

# Modelagem simultânea da média e da dispersão (MLG's duplos)

Prof. Caio Azevedo

# Modelo linear generalizado duplo

- Um MLG duplo (na sua forma mais simples) é dado por:

$$Y_i \stackrel{ind.}{\sim} FE(\theta_i, \phi_i) \quad , \quad \theta_i = h(\mu_i), i = 1, \dots, n,$$

$$g(\mu_i) = \eta_i = \mathbf{X}_i' \boldsymbol{\beta} = \sum_{j=1}^p X_{ji} \beta_j; \mathbf{X}_i = (X_{1i}, \dots, X_{pi})',$$

$$h(\phi_i) = \lambda_i = \mathbf{Z}_i' \boldsymbol{\gamma} = \sum_{j=1}^q Z_{ji} \gamma_j; \mathbf{Z}_i = (Z_{1i}, \dots, Z_{qi})',$$

em que  $\boldsymbol{\beta} \in \mathcal{R}^p, \boldsymbol{\gamma} \in \mathcal{R}^q$ ,  $g(\cdot)$  e  $h(\cdot)$  são chamadas de função de ligação e  $\eta_i, \lambda_i$  são preditores lineares (relacionados ao indivíduo  $i$ ).  
Eventualmente,  $\mathbf{X}_i$  e  $\mathbf{Z}_i$  podem ser iguais, ou ter elementos em comum ( $i=1,2,\dots,n$ ).

## Cont.

- Note que se  $Y_i \sim \text{FE}(\theta_i, \phi_i)$ ,  $i = 1, 2, \dots, n$ , então:

$$f_{Y_i}(y_i; \theta_i, \phi_i) = \exp \{ \phi_i [y_i \theta_i - b(\theta_i)] + c(y_i, \phi_i) \} \mathbb{1}_A(y_i),$$

em que, com as devidas adaptações, as funções da fdp acima são como descritas [aqui](#).

- Das distribuições (pertencentes à família exponencial) vistas no curso, faz sentido considerar essa estrutura somente para a normal, gama e normal inversa. Nesse caso, temos que (exercício):

$$c(y_i; \phi_i) = d(\phi_i) + \phi_i a(y_i) + u(y_i).$$

## Cont.

- Algumas propriedades (exercícios). Defina

$$T_i = Y_i\theta_i - b(\theta_i) + a(Y_i),$$

então

- $\mathcal{E}(T_i) = -\frac{d}{d\phi_i}d(\phi).$
- $\mathcal{V}(T_i) = -\frac{d^2}{d\phi_i^2}d(\phi).$

# Estimação

- (Cont.) em que  $d(\cdot)$ ,  $a(\cdot)$  e  $u(\cdot)$  são funções duplamente diferenciáveis que dependem da distribuição escolhida (exercício).
- Verossimilhança (defina  $\boldsymbol{\vartheta} = (\boldsymbol{\beta}', \boldsymbol{\gamma}')$ ), assim, temos que:

$$\begin{aligned} L(\boldsymbol{\vartheta}) &= \exp \left\{ \sum_{i=1}^n \{ \phi_i [y_i \theta_i - b(\theta_i)] + d(\phi_i) + \phi_i a(y_i) + u(y_i) \} \right\} \\ &= \exp \left\{ \sum_{i=1}^n \{ \phi_i t_i + d(\phi_i) + u(y_i) \} \right\}. \end{aligned}$$

- Log-verossimilhança

$$l(\boldsymbol{\vartheta}) = \sum_{i=1}^n \{ \phi_i t_i + d(\phi_i) + u(y_i) \}.$$

# Estimação

- Temos que obter  $S(\beta_j) = \frac{\partial}{\partial \beta_j} l(\boldsymbol{\vartheta})$ ,  $j = 1, 2, \dots, p$  e

$S(\gamma_r) = \frac{\partial}{\partial \gamma_r} l(\boldsymbol{\vartheta})$ ,  $r = 1, 2, \dots, q$  e resolver o que seguinte sistema de equações

$$\begin{cases} \mathbf{S}(\tilde{\boldsymbol{\beta}}) = \mathbf{0}_{(p \times 1)} \\ \mathbf{S}(\tilde{\boldsymbol{\gamma}}) = \mathbf{0}_{(q \times 1)} \end{cases},$$

em que  $\mathbf{S}(\tilde{\boldsymbol{\beta}}) = (S(\beta_1), \dots, S(\beta_p))'$  e  $\mathbf{S}(\tilde{\boldsymbol{\gamma}}) = (S(\gamma_1), \dots, S(\gamma_q))'$ .

- Como o sistema acima não tem solução analítica, podemos usar algum algoritmo, com o Escore de Fisher, para obter as emv.

# Estimação

- Adicionalmente, pode-se provar que  $\mathbf{S}(\vartheta) = (\mathbf{S}(\beta), \mathbf{S}(\gamma))'$ :

$$\mathbf{S}(\beta) = \mathbf{X}'\Phi\mathbf{W}^{1/2}\mathbf{V}^{-1/2}(\mathbf{y} - \boldsymbol{\mu}),$$

$$\mathbf{S}(\gamma) = \mathbf{Z}'\mathbf{H}_\gamma^{-1}(\mathbf{t} - \boldsymbol{\mu}_t),$$

em que  $\mathbf{X} = (\mathbf{X}_1, \dots, \mathbf{X}_n)'$ ,  $\mathbf{W} = \text{diag}(\omega_1, \dots, \omega_n)$ ,

$\omega_i = (d\mu_i/d\eta_i)^2 / V_i$ ,  $\Phi = \text{diag}(\phi_1, \dots, \phi_n)$ ,  $\mathbf{y} = (y_1, \dots, y_n)'$ ,

$\boldsymbol{\mu} = (\mu_1, \dots, \mu_n)'$ ,  $\mathbf{H}_\gamma = \text{diag}(h'(\phi_1), \dots, h'(\phi_n))$ ,  $\mathbf{t} = (t_1, \dots, t_n)'$ ,

$\boldsymbol{\mu}_t = (\mathcal{E}(T_1), \dots, \mathcal{E}(T_n))' = (-d'(\phi_1), \dots, -d'(\phi_n))$ .

# Estimação

- Com relação à informação de Fisher, temos que:

$$I(\vartheta) \begin{bmatrix} I(\beta, \beta) & I(\beta, \gamma) = \mathbf{0}_{(p \times q)} \\ I(\gamma, \beta) = \mathbf{0}_{(q \times p)} & I(\gamma, \gamma) \end{bmatrix},$$

em que

$$I(\beta, \beta) = \mathbf{X}'\Phi\mathbf{W}\mathbf{X}; I(\gamma, \gamma) = \mathbf{Z}'\mathbf{P}\mathbf{Z},$$

$$\text{e } \mathbf{P} = \mathbf{V}_\gamma \mathbf{H}_\gamma^{-2}, \mathbf{V}_\gamma = \text{diag} = (-d''(\phi_1), \dots, -d''(\phi_n)).$$

# Estimação

- Similarmente aos MLG's (usuais) pode-se desenvolver um processo iterativo **score de Fisher** para encontrar as estimativas de máxima verossimilhança  $(\tilde{\beta}', \tilde{\gamma}')$ , ou seja:

$$\begin{aligned}\beta^{(m+1)} &= \left( \mathbf{X}' \Phi^{(m)} \mathbf{W}^{(m)} \mathbf{X} \right)^{-1} \mathbf{X}' \Phi^{(m)} \mathbf{W}^{(m)} \mathbf{y}^{*(m)}, \\ \gamma^{(m)} &= \left( \mathbf{Z}' \mathbf{P}^{(m)} \mathbf{X} \right)^{-1} \mathbf{Z}' \mathbf{P}^{(m)} \mathbf{z}^{*(m)},\end{aligned}$$

$m = 0, 1, 2, \dots$  (até que algum critério de convergência seja alcançado), em que  $\mathbf{y}^* = \mathbf{X}\beta + \mathbf{W}^{-1/2} \mathbf{V}^{-1/2} (\mathbf{y} - \mu)$ ,  
 $\mathbf{z}^* = \mathbf{Z}\gamma + \mathbf{V}_\gamma^{-1} \mathbf{H}_\gamma (\mathbf{t} - \mu_t)$ .

# Estimação

- Sob certas condições de regularidade (veja Seção 1.6.3 de [Paula \(2024\)](#)) temos, para  $n$  suficientemente grande, que:

$$\hat{\beta} \approx N_p(\beta, I^{-1}(\beta, \beta)), \hat{\gamma} \approx N_q(\gamma, I^{-1}(\gamma, \gamma)), \hat{\beta} \perp \hat{\gamma}$$

- Testes de hipótese, com as devidas adaptações, podem ser implementados com visto [aqui](#).
- Seleção e comparação de modelos, com as devidas adaptações, podem ser implementadas como visto [aqui](#).

# Análise residual e desvio

- Na classe dos MLGs duplos pode-se definir desvios para tanto para a média e para a precisão.
- O desvio para a média assume a mesma expressão da classe dos MLGs em que somente a média é ajustada (**aqui**), com  $\phi_i$  no lugar de  $\phi$ , ou seja

$$D_1^*(\mathbf{y}; \hat{\boldsymbol{\mu}}, \phi) = \sum_{i=1}^n d_1^*(y_i; \hat{\mu}_i, \phi_i), \quad (1)$$

em que  $d_1^*(y_i; \hat{\mu}_i, \phi_i) = 2\phi_i \left[ y_i \left( \hat{\theta}_i^{(0)} - \hat{\theta}_i \right) + \left( b \left( \hat{\theta}_i \right) - b \left( \hat{\theta}_i^{(0)} \right) \right) \right]$ .

## Análise residual e desvio

- Para  $\phi_i$  grande  $\forall i$  o desvio (Equação (1)) pode ser comparado com os quantis da distribuição qui-quadrado com  $(n - p)$  graus de liberdade.
- O resíduo componente do desvio para a média fica dado como

$$T_{D_{1i}} = \text{sinal}(Y_i - \hat{\mu}_i) \sqrt{\frac{d_1^* (Y_i; \hat{\mu}_i, \hat{\phi}_i)}{1 - \hat{h}_{ii}}},$$

$$\text{em que } \hat{h}_{ii} = \hat{\phi}_i \hat{\omega}_i \mathbf{X}'_i \left( \mathbf{X}' \hat{\Phi} \hat{W} \mathbf{X} \right)^{-1} \mathbf{X}_i, \quad i = 1, 2, \dots, n.$$

# Análise residual e desvio

- Sob o bom ajuste do modelo e, sob certas condições, espera-se que

$$T_{D_i} \xrightarrow[n \rightarrow \infty]{D} N(0, 1).$$

- Pode-se fazer, essencialmente, os mesmos gráficos considerados para o caso do RCD para o MLG usual ([aqui](#)).

# Análise residual e desvio

- Por outro lado, o desvio para a precisão é dado por

$$D_2^* (\mathbf{y}; \boldsymbol{\mu}, \hat{\boldsymbol{\phi}}) = \sum_{i=1}^n d_1^* (y_i; \mu_i, \hat{\phi}_i), \quad (2)$$

em que  $d_2^* (y_i; \mu_i, \hat{\phi}_i) = 2 \left[ t_i \left( \hat{\phi}_i^{(0)} - \hat{\phi}_i \right) + \left( d \left( \hat{\phi}_i \right) - d \left( \hat{\phi}_i^{(0)} \right) \right) \right]$  e  $\hat{\phi}_i^{(0)}$  é o estimador para  $\phi$  sob o modelo saturado.

- Aqui também, para  $\phi_i$  grande  $\forall i$  o desvio (Equação (2)) pode ser comparado com os quantis da distribuição qui-quadrado com  $(n - q)$  graus de liberdade.

# Análise residual e desvio

- O resíduo componente do desvio para a precisão fica dado como

$$T_{D_{2i}} = \text{sinal}(\widehat{T}_i + d''\widehat{\phi}_i) \sqrt{\frac{d_2^* (Y_i; \widehat{\mu}_i, \widehat{\phi}_i)}{1 - \widehat{r}_{ii}}},$$

em que  $\widehat{r}_{ii} = \widehat{p}_i \mathbf{Z}_i' (\mathbf{Z}' \widehat{\mathbf{P}} \mathbf{Z})^{-1} \mathbf{Z}_i$ ,  $\widehat{p}_i = -d''(\widehat{\phi}_i) \{h'(\widehat{\phi}_i)\}^{-2}$   
 $i = 1, 2, \dots, n$ .

# Análise residual e desvio

- Sob o bom ajuste do modelo e, sob certas condições, espera-se que

$$T_{D_2} \xrightarrow[n \rightarrow \infty]{D} N(0, 1).$$

- Pode-se fazer, essencialmente, os mesmos gráficos considerados para o caso do RCD para o MLG usual ([aqui](#)).

# Análise de influência

- Para avaliar a sensibilidade das estimativas dos parâmetros que modelam a média pode-se usar a medida vista [aqui](#) com  $\hat{\phi}_i$  no lugar de  $\hat{\phi}$ , ou seja:

$$LD_i^\beta = \left\{ \frac{\hat{h}_{ii}}{1 - \hat{h}_{ii}} \right\} T_{S_i}^2,$$

em que  $T_{S_i}^2 = \frac{\sqrt{\hat{\phi}_i} (Y_i - \hat{\mu}_i)}{\sqrt{\hat{V}_i (1 - \hat{h}_{ii})}}$ .

- Pode-se considerar um gráfico índice  $\times LD_i^\beta$ .

## Análise de influência

- Por outro lado, para avaliar a sensibilidade das estimativas dos parâmetros que modelam a precisão pode-se usar

$$LD_i^\gamma = \left\{ \frac{\hat{r}_{ii}}{1 - \hat{r}_{ii}} \right\} T_{T_i}^2,$$

em que  $T_{T_i}^2 = \frac{\sqrt{\hat{\phi}_i} \left( T_i + d' \left( \hat{\phi}_i \right) \right)}{\sqrt{-d'' \left( \hat{\phi}_i \right) (1 - \hat{r}_{ii})}}$ .

- Pode-se considerar um gráfico índice  $\times LD_i^\gamma$ .
- Em ambos os casos, assim como no caso dos **MLGs usuais**, não há um ponto de corte. A ideia é avaliar as observações com valores de  $LD^{(\cdot)}$  que se destacam em relação as demais.

# Análise no R

- No R, com uma sintaxe bem parecida com a da função *glm*, podemos usar a função *dglm* do pacote *dglm*. Com efeito

```
dglm(Y~X1 + X2 + ... + Xp,  
~Z1 + Z2 + ... + Zq,family=Gamma(link="log"),  
dlink = "log")
```

(sem intercepto)

```
dglm(Y~-1+X1 + X2 + ... + Xp,  
~-1+ Z1 + Z2 + ... + Zq,family=Gamma(link="log"),  
dlink = "log")
```

# Análise no R

- No `gamlss`

```
gamlss(Y~X1 + X2 + ... + Xp,  
sigma.formula~Z1 + Z2 + ... + Zq,  
family=GA(mu.link="log",sigma.link ="log"))
```

(sem intercepto)

```
gamlss(Y~-1+X1 + X2 + ... + Xp,  
sigma.formula~-1+Z1 + Z2 + ... + Zq,  
family=GA(mu.link="log",sigma.link ="log"))
```

# Análise no R

- Observação, tanto no pacote *dglm* quanto no *gamlss* modela-se  $\phi^{-1}$  (dispersão), ao invés de  $\phi$  (precisão).
- Nos desenvolvimentos apresentados se, por exemplo,  $h \equiv \ln(\cdot)$ , então

$$\ln(\phi) = \sum_{j=1}^q Z_{ij} \gamma_j,$$

$$\ln(\phi^{-1}) = -\ln(\phi) \rightarrow \ln(\phi) = \sum_{j=1}^q Z_{ij} (-\gamma_j).$$

- Para mais detalhes veja ([aqui](#)), ([aqui](#)) e ([aqui](#)).

## Exemplo 13: diferentes de um novo tipo de snack

- Os dados aqui considerados são parte de um experimento desenvolvido no Departamento de Nutrição da Faculdade de Saúde Pública da USP em que 5 (cinco) formas diferentes de um novo tipo de snack (“lanche”), com baixo teor de gordura saturada e de ácidos graxos, foram comparados ao longo de 20 semanas.
- Neste novo produto a gordura vegetal hidrogenada, responsável pela fixação do aroma do produto, foi substituída, total ou parcialmente, por óleo de canola.

## Exemplo 13: diferentes de um novo tipo de snack

- As formas são as seguintes: A (22% de gordura, 0% de óleo de canola), B (0% de gordura, 22% de óleo de canola), C (17% de gordura, 5% de óleo de canola), D (11% de gordura, 11% de óleo de canola) e E (5% de gordura, 17% de óleo de canola).
- O experimento foi conduzido de modo que nas semanas pares, 15 embalagens de cada um dos produtos A, B, C, D e E fossem analisadas em laboratório e observadas diversas variáveis.

## Exemplo 13: diferentes de um novo tipo de snack

- Em particular, temos o interesse de estudar o comportamento da textura dos produtos através da força necessária para o cisalhamento (resposta).
- As variáveis explicativas são: 1) formas do snack (qualitativa nominal), 2) semana na qual ocorreu a medição (quantitativa)
- Os dados referentes a esta variável estão disponíveis no arquivo *snack.txt*.
- Veja também [Paula \(2024\)](#).


## Medidas resumo por formas de snack

snack	média	dp	var.	cv (%)	ca	curt	min	max
A	66,20	18,71	349,97	28,26	0,21	2,68	29,02	118,83
B	55,29	13,14	172,73	23,77	0,37	2,44	30,29	87,08
C	61,63	19,60	384,21	31,80	0,94	3,95	30,06	132,62
D	51,03	10,96	120,13	21,48	0,81	4,33	29,48	95,95
E	50,26	11,40	130,00	22,69	0,92	3,94	26,69	91,17


## Medidas resumo pelas semanas

semana	média	dp	var.	cv (%)	ca	curt	min	max
2	50,95	13,12	172,22	25,76	0,65	2,90	26,69	86,32
4	44,66	9,76	95,22	21,85	1,86	7,06	32,73	82,19
6	50,08	15,97	255,00	31,88	1,42	4,51	29,48	101,15
8	55,57	16,28	265,06	29,30	0,71	2,91	30,06	104,70
10	60,15	14,72	216,65	24,47	1,01	4,02	32,89	104,24
12	57,84	13,61	185,26	23,53	0,74	3,64	30,91	99,90
14	71,57	20,17	406,76	28,18	0,52	3,56	29,02	132,62
16	65,18	16,95	287,36	26,01	1,09	3,78	40,31	120,20
18	60,37	10,25	105,03	16,97	0,80	3,16	42,80	87,84
20	52,46	12,58	158,37	23,99	0,70	3,32	30,09	91,17


# Gráficos de perfis médios (amostrais)




# Variâncias amostrais




# Coeficientes de variação amostrais





# Coefficientes de assimetria amostrais




# Coeficientes de curtose amostrais



## Box plots por snack e semana



## Box plots por snack $\times$ semana



# Modelagem

## ■ Modelo 1

$$Y_{ijk} \stackrel{ind.}{\sim} \text{gama}(\mu_{ijk}, \phi)$$

$$\ln \mu_{ijk} = \alpha + \beta_i + (\gamma + \gamma_i) x_{ijk} + (\delta + \delta_i) x_{ijk}^2$$

$$\beta_1 = \gamma_1 = \delta_1 = 0$$

$$i = 1(A), 2(B), 3(C), 4(D), 5(E)(\text{snack}),$$





$$j = 1(2), 2(4), 3(6), 4(8), 5(10), 6(12), 7(14), 8(16), 9(18), \\ 10(20)(\text{semana})$$

$$k = 1, 2, \dots, 15$$


# Modelagem

- $Y_{ijk}$ : força de cisalhamento relativa à unidade experimental (UE)  $k$ , do tipo de snack  $i$ , no índice da semana  $j$ .
- $x_{ijk} = x_{ijk}^* - 2$ : em que  $x_{ijk}^*$  é a semana (2,4,...,20) relativa à unidade experimental (UE)  $k$ , do tipo de snack  $i$ , no índice da semana  $j$ .
- Exercício: obter interpretações para os parâmetros e/ou funções deles.


# Gráficos de diagnóstico: modelo 1



# Envelope para os resíduos: modelo 1



# Worm plot para os resíduos: modelo 1



# Comentários

- O modelo não se ajustou bem (heterocedastidade do RCD e uma certa tendência no RQ), apesar do desvio indicar um bom ajuste ( $p = 0,2820$ ) e o TSW indicar normalidade do RCD ( $p=0,0976$ ), assim como o gráfico de envelopes.
- Resultados para  $\phi$ :  $18,74(0,96)$   $[16,86; 20,62]$ .
- Esses resultados indicam que um modelo (gama) com dispersão (precisão) variável, possa ser apropriado (melhor do que o modelo de precisão não variável).
- As estimativas indicam que os efeitos quadráticos não são significativos.

# Estimativas





Par.	Est.	EP	IC(95%)	Estat. $Z_t$	p-valor
$\alpha$	4,023	0,047	[3,931 ; 4,115]	85,786	< 0,0001
$\beta_2$	-0,203	0,066	[-0,333 ; -0,073]	-3,057	0,0022
$\beta_3$	-0,198	0,066	[-0,328 ; -0,068]	-2,979	0,0029
$\beta_4$	-0,329	0,066	[-0,459 ; -0,199]	-4,961	< 0,0001
$\beta_5$	-0,394	0,066	[-0,524 ; -0,264]	-5,936	< 0,0001
$\gamma$	0,053	0,012	[0,029 ; 0,077]	4,354	< 0,0001
$\delta$	-0,003	0,001	[-0,004 ; -0,001]	-4,176	< 0,0001
$\gamma_2$	-0,012	0,017	[-0,045 ; 0,022]	-0,685	0,4931
$\gamma_3$	0,017	0,017	[-0,017 ; 0,050]	0,977	0,3284
$\gamma_4$	<-0,001	0,017	[-0,034 ; 0,033]	-0,028	0,9773
$\gamma_5$	0,002	0,017	[-0,031 ; 0,036]	0,141	0,8879
$\delta_2$	0,001	0,001	[-0,001 ; 0,003]	1,225	0,2205
$\delta_3$	< - 0,001	0,001	[-0,002 ; 0,002]	-0,281	0,7783
$\delta_4$	0,001	0,001	[-0,001 ; 0,002]	0,678	0,4980
$\delta_5$	0,001	0,001	[-0,001 ; 0,003]	0,872	0,3832

# Modelagem





## ■ Modelo 2

$$Y_{ijk} \stackrel{ind.}{\sim} \text{gama}(\mu_{ijk}, \phi_{ijk}^{-1})$$
$$\ln \mu_{ijk} = \alpha^{(\mu)} + \beta_i^{(\mu)} + (\gamma^{(\mu)} + \gamma_i^{(\mu)}) x_{ijk} + (\delta^{(\mu)} + \delta_i^{(\mu)}) x_{ijk}^2$$
$$\ln \phi_{ijk} = \alpha^{(\phi)} + \beta_i^{(\phi)} + (\gamma^{(\phi)} + \gamma_i^{(\phi)}) x_{ijk} + (\delta^{(\phi)} + \delta_i^{(\phi)}) x_{ijk}^2$$
$$\beta_1^{(\mu)} = \gamma_1^{(\mu)} = \delta_1^{(\mu)} = \beta_1^{(\phi)} = \gamma_1^{(\phi)} = \delta_1^{(\phi)} = 0$$
$$i = 1(A), 2(B), 3(C), 4(D), 5(E)(\text{snack}),$$
$$j = 1(2), 2(4), 3(6), 4(8), 5(10), 6(12), 7(14), 8(16), 9(18),$$
$$10(20)(\text{semana})$$
$$k = 1, 2, \dots, 15$$


## Gráficos de diagnóstico (média): modelo 2




# Gráficos de diagnóstico (dispersão): modelo 2




## Envelope para os resíduos (média): modelo 2



## Envelope para os resíduos (precisão): modelo 2



## Worm plot para os resíduos: modelo 2



# Estimativas ( $\mu$ )

Par.	Est.	EP	IC(95%)	Estat. $Z_t$	p-valor
$\alpha$	4,015	0,052	[3,912;4,117]	76,710	< 0,0001
$\beta_2$	-0,309	0,089	[-0,483;-0,134]	-3,466	0,0006
$\beta_3$	-0,223	0,086	[-0,391;-0,055]	-2,599	0,0095
$\beta_4$	-0,481	0,090	[-0,657;-0,306]	-5,372	< 0,0001
$\beta_5$	-0,387	0,067	[-0,519;-0,256]	-5,779	< 0,0001
$\gamma$	0,055	0,013	[0,029;0,081]	4,184	< 0,0001
$\delta$	-0,003	0,001	[-0,004;-0,001]	-4,052	0,0001
$\gamma_2$	0,011	0,020	[-0,029;0,050]	0,529	0,5969
$\gamma_3$	0,024	0,020	[-0,015;0,064]	1,196	0,2322
$\gamma_4$	0,036	0,020	[-0,003;0,074]	1,828	0,0679
$\gamma_5$	0,001	0,017	[-0,033;0,034]	0,038	0,9694
$\delta_2$	0,000	0,001	[-0,002;0,002]	0,190	0,8497
$\delta_3$	-0,001	0,001	[-0,003;0,001]	-0,614	0,5396
$\delta_4$	-0,001	0,001	[-0,003;0,001]	-1,092	0,2754
$\delta_5$	0,001	0,001	[-0,001;0,003]	0,983	0,3260


# Estimativas ( $\phi$ )

Par.	Est.	EP	IC(95%)	Estat. $Z_t$	p-valor
$\alpha$	-2,782	0,284	[-3,339;-2,226]	-9,799	< 0,0001
$\beta_2$	0,429	0,401	[-0,357;1,215]	1,069	0,2850
$\beta_3$	0,203	0,401	[-0,583;0,990]	0,507	0,6123
$\beta_4$	0,218	0,402	[-0,570;1,005]	0,542	0,5880
$\beta_5$	-1,246	0,403	[-2,036;-0,456]	-3,090	0,0020
$\gamma$	0,080	0,073	[-0,063;0,224]	1,096	0,2730
$\delta$	-0,004	0,004	[-0,012;0,003]	-1,143	0,2529
$\gamma_2$	-0,256	0,104	[-0,460;-0,052]	-2,464	0,0137
$\gamma_3$	-0,031	0,104	[-0,235;0,172]	-0,302	0,7626
$\gamma_4$	-0,240	0,104	[-0,444;-0,036]	-2,306	0,0211
$\gamma_5$	0,021	0,104	[-0,183;0,225]	0,200	0,8418
$\delta_2$	0,012	0,006	[0,001;0,023]	2,230	0,0258
$\delta_3$	0,001	0,006	[-0,010;0,012]	0,132	0,8951
$\delta_4$	0,010	0,006	[-0,001;0,021]	1,769	0,0769
$\delta_5$	0,001	0,006	[-0,010;0,012]	0,183	0,8551


# Comentários

- Ajustou-se vários modelos reduzidos (retirando-se parâmetros tanto relativos à  $\mu$  quanto à  $\phi$  não significativos).
- Em todos os casos o ajuste piorou (tendo, em muitos casos, ficando ruim) em termos de resíduos, predição e critérios de informação.
- Portanto, optou-se por utilizar o modelo (duplo) inicial, que mostrou um ajuste muito bom (resíduos e predição).
- A seguir, comparemos as médias observadas com as previstas pelo modelo em questão. Em geral, as previsões pontuais e intervalares foram muito boas.
- Exercício: fazer uma análise de influência dos pontos destacados.


# Previsão para as médias




# Previsão para as médias




# Previsão para as médias



# Previsão para as médias



# Previsão para as médias



# Análise de influência

