

# Introdução aos modelos lineares mistos

Prof. Caio Azevedo

# Introdução

- Os dados longitudinais podem ser classificados como
  - Em relação às condições de avaliação: regulares - quando o intervalo entre duas medidas consecutivas é constante; irregulares - caso contrário (determinação da escolha da estrutura de covariância).
  - Quanto ao planejamento: balanceados - quando as medidas são obtidas nos mesmos instantes de avaliação em todas as unidades amostrais; não balanceados - caso contrário (estimação dos parâmetros).
  - Em relação as observações: completos - quando não há observações perdidas ou dados omissos (por alguma razão); incompletos - caso contrário (estimação dos parâmetros).

## Exemplo 15: Concentração de bilirrubina em recém-nascidos saudáveis

- Os dados correspondem a um estudo realizado na Escola Paulista de Medicina (UNIFESP), em que foi medida a concentração de bilirrubina ( $\mu$  mol/L) em 89 recém-nascidos a termo (gestação entre 37 e 42 semanas) saudáveis em aleitamento materno durante 1, 2, 3, 4, 5, 6, 8, 10 e 12 dias após o nascimento.
- O objetivo era explicar a variação da concentração de bilirrubina em função da idade.

## Exemplo 15: cont.

- A bilirrubina é uma substância amarelada encontrada na bile, que permanece no plasma sanguíneo até ser eliminada na urina. Quanto mais bilirrubina eliminada na urina, mais amarela ela se torna. Excesso de bilirrubina (hiperbilirrubinemia) pode indicar problemas no fígado, baço, nos rins ou na vesícula biliar.
- Estudo irregular, balanceado e completo (89 observações para cada condição de avaliação e 9 por indivíduo).

## Banco de dados (multivariado)

RN	Dia								
	1	2	3	4	5	6	8	10	12
1	2,70	0,40	0,00	0,50	0,60	0,00	0,00	0,50	0,80
2	4,50	5,50	3,90	2,70	2,90	2,00	1,50	1,30	1,70
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
87	3,60	6,60	9,90	8,80	11,50	12,00	12,00	11,30	9,70
88	3,60	3,70	2,80	2,00	1,50	0,00	1,20	1,60	0,50
89	2,60	1,40	1,30	1,00	1,60	0,40	0,00	0,30	0,00


# Banco de dados (longitudinal)

RN	Dia	Bilirrubina
1	1	2,70
1	2	0,40
⋮	⋮	⋮
1	12	0,80
⋮	⋮	⋮
89	1	2,60
89	2	1,40
⋮	⋮	⋮
89	12	0,60

## Medidas resumo


Dia	Média	DP	Var.	CV(%)	Min.	Med.	Máximo	n
1	4,44	1,99	3,98	44,95	0,00	4,50	9,10	89
2	5,76	2,92	8,50	50,64	0,00	6,10	11,40	89
3	5,87	3,86	14,92	65,77	0,00	5,80	14,60	89
4	5,59	4,12	16,97	73,76	0,00	4,60	14,30	89
5	5,02	4,02	16,20	80,17	0,00	4,10	14,80	89
6	4,60	3,90	15,25	84,89	0,00	3,30	13,10	89
8	3,99	3,70	13,70	92,73	0,00	2,80	13,50	89
10	3,59	3,39	11,50	94,56	0,00	2,70	13,60	89
12	3,12	2,97	8,85	95,39	0,00	2,10	12,40	89

# Perfil médio







# Perfis individuais: amostra completa




# Perfis individuais: amostra completa e perfil médio




## Perfis individuais: 20 RN selecionados aleatoriamente




## Cont.: 20 RN selecionados aleatoriamente e perfil médio




# Perfis individuais centrados: amostra completa



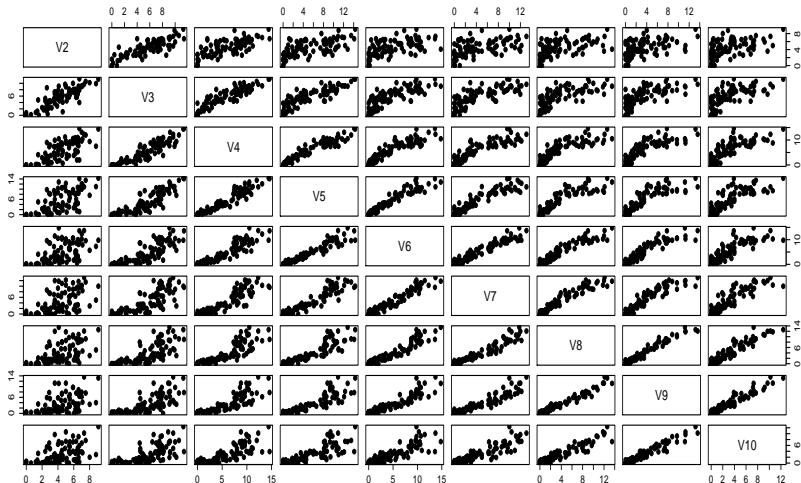
## Cont.: 20 RN selecionados aleatoriamente



# Box plot



# Matriz de diagramas de dispersão







# Variâncias (diagonal), correlações (acima) e covariâncias (abaixo)

	Dia								
Dia	1	2	3	4	5	6	8	10	12
1	3,98	0,82	0,71	0,63	0,55	0,52	0,51	0,50	0,48
2	4,76	8,51	0,90	0,86	0,79	0,76	0,72	0,70	0,68
3	5,47	10,09	14,93	0,95	0,91	0,88	0,85	0,82	0,78
4	5,16	10,32	15,06	16,97	0,95	0,93	0,88	0,85	0,81
5	4,42	9,32	14,09	15,71	16,20	0,96	0,94	0,91	0,85
6	4,05	8,62	13,27	14,92	15,06	15,25	0,96	0,93	0,88
8	3,78	7,79	12,11	13,49	14,01	13,81	13,70	0,98	0,94
10	3,37	6,95	10,79	11,94	12,47	12,28	12,25	11,50	0,96
12	2,87	5,88	9,02	9,90	10,16	10,26	10,31	9,68	8,85


# Variâncias em cada condição



# Variâncias em cada condição com intervalos de confiança








# Gráficos dos perfis das linhas da matriz de correlações







lag: distância entre as condições de avaliação



# Gráficos de Envelope



# Gráficos de Envelope (continuação)



# Variograma

- Para um processo estocástico estacionário  $\{Y(t), t \in \mathcal{R}\}$ , ou seja,  $\mathcal{E}(Y(t)) = \mathcal{E}(Y(t - u))$  e  $\mathcal{V}(Y) = \mathcal{V}(Y(t - u))$ ,  $\forall t \in \mathcal{R}$  e  $u \in \mathcal{R}^+$ , o variograma é definido como:

$$g(u) = \frac{1}{2} \mathcal{E} \left[ (Y(t) - Y(t - u))^2 \right]$$

- Definindo,  $\gamma(u) = \text{Cov}(Y(t), Y(t - u))$ , temos que  $g(u) = \gamma(0) - \gamma(u) = \sigma^2(1 - \rho(u))$ . (exercício)
- Para estimar o variograma é útil considerar as observações padronizadas  $\Delta_{ij} = \frac{y_{ij} - \bar{y}_j}{s_j}$  (para se obter estacionariedade).

## Variograma (Cont.)

- Os pontos componentes do variograma amostral são calculados a partir de duas observações da mesma unidade amostral como  $v_{ijk} = \frac{1}{2}(\Delta_{ij} - \Delta_{ik})^2$ .
- Plota-se  $v_{ijk}$  em função de  $u_{ijk} = |t_{ij} - t_{ik}|$  (distância entre as condições de avaliação, também conhecido como “lag”).
- Estima-se  $\sigma^2$  através de


$$\hat{\sigma}^2 = \frac{1}{2Nk} \sum_{i \neq l} \sum_{j,k} \frac{1}{2} (\Delta_{ij} - \Delta_{lk})^2 = \frac{1}{2Nk} \sum_{i \neq l} \sum_{j,k} v_{ijkl},$$



## Variograma (Cont.)

- em que  $k$  é a quantidade de termos de  $\sum_{j,k}$ ,  $v_{ijkl} = \frac{1}{2}(\Delta_{ij} - \Delta_{lk})^2$  e  $N$  é o número de pares de observações obtidas em unidades experimentais diferentes.
- Como o processo é estacionário e sob independência entre as observações de diferentes indivíduos, temos que  $\hat{\sigma}^2$  é um estimador não viciado de  $\sigma^2$ .
- Como  $\rho(u) = 1 - \frac{g(u)}{\sigma^2}$ , quanto mais próximos de  $\hat{\sigma}^2$  forem os valores de  $\hat{g}(u)$ , menor o valor da correlação para a defasagem  $u$ .

# Variograma



# Modelagem para os dados (sob independência)

$$Y_{ij} = \beta_0 + (x_{ij} - 1)\beta_1 + \xi_{ij},$$

$j = 1, 2, \dots, 89$ , (indivíduo),  $i = 1, \dots, 9$  (dia (condição de avaliação)),

- $Y_{ij}$  : concentração de bilirrubina da criança  $j$  no dia  $i$ .
- $x_{ij}$  : dia correspondente ao instante  $j$  em que fora medida a concentração de bilirrubina da criança  $i$
- $\beta_0$  : concentração de bilirrubina esperada para crianças com 1 dia de vida.
- $\beta_1$  : incremento (positivo ou negativo) na concentração esperada de bilirrubina para o aumento em um dia na idade da criança.
- $\xi_{ij} \stackrel{i.i.d}{\sim} N(0, \sigma^2)$

# Modelagem alternativa

$$Y_{ij} = \beta_0 + (x_{ij} - 1)\beta_1 + b_j + \xi_{ij},$$

$j = 1, 2, \dots, 89$ , (indivíduo),  $i = 1, \dots, 9$  (dia (condição de avaliação)),

- Admita que:  $b_j \perp \xi_{ij}, \forall i, j$ ,  $b_j \stackrel{i.i.d.}{\sim} N(0, \psi)$  e  $Cov(\xi_{ij}, \xi_{i'j}) = \rho$  e  $\mathcal{V}(\xi_{ij}) = \sigma^2$ ,  $\xi_j \stackrel{ind.}{\sim} N(\mathbf{0}, \Sigma_j)$ .

- Assim,

- $$Cov(Y_{ij}, Y_{i'j'}) = \begin{cases} 0, & \text{se } j \neq j' \\ \psi + \sigma^2, & \text{se } i = i' \text{ e } j = j' \\ \psi + \rho, & \text{se } i \neq i', \text{ e } j = j' \end{cases}$$

- Se  $\rho = 0$ , teremos o chamado modelo de independência condicional, pois, condicionado à  $b_j$ , as observações serão independentes.

## Cont.

- $x_{ij}$  : é o dia (1,2,3,4,5,6,8,10,12), em que a concentração de bilirrubina, correspondente ao instante  $i$ , foi medida no indivíduo  $j$ .
- $Y_{ij}$  : é a concentração de bilirrubina no instante  $i$  do indivíduo  $j$ .
- $E(Y_{ij}|x_{ij} = 1) = \beta_0$  é a concentração esperada de bilirrubina no primeiro dia de vida (perfil marginal).
- $\beta_1$  : é o incremento na concentração esperada de bilirrubina no intervalo de um dia.
- No entanto,  $E(Y_{ij}|x_{ij} = 1, b_j) = \beta_0 + b_j$  (perfil condicional).

## Cont.

$$Y_{ij} = \beta_0 + (x_{ij} - 1)\beta_1 + b_j + \xi_{ij},$$

$j = 1, 2, \dots, 89$ , (indivíduo),  $i = 1, \dots, 9$  (dia (condição de avaliação)),

- Admita agora que:  $b_j \perp \xi_{ij}, \forall i, j$ ,  $b_j \stackrel{i.i.d.}{\sim} N(0, \psi)$  e

$$\text{Corr}(\xi_{ij}, \xi_{i'j'}) = h[d(\mathbf{t}_{ij}, \mathbf{t}_{i'j}), \boldsymbol{\varrho}] \text{ e } \mathcal{V}(\xi_{ij}) = \sigma^2 \lambda^2(\boldsymbol{\delta}, \mathbf{v}_{ij}), \boldsymbol{\xi}_j \stackrel{ind.}{\sim} N(\mathbf{0}, \boldsymbol{\Sigma}_j).$$

- Assim,

$$\text{Cov}(Y_{ij}, Y_{i'j'}) = \begin{cases} 0, & \text{se } j \neq j' \\ \psi + \sigma^2 \lambda^2(\boldsymbol{\delta}, \mathbf{v}_{ij}), & \text{se } i = i' \text{ e } j = j' \\ \psi + \sigma^2 h[d(\mathbf{t}_{ij}, \mathbf{t}_{i'j}), \boldsymbol{\varrho}], & \text{se } i \neq i', \text{ e } j = j' \end{cases}$$

## Cont.

- Se considerarmos  $\xi_{ij} \stackrel{i.i.d.}{\sim} N(0, \sigma^2)$  e  $b_j \equiv 0$ , ou de modo equivalente ( $\psi \equiv 0$ ), teremos o modelo de regressão linear tradicional (homocedástico e com as observações independentes).
- Entretanto, temos indícios de que é mais apropriado considerar alguma estrutura de dependência entre os erros (em relação às medidas feitas no mesmo indivíduo) bem como considerar perfis (individuais) diferentes.

# Modelo normal linear misto

$$\mathbf{Y}_{j(k_j \times 1)} = \mathbf{X}_{j(k_j \times p)}\boldsymbol{\beta}_{(p \times 1)} + \mathbf{Z}_{j(k_j \times q)}\mathbf{b}_{j(q \times 1)} + \boldsymbol{\xi}_{j(k_j \times 1)} \quad (1)$$

,  $j = 1, \dots, n$  (indivíduo)

- $\mathbf{Y}_j = (Y_{j1}, \dots, Y_{jk_j})'$ ,  $k_j$ : número de condições de avaliação em que o indivíduo  $j$  é avaliado.
- $\mathbf{X}_j$ : matriz de planejamento associada aos efeitos fixos para o indivíduo  $j$  (não-aleatória e conhecida).
- $\mathbf{Z}_j$ : matriz de planejamento associada aos efeitos aleatórios para o indivíduo  $j$  (não-aleatória e conhecida).
- $\boldsymbol{\beta}$ : vetor de efeitos fixos (não-aleatório e desconhecido).
- $\mathbf{b}_j$ : vetor de efeitos aleatórios associado ao indivíduo  $j$  (aleatório e desconhecido),  $\mathbf{b}_j \stackrel{ind.}{\sim} N(\mathbf{0}, \boldsymbol{\Psi})$ .
- $\boldsymbol{\xi}_j$ : vetor de erros associado ao indivíduo  $j$ ,  $\boldsymbol{\xi}_j \stackrel{ind.}{\sim} N(\mathbf{0}, \boldsymbol{\Sigma}_j)$ ,  $\mathbf{b}_j \perp \boldsymbol{\xi}_j, \forall i$ .



# Cont.

- Efeitos fixos: modelam características populacionais.
- Efeitos aleatórios: modelam características individuais.

## Voltando ao Exemplo 15

$$\mathbf{Y}_j = \begin{bmatrix} Y_{1j} \\ Y_{2j} \\ \vdots \\ Y_{9j} \end{bmatrix}; \mathbf{X}_j = \begin{bmatrix} 1 & 0 \\ 1 & 1 \\ 1 & 2 \\ \vdots & \vdots \\ 1 & 11 \end{bmatrix}; \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}; \mathbf{Z}_j = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}; \mathbf{b}_j = b_j;$$
$$\boldsymbol{\xi}_j = \begin{bmatrix} \xi_{1j} \\ \xi_{2j} \\ \vdots \\ \xi_{9j} \end{bmatrix}$$

## Cont.

$$\mathbf{Y} = \begin{bmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_{89} \end{bmatrix}; \mathbf{X} = \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \\ \vdots \\ \mathbf{X}_{89} \end{bmatrix}; \boldsymbol{\xi} = \begin{bmatrix} \boldsymbol{\xi}_1 \\ \boldsymbol{\xi}_2 \\ \vdots \\ \boldsymbol{\xi}_{89} \end{bmatrix}$$

$$\mathbf{Z} = \begin{bmatrix} \mathbf{Z}_1 & 0 & \dots & 0 \\ 0 & \mathbf{Z}_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mathbf{Z}_{89} \end{bmatrix}$$

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b} + \boldsymbol{\xi}, \mathbf{b} = (\mathbf{b}_1, \dots, \mathbf{b}_n)'$$

## Algumas propriedades do modelo

- $\mathcal{E}(\mathbf{Y}_j|\mathbf{b}_j) = \mathbf{X}_j\boldsymbol{\beta} + \mathbf{Z}_j\mathbf{b}_j$ .
- $\mathcal{E}(\mathbf{Y}_j) = \mathbf{X}_j\boldsymbol{\beta}$ .
- $\text{Cov}(\mathbf{Y}_j|\mathbf{b}_j) = \boldsymbol{\Sigma}_j$ .
- $\text{Cov}(\mathbf{Y}_j) = \mathbf{V}_j = \mathbf{Z}_j\boldsymbol{\Psi}\mathbf{Z}_j' + \boldsymbol{\Sigma}_j$ .
- $\mathbf{Y}_j|\mathbf{b}_j \sim N_{k_j}(\mathbf{X}_j\boldsymbol{\beta} + \mathbf{Z}_j\mathbf{b}_j, \boldsymbol{\Sigma}_j)$ . Além disso, como

$$\mathbf{Y}_j|\mathbf{b}_j \sim N(\mathbf{X}_j\boldsymbol{\beta} + \mathbf{Z}_j\mathbf{b}_j, \boldsymbol{\Sigma}_j)$$

$$\mathbf{b}_j \sim N(\mathbf{0}, \boldsymbol{\Psi})$$

portanto

$$\mathbf{Y}_j \sim N_{k_j}(\mathbf{X}_j\boldsymbol{\beta}, \mathbf{Z}_j\boldsymbol{\Psi}\mathbf{Z}_j' + \boldsymbol{\Sigma}_j)$$

# Estruturas para as matrizes de covariância

- Diferentes escolhas para  $\Psi$  e  $\Sigma_j$  induzem diferentes estruturas de dependência para o vetor de respostas.
- Por exemplo, quando  $\Sigma_j = \sigma^2 I_{k_j}$ , tem-se o modelo de independência condicional homocedástico. Modelos de independência condicional são bastante considerados em psicometria (Teoria de Resposta ao item).
- Por outro lado, quando  $\Sigma_j = \sigma^2 I_{k_j}$  e  $\Psi \equiv \mathbf{0}$ , tem-se o modelo de regressão linear usual (homocedástico e com as observações independentes).
- Dependendo da importância dos efeitos aleatórios para o estudo, podemos pensar em diferentes estruturas de covariância para eles.

# Modelos para a estrutura de covariância

- Podemos, essencialmente, escolher para  $\Psi$  e  $\Sigma_j$  alguma das opções já vistas anteriormente.
- A covariâncias do vetor de resposta será, portanto, uma combinação das matrizes escolhidas para os erros e para os efeitos aleatórios.
- Naturalmente, as escolhas são limitadas pelo recurso computacional a ser utilizado.
- Em geral a matriz  $\Psi$  é assumida ser não estruturada ou diagonal.

# Estimação

- Sob a ótica frequentista, em geral, trabalha-se com a distribuição marginal de  $\mathbf{Y}_j$  em relação à  $\mathbf{b}_j$ , ou seja  $\mathbf{Y}_j \sim N(\mathbf{X}_j\boldsymbol{\beta}, \mathbf{Z}_j\boldsymbol{\Psi}\mathbf{Z}_j' + \boldsymbol{\Sigma}_j)$
- Alternativa: algoritmo EM utilizando a distribuição conjunta de  $(\mathbf{Y}, \mathbf{b})$ .
- Também existem métodos Bayesianos.
- Suposição :  $\boldsymbol{\Sigma}_j = g(\boldsymbol{\theta}_1)$  e  $\boldsymbol{\Psi} = h(\boldsymbol{\theta}_2)$  de modo que  $\boldsymbol{\theta}_1$  e  $\boldsymbol{\theta}_2$  não possuem componentes comuns.

## Cont.

- Log-verossimilhança (marginal) para  $n$  observações:

$$\begin{aligned}l(\boldsymbol{\beta}, \boldsymbol{\theta}) &= -\frac{1}{2} \ln(2\pi) \sum_{j=1}^n k_j - \frac{1}{2} \sum_{j=1}^n \ln |\mathbf{V}_j| \\ &+ -\frac{1}{2} \sum_{j=1}^n (\mathbf{Y}_j - \mathbf{X}_j \boldsymbol{\beta})' \mathbf{V}_j^{-1} (\mathbf{Y}_j - \mathbf{X}_j \boldsymbol{\beta})\end{aligned}\quad (2)$$

$$\mathbf{V}_i \equiv \mathbf{V}_i(\boldsymbol{\theta}) = \mathbf{Z}_j \boldsymbol{\Psi}(\boldsymbol{\theta}_2) \mathbf{Z}_j' + \boldsymbol{\Sigma}_j(\boldsymbol{\theta}_1), \quad \boldsymbol{\theta} = (\boldsymbol{\theta}'_1, \boldsymbol{\theta}'_2)'$$

- Se  $\boldsymbol{\theta}$  for conhecido, o estimador de MV (que corresponde ao estimador de MQG) de  $\boldsymbol{\beta}$  é dado por:

$$\hat{\boldsymbol{\beta}} = \left( \sum_{j=1}^n \mathbf{X}_j' \mathbf{V}_j^{-1} \mathbf{X}_j \right)^{-1} \left( \sum_{j=1}^n \mathbf{X}_j' \mathbf{V}_j^{-1} \mathbf{Y}_j \right)\quad (3)$$



## Cont.

- Para estimar  $(\theta)$ , substituímos (3) em (2), obtendo uma log-verossimilhança perfilada:

$$\begin{aligned} l(\theta) &= -\frac{1}{2} \ln(2\pi) \sum_{j=1}^n k_j - \frac{1}{2} \sum_{j=1}^n \ln |\mathbf{V}_j| \\ &\quad - \frac{1}{2} \sum_{j=1}^n (\mathbf{Y}_j - \mathbf{X}_j \hat{\beta})' \mathbf{V}_j^{-1} (\mathbf{Y}_j - \mathbf{X}_j \hat{\beta}) \end{aligned} \quad (4)$$

- A maximização da log-verossimilhança (4) tem de ser feita através de métodos iterativos como os algoritmos de Newton-Raphson, Escore de Fisher, Gauss-Newton, BFGS.
- Uma vez que tais estimativas forem obtidas, as inserimos em (3).

## Cont.

- As distribuições assintóticas dos estimadores podem ser obtidas através do TCL.
- Os erros-padrão assintóticos podem ser obtidos através das inversas das informações de Fisher para (para  $\theta$ ) e através de uma fórmula analítica (para  $\beta$ ).
- Os estimadores de MV para  $\beta$  são não viesados, mas o mesmo não acontece com os estimadores de MV de  $\theta$ .
- Alternativa: estimadores de MV restritos (MVR) (também chamados de estimadores MV residuais).

## Algoritmo (estimação por MV)

- Estima-se  $\theta$  através de algum algoritmo de maximização conveniente (NR, RF, Gauss-Newton, BFGS), resolvendo-se o sistema de equações dado por:

$$\begin{aligned} S(\theta_k) &= \frac{\partial l(\theta)}{\partial \theta_k} = -\frac{1}{2} \sum_{j=1}^n \frac{\partial \ln |\mathbf{V}_j|}{\partial \theta_k} - \frac{1}{2} \sum_{j=1}^n \text{tr} \left[ \frac{\partial \mathbf{V}_j^{-1}}{\partial \theta_k} (\mathbf{Y}_j - \mathbf{X}_j \hat{\beta}) (\mathbf{Y}_j - \mathbf{X}_j \hat{\beta})' \right. \\ &+ \left. \mathbf{V}_j^{-1} \frac{\partial (\mathbf{Y}_j - \mathbf{X}_j \hat{\beta}) (\mathbf{Y}_j - \mathbf{X}_j \hat{\beta})'}{\partial \theta_k} \right] = -\frac{1}{2} \sum_{j=1}^n \text{tr} \left[ \mathbf{V}_j^{-1} \frac{\partial \mathbf{V}_j}{\partial \theta_k} \right] \\ &- \frac{1}{2} \sum_{j=1}^n \text{tr} \left[ \frac{\partial \mathbf{V}_j^{-1}}{\partial \theta_k} (\mathbf{Y}_j - \mathbf{X}_j \hat{\beta}) (\mathbf{Y}_j - \mathbf{X}_j \hat{\beta})' \right. \\ &+ \left. \mathbf{V}_j^{-1} \frac{\partial (\mathbf{Y}_j - \mathbf{X}_j \hat{\beta}) (\mathbf{Y}_j - \mathbf{X}_j \hat{\beta})'}{\partial \theta_k} \right] \end{aligned}$$

## Algoritmo (estimação por MV)

- A notação  $\frac{\partial \mathbf{V}_j}{\partial \boldsymbol{\theta}}$  representa a derivada de  $\mathbf{V}_j$  com relação à cada componente de  $\boldsymbol{\theta}$  o que resulta, para cada componente, numa matriz.
- Com as estimativas de  $\boldsymbol{\theta}$ , digamos  $\tilde{\boldsymbol{\theta}}$ , obtem-se as estimativas de  $\boldsymbol{\beta}$ , através de:

$$\tilde{\boldsymbol{\beta}} = \left( \sum_{j=1}^n \mathbf{x}'_j \mathbf{V}_j(\tilde{\boldsymbol{\theta}})^{-1} \mathbf{x}_j \right)^{-1} \left( \sum_{j=1}^n \mathbf{x}'_j \mathbf{V}_j^{-1}(\tilde{\boldsymbol{\theta}}) \mathbf{y}_j \right)$$

- A matriz de covariâncias de  $\hat{\boldsymbol{\beta}}$  é dada por  $\boldsymbol{\Sigma}_{\boldsymbol{\beta}} = \left( \sum_{j=1}^n \mathbf{x}'_j \mathbf{V}_j(\boldsymbol{\theta})^{-1} \mathbf{x}_j \right)^{-1}$  e uma estimativa é dada por:  $\tilde{\boldsymbol{\Sigma}}_{\boldsymbol{\beta}} = \left( \sum_{j=1}^n \mathbf{x}'_j \mathbf{V}_j(\tilde{\boldsymbol{\theta}})^{-1} \mathbf{x}_j \right)^{-1}$ .

- Para o estimador  $\hat{\theta}$  uma aproximação da matriz de covariâncias pode ser obtida através da inversa da matriz  $-\mathbf{H}(\theta) = -\frac{\partial l(\theta)}{\partial \theta \partial \theta'}$  e uma estimativa é dada pela inversa de:  $-\mathbf{H}(\tilde{\theta}) = -\frac{\partial l(\theta)}{\partial \theta \partial \theta'} \Big|_{\theta=\tilde{\theta}}$ , respectivamente  $\boldsymbol{\Sigma}_{\theta} = -\mathbf{H}(\theta)^{-1}$  e  $\tilde{\boldsymbol{\Sigma}}_{\theta} = -\mathbf{H}(\tilde{\theta})^{-1}$ .
- Os erros-padrão dos estimadores  $\hat{\beta}$  e  $\hat{\theta}$  correspondem à raiz quadrada dos elementos da diagonal principal das respectivas matrizes de covariância.

- A distribuição dos estimadores (exata ou assintótica) pode ser obtida através de um dos seguintes métodos:
  - Convergência em distribuição dos estimadores de máxima verossimilhança ( $\hat{\beta} \approx N_p(\beta, \Sigma_\beta)$  e  $\hat{\theta} \approx N_r(\theta, \Sigma_\theta)$ ), para  $n$  suficientemente grande.
  - Métodos de reamostragem.
  - Método Delta (para funções, não lineares, dos parâmetros, que sejam de interesse).

# Máxima verossimilhança restrita (ou residual)

- MVR: consiste em maximizar a verossimilhança de uma transformação ortogonal do vetor de respostas, ou seja, da verossimilhança induzida por  $\mathbf{Y}_j^* = \mathbf{U}_j \mathbf{Y}_j$ ,
- Em geral,  $\mathbf{U}_j = \mathbf{I}_{k_j} - \mathbf{X}_j(\mathbf{X}_j' \mathbf{X}_j)^{-1} \mathbf{X}_j'$ .
- Assim,  $\mathbf{Y}_j^* \sim N(\mathbf{0}_{k_j}, \mathbf{U}_j \mathbf{V}_j \mathbf{U}_j')$ , em que  $\mathbf{V}_j = \text{Cov}(\mathbf{Y}_j) = \mathbf{Z}_j \boldsymbol{\Psi} \mathbf{Z}_j' + \boldsymbol{\Sigma}_j$ .
- Os estimadores de MVR de  $\beta$  são não viesados enquanto que o viés do estimadores de MVR de  $\theta$  são menores em comparação com os estimadores de MV.
- O nome “residual” vem do fato de que a matriz  $\mathbf{U}_j$  gera os resíduos no ajuste por mínimos quadrados ordinários.

- A log-verossimilhança residual ou restrita é dada por

$$\begin{aligned}l_R(\boldsymbol{\theta}) &= -\frac{1}{2} \ln(2\pi) \sum_{j=1}^n k_j - \frac{1}{2} \sum_{j=1}^n \ln |\mathbf{U}_j \mathbf{V}_j \mathbf{U}_j| \\ &- \frac{1}{2} \sum_{j=1}^n (\mathbf{Y}_j^*)' \mathbf{U}_j \mathbf{V}_j^{-1} \mathbf{U}_j (\mathbf{Y}_j^*).\end{aligned}$$



## Cont.

- A log-verossimilhança residual ou restrita pode ser escrita como

$$\begin{aligned}l_R(\boldsymbol{\theta}) &= -\frac{1}{2} \ln(2\pi) \sum_{j=1}^n k_j - \frac{1}{2} \sum_{j=1}^n \ln |\mathbf{V}_j| \\ &\quad - \frac{1}{2} \sum_{j=1}^n \left( \boldsymbol{y}_j - \mathbf{x}_j \hat{\boldsymbol{\beta}} \right)' \mathbf{V}_j^{-1} \left( \boldsymbol{y}_j - \mathbf{x}_j \hat{\boldsymbol{\beta}} \right) \\ &\quad - \frac{1}{2} \ln \left| \sum_{j=1}^n \mathbf{x}_j' \mathbf{V}_j^{-1} \mathbf{x}_j \right| + \text{const.}\end{aligned}\tag{5}$$

em que  $\hat{\boldsymbol{\beta}}$  é dado em (3).

- Uma vez que os estimadores de MVR de  $\boldsymbol{\theta}$  forem obtidos, maximizando-se (5) (numericamente), os estimadores de MVR de  $\boldsymbol{\beta}$  podem ser obtidos inserindo aqueles em (3).

## Cont.

- As distribuições exatas ou assintóticas dos estimadores de MVR podem ser obtidas de modo semelhante aos dos estimadores de MV.
- Lembrem-se de que estamos lidando com um conjunto de vetores aleatórios independentes mas não identicamente distribuídos  $\mathbf{Y}_j \stackrel{ind.}{\sim} N_{k_j}(\mathbf{X}_j\boldsymbol{\beta}, \mathbf{V}_j)$ .
- TLC's que levem tal estrutura em consideração devem ser utilizados.

## Algoritmo (estimação por MVR)

- Estima-se  $\theta$  através de algum algoritmo de maximização conveniente (NR, RF, Gauss-Newton, BFGS), resolvendo-se o sistema de equações dado por:

$$\begin{aligned} S(\theta_k) &= \frac{\partial l_R(\theta)}{\partial \theta_k} = -\frac{1}{2} \sum_{j=1}^n \text{tr} \left[ \mathbf{V}_j^{-1} \frac{\partial \mathbf{V}_j}{\partial \theta_k} \right] \\ &- \frac{1}{2} \sum_{j=1}^n \text{tr} \left[ \frac{\partial \mathbf{V}_j^{-1}}{\partial \theta_k} (\mathbf{Y}_j - \mathbf{X}_j \hat{\boldsymbol{\beta}}) (\mathbf{Y}_j - \mathbf{X}_j \hat{\boldsymbol{\beta}})' \right. \\ &+ \left. \mathbf{V}_j^{-1} \frac{\partial (\mathbf{Y}_j - \mathbf{X}_j \hat{\boldsymbol{\beta}}) (\mathbf{Y}_j - \mathbf{X}_j \hat{\boldsymbol{\beta}})'}{\partial \theta_k} \right] - \frac{1}{2} \sum_{i=1}^n \text{tr} \left[ \mathbf{V}_j^{-1} \mathbf{X}_i' \mathbf{V}_j^{-1} \frac{\partial \mathbf{V}_j^{-1}}{\partial \theta_k} \mathbf{V}_j^{-1} \mathbf{X}_i \right] \end{aligned}$$

# Algoritmo (estimação por MVR)

- Com as estimativas de  $\theta$ , digamos  $\tilde{\theta}_R$ , obtem-se as estimativas de  $\beta_R$ , ou seja:

$$\tilde{\beta}_R = \left( \sum_{j=1}^n \mathbf{x}'_j \mathbf{V}_j(\tilde{\theta})^{-1} \mathbf{x}_j \right)^{-1} \left( \sum_{j=1}^n \mathbf{x}'_j \mathbf{V}_j^{-1}(\tilde{\theta}) \mathbf{y}_j \right)$$

- A matriz de covariâncias de  $\hat{\beta}_R$  é dada por  $\Sigma_{\beta_R} = \left( \sum_{j=1}^n \mathbf{x}'_j \mathbf{V}_j(\theta)^{-1} \mathbf{x}_j \right)^{-1}$  e uma estimativa é dada por:  
 $\tilde{\Sigma}_{\beta_R} = \left( \sum_{j=1}^n \mathbf{x}'_j \mathbf{V}_j(\tilde{\theta})^{-1} \mathbf{x}_j \right)^{-1}$ .

- Para o estimador  $\theta_R$  uma aproximação da matriz de covariâncias pode ser obtida através da inversa da matriz

$$\Sigma_{\theta_R} = -\mathbf{H}_R(\theta) = -\frac{\partial l_R(\theta)}{\partial \theta \partial \theta'}$$

e uma estimativa é dada pela inversa de:

$$-\mathbf{H}_R(\tilde{\theta}) = -\frac{\partial l_R(\theta)}{\partial \theta \partial \theta'} \Big|_{\theta=\tilde{\theta}}, \text{ respectivamente } \Sigma_{\theta_R} = -\mathbf{H}_R(\theta)^{-1} \text{ e}$$
$$\tilde{\Sigma}_{\theta_R} = -\mathbf{H}_R(\tilde{\theta})^{-1}.$$

- Os erros-padrão dos estimadores  $\hat{\beta}_R$  e  $\hat{\theta}_R$  correspondem à raiz quadrada dos elementos da diagonal principal das respectivas matrizes de covariância.

- A distribuição dos estimadores pode ser obtida através de um dos seguintes métodos:
  - Convergência em distribuição dos estimadores de máxima verossimilhança.
  - Métodos de reamostragem
  - Método Delta.

## Cont.

- Preditores para os efeitos aleatórios podem ser obtidos através da distribuição condicional (à posteriori), de  $\mathbf{b}_j | \mathbf{y}_j$ , ou seja

$$p(\mathbf{b}_j | \mathbf{y}_j) = \frac{p(\mathbf{y}_j | \mathbf{b}_j) p(\mathbf{b}_j)}{\int_{\mathbb{R}^q} p(\mathbf{y}_j | \mathbf{b}_j) p(\mathbf{b}_j) d\mathbf{b}}$$

a qual corresponde à

$$\mathbf{b}_j | \mathbf{y}_j \sim N_q \left( \boldsymbol{\Psi} \mathbf{Z}_j' \mathbf{V}_j^{-1} (\mathbf{y}_j - \mathbf{X}_j \boldsymbol{\beta}), (\mathbf{Z}_j \boldsymbol{\Sigma}_j^{-1} \mathbf{Z}_j' + \boldsymbol{\Psi}^{-1})^{-1} \right)$$

- Assim, um preditor para  $\mathbf{b}_j$  seria sua média condicional (à posteriori) ou seja,  $\hat{\mathbf{b}}_j = \hat{\boldsymbol{\Psi}} \mathbf{Z}_j' \hat{\mathbf{V}}_j^{-1} (\mathbf{y}_j - \mathbf{X}_j \hat{\boldsymbol{\beta}})$ , em que  $\hat{\cdot}$  denota um dos estimadores vistos anteriormente (MV ou MVR).

## Cont.

- Medida de precisão de  $\hat{\mathbf{b}}_j - \mathbf{b}_j$ ,  $\text{Cov}(\hat{\mathbf{b}}_j - \mathbf{b}_j) = \Psi - \text{Cov}(\hat{\mathbf{b}}_j)$ . Em que

$$\text{Cov}(\hat{\mathbf{b}}_j) = \Psi \mathbf{Z}'_j \left( \mathbf{V}_j^{-1} - \mathbf{V}_j \mathbf{X}_j \left( \sum_{j=1}^n \mathbf{X}'_j \mathbf{V}_j \mathbf{X}_j \right)^{-1} \mathbf{X}'_j \mathbf{W}_j \right) \mathbf{X}_j \Psi$$



# Intervalos de Confiança

- Seja  $\hat{\vartheta}$  o componente de interesse do vetor  $\hat{\beta}$  ou do vetor  $\hat{\theta}$  e  $\widehat{EP}(\hat{\vartheta})$  um estimador consistente (como aqueles apresentados) do respectivo erro-padrão.
- IC assintótico com coeficiente de confiança de  $\gamma$

$$\hat{\vartheta} \pm z_{(1+\gamma)/2} \widehat{EP}(\hat{\vartheta})$$

$$P(Z \leq z_{(1+\gamma)/2}) = \frac{1+\gamma}{2}$$

# Testes de Hipótese

- Seja  $\widehat{\Sigma}_\beta$  um estimador consistente da matriz de covariâncias de  $\widehat{\beta}$  (como aqueles apresentados).
- Desejamos testar  $H_0 : \mathbf{C}\beta = \mathbf{M}$  vs  $H_1 : \mathbf{C}\beta \neq \mathbf{M}$
- Podemos usar a seguintes estatística (do tipo Wald)

$$Q = (\mathbf{C}\widehat{\beta} - \mathbf{M})' (\mathbf{C}\widehat{\Sigma}_\beta\mathbf{C}')^{-1} (\mathbf{C}\widehat{\beta} - \mathbf{M})$$

para  $n$  suficientemente grande, temos que  $Q \sim \chi^2_{(r(\mathbf{C}),\delta)}$ ,

$$\delta = (\mathbf{C}\beta - \mathbf{M})' (\mathbf{C}\Sigma_\beta\mathbf{C}')^{-1} (\mathbf{C}\beta - \mathbf{M})$$

# Comentários

- Em relação aos testes de hipótese para  $\theta$ , podemos proceder de modo análogo ao que fizemos para  $\beta$ .
- Note, contudo, que existem três tipos de parâmetros em  $\theta$ : parâmetros de variância ( $\sigma^2$ ), de correlação ( $\rho$ ) e de covariância ( $\sigma_1$ ). Para os parâmetros de variância, faz-se necessário testes mais específicos quando  $M = 0$ .
- Para outros detalhes, veja as referências.

# Seleção de modelos: Teste da razão de verossimilhanças

- Seja  $\hat{\theta}_i$  o estimador de máxima verossimilhança obtido sob o modelo  $i$  e  $\tilde{\theta}_i$  sua respectiva estimativa.
- Denote por  $L_i(\hat{\theta}_i)$  e  $l_i(\hat{\theta}_i)$  o máximo da verossimilhança e da log-verossimilhança do modelo  $i$ , respectivamente, avaliados nos respectivos estimadores de MV, enquanto que  $L_i(\tilde{\theta}_i)$  e  $l_i(\tilde{\theta}_i)$  são os respectivos máximos avaliados nas estimativas de MV.
- No caso dos modelos mistos usa-se a log-verossimilhança marginal.

## Teste da razão de verossimilhanças (cont.)

- A estatística do TRV é dada por  $\Delta = \frac{L_1(\hat{\theta}_1)}{L_2(\hat{\theta}_2)}$ .
- Rejeita-se  $H_0$  se  $\Delta \leq \delta_c$ , em que  $\delta_c$  é um valor crítico adequado.
- Alternativamente, rejeitamos  $H_0$  se

$$\Lambda = -2\ln(\Delta) = -2 \left( l_1(\hat{\theta}_1) - l_2(\hat{\theta}_2) \right) \geq \lambda_c,$$

em que  $P(Q \geq \lambda_c) = \alpha$ ,  $Q \approx \chi^2_{(\gamma)}$  e

$\gamma =$  número de parâmetros do modelo  $M_2$  - número de parâmetros do modelo  $M_1$ .

- Nesse caso,  $p$ -valor  $\approx P(Q \geq \lambda | H_0)$ , em que  $\lambda$  é o valor observado da estatística  $\Lambda$  e  $Q \sim \chi^2_{(\gamma)}$ . Assim, rejeita-se  $H_0$  se  $p$ -valor  $\leq \alpha$ .

# Estatísticas de comparação de modelos

- O TRV é apropriado na comparação somente de modelos encaixados (o modelo com menor número de parâmetros é um caso particular do modelo com maior número de parâmetros).
- Além disso, ele não leva em consideração (diretamente) o número de parâmetros do modelo (somente na distribuição da estatística).
- Existem várias alternativas, em termos de estatísticas para comparar modelos, que “penalizam” a verossimilhança em relação ao número de parâmetros, tamanho da amostra entre outros fatores.
- Veremos o AIC e o BIC.

## Estatísticas de comparação de modelos (cont.)

- O AIC e BIC, para o  $i$ -ésimo modelo, são dados, respectivamente, por:

$$AIC_i = -2l_i(\tilde{\theta}_i) + 2k$$

$$BIC_i = -2l_i(\tilde{\theta}_i) + k \ln(n)$$

que  $l_i(\tilde{\theta}_i)$  denota a log-verossimilhança do  $i$ -ésimo modelo avaliada em alguma estimativa (p.e. máxima verossimilhança),  $k$  é o número de parâmetros e  $n$  é o número de observações.

- Portanto, o modelo que apresentar os menores valores, será o modelo “melhor ajustado” aos dados.

## Função “lme” pacote “nlme”

- Ajusta a classe de modelos (32) por MV ou MRV, permitindo heterocedasticidade (entre as condições de avaliação e/ou grupos) sob diversas estruturas de correlação.
- Seja  $\mu_{(c)ij} = \mathcal{E}(Y_{ij}) = \mathbf{X}'_{ij}\boldsymbol{\beta} + \mathbf{Z}'_{ij}\mathbf{b}_j$  (média condicional),  $\mu_{(m)ij} = \mathcal{E}(Y_{ij}) = \mathbf{X}'_{ij}\boldsymbol{\beta}$  (média marginal), em que  $\mathbf{X}'_{ij}$  é  $i$ -ésima linha da matriz  $\mathbf{X}_j$  e o equivalente em relação à matriz  $\mathbf{Z}'_{ij}$ .
- A função lme trabalha com a estrutura  $\text{Cov}(\mathbf{Y}_j) = \mathbf{V}_j = \sigma^2 \mathbf{Z}_j \mathbf{D}(\boldsymbol{\theta}_D) \mathbf{Z}'_j + \sigma^2 \mathbf{R}_j = \sigma^2 \mathbf{Z}_j \mathbf{D}(\boldsymbol{\theta}_D) \mathbf{Z}'_j + \sigma^2 \boldsymbol{\Lambda}_j \mathbf{C}_j \boldsymbol{\Lambda}_j$ , em que  $\sigma^2 > 0$  é um parâmetro de escala,  $\boldsymbol{\Lambda}_j$  é uma matriz diagonal com elementos positivos (para permitir heterocedasticidade) e  $\mathbf{C}_j$  é uma matriz de correlações (como aquelas vistas anteriormente).



- Temos ainda que

$$\mathbf{R}_j(\mu_{ij}, \boldsymbol{\theta}; \mathbf{v}_{ij}) = \begin{cases} \mathbf{R}_j(\boldsymbol{\theta}; \mathbf{v}_{ij}) = \Lambda_j(\boldsymbol{\delta}; \mathbf{v}_{ij}) \mathbf{C}_j(\boldsymbol{\varrho}) \Lambda_j(\boldsymbol{\delta}; \mathbf{v}_{ij}) \\ \Lambda_j(\mu_{ij}, \boldsymbol{\delta}; \mathbf{v}_{ij}) \mathbf{C}_j(\boldsymbol{\varrho}) \Lambda_j(\mu_{ij}, \boldsymbol{\delta}; \mathbf{v}_{ij}) \end{cases}$$

em que  $\boldsymbol{\theta} = (\boldsymbol{\delta}', \boldsymbol{\varrho}')$ ,  $\boldsymbol{\delta}$  é um vetor de parâmetros de variância e  $\mathbf{v}_{ij}$  é um vetor de covariáveis (conhecidas) das variâncias.

- Portanto, a variância de cada observação é dada por

$$\mathcal{V}(Y_{ij}) = \sigma^2 D_j + \begin{cases} \sigma^2 \lambda^2(\boldsymbol{\delta}; \mathbf{v}_{ij}) \\ \sigma^2 \lambda^2(\mu_{ij}, \boldsymbol{\delta}; \mathbf{v}_{ij}) \end{cases}$$

em que  $D_j$  é o  $j$ -ésimo elemento da diagonal principal de  $\mathbf{Z}_j \mathbf{D}(\boldsymbol{\theta}_D) \mathbf{Z}_j'$ .

## Cont.

- Especificação da matriz de covariâncias dos efeitos aleatórios ( $\Psi$ ) na notação do pacote lme ( $D$ ).

Nome	Descrição
pdIdent	$\psi I_q$
pdDiag	$\text{diag}(\psi_1, \dots, \psi_q)$
pdCompSymm	uniforme
pdLogChol	não estruturada com parametrização log-Cholesky (default)
pdSymm	não estruturada com parametrização SVD (decomposição)
pdNatural	não estruturada com parametrização "natural"
pdBlocked	matriz bloco diagonal com os blocos definidos como uma das classes acima

# Modelagem para os dados do Exemplo 15 (bilirrubina)

$$Y_{ij} = \mu_{ij} + \xi_{ij},$$

- (1)  $\mu_{ij} = \beta_0 + \beta_1(x_{ij} - 1)I_{(i \in \{1,2\})} + \beta_2(x_{ij} - 1)I_{(i \in \{3,4,5,6,7,8,9\})} + b_{1j}$ ;  
; (2)  $\mu_{ij} = \beta_0 + \beta_1(x_{ij} - 1)I_{(i \in \{1,2\})} + \beta_2(x_{ij} - 1)I_{(i \in \{3,4,5,6,7,8,9\})} + b_{1j} + b_{2j}x_{ij}$ .

- (1)  $\mathcal{V}(Y_{ij}) = \sigma^2$  (homocedástico);  
(2)  $\mathcal{V}(Y_{ij}) = \sigma_i^2 = \sigma^2 \exp(x_{ij}\delta)$ ,  $i = 1, 2, \dots, 9$  (heterocedástico) (note que  $x_{ij} = x_{ij'}$ ,  $\forall i, j, j'$ ).

- $\text{Corre}(\xi_{ij}, \xi_{i'j})$  (1) AR(1), (2)(ARMA(1,1)).

- $b_{1j} \stackrel{i.i.d}{\sim} N(0, \psi_1)$ ,  $(b_{1j}, b_{2j}) \stackrel{i.i.d}{\sim} N_2(\mathbf{0}, \Psi)$ ,  $\Psi = \begin{bmatrix} \psi_1 & \psi_0 \\ \psi_0 & \psi_2 \end{bmatrix}$

# Modelos

Modelo	Variância	Correlação	Efeitos aleatórios
HAR1I	Homocedástico	AR(1)	intercepto
HAR1ICA	Homocedástico	AR(1)	intercepto, coeficiente angular
HARMA11I	Homocedástico	ARMA(1,1)	intercepto
HARMA11ICA	Homocedástico	ARMA(1,1)	intercepto, coeficiente angular
HEAR1I	Heterocedástico	AR(1)	intercepto
HEAR1ICA	Heterocedástico	AR(1)	intercepto, coeficiente angular
HEARMA11I	Heterocedástico	ARMA(1,1)	intercepto
HEARMA11ICA	Heterocedástico	ARMA(1,1)	intercepto, coeficiente angular

# Modelos

Modelo	AIC	BIC
HAR1I	2926,41	2954,51
HAR1ICA	2930,41	2967,87
HARMA11I	2920,82	2953,59
HARMA11ICA	2924,82	2966,95
<b>HEAR1I</b>	2854,91	2887,69
HEAR1ICA	2858,91	2901,05
HEARMA11I	2852,96	2890,41
HEARMA11ICA	2856,96	2903,78

O MMM selecionado foi HEARMA11 (mesma função de variância e com regressão segmentada): AIC= 2871,71; BIC=2904,48

# Estimativas dos parâmetros

MLM

Parâmetro	Estimativa	EP	IC(95%)	Estatística	p-valor
$\beta_0$	5,37	0,40	[4,59 ; 6,15 ]	13,48	<0,0001
$\beta_1$	0,32	0,14	[0,05 ; 0,59 ]	2,33	0,0198
$\beta_2$	-0,21	0,02	[-0,26 ; -0,16 ]	-8,36	<0,0001

# Estimativas dos parâmetros

## MLM

Parâmetro	Estimativa	IC(95%)
$\sigma^2$	13,20	[9,45 ; 18,44 ]
$\delta$	-0,08	[-0,10 ; -0,07 ]
$\psi_1$	6,45	[4,29 ; 9,68 ]

OBS: No modelo com intercepto e coeficiente aleatório, semelhante ao modelo escolhidos,  $\tilde{\psi}_2 = < 0,0001$  (indicando uma não significância do efeito aleatório).

# Estimativas dos parâmetros


MLM


Parâmetro	Estimativa	IC(95%)
$\phi$	0,84	[0,78 ; 0,89 ]

OBS: No modelo ARMA(1,1), semelhante ao modelo escolhido,


$\tilde{\theta}_1 = 0,086[-0,002; 0,173]$  (indicando uma contribuição menos significativa desse coeficiente).









# Correlações observadas e estimadas







Valores individuais preditos:  $\widehat{Y}b_j = \mathbf{X}_j\widehat{\beta} + \mathbf{Z}_j\widehat{b}_j$



# Perfis individuais preditos e observados



# Efeitos aleatórios



# Análise de resíduos para modelos mistos

- Existem duas fontes de variação: os efeitos aleatórios  $\mathbf{b}$  e os erros (marginais)  $\xi$ .
- Tipos de erros:
  - Erros condicionais:  $\xi_j = \mathbf{Y}_j - \mathbf{X}_j\boldsymbol{\beta} - \mathbf{Z}_j\mathbf{b}_j$
  - Erros marginais:  $\epsilon = \mathbf{Y}_j - \mathbf{X}_j\boldsymbol{\beta} = \mathbf{Z}_j\mathbf{b}_j + \xi_j$
  - Efeitos aleatórios:  $\mathbf{Z}_j\mathbf{b}_j = \mathcal{E}(\mathbf{Y}_j|\mathbf{b}_j) - \mathcal{E}(\mathbf{Y}_j)$ .
- Respetivos resíduos (valores preditos):
  - Resíduos condicionais:  $\hat{\xi}_j = \mathbf{Y}_j - \mathbf{X}_j\hat{\boldsymbol{\beta}} - \mathbf{Z}_j\hat{\mathbf{b}}_j$
  - Resíduos marginais:  $\hat{\epsilon}_j = \mathbf{Y}_j - \mathbf{X}_j\hat{\boldsymbol{\beta}} = \mathbf{Z}_j\hat{\mathbf{b}}_j + \hat{\xi}_j$

# Tipos de resíduos

- Segundo Hilden-Minton (1995)
  - Resíduo puro (para um específico tipo de erro): se ele depende apenas das componentes fixas e do erro que ele pretende predizer.
  - Resíduo confundido: depende de outros tipos de erros.



# Tipos de resíduos

- Na função “lme”

- Resíduo condicional normalizado:  $\hat{\xi}_j^* = (\hat{\sigma} \hat{\mathbf{U}}_{(c)j})^{-1} \hat{\xi}_j$





- Resíduo marginal normalizado:  $\hat{\epsilon}_j^* = (\hat{\sigma} \hat{\mathbf{U}}_{(m)j})^{-1} \hat{\epsilon}_j$

em que  $\hat{\mathbf{U}}_{(c)j}$  é a matriz triangular superior da decomposição de Cholesky de  $\hat{\mathbf{R}}_j = \hat{\mathbf{U}}'_{(c)j} \hat{\mathbf{U}}_{(c)j}$  e  $\hat{\mathbf{U}}_{(m)j}$  é a matriz triangular superior da decomposição de Cholesky de  $\hat{\mathbf{V}}_j = \hat{\mathbf{U}}'_{(m)j} \hat{\mathbf{U}}_{(m)j}$ .



# Tipos de resíduos

- Segundo Pinheiro and Bates (2000), página 239, e Schabenberger (2004), respectivamente,  $\hat{\xi}_j^*$  e  $\hat{\epsilon}_j^*$  devem seguir, aproximadamente uma distribuição  $N(0,1)$ , no caso do modelo estar bem ajustado.
- No entanto, Nobre and Singer (2007) sugerem a utilização do resíduo de confundimento mínimo proposto por Hilden-Milton (1995), veja também Nobre (2004).

# Usando os resíduos $\hat{\xi}_j^*$



# Usando os resíduos $\hat{\xi}_j^*$



# Mais material

http:

[//www.ime.unicamp.br/~cnaber/Material\\_ADL\\_POS\\_2S\\_2015.htm](http://www.ime.unicamp.br/~cnaber/Material_ADL_POS_2S_2015.htm)

e referências apresentadas no site.