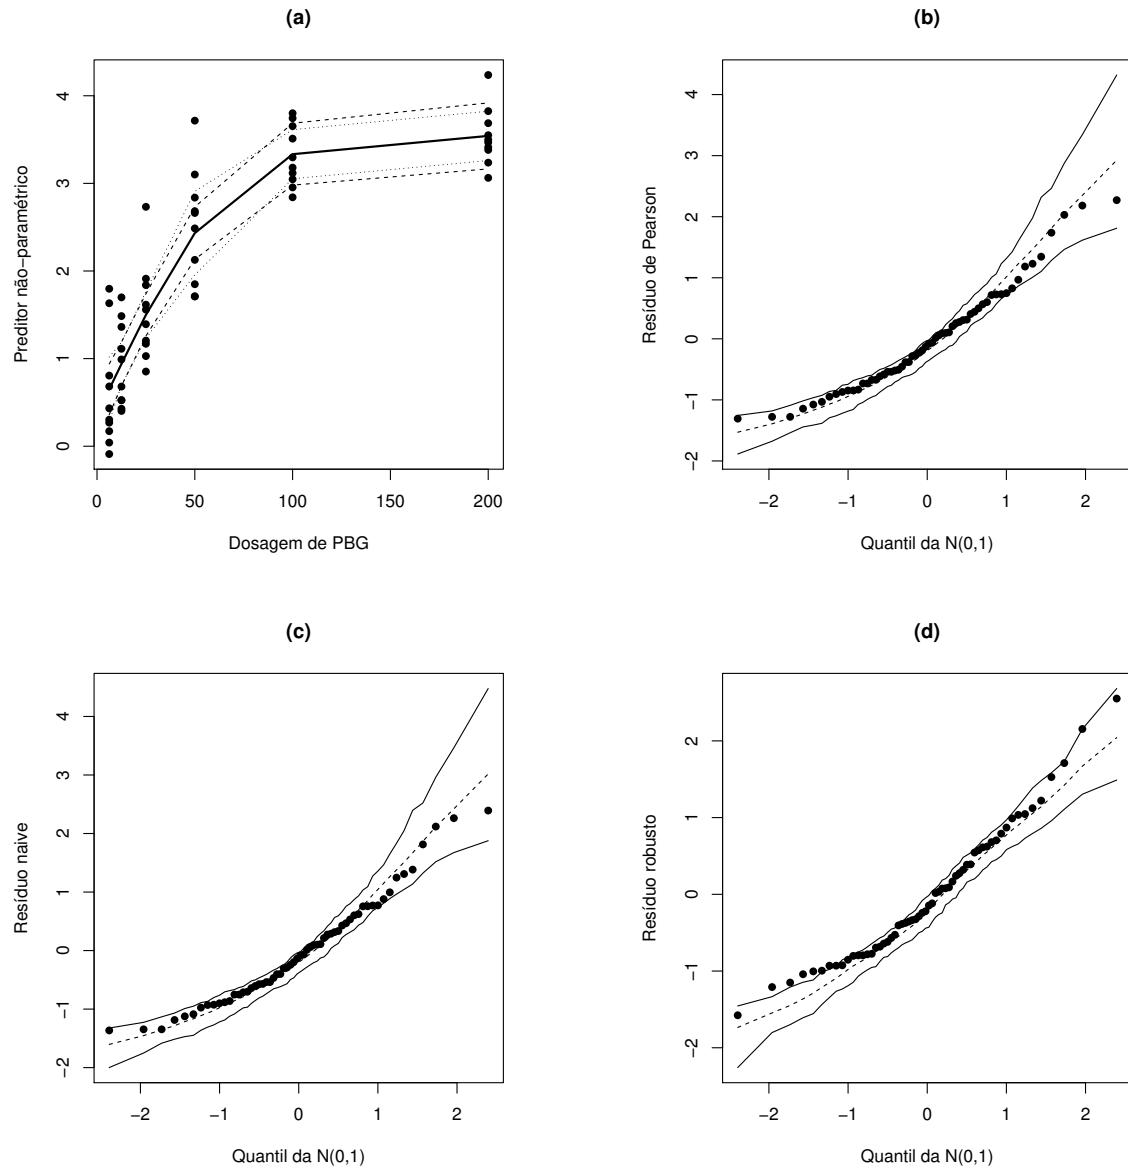
Fonte: O autor (2016).

Considerando o parâmetro  $\beta_1$  e as funções não-paramétricas, através da Tabela 8.2 observamos que os valores das estimativas são os mesmos em ambos os casos. Para as estimativas dos erros-padrão “naive” alguns valores diferem ligeiramente entre os dois casos considerados e em geral são maiores sob o caso 2. Considerando as estimativas dos erros-padrão “robustas”, os valores estimados sob os casos 1 e 2 são os mesmos, com exceção da estimativa do erro-padrão para a estimativa de  $f(25)$ , com valor ligeiramente maior sob o caso 2. Portanto o tratamento segundo a droga MDL 72222 é significativo para retardar o crescimento da pressão sanguínea, assim como as funções não-paramétricas são significativas segundo os modelos ajustados tanto sob o caso 1 como sob o caso 2. Temos ainda que a estimativa do parâmetro de correlação sob o caso 2 foi de  $\hat{\rho} = 0,388$ , valor ligeiramente maior que aquele obtido sob o caso 1 ( $\hat{\rho} = 0,354$ ). Ainda, a estimativa do parâmetro de dispersão sob o caso 2 foi de  $\hat{\phi} = 3,130$ , ou seja, ligeiramente menor que a estimativa obtida sob o caso 1 ( $\hat{\phi} = 3,835$ ). Temos ainda que a estimativa do parâmetro de suavização sob o caso 2 foi de  $\hat{\alpha} = 28.834,851$ , valor menor que aquele obtido sob o caso 1 ( $\hat{\alpha} = 29.023,745$ ), selecionado dentre 20 valores entre  $8,515 \times 10^{-5}$  e  $2,298 \times 10^6$ . O valor selecionado pode ser considerado baixo, indicando desta forma um comportamento não linear para a função não-paramétrica, assim como na abordagem sob as EEG-1.

A função não-paramétrica estimada é ilustrada no gráfico (a) da Figura 8.4 (curva em negrito), com bandas de confiança aproximadas utilizando estimativas “naive” (curvas tracejadas) e “robustas” (curvas pontilhadas) dos erros padrão das estimativas. A partir deste gráfico podemos notar o comportamento não linear da relação entre a dosagem de PBG e a pressão sanguínea, mesmo comportamento observado no ajuste do MPLAG para dados correlacionados sob o caso 1 para estes dados.

Considerando os gráficos de quantis normais com envelopes simulados para os resíduos de Pearson (b), resíduos “naive” (c) e resíduos “robustos” (d) da Figura 8.4, há evidências de que a distribuição marginal gama assumida para a pressão sanguínea média está corretamente especificada sob o MPLAG para dados correlacionados ajustado sob o caso

**Figura 8.4** Gráfico da função não-paramétrica estimada (a) e gráficos de quantis normais com envelopes simulados (95% de confiança) para os resíduos de Pearson (b) “naive” (c) e “robustos” (d) sob o MPLAG para dados correlacionados com distribuição marginal gama ajustado segundo o caso 2 para os Dados de Pressão Sanguínea.



Fonte: O autor (2016).

2 aos Dados de Pressão Sanguínea, uma vez que em cada um destes gráficos a maioria dos pontos encontra-se dentro dos respectivos envelopes simulados. Ainda, assim como no caso 1 (abordagem via EEG-1), sob as EEG-2 os comportamentos dos pontos nos gráficos de quantis referentes aos resíduos de Pearson, resíduos “naive” e resíduos “robustos” (gráficos (b), (c) e (d), respectivamente) indicam que os três resíduos considerados apresentam distribuições com certa assimetria.

Finalmente, assim como no primeiro exemplo de aplicação, os resultados obtidos sob o caso 1 (GEE-1) e sob o caso 2 (GEE-2) foram similares. Portanto, podemos optar por qualquer uma das duas abordagens para a modelagem dos dados referentes a este exemplo de aplicação.

## Capítulo 9

# Conclusões e Trabalhos Futuros

Apresentamos nesta tese algumas técnicas de diagnóstico nos modelos parcialmente lineares aditivos generalizados para dados correlacionados, considerados sob as equações de estimação conhecidas na literatura como EEG-1 e EEG-2. As equações de estimação referentes aos MPLAG para dados correlacionados podem ser consideradas como generalizações das EEG paramétricas, dadas por exemplo em Liang e Zeger (1986). No caso do MPLAG para observações independentes estas generalizações podem ser vistas, por exemplo, em Green (1997), derivadas a partir da função de verossimilhança penalizada.

Propusemos três técnicas de diagnóstico a serem utilizadas a partir dos ajustes do MPLAG para dados correlacionados:

- (i) medidas de alavancagem;
- (ii) análise de resíduos;
- (iii) análise de influência local através do cálculo da curvatura normal.

Foi realizado um estudo de simulação para verificar algumas propriedades de  $\hat{\xi}$ ,  $\widehat{\text{Var}}_N(\hat{\xi})$  e  $\widehat{\text{Var}}_R(\hat{\xi})$ , bem como para investigar o comportamento dos resíduos de Pearson, “naive” e “robustos”. Em geral os estimadores apresentam forte indício de consistência, pois seus respectivos erros quadráticos médios, desvios-padrão e vieses decaem à medida que o tamanho da amostra cresce, em praticamente todos os cenários considerados. Os

coeficientes de assimetria assumiram, em geral, valores próximos de zero e os coeficientes de curtose assumiram valores próximos de três, sugerindo uma distribuição assintótica aproximadamente normal para os estimadores estudados sob os cenários considerados no estudo.

Considerando os três tipos de resíduos propostos nesta tese, temos que sob uma distribuição marginal normal, os três resíduos propostos são aproximadamente simétricos. Sob as distribuições Poisson e gama os resíduos considerados apresentam alguma assimetria. Os valores médios registrados ficaram em torno de zero e os desvios-padrão assumiram valores próximos de um para os três resíduos considerados. Portanto, concluímos que os três tipos de resíduos devem ser utilizados na detecção de observações discrepantes.

As medidas de alavancagem foram utilizadas no exemplo de aplicação referente ao Estudo de Poluição do Ar, possibilitando a detecção de grupos e observações que potencialmente poderiam exercer influência relevante nos valores preditos. Através da construção de gráficos de quantis normais com bandas de confiança simuladas para os resíduos investigamos as suposições de uma distribuição marginal gama no MPLAG para dados correlacionados utilizado no ajuste dos dados provenientes do Estudo de Poluição do Ar e de uma distribuição marginal gama no MPLAG para dados correlacionados ajustado para os Dados de Pressão Sanguínea, utilizando EEG-1 e posteriormente EEG-2. A análise de influência local através da curvatura normal foi realizada para o Estudo de Poluição do Ar sob a perturbação de casos, perturbação na variável resposta e perturbação em uma variável explicativa. Desta forma, foram detectadas observações potencialmente influentes nas estimativas dos parâmetros.

Concluímos portanto que as técnicas de diagnóstico para os MPLAG para dados correlacionados desenvolvidas neste trabalho constituem uma grande contribuição para a análise de dados correlacionados. As medidas de alavancagem, a análise dos três tipos de resíduos aqui propostos e a análise de influência local segundo a curvatura normal contribuem significativamente para a literatura acerca de modelos semiparamétricos uti-

lizados na modelagem de dados multivariados e, desta forma, constituem um conjunto de técnicas fundamentais na análise dos ajustes dos MPLAG para dados correlacionados.

Como trabalhos futuros temos, entre outras, as seguintes propostas:

- Estudar os MPLAG para dados correlacionados sob diferentes estruturas semiparamétricas, considerando por exemplo o uso de outras representações de funções como B-splines e P-splines;
- Implementar um pacote no software estatístico R para o ajuste dos MPLAG para dados correlacionados, tanto sob as EEG-1 como sob as EEG-2;
- Investigar o uso de funções não paramétricas na estimativa do vetor de parâmetros de correlação nos MPLAG para dados correlacionados sob as EEG-2;
- Estender a classe dos Modelos Elípticos Multiníveis (MANGHI, 2011), introduzindo componentes não-paramétricas ao modelos pertencentes a esta classe, assim como propor medidas de diagnóstico sob esta generalização.

## Referências

- ARTES, R.; JØRGENSEN, B. Longitudinal data estimating equations for dispersion models. **Scandinavian Journal of Statistics**, v. 27, p. 321–334, 2000.
- BALEMI, A.; LEE, A. Comparison of GEE1 and GEE2 estimation applied to clustered logistic regression. **Journal of Statistical Computation and Simulation**, v. 79, p. 361–378, 2009.
- BOENTE, G. et al. Testing in generalized partially linear models: a robust approach. **Statistics & Probability Letters**, v. 83, p. 203–212, 2013.
- BUJA, A.; HASTIE, T; TIBSHIRANI, R. Linear smoothers and additive models. **The Annals of Statistics**, v. 17, p. 453–510, 1989.
- CHANG, Y. Residuals analysis of the generalized linear models for longitudinal data. **Statistics in Medicine**, v. 19, p. 1277–1293, 2000.
- CHEN, Z. et al. Efficient semiparametric estimation via Cholesky decomposition for longitudinal data. **Comp. Stat. and Data Analysis**, v. 55, p. 3344–3354, 2011.
- CHEN, B.; ZHOU, X. Generalized partially linear models for incomplete longitudinal data in the presence of population-level information. **Biometrics** v. 69, p. 386–395, 2013.
- CHENG, P. E. A note on strong convergence rates in nonparametric regression. **Statistics & Probability Letters**, v. 24, p. 357–364, 1995.
- CHENG, G.; YU, Z.; HUANG, J. Z. The cluster bootstrap consistency in generalized estimating equations. **Journal of Multivariate Analysis**, v. 115, p. 33–47, 2013.
- CHOKRI, K.; LOUANI, D. Asymptotic results for the linear parameter estimate in partially linear additive regression model. **Comptes Rendus Mathematique**, v. 349, p. 1105–1109, 2011.
- COOK, R. D. Assessment of local influence. **Journal of the Royal Statistical Society - Series B (Methodological)**, v. 48, p. 133–169, 1986.
- CROWDER, M. On linear and quadratic estimating functions. **Biometrika**, v. 74, p. 591–597, 1987.

- CROWDER, M. On the use of a working correlation matrix in using generalised linear models for repeated measures. **Biometrika**, v. 82, p. 407–410, 1995.
- CRUMP, S. L. The estimation of variance components in analysis of variance. **Biometrics Bulletin**, v. 2, p. 7–11, 1946.
- DOCKERY, D. W. et al. Distribution of FVC and FEV1 in children 6 to 11 years old. **American Review of Respiratory Disease**, v. 128, p. 405–412, 1983.
- DOORNIK, J. A. **Object-oriented matrix programming using OX**. Oxford, 2007. Disponível em: <<http://www.doornik.com>>. Acesso em: 01 mar. 2013.
- EILERS, P. H. C.; MARX, B. D. Flexible smoothing with B-splines and penalties. **Statistical Science**, v. 11, p. 89–121, 1996.
- EUBANK, R. L. The hat matrix for smoothing splines. **Statistics & Probability Letters**, v. 2, p. 9–14, 1984.
- EUBANK, R. L.; WHITNEY, P. Convergence rates for estimation in certain partially linear models. **Journal of Statistical Planning and Inference**, v. 23, p. 33–43, 1989.
- GIAMPAOLI, V.; SINGER, J. M. Likelihood ratio tests for variance components in linear mixed models. **Journal of Statistical Planning and Inference**, v. 139, p. 1435–1448, 2009.
- GOSHO, M.; HAMADA, C.; YOSHIMURA, I. Selection of working correlation structure in weighted generalized estimating equation method for incomplete longitudinal data. **Communications in Statistics - Simulation and Computation**, v. 43, p. 62–81, 2014.
- GREEN, P. J. Penalized likelihood for general semi-parametric regression models. **International Statistical Review**, v. 55, p. 245–259, 1987.
- GREEN, P. J.; SILVERMAN, B. W. **Nonparametric regression and generalized linear models: a roughness penalty approach**. Londres: Chapman & Hall, 1994.
- HANSEN, L. P. Large sample properties of generalized methods of moments estimators. **Econometrica**, v. 50, p. 1029–1054, 1982.
- HASTIE, T.; TIBSHIRANI, R. **Generalized additive models**. Londres: Chapman & Hall, 1990.
- HECKMAN, N. E. Spline smoothing in a partly linear model. **Journal of the Royal Statistical Society - Series B (Methodological)**, v. 48, p. 244–248, 1986.
- HU, Z., WANG, N; CARROLL, R. J. Profile-kernel versus backfitting in the partially linear models for longitudinal/clustered data. **Biometrika**, v. 91, p. 251–262, 2004.

- IBACACHE-PULGAR, G.; PAULA, G. A.; GALEA, M. Influence diagnostics for elliptical semiparametric mixed models. **Statistical Modelling**, v. 12, p. 165–193, 2012.
- JUNG, K. Local influence in generalized estimating equations. **Scandinavian Journal of Statistics**, v. 35, p. 286–294, 2008.
- KIM, C. Cook's distance in spline smoothing. **Statistics & Probability Letters**, v. 31, p. 139–144, 1996.
- LAIRD, N. M.; WARE, J. H. Random-effects models for longitudinal data. **Biometrics**, v. 38, p. 963–974, 1982.
- LIAN, H.; LIANG, H.; WANG, L. Generalized additive partial linear models for clustered data with diverging number of covariates using gee **Statistica Sinica**, v. 24, p. 173–196, 2014.
- LIANG, K.; ZEGER, S. L. Longitudinal data analysis using generalized linear models. **Biometrika**, v. 73, p. 13–22, 1986.
- LIANG, K.; ZEGER, S. L.; QAQISH, B. Multivariate regression analyses for categorical data. **Journal of the Royal Statistical Society - Series B (Methodological)**, v. 54, p. 3–40, 1992.
- LIN, X.; CARROLL, R. J. Semiparametric regression for clustered data using generalized estimating equations. **Journal of the American Statistical Association**, v. 96, p. 1045–1056, 2001.
- LIN, X.; ZHANG, D. Inference in generalized additive mixed models by using smoothing splines. **Journal of the Royal Statistical Society - Series B (Statistical Methodology)**, v. 61, p. 381–400, 1999.
- LIPSITZ, S. R.; LAIRD, N. M.; HARRINGTON, D. P. Generalized estimating equations for correlated binary data: using the odds ratio as a measure of association. **Biometrika**, v. 78, p. 153–160, 1991.
- LUDBROOK, J. Repeated measurements and multiple comparisons in cardiovascular research. **Cardiovascular Research**, v. 28, p. 303–311, 1994.
- MANGHI, R. F. **Modelos elípticos multiníveis**. Dissertação de mestrado, Universidade de São Paulo, 2011.
- MCLEAN, R. A.; SANDERS, W. L.; STROUP, W. W. A unified approach to mixed linear models. **The American Statistician**, v. 45, p. 54–64, 1991.
- MCCULLAGH, P; NELDER, J. A. **Generalized linear models**. Londres: Chapman & Hall, 1983.
- NELDER, J. A.; PREGIBON, D. An extended quasi-likelihood function. **Biometrika**, v. 74, p. 22–232, 1987.

- NELDER, J. A.; WEDDERBURN, R. W. M. Generalized linear models. **Journal of the Royal Statistical Society - Series A (General)**, v. 135, p. 370–384, 1972.
- OPSOMER, J. D.; RUPPERT, D. A root-n consistent backfitting estimator for semiparametric additive modeling. **Journal of Computational and Graphical Statistics**, v. 8, p. 715–732, 1999.
- PAN, W. Akaike's information criterion in generalized estimating equations. **Biometrics**, v. 57, p. 120–125, 2001a.
- PAN, W. On the robust variance estimator in generalised estimating equations. **Biometrika**, v. 88, p. 901–906, 2001b.
- PARK, C. G.; SHIN, D. W. An algorithm for generating correlated random variables in a class of infinitely divisible distributions. **Journal of Statistical Computation and Simulation**, v. 61, p. 127–139, 1998.
- PAULA, G. A.; CYSNEIROS, F. J. A. Systematic risk estimation in symmetric models. **Applied Economics Letters**, v. 16, p. 217–221, 2009.
- POON, W.; POON, Y. S. Conformal normal curvature and assessment of local influence. **Journal of the Royal Statistical Society - Series B (Statistical Methodology)**, v. 61, p. 51–61, 1999.
- PRENTICE, R. L. Correlated binary regression with covariates specific to each binary observation. **Biometrics**, v. 44, p. 1033–1048, 1988.
- PRENTICE, R. L.; ZHAO, L. P. Estimating equations for parameters in means and covariances of multivariate discrete and continuous responses. **Biometrics**, v. 47, p. 825–839, 1991.
- PREISSER, J. S.; QAQISH, B. F. Deletion diagnostics for generalised estimating equations. **Biometrika**, v. 83, p. 551–562, 1996.
- R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing. Vienna, 2014. Disponível em: <<http://www.r-project.org>>. Acesso em: 01 mar. 2014.
- RICE, J. Convergence rates for partially splined models. **Statistics & Probability Letters**, v. 4, p. 203–208, 1986.
- SEARLE, S. R.; CASELLA, G.; MCCULLOCH, C. E. **Variance components**. Nova Iorque: Wiley, 1992.
- SILVAPULLE, M. J.; SILVAPULLE, P. A score test against one-sided alternatives. **Journal of the American Statistical Association**, v. 90, p. 342–349, 1995.

- SULIADI, S.; IBRAHIM, N. A.; DAUD, I. Semiparametric estimation with profile algorithm for longitudinal binary data. **Communications in Statistics - Simulation and Computation**, v. 42, p. 138–152, 2013.
- TAN, M., QU, Y.; KUTNER, M. H. Model diagnostics for marginal regression analysis of correlated binary data. **Communications in Statistics - Simulation and Computation**, v. 26, p. 539–558, 1997.
- VENABLES, W. N.; RIPLEY, B. D. **Modern applied statistics with S**. Nova Iorque: Springer, 2002.
- VENEZUELA, M. K.; BOTTER, D. A.; SANDOVAL, M. C. Diagnostic techniques in generalized estimating equations. **Journal of Statistical Computation and Simulation**, v. 77, p. 879–888, 2007.
- VENEZUELA, M. K.; SANDOVAL, M. C.; BOTTER, D. A. Local influence in estimating equations. **Comp. Stat. and Data Analysis**, v. 55, p. 1867–1883, 2011.
- VERBEKE, G.; MOLENBERGHS, G. **Linear mixed models for longitudinal data**. Nova Iorque: Springer, 2000.
- VERBEKE, G.; MOLENBERGHS, G. The use of score tests for inference on variance components. **Biometrics**, v. 59, p. 254–262, 2003.
- WANG, L. et al. Estimation and model selection in generalized additive partial linear models for correlated data with diverging number of covariates. **The Annals of Statistics**, v. 42, p. 592–624, 2014.
- WATERNAUX, C.; LAIRD, N. M.; WARE, J. H. Methods for analysis of longitudinal data: blood-lead concentrations and cognitive development. **Journal of the American Statistical Association**, v. 84, p. 33–41, 1989.
- WEDDERBURN, R. W. M. Quasi-likelihood functions, generalized linear models, and the Gauss-Newton method. **Biometrika**, v. 61, p. 439–447, 1974.
- WOOD, S. N. **Generalized additive models: an introduction with R**. Boca Raton: Chapman & Hall, 2006.
- XUE, L.; ZHU, L. Empirical likelihood semiparametric regression analysis for longitudinal data. **Biometrika**, v. 94, p. 921–937, 2007.
- ZHAO, L. P.; PRENTICE, R. L. Correlated binary regression using a quadratic exponential model. **Biometrika**, v. 77, p. 642–648, 1990.
- ZIEGLER, A. The Different Parameterizations of the GEE1 and the GEE2. **Proc. of the 10th International Workshop on Stat. Modelling**, v. 104, p. 315–324, 1995.
- ZIEGLER, A.; KASTNER, C.; BLETTNER, M. The generalised estimating equations: an annotated bibliography. **Biometrical Journal**, v. 40, p. 115–139, 1998.