

Modelos Gaussianos com covariáveis

Paulo Inácio Prado e João L.F. Batista

BIE5781 - Pós-Graduação em Ecologia USP

Novembro de 2021

Objetivo da Aula

Os objetivos dessa aula são:

1. Apresentar o conceito de modelos com parâmetros que são funções de outras medidas;
2. Apresentar os modelos deste tipo para a distribuição Gaussiana;
3. Mostrar os comandos básicos no R para ajustar e avaliar esses modelos;
4. Mostrar que alguns deles são modelos de regressão linear e não-linear;

Onde estamos

Até agora vimos:

- ▶ Modelos de várias distribuições com parâmetros constantes:

$$Y \sim N(\mu = \alpha_0, \sigma = \beta_0)$$

$$Y \sim P(\lambda = \alpha_0)$$

...

Para onde vamos

Hoje veremos modelos de distribuições Gaussianas cujos parâmetros são funções de outra medidas X_i :

- ▶ Modelos lineares:

$$Y \sim N(\mu = \alpha_0 + \alpha_1 X_1, \sigma = \beta_0)$$

- ▶ Modelos não-lineares:

$$Y \sim N(\mu = \alpha_0 X_1^{\alpha_1}, \sigma = \beta_0)$$

- ▶ Modelos com σ também variável:

$$Y \sim N(\mu = \alpha_0 + \alpha_1 X_1, \sigma = e^{\beta_0 + \beta_1 X_1})$$

$$Y \sim N(\mu = \alpha_0 X_1^{\alpha_1}, \sigma = e^{\beta_0 + \beta_1 X_1})$$

Ou seja

Uma expressão geral para modelos Gaussianos

$$Y \sim N(\mu = f(X_i), \sigma = g(X_i))$$

Em palavras

Y é uma variável aleatória, cujos valores têm probabilidades definidas pela função de densidade Gaussiana, cujos parâmetros μ e σ são funções de variáveis X_i .

Conceitos

Y : variável dependente, ou variável resposta

X_i : variáveis independentes ou preditoras

Modelos lineares

- ▶ Com uma preditora

$$Y \sim N(\mu = \alpha_0 + \alpha_1 X_1, \sigma = \beta_0)$$

- ▶ Com muitas preditoras


$$Y \sim N(\mu = \alpha_0 + \alpha_1 X_1 + \alpha_2 X_2, + \dots + \alpha_i X_i, \sigma = \beta_0)$$

- ▶ Generalizando

$$Y \sim N(\mu = \alpha_0 + \sum \alpha_i X_i, \sigma = \beta_0)$$

- ▶ Chamamos $[\alpha_0 + \sum \alpha_i X_i]$ de **preditor linear** (detalhes em breve).

Modelo Linear Gaussiano com uma preditora e σ constante



Um exemplo de modelo linear com uma preditora


- ▶ Altura de filhos e de seus pais (Galton 1885 ¹)
- ▶ Preditora: altura da mãe (polegadas)
- ▶ Resposta: altura de um filho ou filha (polegadas)
- ▶ Tamanho da amostra = 197

```
> head(galton1, 5)
```

	Family	Father	Mother	Gender	Height	Kids
1	1	78.5	67.0	M	73.2	4
5	2	75.5	66.5	M	73.5	4
9	3	75.0	64.0	M	71.0	2
11	4	75.0	64.0	M	70.5	5
16	5	75.0	58.5	M	72.0	6

¹<https://www.randomservices.org/random/data/Galton.html>

Um exemplo de modelo linear com uma preditora



Modelo linear com uma variável: Ajuste no R

Função de log-verossimilhança negativa

```
> galton.LL1 <- function(a0, a1, b0){  
+   PL <- a0 + a1*galton1$Mother  
+   -sum( dnorm(galton1$Height, mean = PL, sd = b0 ,  
+             log=T))}
```

Ajuste numérico do modelo no R

```
> galton.m1 <- mle2(galton.LL1,  
+                   start = list(a0=0, a1=1, b0=5))
```

Modelo linear com uma variável: Ajuste no R

MLEs

```
> coef(galton.m1)
```

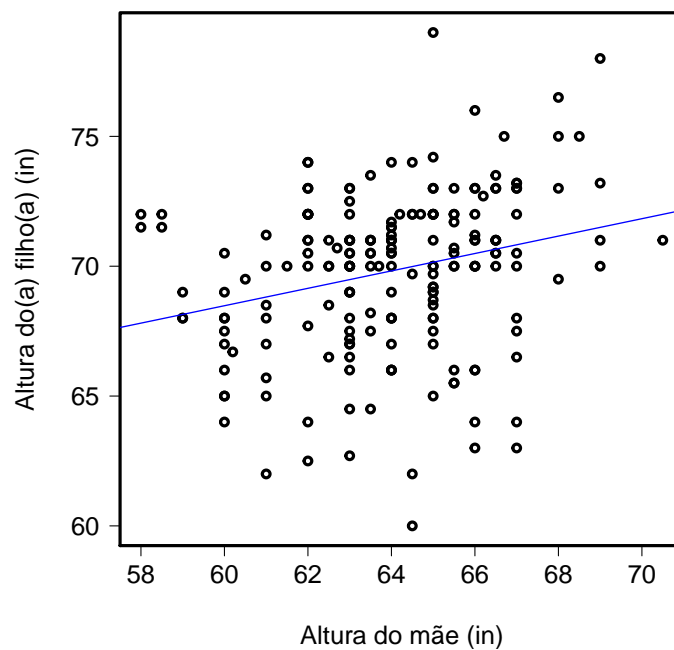
a0	a1	b0
48.3657449	0.3352066	2.9485752

Log-verossimilhança


```
> logLik(galton.m1)
```

```
'log Lik.' -492.5617 (df=3)
```

Inspeção visual do ajuste



Intervalos de plausibilidade



Regressão não-linear simples no R – Ajuste

Otimização

```
> galton.LL1 <- function(a0, a1, b0){  
+   PL <- a0 + a1*galton1$Mother  
+   -sum( dnorm(galton1$Height, mean = PL, sd = b0 ,  
+             log=T))}
```

```
> galton.m1 <- mle2(galton.LL1,  
+                   start = list(a0=0, a1=1, b0=5))
```

Regressão linear simples no R – Ajuste

Mínimos quadrados

```
> galton.lm1 <- lm(Height ~ Mother, data = galton1)
```

Regressão linear simples no R – MLEs

Otimização

```
> coef(galton.m1)
      a0      a1      b0
48.3657449 0.3352066 2.9485752
```

Mínimos quadrados

```
> coef(galton.lm1)
(Intercept)      Mother
 48.3699889    0.3351405
```


Regressão linear simples no R- Log-verossimilhança


Otimização

```
> logLik(galton.m1)
'log Lik.' -492.5617 (df=3)
```

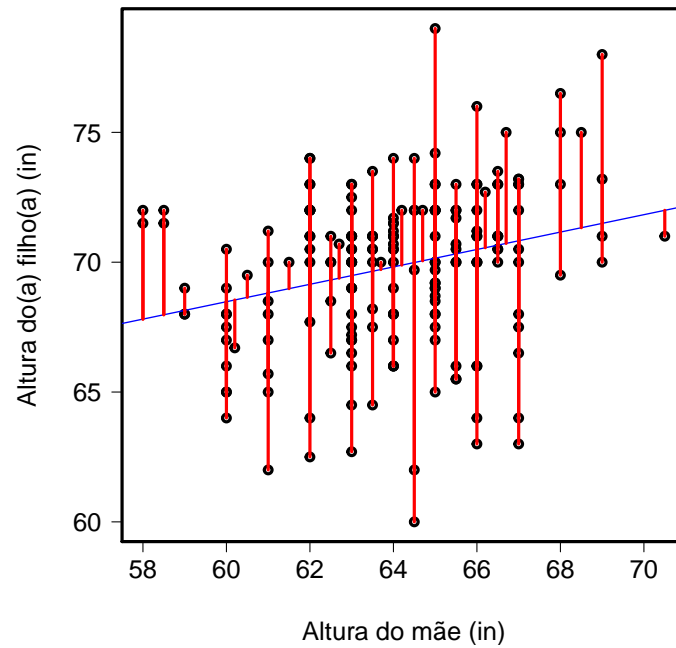
Mínimos quadrados

```
> logLik(galton.lm1)
'log Lik.' -492.5617 (df=3)
```

Quadrados mínimos



Quadrados mínimos



Duas maneiras de interpretar uma regressão linear

Resposta como variável Gaussiana

$$Y \sim N(\mu = \alpha_0 + \sum \alpha_i X_i, \sigma = \beta_0)$$

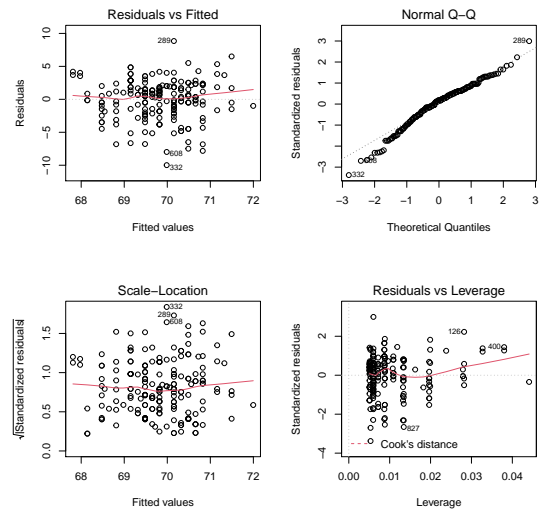
Resposta como medida + erro

$$Y = \alpha_0 + \sum \alpha_i X_i + \epsilon,$$


$$\epsilon \sim N(\mu = 0, \sigma = \beta_0)$$

Análise de resíduos


```
> par(mfrow=c(2,2))  
> plot(galton.lm1)  
> par(mfrow=c(1,1))
```



Análise de resíduos: têm média zero e variância constante?



Análise de resíduos: têm distribuição normal?



Preditores lineares

Todos que podem ser escritos na forma $\Theta = \sum \alpha_i X_i$, sendo Θ uma resposta.

exemplos

- ▶ $\alpha_0 + \alpha_1 X_1$, sendo $X_0 = 1$
- ▶ $\alpha_0 + \alpha_1 X_1 + \alpha_2 X_1^2$, pois podemos chamar X_1^2 de X_2
- ▶ $\alpha_0 + \alpha_1 X_1 + \alpha_2 \ln(X_1)$, pois podemos chamar $\ln X_1$ de X_2
- ▶ $\alpha_0 + \alpha_1 X_1 + \alpha_2 X_2 + \alpha_3 X_1 X_2$, pois podemos chamar $X_1 X_2$ de X_3
- ▶ ...

Modelos lineares múltiplos aditivos

- ▶ O preditor é a soma de variáveis independentes isoladas, cada uma multiplicada por seu coeficiente
- ▶ A soma **não** inclui variáveis independentes que são produtos de outras presentes no modelo:

$$\alpha_0 + \alpha_1 X_1 + \alpha_2 X_2 + \cdots + \alpha_i X_i$$

- ▶ Se a uma variável independente X_i dobra, seu efeito no preditor vai aumentar em $2 \times \alpha_i$, não importando o valor das outras variáveis.
- ▶ Ou seja, os efeitos das preditoras são **aditivos**. Não são afetados pelo valor das demais variáveis.

Modelos lineares múltiplos com interações

- ▶ O preditor inclui variáveis que são produtos de pelos menos outras duas presentes no modelo, por exemplo

$$\alpha_0 + \alpha_1 X_1 + \alpha_2 X_2 + \alpha_3 X_1 X_2$$

- ▶ Se a uma variável independent X_i dobra, seu efeito no preditor vai aumentar em

$$2 \times \alpha_i + 2 \times \alpha_3 X_2.$$

- ▶ Ou seja, o efeito de uma preditora depende do valor de outra(s). Há uma **interação** estatística.

Exemplo de preditor linear aditivo

Duas predictoras:

X_1 : altura da mãe, contínua

X_2 : Gênero binário (Masculino = 0, Feminino = 1)

Preditor:

expressão : $\alpha_0 + \alpha_1 X_1 + \alpha_2 X_2$

masculino : $\alpha_0 + \alpha_1 X_1 + \alpha_2 \times 0 = \alpha_0 + \alpha_1 X_1$

feminino : $\alpha_0 + \alpha_1 X_1 + \alpha_2 \times 1 = [\alpha_0 + \alpha_2] + \alpha_1 X_1$

Exemplo de preditor linear com uma interação

Duas predictoras:

X_1 : altura da mãe, contínua

X_2 : Gênero binário (Masculino = 0, Feminino = 1)

Preditor:

expressão : $\alpha_0 + \alpha_1 X_1 + \alpha_2 X_2 + \alpha_3 X_1 X_2$

masculino : $\alpha_0 + \alpha_1 X_1 + \alpha_2 \times 0 + \alpha_3 X_1 \times 0 = \alpha_0 + \alpha_1 X_1$

feminino :

$\alpha_0 + \alpha_1 X_1 + \alpha_2 \times 1 + \alpha_3 X_1 \times 1 = [\alpha_0 + \alpha_2] + [\alpha_1 + \alpha_3] X_1$

Gráfico do exemplo aditivo

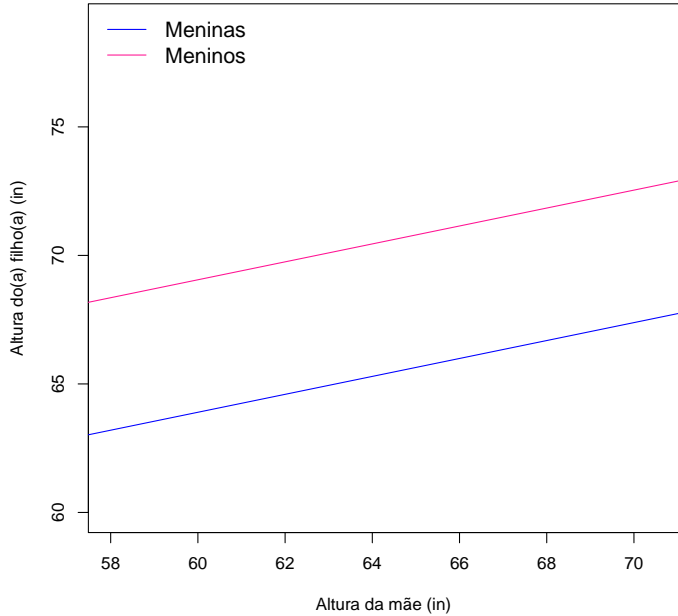
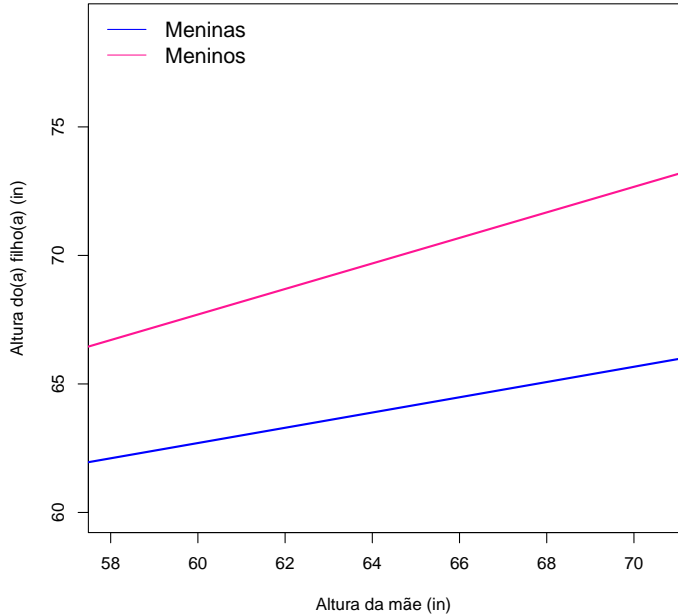


Gráfico do exemplo com interação



Preditores não lineares

Todos que não podem ser reduzidos à forma $\Theta = \sum \alpha_i X_i$.

exemplos

- ▶ $\alpha_0 X_1^{\alpha_1}$
- ▶ $\alpha_0 e^{\alpha_1 X_1}$
- ▶ $\frac{\alpha_1 X_1}{1 + \alpha_1 \alpha_2 X_1}$
- ▶ E muitas, muitas mais.

Regressão não-linear

Resposta como variável Gaussiana

$$Y \sim N(\mu = f(X_i), \sigma = \beta_0)$$

Resposta como medida + erro

$$Y = f(X_i) + \epsilon,$$

$$\epsilon \sim N(\mu = 0, \sigma = \beta_0)$$

Um exemplo de modelo não-linear

- ▶ N de espécies de plantas endêmicas em áreas costeiras da Califórnia (Johnson *et al* 1968 ²)
- ▶ Preditora: área (mi^2)
- ▶ Resposta: número de espécies registradas na área
- ▶ Tamanho da amostra = 9

```
> head(johnson, 4)
              area Nspp
Tiburon Peninsula      5.9  370
San Francisco          45.0  640
Santa Barbara area    110.0  680
Santa Monica Mountains 320.0  640
```

²<http://math.hws.edu/~mitchell/SpeciesArea/index.html>

Modelo não-linear: Ajuste no R


Função de log-verossimilhança negativa

```
> johnson.LL <- function(a0, a1, b0){
+   PL <- a0*johnson$area^a1
+   -sum( dnorm(johnson$Nspp, mean = PL, sd = b0 ,
+             log=T))}
```


Ajuste numérico do modelo no R

```
> johnson.m1 <- mle2(johnson.LL,
+                   start = list(a0=200, a1=0.25, b0=10)
+                   )
```

Inspeção visual do ajuste



Intervalos de plausibilidade



Regressão não-linear no R – Ajuste

Mínimos quadrados

```
> johnson.nls <- nls(Nspp ~ a0*area^a1, data = johnson)

Warning in nls(Nspp ~ a0 * area^a1, data = johnson):
No starting values specified for some parameters.
Initializing 'a0', 'a1' to '1.'.
Consider specifying 'start' or using a selfStart model
```

Regressão não-linear no R – MLEs

Otimização

```
> coef(johnson.m1)

          a0          a1          b0
196.0414936  0.2492566 107.7050628
```

Mínimos quadrados

```
> coef(johnson.nls)

          a0          a1
195.7665566  0.2494165
```

Regressão não-linear no R – Verossimilhança


Otimização

```
> logLik(johnson.m1)
'log Lik.' -54.87376 (df=3)
```

Mínimos quadrados

```
> logLik(johnson.nls)
'log Lik.' -54.8737 (df=3)
```

Heteroscedasticidade



Um modelo linear com σ variável

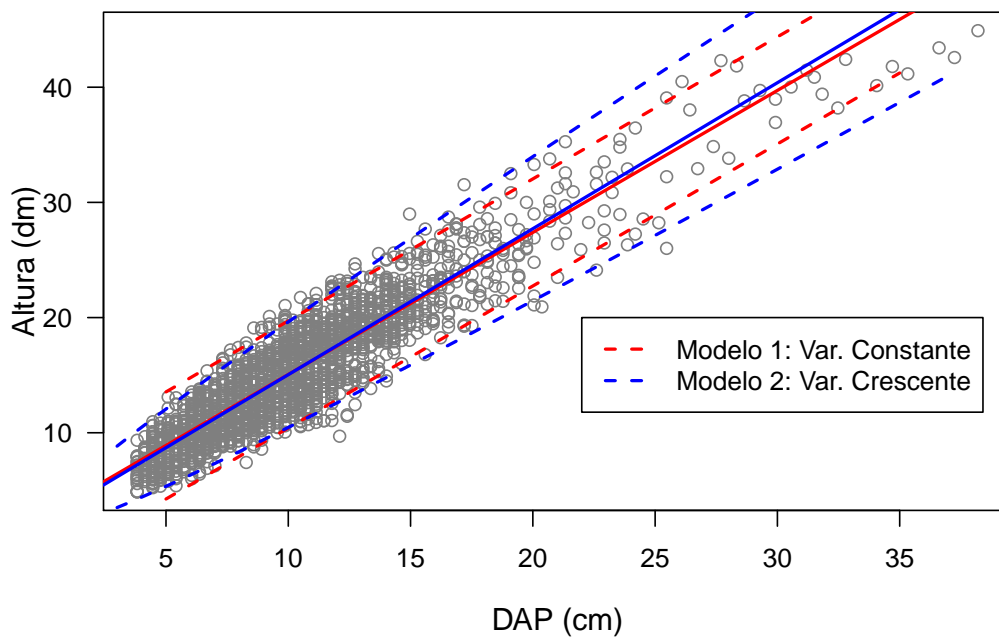
Expressão simbólica

$$Y \sim N(\mu = \alpha_0 + \alpha_1 X_1, \sigma = e^{\beta_0 + \beta_1 X_1})$$

Função de verossimilhança no R

```
> LL3 <- function(a0, a1, b0, b1){  
+   LP.mu <- a0 + a1*X  
+   LP.sig <- exp(b0 + b1*X)  
+   -sum(dnorm(Y, mean = LP.mu, sd = LP.sig,  
+             start = list(a0 = 0, a1 = 1, b0 = 0.1, b1 = -1),  
+             log = TRUE))  
+ }
```

Relação Altura-DAP em *E.grandis*: Comparação Gráfica



Modelos Gaussianos: Resumo

1. Nos modelos Gaussianos podemos ter duas funções preditivas:
 - ▶ uma para média,
 - ▶ outra da o desvio padrão
2. Nos modelo de Regressão Linear Clássicos:
 - ⇒ a média é uma função *linear*.
 - ⇒ o desvio padrão é constante.
3. Nos modelo de Regressão Não-Linear Clássicos:
 - ⇒ a média é uma função *não-linear*.
 - ⇒ o desvio padrão é constante.
4. O contexto dos modelos clássicos pode ser ampliado:
 - ⇒ Acrescentando uma função preditiva para o desvio padrão.
 - ⇒ Outras formas? Sim! *muitas outras!*