

Modelos não lineares mistos

Prof. Caio Azevedo

Relembrando

- MLM : $\mu_{ij} = \mathbf{X}'_j\boldsymbol{\beta} + \mathbf{Z}_j\mathbf{b}_j$.
- MLGM : $\mu_{ij} = g^{-1}(\mathbf{X}'_j\boldsymbol{\beta} + \mathbf{Z}_j\mathbf{b}_j)$.
- Nem sempre a relação entre as covariáveis (\mathbf{X}_j) e os efeitos aleatórios é adequadamente descrita por um modelo linear ou por um modelo linear generalizado.
- Modelos não lineares (mistos) (MNLM) podem ser mais apropriados em situações em que o comportamento das médias (em função de covariáveis como o tempo, por exemplo) não é satisfatoriamente modelado pelos MLM ou pelos MLGM.

Limitações dos MLM e MLGM e vantagens dos MNLM

- O comportamento linear e não linear induzidos, respectivamente, pelo MLM e MLGM podem não ser adequados para representar o comportamento da média.
- Existência de assíntotas (inferior e/ou superior)
- As interpretações dos parâmetros de modelos não lineares podem ser mais adequadas do que aquelas associadas aos parâmetros do MLM e do MLGM (particularmente, polinômios de grau ≥ 3 possuem parâmetros de difícil interpretação), principalmente em termos do problema.


Limitações dos MLM e MLGM e vantagens dos MNLM

- Os MNLM, em geral, apresentam poucos parâmetros com interpretações úteis em termos do problema.
- Garantia de que as médias preditas respeitarão o espaço paramétrico associado.


Exemplo 6: cinética de indometacina, Kwan et al (1976)

- Os dados correspondem à um experimento de farmacocinética (etapas pelas quais a droga passa desde a ministração, introdução do fármaco no organismo, como tomar um comprimido, até sua eliminação, processo pela qual o fármaco deixa o organismo definitivamente) da droga indometacina (um tipo de anti-inflamatório).
- Seis indivíduos receberam de modo intravenoso a mesma dose de indometacina, e tiveram sua concentração de droga no plasma (em mcg/ml) medidas 11 vezes entre 15 minutos e 8 horas após o medicamento ser ministrado.
- Estudar o comportamento da concentração ao longo do tempo.


Perfis individuais (separados)




Perfis individuais (juntos)



Perfis médios



Perfis médios e individuais



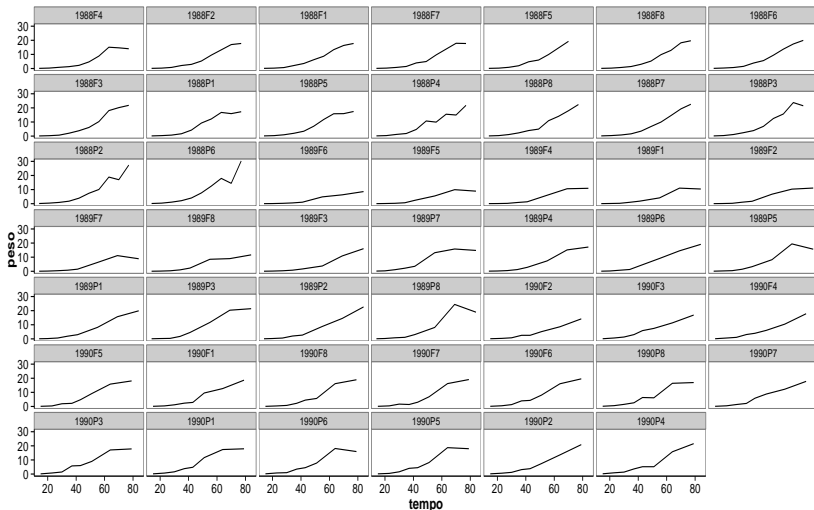
Exemplo 7: crescimento de plantas de soja, Davidian and Giltinan (1995) (1976)

- Os dados correspondem à um experimento sobre crescimentos de dois tipos de soja: “Plant Introduction” # 416937 (P) um tipo experimental de cepa (parte da planta a que se cortou o caule e permanece viva no solo) e “Forrest” (F) (uma variedade comercial).
- O peso médio das folhas (em gramas) de seis plantas escolhidas aleatoriamente de cada parcela (área de cultivo) foi medida (aproximadamente) numa frequência semanal entre duas à sete semanas depois de plantadas.


Cont.

- O experimento foi conduzido em três anos diferentes: (1988, 1989 e 1990).
- Objetivo: comparar os tipos de plantas, quanto crescimento, ao longo do tempo.


Perfis individuais por variedade x anos (separados)



Perfis individuais por variedade x anos (juntos)



Perfis individuais e médios por variedade x anos



Modelo não linear (sem efeito aleatório)

$$Y_j = f(\phi_j, \mathbf{X}_j, \mathbf{W}_j) + \xi_j; j = 1, \dots, n(\text{indivíduo})$$

- Em que \mathbf{X}_j representa covariáveis (matriz de planejamento) de interesse associadas aos efeitos fixos.
- $\phi_j = \mathbf{X}_j \beta$.
- \mathbf{W}_j : outras covariáveis como o tempo, por exemplo.
- $f(., ., .)$ é uma função geral, real e diferenciável e não linear em pelo menos uma componente do vetor ϕ_j .
- $\xi_j \stackrel{i.i.d}{\sim} N(0, \sigma^2)$.

Modelo não lineares: exemplos

- $(M_1) : Y_j = \phi_1 + \phi_2 \exp(\phi_3/w_j) + \xi_j.$
- $(M_2) : Y_j = \phi_1 - \phi_2 (w_j + \phi_3)^{-1} + \xi_j.$
- $(M_3) : Y_j = \phi_1 w_j^{\phi_2} + \xi_j.$
- $(M_4) : Y_j = \phi_1 / (1 + \exp(-(w_j - \phi_2)/\phi_3)) + \xi_j.$
- $(M_5) : Y_j = \phi_1 + \phi_2 w_j - e^{\phi_3 + \phi_4 w_j} + \xi_j.$

Para os modelos M_1, M_2, M_4 , $\phi_j = (\phi_1, \phi_2, \phi_3)' = (\beta_1, \beta_2, \beta_3)'$, ou seja $\mathbf{X}_j = \mathbf{I}_3$. Para o modelo M_3 $\phi_j = (\phi_1, \phi_2)' = (\beta_1, \beta_2)'$, ou seja $\mathbf{X}_j = \mathbf{I}_2$, enquanto que para o modelo M_5 $\phi_j = (\phi_1, \phi_2, \phi_3, \phi_4)' = (\beta_1, \beta_2, \beta_3, \beta_4)'$, ou seja $\mathbf{X}_j = \mathbf{I}_4$. Em todos os casos, a matriz \mathbf{W}_j corresponde à variável w_j , que pode ser o tempo.

Cont.

- Os modelos M_1 e M_5 podem ser apresentados de uma outra forma:


M_1

$$\beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \end{bmatrix}; \mathbf{X}_j = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & w_j^{-1} \end{bmatrix}$$

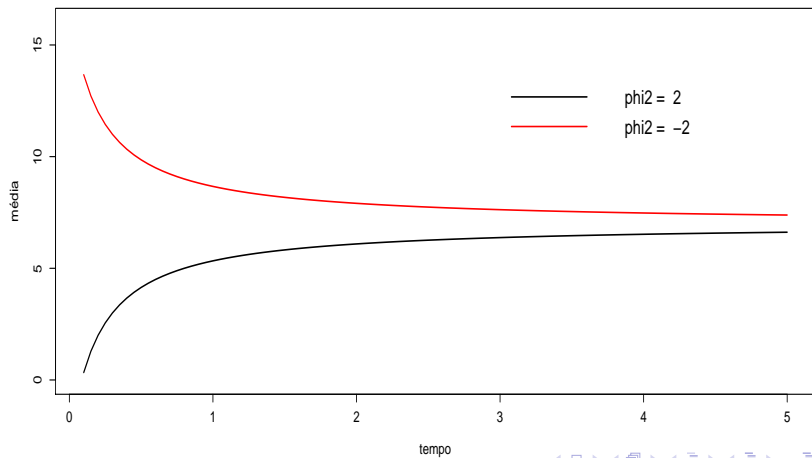
M_5

$$\beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \\ \beta_4 \end{bmatrix}; \mathbf{X}_j = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & w_j \end{bmatrix}$$


Modelo 1: $\phi_1 = 1, \phi_2 = 2$



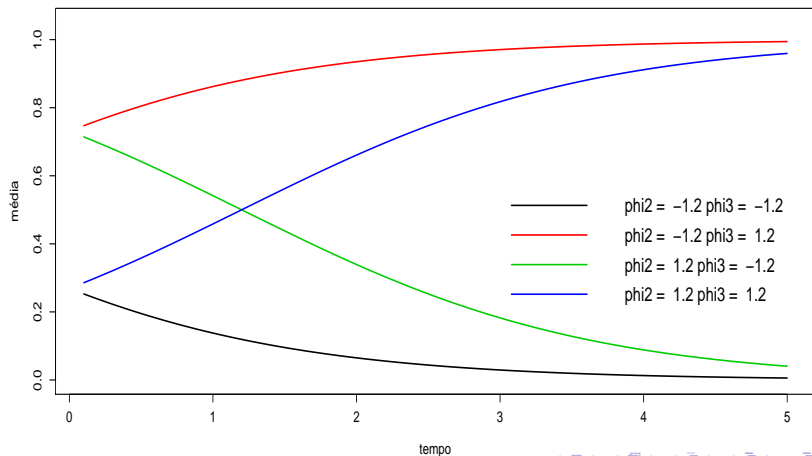
Modelo 2: $\phi_1 = 7, \phi_3 = 0,2$



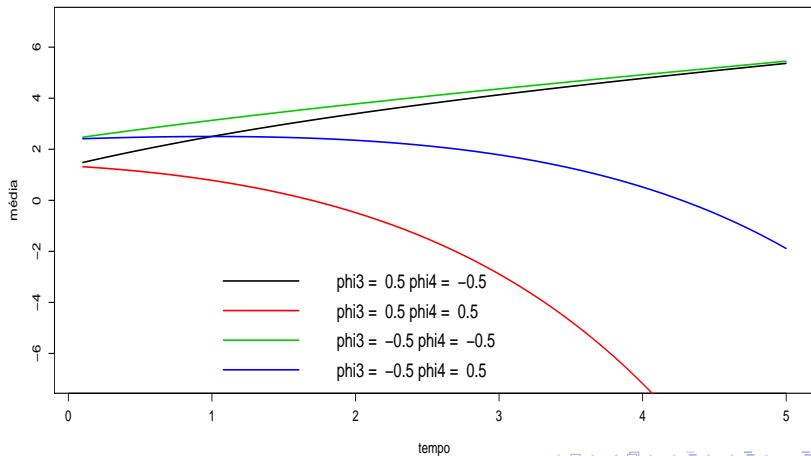
Modelo 3: $\phi_1 = 1$



Modelo 4: $\phi_1 = 1$



Modelo 5: $\phi_1 = 3, \phi_2 = 0,5$



Modelo não linear misto

$$Y_{ij} = f(\phi_{ij}, \mathbf{X}_{ij}, \mathbf{W}_{ij}) + \xi_{ij}; j = 1, \dots, n(\text{indivíduo}); i = 1, \dots, k_j(\text{medida repetida})$$

- Em que \mathbf{X}_{ij} representa covariáveis (matrizes de planejamento) de interesse associadas aos efeitos fixos (\mathbf{A}_{ij}) e aleatórios (\mathbf{B}_{ij}).
- $\phi_{ij} = \mathbf{A}_{ij}\beta + \mathbf{B}_{ij}\mathbf{b}_j$.
- \mathbf{W}_{ij} : outras covariáveis como o tempo, por exemplo.
- $f(.,.,.)$ é uma função geral, real e diferenciável e não linear em pelo menos uma componente do vetor ϕ_{ij} .
- $\xi_{ij} \stackrel{i.i.d.}{\sim} N(0, \sigma^2), \mathbf{b}_j \stackrel{i.i.d.}{\sim} N_q(\mathbf{0}, \Psi), \xi_{ij} \perp \mathbf{b}_j \forall i, j$.

Modelo não linear misto (forma vetorial)

$$\mathbf{Y}_j = \mathbf{f}(\phi_j, \mathbf{X}_j, \mathbf{W}_j) + \xi_j; j = 1, \dots, n$$

$$\mathbf{Y}_j = \begin{bmatrix} Y_{1j} \\ Y_{2j} \\ \vdots \\ Y_{kjj} \end{bmatrix}; \mathbf{X}_j = \begin{bmatrix} \mathbf{X}_{1j} \\ \mathbf{X}_{2j} \\ \vdots \\ \mathbf{X}_{kjj} \end{bmatrix}; \mathbf{A}_j = \begin{bmatrix} \mathbf{A}_{1j} \\ \mathbf{A}_{2j} \\ \vdots \\ \mathbf{A}_{kjj} \end{bmatrix}; \mathbf{B}_j = \begin{bmatrix} \mathbf{B}_{1j} \\ \mathbf{B}_{2j} \\ \vdots \\ \mathbf{B}_{kjj} \end{bmatrix};$$

$$\phi_j = \begin{bmatrix} \phi_{1j} \\ \phi_{2j} \\ \vdots \\ \phi_{kjj} \end{bmatrix}; \xi_j = \begin{bmatrix} \xi_{1j} \\ \xi_{2j} \\ \vdots \\ \xi_{kjj} \end{bmatrix}; \mathbf{f}(\phi_j, \mathbf{X}_j) = \begin{bmatrix} f(\phi_{1j}, \mathbf{X}_{1j}, \mathbf{W}_{1j}) \\ f(\phi_{2j}, \mathbf{X}_{2j}, \mathbf{W}_{2j}) \\ \vdots \\ f(\phi_{kjj}, \mathbf{X}_{kjj}, \mathbf{W}_{kjj}) \end{bmatrix}; \mathbf{W}_j = \begin{bmatrix} \mathbf{W}_{1j} \\ \mathbf{W}_{2j} \\ \vdots \\ \mathbf{W}_{kjj} \end{bmatrix}$$

Modelo não lineares mistos: exemplos

- $(M_1) : Y_{ij} = \phi_{1j} + \phi_{2j} \exp(\phi_{3j}/w_{ij}) + \xi_{ij}.$
- $(M_2) : Y_{ij} = \phi_{1j} - \phi_{2j} (w_{ij} + \phi_{3j})^{-1} + \xi_{ij}.$
- $(M_3) : Y_{ij} = \phi_{1j} w_{ij}^{\phi_{2j}} + \xi_{ij}.$
- $(M_4) : Y_{ij} = \phi_{1j} / (1 + \exp(-(w_{ij} - \phi_{2j})/\phi_{3j})) + \xi_{ij}.$
- $(M_5) : Y_{ij} = \phi_{1j} + \phi_{2j} w_{1j} - e^{\phi_{3j} + \phi_{4j} w_{ij}} + \xi_{ij}.$

Modelo 1 misto

- $Y_{ij} = \phi_{1j} + \phi_{2j} \exp(\phi_{3j}/w_{ij}) + \xi_{ij}$.

$\phi_{1j} = \beta_1 + b_{1j}$, $\phi_{2j} = \beta_2$ e $\phi_{3j} = \beta_3$, nesse caso, $\boldsymbol{\beta} = (\beta_1, \beta_2, \beta_3)'$,

$\mathbf{b}_j = b_{1j} \stackrel{i.i.d.}{\sim} N(0, \psi)$ e

$$\boldsymbol{\phi}_j = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \end{bmatrix} + \begin{bmatrix} b_{1j} \\ 0 \\ 0 \end{bmatrix}$$

$$\mathbf{A}_{ij} = \mathbf{I}_3, \mathbf{B}_{ij} = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}$$

Modelo 1 misto

- $Y_{ij} = \phi_{1j} + \phi_{2j} \exp(\phi_{3j}/w_{ij}) + \xi_{ij}$.

$\phi_{1j} = \beta_1 + b_{1j}$, $\phi_{2j} = \beta_2 + b_{2j}$ e $\phi_{3j} = \beta_3$, nesse caso,

$\boldsymbol{\beta} = (\beta_1, \beta_2, \beta_3)'$, $\mathbf{b}_j = (b_{1j}, b_{2j})'$ $i.i.d.$ $N_2(\mathbf{0}, \boldsymbol{\Psi})$ e

$$\boldsymbol{\phi}_j = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \end{bmatrix} + \begin{bmatrix} b_{1j} \\ b_{2j} \\ 0 \end{bmatrix}$$

$$\mathbf{A}_{ij} = \mathbf{I}_3, \mathbf{B}_{ij} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 0 & 0 \end{bmatrix}$$

Modelo 1 misto

- $Y_{ij} = \phi_{1j} + \phi_{2j} \exp(\phi_{3j}/w_{ij}) + \xi_{ij}$.

$\phi_{1j} = \beta_1 + \mathbf{b}_{1j}$, $\phi_{2j} = \beta_2 + \mathbf{b}_{2j}$ e $\phi_{3j} = \beta_3 + \mathbf{b}_{3j}$, nesse caso,

$\boldsymbol{\beta} = (\beta_1, \beta_2, \beta_3)'$, $\mathbf{b}_j = (\mathbf{b}_{1j}, \mathbf{b}_{2j}, \mathbf{b}_{3j})' \stackrel{i.i.d}{\sim} N_3(\mathbf{0}, \boldsymbol{\Psi})$ e

$$\boldsymbol{\phi}_j = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \end{bmatrix} + \begin{bmatrix} \mathbf{b}_{1j} \\ \mathbf{b}_{2j} \\ \mathbf{b}_{3j} \end{bmatrix}$$

$$\mathbf{A}_{ij} = \mathbf{I}_3, \mathbf{B}_{ij} = \mathbf{I}_3$$

Em todos os casos, a matriz \mathbf{W}_{ij} corresponde à variável w_{ij} , que pode ser o tempo.

Modelo 3 misto

- $Y_{ij} = \phi_{1j} w_{ij}^{\phi_{2j}} + \xi_{ij}$.

$\phi_{1j} = \beta_1 + \mathbf{b}_{1j}$ e $\phi_{2j} = \beta_2$, nesse caso, $\boldsymbol{\beta} = (\beta_1, \beta_2)'$,

$\mathbf{b}_j = b_{1j} \stackrel{i.i.d.}{\sim} N(0, \psi)$ e

$$\boldsymbol{\phi}_j = \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix} + \begin{bmatrix} b_{1j} \\ 0 \end{bmatrix}$$

$$\mathbf{A}_{ij} = \mathbf{I}_2, \mathbf{B}_{ij} = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$$

Modelo 3 misto

- $Y_{ij} = \phi_{1j} w_{ij}^{\phi_{2j}} + \xi_{ij}$.

$\phi_{1j} = \beta_1 + b_{1j}$ e $\phi_{2j} = \beta_2 + b_{2j}$, nesse caso, $\boldsymbol{\beta} = (\beta_1, \beta_2)'$,

$\mathbf{b}_j = (b_{1j}, b_{2j}) \stackrel{i.i.d}{\sim} N_2(\mathbf{0}, \boldsymbol{\Psi})$ e

$$\boldsymbol{\phi}_j = \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix} + \begin{bmatrix} b_{1j} \\ b_{2j} \end{bmatrix}$$

$$\mathbf{A}_{ij} = \mathbf{I}_2, \mathbf{B}_{ij} = \mathbf{I}_2$$

Estimação

- Parâmetros para estimar $(\beta, \mathbf{b}, \theta, \sigma^2)$, em que $\Psi = \Psi(\theta)$.
- Verossimilhança completa:

$$L(\beta, \mathbf{b}, \theta, \sigma^2) = \exp \left\{ - \sum_{j=1}^n \sum_{i=1}^{k_j} \frac{(y_{ij} - f(\phi_{ij}, \mathbf{X}_{ij}, \mathbf{W}_{ij}))^2}{2\sigma^2} \right\} \\ \times \exp \left\{ -0,5 \sum_{j=1}^n \mathbf{b}'_j \Psi^{-1} \mathbf{b}_j \right\} |\Psi|^{-n/2}$$

Verossimilhança marginal

$$L(\boldsymbol{\beta}, \boldsymbol{\theta}, \sigma^2) \propto \prod_{j=1}^n \int_{\mathbb{R}^q} \exp \left\{ - \sum_{i=1}^{k_j} \frac{(y_{ij} - f(\phi_{ij}, \mathbf{X}_{ij}, \mathbf{W}_{ij}))^2}{2\sigma^2} \right\} \\ \times \exp \{ -0,5 \mathbf{b}_j' \boldsymbol{\Psi}^{-1} \mathbf{b}_j \} |\boldsymbol{\Psi}|^{-1/2} d\mathbf{b}$$

A integral acima não tem solução explícita (lembrando que ϕ_{ij} é função de \mathbf{b}_j).

Resolução da integral

- Quadratura (gaussiana).
- Quadratura adaptativa.
- Aproximação da verossimilhança por um modelo linear misto.
- Aproximação de Laplace.
- Aproximação do integrando usando o primeiro termo da expansão em séries de Taylor em torno do valor esperado condicional dos efeitos aleatórios.
- Aproximação do integrando usando o primeiro termo da expansão em séries de Taylor em torno da moda condicional dos efeitos aleatórios.
- Monte carlo.

Discutiremos brevemente

- Quadratura adaptativa.
- Aproximação da verossimilhança por um modelo linear misto (método de Lindstrom and Bates).
- Aproximação de Laplace.

Verossimilhança

- Vamos utilizar a seguinte decomposição da matriz $\Psi^{-1} = \sigma^{-2} \mathbf{\Delta}' \mathbf{\Delta}$, em que $\mathbf{\Delta}$ (associado à decomposição de Cholesky) é uma matriz de precisão ($N = \sum_{j=1}^n k_j$). Assim:

$$\begin{aligned} L(\boldsymbol{\beta}, \boldsymbol{\theta}, \sigma^2) &\propto (\sigma^2)^{-(N+nq)/2} \\ &\times \prod_{j=1}^n \int_{\mathbb{R}^q} \exp \left\{ - \sum_{i=1}^{k_j} \frac{(y_{ij} - f(\phi_{ij}, \mathbf{X}_{ij}, \mathbf{W}_{ij}))^2 + \|\mathbf{\Delta} \mathbf{b}_j\|^2}{2\sigma^2} \right\} \\ &\times |\mathbf{\Delta}| d\mathbf{b}_j \end{aligned} \quad (1)$$

em que $\|\cdot\|^2$ é a norma Euclidiana elevada ao quadrado.

Método de Lindstrom and Bates

- Tal método consiste em iterar entre dois passos: um passo de mínimos quadrados não lineares penalizado (MQNLP) e um passo de modelos lineares mistos (MLM).
- No passo MQNLP, consideramos uma estimativa provisória de Δ e obtemos estimativas provisórias de \mathbf{b}_j e β minimizando

$$\sum_{j=1}^n \left[\sum_{i=1}^{k_j} (y_{ij} - f(\phi_{ij}, \mathbf{X}_{ij}, \mathbf{W}_{ij}))^2 + \|\Delta \mathbf{b}_j\|^2 \right]$$

Cont.

- No passo MLM a matriz $\mathbf{\Delta}$ é atualizada baseada na expansão de primeira ordem em séries de Taylor da função $f(.,.,.)$ em torno de estimativas provisórias de β e \mathbf{b}_j , as quais serão denotadas por $\tilde{\beta}^{(w)}$ e $\tilde{\mathbf{b}}_j^{(w)}$. Defina ainda

$$\tilde{\mathbf{w}}_j^{(w)} = \mathbf{y}_j - \mathbf{f}_j(\tilde{\beta}^{(w)}, \tilde{\mathbf{b}}_j^{(w)}) + \tilde{\mathbf{X}}_j^{(w)} \tilde{\beta}^{(w)} + \tilde{\mathbf{Z}}_j^{(w)} \tilde{\mathbf{b}}_j^{(w)}$$

em que $\tilde{\mathbf{X}}_j^{(w)} = \left. \frac{\partial \mathbf{f}_j}{\partial \beta'} \right|_{\tilde{\beta}^{(w)}, \tilde{\mathbf{b}}_j^{(w)}}$ e $\tilde{\mathbf{Z}}_j^{(w)} = \left. \frac{\partial \mathbf{f}_j}{\partial \mathbf{b}_j'} \right|_{\tilde{\beta}^{(w)}, \tilde{\mathbf{b}}_j^{(w)}}$

Cont.

- Assim a log-verossimilhança aproximada (para estimar $\mathbf{\Delta}$) é dada por:

$$\begin{aligned} l_{MLM}(\boldsymbol{\beta}, \mathbf{\Delta}, \sigma^2) &= -\frac{N}{2} \ln(2\pi\sigma^2) - \frac{1}{2} \sum_{j=1}^n \left\{ \ln |\boldsymbol{\Sigma}_j(\mathbf{\Delta})| \right. \\ &\quad + \sigma^{-2} \left[\mathbf{w}_j^{(w)} - \tilde{\mathbf{X}}_j^{(w)} \boldsymbol{\beta} \right]' \boldsymbol{\Sigma}_j^{-1}(\mathbf{\Delta}) \\ &\quad \left. \times \left[\mathbf{w}_j^{(w)} - \tilde{\mathbf{X}}_j^{(w)} \boldsymbol{\beta} \right] \right\} \end{aligned} \quad (2)$$

em que $\boldsymbol{\Sigma}_j(\mathbf{\Delta}) = \mathbf{I} + \tilde{\mathbf{Z}}_j^{(w)} \mathbf{\Delta}^{-1} (\mathbf{\Delta}^{-1})' \tilde{\mathbf{Z}}_j^{(w)'}$

Cont.

- De modo semelhante ao que é feito nos MLM, podemos obter os valores que maximizam a função acima, em relação à β e σ^2 , explicitamente em função de Δ e trabalhar com a verossimilhança perfilada de Δ para estimá-la.

Cont.

- Pode-se também trabalhar com a logverossimilhança restrita (veja slides sobre MLM), ou seja:

$$l_R(\sigma^2, \mathbf{\Delta}) = l(\tilde{\boldsymbol{\beta}}(\mathbf{\Delta}), \mathbf{\Delta}, \sigma^2) - \frac{1}{2} \sum_{j=1}^n \ln |\sigma^{-2} \tilde{\mathbf{X}}_j^{(w)'} \boldsymbol{\Sigma}_j(\mathbf{\Delta}) \tilde{\mathbf{X}}_j^{(w)}|$$

em que $l(\tilde{\boldsymbol{\beta}}(\mathbf{\Delta}), \mathbf{\Delta}, \sigma^2)$ é dada por (2), com $\boldsymbol{\beta}$ substituído por $\tilde{\boldsymbol{\beta}}$.

- O algoritmo alterna entre os passos MQNLP e MLM, até que algum critério de convergência seja alcançado.

Aproximação de Laplace

- A integral que queremos aproximar é a constante na expressão abaixo:

$$L(\boldsymbol{\beta}, \boldsymbol{\theta}, \sigma^2) \propto \prod_{j=1}^n \int_{\mathbb{R}^q} \exp \left\{ - \sum_{i=1}^{k_j} \frac{(y_{ij} - f(\boldsymbol{\phi}_{ij}, \mathbf{X}_{ij}, \mathbf{W}_{ij}))^2 + \|\boldsymbol{\Delta} \mathbf{b}_j\|^2}{2\sigma^2} \right\} \\ \times (2\pi\sigma^2)^{-(k_j+1)/2} |\boldsymbol{\Delta}| d\mathbf{b}$$

- Seja $g(\boldsymbol{\beta}, \boldsymbol{\Delta}, \mathbf{y}_j, \mathbf{b}_j) = \sum_{i=1}^{k_j} (y_{ij} - f(\boldsymbol{\phi}_{ij}, \mathbf{X}_{ij}, \mathbf{W}_{ij}))^2 + \|\boldsymbol{\Delta} \mathbf{b}_j\|^2$.

Aproximação de Laplace

- Defina:

$$\begin{aligned}\tilde{\mathbf{b}}_j &= \operatorname{argmin}_{\mathbf{b}_j} g(\boldsymbol{\beta}, \boldsymbol{\Delta}, \mathbf{y}_j, \mathbf{b}_j) \\ g'(\boldsymbol{\beta}, \boldsymbol{\Delta}, \mathbf{y}_j, \mathbf{b}_j) &= \frac{\partial g(\boldsymbol{\beta}, \boldsymbol{\Delta}, \mathbf{y}_j, \mathbf{b}_j)}{\partial \mathbf{b}_j} \\ g''(\boldsymbol{\beta}, \boldsymbol{\Delta}, \mathbf{y}_j, \mathbf{b}_j) &= \frac{\partial^2 g(\boldsymbol{\beta}, \boldsymbol{\Delta}, \mathbf{y}_j, \mathbf{b}_j)}{\partial \mathbf{b}_j \partial \mathbf{b}_j'}\end{aligned}$$

- Considere a expansão em séries de Taylor de segunda ordem de g em torno de $\tilde{\mathbf{b}}_j$:

$$g(\boldsymbol{\beta}, \boldsymbol{\Delta}, \mathbf{y}_j, \mathbf{b}_j) \approx g(\boldsymbol{\beta}, \boldsymbol{\Delta}, \mathbf{y}_j, \tilde{\mathbf{b}}_j) + \frac{1}{2} (\mathbf{b}_j - \tilde{\mathbf{b}}_j)' g''(\boldsymbol{\beta}, \boldsymbol{\Delta}, \mathbf{y}_j, \tilde{\mathbf{b}}_j) (\mathbf{b}_j - \tilde{\mathbf{b}}_j)$$

(note que $g'(\boldsymbol{\beta}, \boldsymbol{\Delta}, \mathbf{y}_j, \tilde{\mathbf{b}}_j) = \mathbf{0}$)

Cont.

- A aproximação de Laplace da verossimilhança é dada por:

$$L(\beta, \theta, \sigma^2) \approx (2\pi\sigma^2)^{-N/2} |\mathbf{\Delta}|^n \\ \times \exp \left[-\frac{1}{2\sigma^2} \sum_{j=1}^n g(\beta, \mathbf{\Delta}, \mathbf{y}_j, \tilde{\mathbf{b}}_j) \right] \prod_{i=1}^n |g''(\beta, \mathbf{\Delta}, \mathbf{y}_j, \tilde{\mathbf{b}}_j)|^{-1/2}$$

- Temos que (veja Pinheiro and Bates (2009), pag. 316-317)

$$g''(\beta, \mathbf{\Delta}, \mathbf{y}_j, \tilde{\mathbf{b}}_j) \approx \mathbf{G}(\beta, \mathbf{\Delta}, \mathbf{y}_j) = \frac{\partial \mathbf{f}_j(\beta, \mathbf{b}_j)}{\partial \mathbf{b}_j} \bigg|_{\tilde{\mathbf{b}}_j} \frac{\partial \mathbf{f}_j(\beta, \mathbf{b}_j)}{\partial \mathbf{b}'_j} \bigg|_{\tilde{\mathbf{b}}_j} + \mathbf{\Delta}' \mathbf{\Delta}$$

- A aproximação de Laplace da logverossimilhança modificada é dada por:

$$l_{LA}(\beta, \sigma^2, \Delta) = -\frac{N}{2} + n \ln |\Delta| - \frac{1}{2} \left\{ \sum_{j=1}^n \ln |G(\beta, \Delta, \mathbf{y}_j)| + \sigma^{-2} \sum_{j=1}^n g(\beta, \Delta, \mathbf{y}_j, \tilde{\mathbf{b}}_j) \right\}$$

- O procedimento itera entre a maximização de l_{LA} em relação à β, σ^2, Δ e da minimização de $g(\beta, \Delta, \mathbf{y}_j)$ com relação à \mathbf{b}_j .

Quadratura adaptativa

- A idéia é utilizar parte dos resultados da AL e substituir a integral de uma normal multivariada por sucessivas integrais de normais padrão independentes.
- Sejam $z_j, w_j, j = 1, 2, \dots, N_Q$, respectivamente, as abscissas e os pesos para a integração por quadratura Gaussiana (unidimensional) baseado na $N(0,1)$.
- Do resultado da AL temos que o integrando $\exp(-g(\beta, \Delta, \mathbf{y}_j, \mathbf{b}_j)/(2\sigma^2))$ pode ser aproximado por uma distribuição $N_q(\tilde{\mathbf{b}}_j, \sigma^2 G^{-1}(\beta, \Delta, \mathbf{y}_j))$

Quadratura adaptativa

- Assim

$$\begin{aligned} & \int \exp(-g(\beta, \Delta, \mathbf{y}_j, \mathbf{b}_j)/(2\sigma^2)) d\mathbf{b}_j = \int \sigma^q |\mathbf{G}(\beta, \Delta, \mathbf{y}_j)|^{-1/2} \\ & \times \exp\left\{-g\left[\beta, \Delta, \mathbf{y}_j, \tilde{\mathbf{b}}_j + \sigma \mathbf{G}^{-1/2}(\beta, \Delta, \mathbf{y}_j) \mathbf{z}\right] / (2\sigma^2) + \|\mathbf{z}\|^2/2\right\} \\ & \times \exp(-\|\mathbf{z}\|^2/2) d\mathbf{z} \\ & \approx \sigma^q |\mathbf{G}(\beta, \Delta, \mathbf{y}_j)|^{-1/2} \\ & \times \sum_{j_1=1}^{N_Q} \dots \sum_{j_q=1}^{N_Q} \exp\left\{-g\left[\beta, \Delta, \mathbf{y}_j, \tilde{\mathbf{b}}_j + \sigma \mathbf{G}^{-1/2}(\beta, \Delta, \mathbf{y}_j) \mathbf{z}_j\right] / (2\sigma^2) \right. \\ & \left. + \|\mathbf{z}_j\|^2/2\right\} \prod_{k=1}^q w_{jk} \end{aligned}$$

em que $\mathbf{z}_j = (z_{j1}, \dots, z_{jq})$.

Cont.

- A aproximação da logverossimilhança por quadratura adaptativa:

$$\begin{aligned}l_{AQA}(\beta, \sigma^2, \mathbf{\Delta}) &= -\frac{N}{2} \ln(2\pi\sigma^2) + n \ln |\mathbf{\Delta}| - \frac{1}{2} \sum_{j=1}^n \ln |\mathbf{G}(\beta, \mathbf{\Delta}, \mathbf{y}_j)| \\ &= \sum_{j=1}^n \left(\sum_{j_1=1}^{N_Q} \dots \sum_{j_q=1}^{N_Q} \exp \left\{ -g \left[\beta, \mathbf{\Delta}, \mathbf{y}_j, \tilde{\mathbf{b}}_j \right. \right. \right. \\ &\quad \left. \left. \left. + \sigma \mathbf{G}^{-1/2}(\beta, \mathbf{\Delta}, \mathbf{y}_j) \mathbf{z}_j \right] / (2\sigma^2) \right. \right. \\ &\quad \left. \left. \left. + \|\mathbf{z}_j\|^2 / 2 \right\} \prod_{k=1}^q w_{jk} \right)\end{aligned}$$

- A logverossimilhança acima pode ser maximizada através de algoritmos de otimização adequados.

Recursos computacionais

- As funções “nls” (default no R) e “nlme” (pacote nlme) ajustam, respectivamente, modelos não lineares e modelos não lineares mistos.
- A primeira estima os parâmetros via mínimos quadrados (ponderados) não lineares.
- A segunda o faz usando máxima verossimilhança ou máxima verossimilhança restrita.
- Um ponto interessante é que ambas solicitam que o usuário forneçam estimativas iniciais para os parâmetros do preditor não linear.

Cont.

- Há uma certa flexibilidade na escolha do preditor não linear.
- Ele pode ser escrito diretamente na função ou ser inserido como uma função.
- Em geral é melhor entrar com o preditor não linear como uma função na qual conste a respectiva derivada (auxilia na convergência dos algoritmos).
- Há a possibilidade de criar uma outra função através da função “selfStart” na qual é possível inserir o cálculo automático das estimativas iniciais.

Cont.

- Há vários preditores não lineares implementados com esse pacote (derivada e estimativa iniciais) já estão disponíveis na função (*input* : covariável, *dose* : valor inicial de interesse).

Nome	Modelo
SSasymp	$Asym + (R0 - Asym) * \exp(-\exp(lrc) * input)$
SSasympOff	$Asym * (1 - \exp(-\exp(lrc) * (input - c0)))$
SSasympOrig	$Asym * (1 - \exp(-\exp(lrc) * input))$
SSbiexp	$A1 * \exp(-\exp(lrc1) * input) + A2 * \exp(-\exp(lrc2) * input)$
SSfol	$Dose * \exp(IKe + IKa - ICl) * (\exp(-\exp(IKe) * input) - \exp(-\exp(IKa) * input)) * (\exp(IKa) - \exp(IKe))$

Cont.

- (x : covariável)


Nome	Modelo
SSfpl	$A + (B - A)/(1 + \exp((xmid - input)/scal))$
SSgompertz	$Asym * \exp(-b2 * b3^x)$
SSlogis	$Asym/(1 + \exp((xmid - input)/scal))$
SSmicmen	$Vm * input/(K + input)$
SSweibull	$Asym - Drop * \exp(-\exp(lrc) * x^{pwr})$

Voltando ao Exemplo 6


- Ajustou-se os modelos M_1 , M_2 e M_3 (não houve convergência para os modelo M_4 e M_5)
- $(M_1) : Y_{ij} = \phi_{1j} + \phi_2 \exp(\phi_3/w_{ij}) + \xi_{ij}$.
- $(M_2) : Y_{ij} = \phi_{1j} - \phi_2 (w_{ij} + \phi_3)^{-1} + \xi_{ij}$.
- $(M_3) : Y_{ij} = \phi_{1j} w_j^{\phi_2} + \xi_{ij}$.
- $\phi_{1j} = \phi_1 + b_j$, $b_j \stackrel{i.i.d.}{\sim} N(0, \psi)$.
- $\xi_{ij} \stackrel{i.i.d.}{\sim} N(0, \sigma^2)$, $\xi_{ij} \perp b_j$.

Resíduos normalizados com envelopes baseados na $N(0,1)$


Modelo M3






Modelo M1






Modelo M2



Valores individuais observados e preditos



Médias observadas e previstas (via valores preditos indiv.)



Estatísticas de comparação de modelos e somas de quadrados de resíduos

	AIC	BIC
M_3	-72,95	-64,20
M_2	-51,12	-41,18
M_1	-51,80	-40,85

M_3	M_2	M_1
0,915	0,924	0,924

Resíduos normalizados com envelopes baseados no modelo

Gráfico de quantil-quantil (modelo M3)




Gráfico de quantil-quantil (modelo M1)




Gráfico de quantil-quantil (modelo M2)

