

# Análise de Dados Longitudinais

## Modelos Lineares Generalizados Longitudinais

Enrico A. Colosimo-UFMG  
[www.est.ufmg.br/~enricoc](http://www.est.ufmg.br/~enricoc)

## Respostas Longitudinal Não-Gaussiana

1  $Y_{ij}$ ,  $i = 1, \dots, N$ ;  $j = 1, \dots, n$ : binária, contagem, etc.

2 Modelos Estatísticos

- Modelos Marginais: GEE
- Modelos Lineares Generalizados Mistos.

## Exemplos

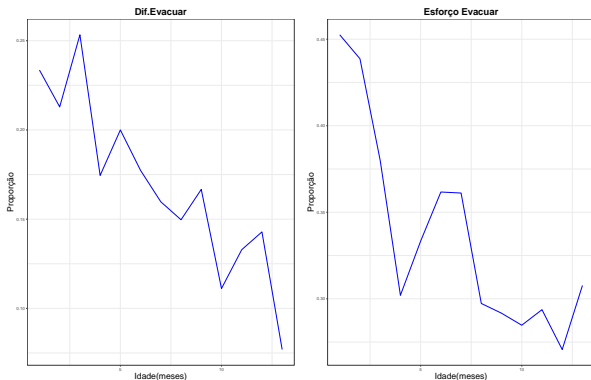
- 1 Mecanismo Evacuatório de Recém-Nascidos
- 2 Fatores de Risco Coronariano: MCRF (Muscatine Coronary Risk Factor), (FLW, pag. 364)

## Mecanismo Evacuatório de Recém-Nascidos

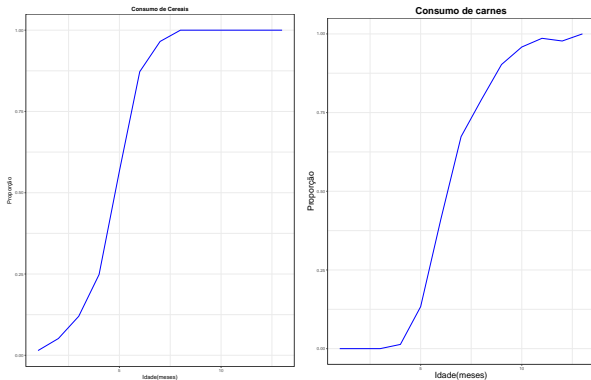
- 151 recém-nascidos foram acompanhados nos primeiros 12 meses de vida no Hospital das Clínicas da UFMG entre os anos de 2008 e 2009.
- Acompanhamento mensal totalizando 1751 medidas (61 perdas)
- Respostas: (1) Binárias: Dificuldade para evacuar, Esforço evacuatório, Dor ao evacuar e (2) Contagem: Frequência evacuatória/semana.
- Variável temporal: idade (em dias ou meses).
- Covariáveis: 1- fixa (sexo) e 2- dependentes do tempo: Aleitamento materno, dieta (0/1): cereais; frutas; vegetais, carnes, etc.
- Objetivo: avaliar o comportamento temporal das respostas e seus respectivos preditores.

## Resposta: Dificuldade e Esforço para Evacuar

Obs.: idade foi arredondada para mês (um único dígito).



## Covariáveis: Consumo de Cereais e de Carnes



## "Muscatine Coronary Risk Factor Study"

- Estudo longitudinal de crianças em idade escolar realizado em Muscatine, Iowa, Estados Unidos na década de 80.
- Cinco coortes de crianças, inicialmente com idades em 5-7, 7-9, 9-11, 11-13 e 13-15 foram acompanhadas bianualmente de 1977 a 1981 (3 medidas).
- Resposta binária: obesidade.
- Variável temporal: idade (em dias ou meses).
- Covariável: sexo.
- Objetivo: avaliar (1) se o risco de obesidade aumenta com a idade e (2) se os padrões de obesidade são os mesmos para meninos e meninas.

## "Muscatine Coronary Risk Factor Study"


---

Gênero	Coorte Idade	Obesidade ( %)		
		1977	1979	1981
Meninos				
	5-7	7.9	15.4	21.2
	7-9	18.8	20.5	23.7
	9-11	21.2	22.7	22.5
	11-13	24.3	21.8	19.4
	13-15	19.2	21.1	18.2
Meninas				
	5-7	14.0	17.2	25.1
	7-9	16.5	24.0	24.9
	9-11	25.4	26.2	22.2
	11-13	23.8	22.1	19.9
	13-15	22.9	25.8	20.9



---



## Resposta: Obesidade



# Estratificação por Sexo



## Revisão: Modelos Lineares Generalizados

Modelos Lineares Generalizados (MLG) é uma classe unificada de modelos de Regressão.

- 1 Considere  $Y_1, \dots, Y_N$  uma amostra aleatória de respostas univariadas (desenho transversal).
- 2 Um vetor de  $p$ -covariáveis associados a cada resposta  $Y_j$ . Ou seja

$$X_i = \begin{pmatrix} X_{i0} \\ X_{i1} \\ \vdots \\ X_{ip} \end{pmatrix}$$

em que  $X_{i0} = 1$ .

## Modelos Lineares Generalizados (MLG)

3 O MLG é definido por três componentes:

- Distribuição de  $Y_i$ .
- Componente Sistemático (preditor linear).

$$\eta_i = \mathbf{X}_i' \boldsymbol{\beta} = \beta_0 + \beta_1 \mathbf{X}_{i1} + \cdots + \beta_p \mathbf{X}_{ip}$$

- Função de Ligação.

## MLG - Família Exponencial

A distribuição de  $Y_i$  pertence a família exponencial que inclui os principais modelos estatísticos: normal, binomial, poisson, exponencial, etc.

Ou seja,

$Y_i$  tem densidade  $f(Y_i|\theta, \phi)$  pertencente a família exponencial.

$$f(y_i|\theta_i, \phi) = \exp\{\phi^{-1}(y_i\theta_i - \psi(\theta_i)) + c(y_i, \phi)\}$$

em que  $\theta_i$  é parâmetro natural,  $\phi$  é o de escala e específicas funções  $\psi(\cdot)$  e  $c(\cdot)$ .

## Modelos Lineares Generalizados

- $\psi(\cdot)$  é a função geradora de momentos

- $\mu = E(Y) = \psi'(\theta)$  e
- $Var(Y) = \phi\psi''(\theta)$

- Em geral, média e variância são relacionadas.

$$Var(Y) = \phi\psi''(\theta) \quad (\psi'^{-1}(\mu) = \theta)$$

- A função  $\nu(\mu)$  é chamada de função de variância.
- $\psi'^{-1}$  que relaciona  $\theta$  com  $\mu$  é chamada de função de ligação.

## Exemplos

### 1 Modelo Normal $(\mu, \sigma^2)$

- $\theta = \mu$
- $\phi = \sigma^2$
- $\psi(\theta) = \theta^2/2$
- Média:  $\mu = \theta$  e  $\nu(\mu) = 1$
- Observe que no modelo normal, média e variância não são relacionadas

$$\phi\nu(\mu) = \sigma^2$$

- Função de ligação natural:  $\theta = \mu$ .

### 2 Modelo Bernoulli ( $\pi$ )

- $\theta = \log(\pi/(1 - \pi))$
- $\phi = 1$
- $\psi(\theta) = \log(1 - \pi) = \log(1 + \exp(\theta))$
- Média:  $\mu = \pi = \frac{\exp(\theta)}{1 + \exp(\theta)}$  e  $\nu(\mu) = \pi(1 - \pi) = \frac{\exp(\theta)}{1 + \exp(\theta)^2}$
- Observe que no modelo bernoulli, média e variância são relacionadas

$$\phi\nu(\mu) = \mu(1 - \mu)$$

- Função de ligação natural:  $\theta = \log(\mu/(1 - \mu))$ .



## Função de Ligação Natural ou Canônica

$$g(\mu_i) = \eta_i = \mathbf{X}_i' \boldsymbol{\beta} = \beta_0 + \beta_1 \mathbf{X}_{i1} + \cdots + \beta_p \mathbf{X}_{ip}$$

- Gaussiano:  $g(\mu_i) = \eta_i$  (identidade)
- Bernoulli:  $g(\mu_i) = \text{logit}(\eta_i)$ .
- Poisson:  $g(\mu_i) = \log(\eta_i)$

## Inferência por MV

- Função de log-verossimilhança  $\log L(\cdot) = l(\cdot)$

$$L(\beta) = \prod_{i=1}^N f(y_i | \theta_i, \phi) = \prod_{i=1}^N \exp\{\phi^{-1}(y_i \theta_i - \psi(\theta_i)) + c(y_i, \phi)\}$$

- Equações escore: derivada de  $l(\cdot)$ .
- Inferência baseada na teoria assintótica de MV.

Referências: Dobson (1990) e Cordeiro e Demétrio (201?)

## Exemplo - Regressão Binária - Somente uma Medida

- Uma amostra de 100 indivíduos acompanhados por um período de cinco anos.
- Resposta: ocorrência de doença coronariana.
- Resposta para cada indivíduo foi sim (1) ou não (0).
- Covariável de interesse: 8 faixas etárias (idade): 20-29, ..., 60-69.
- Aconteceram 43 ocorrências de doença coronariana.

Ref: Giolo (2010) pg. 98- Introdução à Análise de Dados Categóricos.

## Entrada dos Dados

Existem duas formas de entrada dos dados para resposta binária.

- Forma 1: Uma linha para cada indivíduo:


indivíduo	faixa etária	resposta
1	1 (25)	0
.....	..	.
100	5 (47)	1
Total	...	43

## Entrada dos Dados

- Forma 2: Uma linha para cada combinação de covariáveis.

Faixa Etária	Sim	Não
20-29 (25)	1	9
30-34 (32)	2	13
35-39 (38)	3	9
40-44 (43)	5	10
45-49 (47)	6	7
50-54 (53)	5	3
55-59 (57)	13	4
60-69 (65)	8	2

## Descrição Gráfica por Faixa Etária



$$\text{logit}(\text{idade}_i) = \log\{\mu_i/(1 - \mu_i)\} = \beta_0 + \beta_1 \text{idade}_i$$

e

$$E(Y_i/\text{idade}_i) = P(Y_i = 1/\text{idade}_i)$$

O modelo logístico pode ser escrito como:

$$P(Y_i = 1/\text{idade}_i) = \frac{\exp(\beta_0 + \beta_1 \text{idade}_i)}{1 + \exp(\beta_0 + \beta_1 \text{idade}_i)}$$

## Resultados do Ajuste MV

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )	
(Intercept)	-5.25903	1.13739	-4.624	3.77e-06	***
idade	0.10904	0.02394	4.554	5.25e-06	***

Number of Fisher Scoring iterations: 4

```
> anova(ajust1, test="Chisq")
```

Terms added sequentially (first to last)

	Df	Deviance	Resid.	Df	Resid. Dev	Pr(>Chi)
NULL				7	28.7015	
idade	1	28.303		6	0.3984	1.037e-07 ***



## Resultados do Ajuste

Y: presença ou não de doença coronariana;

X: idade (em anos);

$n = 100$ .

Variável	Estimativa	E.P.	Wald
Idade	0,109	0,023	4,55 ( $p < 0,001$ )
Constante	-5,259	1,13	-4,62 ( $p < 0,001$ )

$$\hat{\pi}(x) = \frac{\exp(-5,25 + 0,109 \text{ idade})}{1 + \exp(-5,25 + 0,109 \text{ idade})}$$


$$\widehat{\text{logit}}(x) = -5,25 + 0,109 \text{ idade}$$

$$\log(\text{verossimilhança}) = \log L(\hat{\beta}_0, \hat{\beta}_1) = -10,76$$

Sob  $H_0 : \beta_1 = 0$ ,  $\log L(\hat{\beta}_0) = -24,92$ .

TRV =  $2(-10,76 + 24,91) = \text{Null Deviance} - \text{Residual Deviance} = 28,303$ .

## Modelo Estimado



## Interpretação dos Coeficientes

Interpretação: Razão de chances =  $\exp(0,109) = 1,11$  (1,06;1,17), isto significa que para o aumento de um ano na idade a chance de doença coronariana aumenta em 11%.

## Outras Funções de Ligação

- $Y$  tem uma Bernoulli.
- Outras funções de ligação:
  - $\pi(x) = \Phi(x)$  (probit)
  - $\pi(x) = \exp - \exp(x)$  (complemento log-log)
  - etc (qualquer função de distribuição)

## Modelos para Resposta Gaussiana Longitudinal

### 1 Modelo Marginal

$$Y_{ij} = X'_{ij}\beta + \varepsilon_{ij}$$

e

$$E(Y_{ij}|X_{ij}) = X'_{ij}\beta.$$

### 2 Modelo Condicional

$$Y_{ij} = X'_{ij}\beta + Z'_{ij}b_i + \varepsilon_{ij}$$

em que:

$(\beta)_{p \times 1}$  : efeitos fixos;

$(b_i)_{q \times 1}$  : efeitos aleatórios.

e,

$$b_i \sim N_q(0, \Sigma) \text{ e } \varepsilon_{ij} \sim N(0, \sigma^2)$$

Sendo  $b_i$  e  $\varepsilon_{ij}$  independentes.

## Modelos para Resposta Gaussiana

- Média Condicional ou Específica por Indivíduo

$$E(Y_{ij}|b_i, X_{ij}) = X'_{ij}\beta + Z'_{ij}b_i.$$

e a Covariância Marginal

$$\text{Var}(Y_i) = Z_i\Sigma Z'_i + \sigma^2 I_n.$$

## Modelos para Resposta Não-Gaussiana

- Extensão natural dos modelos lineares generalizados;
- Levar em consideração a variação intra-indivíduo;
- Duas classes de modelos:
  - Modelos Marginais: baseado na média da população;
  - Modelos de Efeitos Mistos: específico por indivíduo
- Interpretação dos coeficientes de regressão para os dois modelos:
  - Mesma para resposta contínua (gaussiana);
  - Diferente para resposta binária, poisson
- Escolha do modelo deve ser baseada nos objetivos do estudo.

## Modelos para Resposta Não-Gaussiana

- 1  $\mu_{ij} = E(Y_{ij}|X_{ij})$  (modelo marginal)  
 $\mu_{ij} = E(Y_{ij}|b_i, X_{ij})$  (modelo condicional).

2 Modelo Bernoulli

- $Y_{ij}$  : 0/1 (Bernoulli)
- função de ligação: logit (mais comum)

$$\text{logit}(\mu_{ij}) = X'_{ij}\beta \quad \text{Modelo Marginal}$$

$$\text{logit}(\mu_{ij}) = X'_{ij}\beta + Z'_{ij}b_i \quad \text{Modelo Condicional}$$



### 3 Modelo Poisson

- $Y_{ij}$  :contagem (Poisson)
- função de ligação: logarítmica (mais comum)

$$\log(\mu_{ij}) = X'_{ij}\beta \quad \text{Modelo Marginal}$$

$$\log(\mu_{ij}) = X'_{ij}\beta + Z'_{ij}b_i \quad \text{Modelo Condicional}$$

## Modelos Lineares Generalizados Longitudinais

- 1 Fácil transferência entre modelos (marginal e condicional) para resposta gaussiana.
- 2 Transferência difícil entre modelos quando a resposta não é gaussiana.
- 3 Modelos Marginais
  - Especificação completa: o ajuste por MV pode ser complicado.
  - Alternativa Não-Verossimilhança: MQG, GEE, etc.
- 4 Modelos Condicionais: ajuste complicado.


- 1 Equações de Estimação Generalizadas (Modelo Marginal)
- 2 Modelos Lineares Mistos Generalizados (Modelo de Efeitos Aleatórios)

## Modelando a Média

- Necessitamos modelar a média em ambos modelos;
- Usamos Análise Exploratória para propor uma forma paramétrica;
- Precisamos fazer os gráficos na escala da função de ligação.


## Resposta Binária: Dificuldade para Evacuar

Obs.: idade foi arredondada para mês (um único dígito).



## Resposta Contagem: Freq. Evac / semana


Obs.: idade foi arredondada para mês (um único dígito).



## "Muscatine Coronary Risk Factor Study"

Gênero	Coorte Idade	Obesidade ( %)		
		1977	1979	1981
Meninos				
	5-7	7.9	15.4	21.2
	7-9	18.8	20.5	23.7
	9-11	21.2	22.7	22.5
	11-13	24.3	21.8	19.4
	13-15	19.2	21.1	18.2
Meninas				
	5-7	14.0	17.2	25.1
	7-9	16.5	24.0	24.9
	9-11	25.4	26.2	22.2
	11-13	23.8	22.1	19.9
	13-15	22.9	25.8	20.9

## Resposta binária: obesidade - Escala logit





## Modelos Marginais: GEE (Liang e Zeger, 1986)

- Modelo Marginal significa que a média (populacional) depende somente das covariáveis de interesse.
- Em outras palavras, a média não incorpora dependência através de efeitos aleatórios nem de repostas em tempos anteriores.
- Não é necessário assumir distribuição conjunta para a resposta  $Y_i$ : GEE.
- Não é necessário ser balanceado.
- Assume que a distribuição marginal pertence a classe dos modelos lineares generalizados.

## Modelos Marginais: GEE

### Equações de Estimação Generalizadas

$$\sum_{i=1}^N D_i' V_i^{-1} (Y_i - \mu_i) = 0,$$

em que

- $D_i = \partial \mu_i / \partial \beta$  e  $\mu_i = g^{-1}(X_i \beta)$ , ou seja, o inverso da função de ligação  $g$ .

- 

$$\text{Var}(Y_i) = V_i = \phi A_i^{1/2}(\beta) R_i(\alpha) A_i^{1/2}(\beta)$$

em que  $A_i$  é uma matriz diagonal formada por  $\text{Var}(Y_{ij})$ ,  $R_i$  é matriz de correlação de trabalho e  $\phi$  é um parâmetro de dispersão/escala.

- $\text{Var}(\hat{\beta})$  é estimada pela variância robusta (estimador sanduiche).

## Formas de Correlação de Trabalho

- *independência*,  $\mathbf{R}_i(\alpha) = \mathbf{I}_n$ ;  
⇒ dados longitudinais não correlacionados.
- *simetria composta*, especifica que  $\mathbf{R}_i(\alpha) = \rho \mathbf{1}_n \mathbf{1}'_n + (1 - \rho) \mathbf{I}_n$ ;  
⇒ mesma correlação.
- *AR-1*, para a qual  $\mathbf{R}_i(\alpha) = \rho^{|j-j'|}$ ;  
⇒ válida para medidas igualmente espaçadas no tempo;
- *não estruturada* estima todas as  $n(n - 1)/2$  correlações de  $\mathbf{R}$ .

## Variância do Estimador

- 1 *Naive* ou “baseada no modelo”

$$\widehat{\text{Var}}(\hat{\beta}) = \left( \sum_{i=1}^N \hat{\mathbf{D}}_i' \mathbf{V}_i(\hat{\alpha})^{-1} \hat{\mathbf{D}}_i \right)^{-1}. \quad (1)$$

- 2 *Robusta* ou “empírica”

$$\widehat{\text{Var}}(\hat{\beta}) = \mathbf{M}_0^{-1} \mathbf{M}_1 \mathbf{M}_0^{-1}, \quad (2)$$

em que

$$\mathbf{M}_0 = \sum_{i=1}^N \hat{\mathbf{D}}_i' \mathbf{V}_i(\hat{\alpha})^{-1} \hat{\mathbf{D}}_i,$$

$$\mathbf{M}_1 = \sum_{i=1}^N \hat{\mathbf{D}}_i' \mathbf{V}_i(\hat{\alpha})^{-1} (\mathbf{y}_i - \hat{\mu}_i)(\mathbf{y}_i - \hat{\mu}_i)' \mathbf{V}_i(\hat{\alpha})^{-1} \hat{\mathbf{D}}_i.$$

## Exemplo: Bernoulli-logit

1  $\mu_{ij} = E(Y_{ij}) = P(Y_{ij} = 1).$

2 
$$\text{logit}(\mu_{ij}) = \log(\mu_{ij}/(1 - \mu_{ij})) = \mathbf{X}'_{ij}\beta$$

$$\mu_{ij} = \frac{e^{\mathbf{X}'_{ij}\beta}}{1 + e^{\mathbf{X}'_{ij}\beta}}$$

3 
$$\text{Var}(Y_{ij}) = \mu_{ij}(1 - \mu_{ij})$$

4 
$$\nu_{ij} = \mu_{ij}(1 - \mu_{ij}) \quad \mathbf{A}_i = \text{diag}(\nu_{i1}, \nu_{i2}, \dots, \nu_{in})$$

## Exemplo: Poisson-log

1  $\log(\mu_{ij}) = X'_{ij}\beta.$

$$\mu_{ij} = e^{X'_{ij}\beta}$$

2

$$\text{Var}(Y_{ij}) = \mu_{ij} = e^{X'_{ij}\beta}$$

3

$$\nu_{ij} = e^{X'_{ij}\beta} = \mu_{ij}$$

## Estimando a Correlação de Trabalho

- Liang e Zeger (1986) utilizaram estimativas de momento para os parâmetros da matriz de correlação de trabalho.
- Ou seja, utilizar estimadores baseados nos resíduos para as quantidades envolvidas em  $R_i$ .
- Resíduos de Pearson:

$$e_{ij} = \frac{y_{ij} - \hat{\mu}_{ij}}{\sqrt{\hat{\nu}_{ij}}},$$

em que  $\nu_{ij} = \mu_{ij}(1 - \mu_{ij})$  para resposta binária e  $\nu_{ij} = \mu_{ij}$ , para contagem.

## Estimadores de Momento usando Resíduos

Estrutura	$Cor(Y_{ij}, Y_{il})$	Estimativa
Independência	0	-
Simetria Composta	$\alpha$	$\hat{\alpha} = 1/N \sum_{i=1}^N 1/(n(n-1)) \sum_{j \neq l} \mathbf{e}_{ij} \mathbf{e}_{il}$
AR1	$\alpha$	$\hat{\alpha} = 1/N \sum_{i=1}^N 1/(n-1) \sum_{j \leq k-1} \mathbf{e}_{ij} \mathbf{e}_{ij+1}$
Não Estruturada	$\alpha_{jl}$	$\hat{\alpha}_{jl} = 1/N \sum_{i=1}^N \mathbf{e}_{ij} \mathbf{e}_{il}$

$$\hat{\phi} = \frac{1}{N} \sum_{i=1}^N \frac{1}{n} \sum_{i=1}^n \mathbf{e}_{ij}^2$$



## Ajustando GEE

- 1 Use MLE para encontrar a estimativa inicial para  $\beta$  (assumindo independência)
- 2 Encontre os resíduos e estime  $\alpha$  e  $\phi$ .
- 3 Faça iterações em 1-2 até a convergência.
- 4 Estime  $Var(\hat{\beta})$  usando o estimador sanduíche.

## Teste de hipóteses - GEE

- 1 Não existe TRV pois não temos função de verossimilhança.
- 2 Testes e Intervalos de confiança são baseados na estatística de Wald

3

$$H_0 : C\beta = 0 \quad \text{vs} \quad H_1 : C\beta \neq 0$$

para  $C$  de posto  $q < p$ .

$$Q = (C\hat{\beta})'(C\widehat{\text{Var}}(\hat{\beta})C')^{-1}(C\hat{\beta})$$

$Q$  sob  $H_0$  tem uma distribuição qui-quadrado limite com  $q$  graus de liberdade.

- 4 o comando `anova` no pacote `geepack` faz este teste.

## Mecanismo Evacuatório de Recém-Nascidos

- 151 recém-nascidos acompanhados nos primeiros 12 meses de vida no Hospital das Clínicas da UFMG em 2010 e 2011.
- Acompanhamento mensal totalizando 1751 medidas (61 perdas)
- Resposta: Binárias: Dificuldade para evacuar.
- Variável temporal: idade (em dias ou meses).
- Covariáveis: 1- fixa (sexo) e 2- dependentes do tempo: Aleitamento materno, dieta (0/1): cereais; frutas; vegetais, carnes, etc.
- Objetivo: avaliar o comportamento temporal das respostas e seus respectivos indicadores.

## Resultados do Ajuste GEE - Resposta binária

```
geeglm(formula = difpevac ~ sexo + idademeses + aleitamcod3,  
        family = binomial(link = "logit"), data = dados, id = Paciente,  
        corstr = "exchangeable", std.err = "san.se")
```

Coefficients:

	Estimate	Std.err	Wald	Pr(> W )	
(Intercept)	-0.9275	0.2182	18.07	2.1e-05	***
sexo1	-0.4858	0.2287	4.51	0.03362	*
idademeses	-0.1240	0.0338	13.49	0.00024	***
aleitamcod31	0.2286	0.2300	0.99	0.32030	
aleitamcod32	0.7969	0.3037	6.88	0.00870	**

---

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

Estimated Scale Parameters:

	Estimate	Std.err
(Intercept)	1.02	0.189

Correlation: Structure = exchangeable Link = identity

Estimated Correlation Parameters:

	Estimate	Std.err
alpha	0.207	0.058

Number of clusters: 151 Maximum cluster size: 12

## Resultados do Ajuste

Y: (0=não /1=sim) Dificuldade para evacuar

X: Covariáveis: (1) idade em meses: (2) sexo (0-menina e 1- menino), (3) consumo de cereais (0-não e 1-sim), (4) consumo de carne (0-não e 1-sim) e (5) aleitamento materno (0-peito, 1-misto e 2-artificial)).

$n = 151$  pacientes e 1751 medições.

Variável	Estimativa	E.P.	Wald
Idade	-0,124	0,038	13,49 ( $p < 0,001$ )
Sexo(Menino)	-0,485	0,22	4,51 ( $p = 0,033$ )
Aleitamento(Misto)	0,228	0,23	0,99 ( $p = 0,32$ )
Aleitamento(Artificial)	0,796	0,30	6,88 ( $p = 0,008$ )
Constante	-0,927	0,218	

## Interpretação dos Coeficientes

- Idade: Razão de chances =  $\exp(-0,124) = 0,83$  (0,81;0,95), isto significa que com o aumento de um ano na idade a chance de dificuldade em evacuar reduz em 17%;
- Sexo: Razão de chances =  $\exp(-0,485) = 0,615$  (0,40;0,947), isto significa que a chance de meninos terem dificuldade em evacuar é 39% menor do a chance das meninas.
- Aleitamento: Razão de chances =  $\exp(0,796) = 2,22$  (1,23;3,99), isto significa que a chance de recém nascidos que tiveram aleitamento artificial ter dificuldade em evacuar é 2,2 vezes a chance daqueles que tiveram aleitamento no peito.

## Ajustando GEE-Poisson

Call:

```
geeglm(formula = freqevac ~ idade meses + aleitamcod3 + carnes,  
        family = poisson(link = "log"), data = dados, id = Paciente,  
        corstr = "exchangeable", std.err = "san.se")
```

Coefficients:

	Estimate	Std.err	Wald	Pr(> W )	
(Intercept)	3.16227	0.05633	3151.97	< 2e-16	***
idade meses	-0.03185	0.00737	18.67	1.6e-05	***
aleitamcod31	-0.31691	0.05209	37.02	1.2e-09	***
aleitamcod32	-0.19479	0.05925	10.81	0.001	**
carnes1	0.12056	0.04812	6.28	0.012	*

---

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

Estimated Scale Parameters:

	Estimate	Std.err
(Intercept)	5.59	0.399

Correlation: Structure = exchangeable Link = identity

Estimated Correlation Parameters:

	Estimate	Std.err
alpha	0.303	0.039

Number of clusters: 151 Maximum cluster size: 12

## Resultados do Ajuste - Resposta Contagem - Modelo Poisson

Y: Frequência evacuatória (número de evacuações/semana)

X: Covariáveis: (1) idade em meses: (2) sexo (0-menina e 1- menino), (3) consumo de cereais (0-não e 1-sim), (4) consumo de carne (0-não e 1-sim) e (5) aleitamento materno(0-peito, 1-misto e 2-artificial)).

$n = 151$  pacientes e 1751 medições.

Variável	Estimativa	E.P.	Wald
Idade	-0,031	0,007	18,67 ( $p < 0,001$ )
Carne(Sim)	0,12	0,04	6,28 ( $p = 0,012$ )
Aleitamento(Misto)	-0,316	0,052	37,02 ( $p < 0,001$ )
Aleitamento(Artificial)	-0,194	0,048	10,81 ( $p = 0,001$ )
Constante	3,16	0,056	



## Interpretação dos Coeficientes

- Idade: Razão de frequências evacuatórias =  $\exp(-0,031) = 0,96$  (0,95;0,98), isto significa que com o aumento de um ano na idade a frequência evacuatória semanal diminui em 4%.
- Carne: Razão de frequências evacuatórias =  $\exp(0,12) = 1,12$  (1,04;1,22), isto significa que a frequência evacuatória semanal em recém nascidos que consomem carne é 12% maior do que aqueles que não consomem carne em sua dieta.
- Aleitamento materno: Razão de frequências evacuatórias =  $\exp(-0,316) = 0,73$  (0,658;0,807), isto significa que a frequência evacuatória semanal de recém nascidos que tiveram aleitamento misto é 27% menor do que aqueles que foram amamentados no peito.
- Razão de frequências evacuatórias =  $\exp(-0,194) = 0,82$  (0,749;0,904), isto significa que a frequência evacuatória semanal de recém nascidos que tiveram aleitamento artificial é 18% menor do que aqueles que tiveram amamentamento no peito.

# Modelos Lineares Generalizados Mistos

## 1 GEE

- Média e Covariância são modeladas separadamente.
- Interpretação dos coeficientes é a nível populacional.

## 2 Modelos Lineares Generalizados Mistos

- Forma alternativa de tratar a associação intra-indivíduo é introduzindo efeitos aleatórios.
- O efeito aleatório reflete uma heterogeneidade entre indivíduos e induz uma estrutura de correlação para as medidas repetidas.
- Produz dificuldades conceituais (interpretação) e analíticas. Interpretações específicas de indivíduos/clusters.

# Modelos Lineares Generalizados Mistos

## 1 Modelos Lineares Generalizados

- Resposta na família exponencial: normal, gama, exponencial, Bernoulli, Poisson, etc.
- Preditor Linear:  $\eta_i = X_i' \beta$ .
- Função de Ligação:  $g(\mu_i) = X_i' \beta$ .

## 2 Modelos Lineares Generalizados Mistos

Preditor Linear:

$$\eta_{ij} = X_{ij}' \beta + Z_{ij}' b_i,$$

em que:

$(\beta)_{p \times 1}$  : efeitos fixos;

$(b_i)_{q \times 1}$  : efeitos aleatórios.

## Modelos Linear Misto Longitudinal

- Modelo Linear Misto:

$$Y_{ij} = X'_{ij}\beta + Z'_{ij}b_i + \varepsilon_{ij}$$

ou

$$Y_i = X_i\beta + Z_i b_i + \varepsilon_i$$

- Média Condicional (Preditor Linear)

$$E(Y_{ij}|b_i) = X'_{ij}\beta + Z'_{ij}b_i$$

.

- Média Populacional (marginal)

$$E(Y_{ij}) = X_i\beta$$

.

## Modelos Generalizado Misto Longitudinal

### 1 Família Exponencial

- Distribuição condicional  $Y_{ij}/b_i$  pertence a família exponencial.
- Dado os efeitos aleatórios,  $Y_{ij}$  e  $Y_{ij'}$ , para  $j \neq j'$ , são independentes (independência condicional).

### 2 Função de Ligação

$$g(E(Y_{ij}|b_i)) = X'_{ij}\beta + Z'_{ij}b_i$$

### 3 Distribuição dos Efeitos Aleatórios

$$b_i \sim N_q(0, \Sigma) \text{ e } \varepsilon_{ij} \sim N(0, \sigma^2)$$

Sendo  $b_i$  e  $\varepsilon_{ij}$  independentes.

## Modelos Generalizado Misto para Respostas Binárias

- Distribuição condicional  $Y_{ij}/b_i$  tem distribuição Bernoulli com:
  - $E(Y_{ij}/b_i) = P(Y_{ij} = 1/b_i)$ ;
  - $Var(Y_{ij}/b_i) = E(Y_{ij}/b_i)(1 - E(Y_{ij}/b_i))$ ;
  - $\phi = 1$ .
- Função de Ligação (logit)

$$g(E(Y_{ij}|b_i)) = \log(P(Y_{ij} = 1/b_i)/P(Y_{ij} = 0/b_i)) = X'_{ij}\beta + Z'_{ij}b_i$$

## Modelos Generalizado Misto para Respostas de Contagem

- Distribuição condicional  $Y_{ij}/b_i$  tem distribuição de Poisson com:
  - $Var(Y_{ij}/b_i) = E(Y_{ij}/b_i)$ ;
  - $\phi = 1$ .
- Função de Ligação (logit)

$$g(E(Y_{ij}|b_i)) = \log(E(Y_{ij}/b_i)) = X'_{ij}\beta + Z'_{ij}b_i$$

## Função de Verossimilhança

$$\begin{aligned}L(\theta/y) &= \prod_{i=1}^N p(y_i/\theta) \\ &= \prod_{i=1}^N \int p(y_i, b_i/\theta) db_i \\ &= \prod_{i=1}^N \int p(y_i/b_i, \theta) p(b_i/\theta) db_i \\ &= \prod_{i=1}^N \int \prod_{j=1}^n p(y_{ij}/b_i, \theta) p(b_i/\theta) db_i\end{aligned}$$

em que,

$p(y_i/b_i, \theta) \sim$  Bernoulli-logit/Poisson-log, etc

e

$p(b_i/\theta) \sim N_q(0, \Sigma)$



## Solução

- No modelo linear-normal, a integral pode ser resolvida analiticamente.
- Em geral, aproximações são necessárias no caso não-normal.
- Aproximação do integrando: Laplace
- Aproximação dos dados
- Aproximação da integral: quadratura gaussiana.

Usualmente, a combinação normal-logit não tem solução simples.

## Interpretação dos Parâmetros do Modelo

- Os parâmetros  $\beta$  não tem interpretação populacional, como aqueles do modelo marginal.
- Os parâmetros  $\beta$  têm interpretação específica de indivíduo/sujeito.
- Ou seja, eles representam o efeito de covariáveis na resposta média de um específico indivíduo.
- Por exemplo, na regressão logística com efeito aleatório no intercepto e somente um regressor  $x$ :

$$\log(P(Y_{ij} = 1/b_i, X = x)/P(Y_{ij} = 0/b_i, X = x)) = b_i + \beta x$$

## Interpretação dos Parâmetros do Modelo

- No modelo linear misto, as interpretações populacional (marginal) e específica (condicional) são equivalentes.

$$\begin{aligned}E(Y_{ij}|X_{ij}) &= E(E(Y_{ij}|X_{ij}, b_i)) \\ &= E(X'_{ij}\beta + Z'_{ij}b_i) \\ &= X'_{ij}\beta\end{aligned}$$

- Nos modelos lineares generalizados em que a função de ligação não é a identidade (não-linear) esta relação não vale.

Ou seja,

$$g(E(Y_{ij}|b_i)) = \log(E(Y_{ij}/b_i)) = X'_{ij}\beta + Z'_{ij}b_i$$

$$g(E(Y_{ij}|b_i)) \neq X'_{ij}\beta$$

## Interpretação dos Parâmetros do Modelo

- De forma a termos a interpretação usual de  $RC = e^{\beta}$  para o aumento em uma unidade de  $X$ , devemos cancelar o efeito aleatório  $b_j$ .
- Daí,  $\beta$  é o log odds da resposta por aumento de uma unidade em  $X$ , para qualquer indivíduo tendo uma propensão de resposta positiva  $b_i$ .
- Coeficientes de regressão específico por indivíduos. MLGM são, portanto, mais úteis quando o objetivo científico é fazer inferência em indivíduos ao invés de médias populacionais.
- Tais interpretações ficam sem sentido se as covariáveis forem entre indivíduos, por exemplo, gênero ou tratamento.

## Interpretação dos Parâmetros

- Portanto, as estimativas dos modelos são diferentes.
- Em casos mais simples, os parâmetros apresentam uma relação.
- Por exemplo, modelo logístico com somente intercepto aleatório,

$$\frac{\hat{\beta}^{EA}}{\hat{\beta}^M} = \sqrt{c^2 \sigma_{\beta_0}^2 + 1} > 1$$

em que

$$c = \frac{16\sqrt{3}}{15\pi} = 0,346$$

## Interpretação dos Parâmetros

Exemplo: Razão de Chances - Modelo Logit-normal

$$\begin{aligned} \text{RC} &= \frac{P(Y_i = 1|X_i = x + 1)/P(Y_i = 0|X_i = x + 1)}{P(Y_i = 1|X_i = x)/P(Y_i = 0|X_i = x)} \\ &= b_j + \beta(x + 1) - (b_l + \beta x) \\ &= \beta + (b_j - b_l) \end{aligned}$$

## Ajuste do Modelo

- Parte numérica complicada pois é necessário encontrar um máximo da função de verossimilhança que envolve uma integral.
- Em particular, a função de ligação logística e a distribuição normal não possuem boa relação.
- O pacote lme4 do R é o usualmente utilizado para ajuste dos MLGM.
- A função lmer é usada para este propósito.

Basic syntax,

```
lmer(formula, data, family=NULL, REML=TRUE)
```

- Exemplos:
  - Random intercept `lmer( Y ~ age + (1 | Id), data=dados)`
  - Random intercept and slope `lmer(Y ~ age + (age | id), data=dados)`

## Mecanismo Evacuatório de Recém-Nascidos

- 151 recém-nascidos acompanhados nos primeiros 12 meses de vida no Hospital das Clínicas da UFMG em 2010 e 2011.
- Acompanhamento mensal totalizando 1751 medidas (61 perdas)
- Resposta: Binárias: Dificuldade para evacuar.
- Variável temporal: idade (em dias ou meses).
- Covariáveis: 1- fixa (sexo) e 2- dependentes do tempo: Aleitamento materno, dieta (0/1): cereais; frutas; vegetais, carnes, etc.
- Objetivo: avaliar o comportamento temporal das respostas e seus respectivos indicadores.



## Ajustando Modelo Misto - Resposta binária

```
Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
Family: binomial ( logit )
Formula: difpevac ~ (1 | Paciente) + aleitamcod3 + sexo * idademeses
Data: dados
```

AIC	BIC	logLik	deviance	df.resid
1427	1465	-706	1413	1743

Scaled residuals:

Min	1Q	Median	3Q	Max
-2.050	-0.412	-0.254	-0.169	4.315

Random effects:

Groups	Name	Variance	Std.Dev.
Paciente	(Intercept)	1.89	1.38

Number of obs: 1750, groups: Paciente, 151

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )	
(Intercept)	-0.9897	0.2665	-3.71	0.00020	***
aleitamcod31	0.3089	0.2335	1.32	0.18587	
aleitamcod32	1.0345	0.3138	3.30	0.00098	***
sexo1	-1.2812	0.3867	-3.31	0.00092	***
idademeses	-0.2085	0.0353	-5.92	3.3e-09	***
sexo1:idademeses	0.1155	0.0437	2.64	0.00823	**

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

## Resultados do Ajuste

Y: (0=não /1=sim) Dificuldade para evacuar

X: Covariáveis: (1) idade em meses: (2) sexo (0-menina e 1- menino), (3) consumo de cereais (0-não e 1-sim), (4) consumo de carne (0-não e 1-sim) e (5) aleitamento materno (0-peito, 1-misto e 2-artificial)).

$n = 151$  pacientes e 1751 medições.

Parte fixa:

Variável	Estimativa	E.P.	Z
Idade	-0,208	0,03	-5,92 ( $p < 0,001$ )
Sexo(Menino)	-1,281	0,38	-3,31 ( $p < 0,001$ )
Aleitamento(Misto)	0,308	0,23	1,32 ( $p = 0,18$ )
Aleitamento(Artificial)	1,034	0,31	3,30 ( $p < 0,001$ )
Idade*Sexo(Masculino)	0,115	0,04	2,64 ( $p = 0,008$ )
Constante	-0,927	0,218	18,07 ( $p < 0,001$ )

Variância estimada da parte aleatória é 1,89 e o desvio padrão correspondente é 1,38.

## Ajustando Modelo Misto-Poisson

```
Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
Family: poisson ( log )
Formula: freqevac ~ (1 | Paciente) + sexo + idade meses + cereais + aleitamcod3 +      carnes
Data: dados
      AIC      BIC  logLik deviance df.resid
      Inf      Inf    -Inf      Inf      1743
Random effects:
Groups   Name      Std.Dev.
Paciente (Intercept) 1
Number of obs: 1751, groups: Paciente, 151
Fixed Effects:
(Intercept)      sexo1      idade meses      cereais1      aleitamcod31      aleitamcod32      carnes1
      3.0092      0.2066      -0.0366      0.1083      -0.3674      -0.2381      0.0901
convergence code 0; 1 optimizer warnings; 13000 lme4 warnings
```

## Resultados do Ajuste - Modelo Misto-Binomial Negativo

Y: Freqüência evacuatória (número de evacuações/semana)

X: Covariáveis: (1) idade em meses: (2) sexo (0-menina e 1- menino), (3) consumo de cereais (0-não e 1-sim), (4) consumo de carne (0-não e 1-sim) e (5) aleitamento materno(0-peito, 1-misto e 2-artificial)).

$n = 151$  pacientes e 1751 medições.

Parte fixa:

Variável	Estimativa	E.P.	Z
Idade	-0,029	0,006	-4,91 ( $p < 0,001$ )
Carnes(Sim)	0,136	0,043	3,11 ( $p = 0,001$ )
Aleitamento(Misto)	-0,316	0,039	-7,96 ( $p < 0,001$ )
Aleitamento(Artificial)	-0,198	0,056	-3,51 ( $p < 0,001$ )
Constante	3,058	0,049	62,18 ( $p < 0,001$ )

Variância estimada da parte aleatória é 0,106 e o desvio padrão correspondente é 0,325.

## Ajustando Modelo Misto-Binomial Negativo

```
Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']  
Family: Negative Binomial(5.54) ( log )  
Formula: freqevac ~ (1 | Paciente) + sexo + idade meses + aleitamcod3 + carnes  
Data: dados
```

AIC	BIC	logLik	deviance	df.resid
12237	12281	-6110	12221	1743

Scaled residuals:

Min	1Q	Median	3Q	Max
-2.013	-0.672	-0.057	0.499	5.770

Random effects:

Groups	Name	Variance	Std.Dev.
Paciente	(Intercept)	0.106	0.325

Number of obs: 1751, groups: Paciente, 151

Fixed effects:


	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	3.05817	0.04918	62.18	< 2e-16 ***
sexo1	0.04932	0.05766	0.86	0.39238
idade meses	-0.02922	0.00694	-4.21	2.6e-05 ***
aleitamcod31	-0.31619	0.03973	-7.96	1.7e-15 ***
aleitamcod32	-0.19843	0.05651	-3.51	0.00045 ***
carnes1	0.13620	0.04385	3.11	0.00189 **

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

## Estudo de Caso: "Muscatine Coronary Risk Factor Study"

- Estudo longitudinal de crianças em idade escolar realizado em Muscatine, Iowa, Estados Unidos na década de 80.
- Cinco coortes de crianças, inicialmente com idades em 5-7, 7-9, 9-11, 11-13 e 13-15 foram acompanhadas bianualmente de 1977 a 1981 (3 medidas).
- Resposta binária: obesidade (sim/não).
- Variável temporal: idade (em dias ou meses).
- Covariável: sexo.
- Objetivo: avaliar (1) se o risco de obesidade aumenta com a idade e (2) se os padrões de obesidade são os mesmos para meninos e meninas.

## Resposta: Obesidade na escala logit



## Modelo Completo: efeito de interação e coorte

$$\begin{aligned}\text{logit}(X_{ij}) &= \beta_1 + \beta_2 \text{sexo}_i + \beta_3 \text{idade}_{i1} + \beta_4 \text{idade}_{i1}^2 \\ &+ \beta_5 \text{sexo}_i \times \text{idade}_{i1} + \beta_6 \text{sexo}_i \times \text{idade}_{i1}^2 \\ &+ \beta_7 (\text{idade}_{ij} - \text{idade}_{i1}) + \beta_8 (\text{idade}_{ij}^2 - \text{idade}_{i1}^2) \\ &+ \beta_9 \text{sexo}_i \times (\text{idade}_{ij} - \text{idade}_{i1}) + \beta_{10} \\ &+ \text{sexo}_i \times (\text{idade}_{ij}^2 - \text{idade}_{i1}^2)\end{aligned}$$

### Teste para efeito de coorte

$$H_0 : \beta_3 - \beta_7 = \beta_4 - \beta_8 = \beta_5 - \beta_9 = \beta_6 - \beta_{10} = 0$$

```
> anova(out0,out)
Analysis of 'Wald statistic' Table
```

```
Model 1 Y ~ GENDER + age1 + I(age1^2) + GENDER:age1 + GENDER:I(age1^2) + I(AGE - age1) + I(AGE^2 -
Model 2 Y ~ AGE + I(AGE^2) + GENDER + AGE:GENDER + I(AGE^2):GENDER
  Df  X2 P(>|Chi|)
1  4 2.02      0.73
```



## Modelo - Sem efeito de coorte

$$\begin{aligned}\text{logit}(X_{ij}) &= \beta_1 + \beta_2 \text{sexo}_i + \beta_3 \text{idade}_{ij} + \beta_4 \text{idade}_{ij}^2 \\ &+ \beta_5 \text{sexo}_i \times \text{idade}_{ij} + \beta_6 \text{sexo}_i \times \text{idade}_{ij}^2\end{aligned}$$

### Teste para efeito de interação

$$H_0 : \beta_5 = \beta_6 = 0$$

```
> anova(out, out1)
```

```
Analysis of 'Wald statistic' Table
```

```
Model 1 Y ~ AGE + I(AGE^2) + GENDER + AGE:GENDER + I(AGE^2):GENDER
```

```
Model 2 Y ~ AGE + GENDER + I(AGE^2)
```

```
  Df  X2 P(>|Chi|)  
1  2 0.96      0.62
```

## Resultados do Ajuste GEE - Resposta binária obesidade

```
geeglm(formula = Y ~ AGE + I(AGE^2) + GENDER, family = binomial(link = "logit"),
  data = dados, id = ID, corstr = "exchangeable", std.err = "san.se")
```

Coefficients:

	Estimate	Std.err	Wald	Pr(> W )	
(Intercept)	-3.98900	0.33954	138.0	< 2e-16	***
AGE	0.41856	0.05632	55.2	1.1e-13	***
I(AGE^2)	-0.01570	0.00231	46.3	1.0e-11	***
GENDER	0.14713	0.06271	5.5	0.019	*

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

Correlation structure = exchangeable

Estimated Scale Parameters:

	Estimate	Std.err
(Intercept)	0.991	0.0271

Link = identity

Estimated Correlation Parameters:

	Estimate	Std.err
alpha	0.543	0.0209

Number of clusters: 4856 Maximum cluster size: 3

## Resultados do Ajuste

Y: (0=não/1=sim) Obesidade


X: Covariáveis: idade em anos:(2) sexo (0-menino e 1- menina).  $n = 4856$  pacientes e 14568 medições.

Variável	Estimativa	E.P.	Wald
Idade	0.419	0,056	55.2 ( $p < 0,001$ )
Idade <sup>2</sup>	-0.016	0.0023	46.3 ( $p < 0,001$ )
Sexo(Menina)	0,147	0,063	5,5 ( $p = 0,019$ )

## Interpretação dos Coeficientes

- Idade: Razão de chances muda de idade
  - mudando de 9 para 10 anos;  
 $RC = \exp(2.62 - 2.5) = 1,13$ , aumento em 13% a obesidade,
  - mudando de 13 para 14 anos  
 $RC = 1$ , não tem mudança.
  - mudando de 15 para 16 anos;  
 $RC = \exp(2.62 - 2.75) = 0,88$ , redução em 12% a obesidade,
- Sexo: Razão de chances =  $\exp(-0,150) = 1,16$  (1,03;1,31), isto significa que a chance de meninas serem obesas é 16% maior que a chance dos meninos.

## Resposta: Obesidade



## Ajustando Modelo Misto - Resposta binária: obesidade

- Modelo misto tem interpretação específica por indivíduo.
- Frequentemente, existem problemas numéricos no ajuste dos modelos mistos, especialmente o binário com ligação logit.
- Componente fixo em idade apresenta um comportamento não-linear. Vamos continuar utilizando o termo quadrático. Vamos centrar idade na média para evitar o efeito de colinearidade, que torna mais sério o problema numéricos.
- Iremos utilizar duas estruturas de efeitos aleatórios: (1) somente no intercepto; (2) intercepto e inclinação.

## Ajustando Modelo Misto - Resposta binária: obesidade

Idade foi centrada na média

```
Generalized linear mixed model fit by maximum likelihood (Laplace Approximation) ['glmerMod']
Family: binomial ( logit )
Formula: Y ~ (idadec | ID) + idadec + I(idadec^2) + GENDER
Data: dados
```

AIC	BIC	logLik	deviance	df.resid
7347	7397	-3666	7333	9849

Scaled residuals:

Min	1Q	Median	3Q	Max
-1.6212	-0.0087	-0.0076	-0.0014	1.2443

Random effects:

Groups Name	Variance	Std.Dev.	Corr
ID (Intercept)	309.5	17.59	
idadec	25.4	5.04	0.18

Number of obs: 9856, groups: ID, 4856

Fixed effects:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-9.1841	0.2621	-35.04	< 2e-16 ***
idadec	0.0447	0.0768	0.58	0.56
I(idadec^2)	-0.1156	0.0188	-6.15	7.6e-10 ***
GENDER	0.1173	0.2540	0.46	0.64

---

## Resultados do Ajuste

Y: (0=não/1=sim) Obesidade

X: Covariáveis: (1) idade em anos e (2) sexo (0-menino e 1- menina)

$n = 4856$  pacientes e 14568 medições.

Somente idade foi importante!