

Modelos de regressão para dados correlacionados

Cibele Russo

cibele@icmc.usp.br

ICMC USP

Mini-curso oferecido no
Workshop on Probabilistic and Statistical Methods

28 a 30 de janeiro de 2013

Conteúdo da aula

- Modelos de regressão:
 - ▶ Modelo de regressão linear simples
 - ▶ Modelo de regressão linear múltipla
 - ▶ A distribuição normal multivariada
 - ▶ Modelo de regressão linear multivariada

Modelos de regressão:

Modelo de regressão linear simples

Modelo de regressão linear múltipla

(sem considerar a correlação entre as observações)

Modelos de regressão

Modelos de regressão são ferramentas estatísticas que buscam explicar a relação entre duas ou mais variáveis.

Essentially, all models are wrong, but some are useful.

George Box

(Box, G. e Draper, N. R. 1987, Empirical Model-Building and Response Surfaces, Wiley Series in Probability and Statistics.)

Modelos de regressão: modelo teórico

- Y : variável resposta (v. aleatória)
- x_1, \dots, x_p : p variáveis preditoras (v. não aleatórias)
- ϵ : erro aleatório

Modelo matemático:

$$Y = f(x_1, \dots, x_p) + \epsilon$$

Suposição mais comum:

$\epsilon \sim (0, \sigma^2)$, $\sigma^2 > 0$ um parâmetro desconhecido.

($E(\epsilon) = 0$ e $\text{Var}(\epsilon_j) = \sigma^2$).

Modelos de regressão: modelo amostral

- Y_i : observação da variável resposta Y na i -ésima unidade experimental (v. aleatória),
- x_{i1}, \dots, x_{ip} : valores de x_1, \dots, x_p variáveis preditoras (v. não aleatórias)
- ϵ_i : erro aleatório e $i = 1, \dots, n$.

Modelo matemático (amostral):

$$Y_i = f(x_{i1}, \dots, x_{ip}) + \epsilon_i, \text{ para } i = 1, \dots, n.$$

Suposições mais comuns:

- ϵ_i é independente de ϵ_j para $i \neq j$ e $i, j = 1, \dots, n$ e
- $\epsilon_i \sim (0, \sigma^2)$, $\sigma^2 > 0$ um parâmetro desconhecido.

$(E(\epsilon_i) = 0, \text{Var}(\epsilon_i) = \sigma^2, \text{Cov}(\epsilon_i, \epsilon_j) = 0 \text{ para todo } i, j = 1, \dots, n \text{ e } i \neq j.)$

Modelo de regressão linear simples

- Y_1, \dots, Y_n : n observações da variável resposta Y (v. aleatória)
- x_1, \dots, x_n : n observações da variável preditora x (v. não aleatória)
- ϵ : erro aleatório

Modelo matemático:

$$Y_i = \beta_0 + \beta_1 x_i + \epsilon_i, \quad i = 1, \dots, n$$

Suposições $\epsilon_i \stackrel{i.i.d}{\sim} (0, \sigma^2)$, $i = 1, \dots, n$.

- β_0 é um parâmetro, chamado intercepto ou coeficiente linear da reta. É o valor esperado de Y quando $x = 0$.
- β_1 é um parâmetro, chamado coeficiente angular da reta. É o aumento (diminuição) médio (a) em Y quando aumentamos uma unidade em x .

Ao assumir um modelo de regressão linear simples para Y em x , assumimos que a relação entre essas duas variáveis é linear e que os erros $\epsilon_1, \dots, \epsilon_n$ são independentes, o que não acontece sempre.

Suponha inicialmente que x e Y estão relacionadas de forma linear e que $\epsilon_1, \dots, \epsilon_n$ são independentes, ou seja, Y_1, \dots, Y_n são independentes.

**Temos interesse em estimar os parâmetros β_0 , β_1 e σ^2 .
Para isso, usamos estimadores, que são funções das observações.**

Vamos denotar os valores observados (observações) de Y_1, \dots, Y_n por y_1, \dots, y_n , respectivamente.

Modelo de regressão linear simples

Queremos encontrar a melhor reta para explicar a relação (suposta linear) entre x e Y . Assim, teremos o

Modelo ajustado:

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i, \quad i = 1, \dots, n$$

- $\hat{\beta}_0$ é uma estimativa de β_0
- $\hat{\beta}_1$ é uma estimativa de β_1
- \hat{Y}_i é o valor ajustado de Y para $x = x_i$.

Resíduo: $e_i = y_i - \hat{Y}_i$

Modelo de regressão linear simples

No modelo de regressão linear simples, o método de mínimos quadrados busca minimizar $\sum_{i=1}^n e_i^2$ e leva aos

Estimadores de mínimos quadrados (EMQ)

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \quad \text{e} \quad \hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

$$\text{com } \bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad \text{e} \quad \bar{y} = \frac{\sum_{i=1}^n y_i}{n}.$$

Modelo de regressão linear simples

Se no modelo

$$Y_i = \beta_0 + \beta_1 x_i + \epsilon_i, \quad i = 1, \dots, n$$

assumirmos que $\epsilon_i \stackrel{i.i.d.}{\sim} N(0, \sigma^2)$, então os estimadores de máxima verossimilhança (EMV) de β_0 e β_1 são dados por

$$\hat{\beta}_{0_{MV}} = \bar{y} - \hat{\beta}_{1_{MV}} \bar{x} \quad \text{e} \quad \hat{\beta}_{1_{MV}} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

com $\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$ e $\bar{y} = \frac{\sum_{i=1}^n y_i}{n}$ (coincidem com os EMQs $\hat{\beta}_0$ e $\hat{\beta}_1$).

Modelo de regressão linear simples

No modelo

$$Y_i = \beta_0 + \beta_1 x_i + \epsilon_i, \quad i = 1, \dots, n, \quad \text{com } \epsilon_i \stackrel{i.i.d.}{\sim} N(0, \sigma^2)$$

o estimador de máxima verossimilhança de σ^2

$$\hat{\sigma}_{MV}^2 = \frac{\sum_{i=1}^n (y_i - \hat{Y}_i)^2}{n} \quad \text{é viesado.}$$

Um estimador não viesado para σ^2 seria

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - \hat{Y}_i)^2}{n - 2}.$$

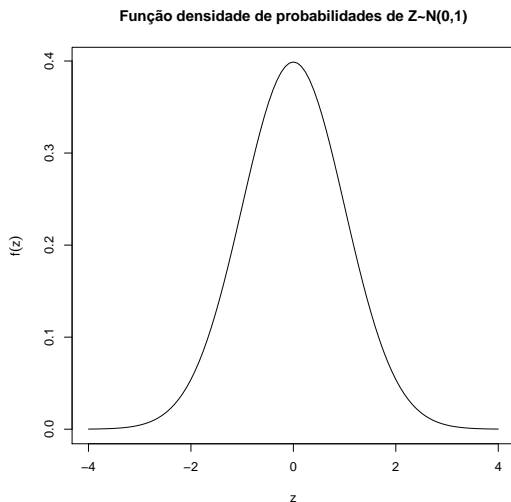
Observação: Distribuição normal

A notação $W \sim N(\mu, \sigma^2)$ indica que W é uma variável aleatória contínua com função densidade de probabilidades (f. d. p.) dada por


$$f(w) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{(x - \mu)^2}{2\sigma^2} \right\} \text{ com } \mu \in \mathbb{R} \text{ e } \sigma^2 > 0.$$

Observação: Distribuição normal

Função densidade de probabilidades de $Z \sim N(0, 1)$.



A suposição de normalidade para os erros



(Figura adaptada de Draper, N. A e Smith, H. 1998, Applied Regression Analysis, Wiley Series in Probability and Statistics, Wiley.)

Modelo de regressão linear múltipla

Modelo matemático:

$$Y_i = \beta_0 + x_{1i}\beta_1 + x_{2i}\beta_2 + \dots + x_{ip}\beta_p + \epsilon_i, \quad i = 1, \dots, n$$

$$\text{Matricialmente: } \mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}$$

- \mathbf{Y} : vetor de respostas ou variáveis dependentes
- \mathbf{X} : matriz do modelo de regressão
- $\boldsymbol{\beta}$: vetor de parâmetros
- $\boldsymbol{\epsilon}$: vetor de erros aleatórios

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ \vdots \\ Y_n \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{21} & \dots & x_{p1} \\ 1 & x_{12} & x_{22} & \dots & x_{p2} \\ \vdots & \vdots & \ddots & \dots & \vdots \\ 1 & x_{n2} & x_{n2} & \dots & x_{n2} \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{bmatrix}, \quad \boldsymbol{\epsilon} = \begin{bmatrix} \epsilon_1 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

Estimação em um modelo de regressão linear múltipla

Assumindo $\epsilon \sim N_n(\mathbf{0}, \sigma^2 I_n)$, o estimador de máxima verossimilhança (ou de mínimos quadrados) de β é dado por

$$\hat{\beta} = (X'X)^{-1}X'y$$

em que \mathbf{y} é o vetor observado de \mathbf{Y} .

Obs 1: I_n é a matriz identidade $n \times n$

Obs 2: Falaremos mais adiante da distribuição normal multivariada.

Estimação em um modelo de regressão linear múltipla

Modelo ajustado:

$$\hat{\mathbf{Y}} = \mathbf{X}\hat{\boldsymbol{\beta}}$$

Vetor de resíduos:

$$\mathbf{e}_i = \mathbf{y} - \hat{\mathbf{Y}}$$

Estimador não viesado de σ^2 :

$$\hat{\sigma}^2 = \frac{(\mathbf{y} - \hat{\mathbf{Y}})'(\mathbf{y} - \hat{\mathbf{Y}})}{n - p - 1}$$

Propriedades

$$\textcircled{1} \hat{\beta} = (X'X)^{-1}X'y \sim N_p(\beta, \sigma^2(X'X)^{-1})$$

$$\textcircled{2} \hat{Y} = X\hat{\beta} = X(X'X)^{-1}X'y \sim N_n(X\beta, X(X'X)^{-1}X'\sigma^2)$$

Propriedades

Predição de novas observações

Dado $\mathbf{X} = \mathbf{x}$, podemos prever o valor de $Y|\mathbf{X} = \mathbf{x}$ fazendo $\widehat{Y|\mathbf{X} = \mathbf{x}} = \mathbf{x}\widehat{\beta}$

Exemplo: Um primeiro modelo

Dados ortodônticos: Suponha que não soubéssemos que os dados são correlacionados e queremos ajustar um modelo de regressão linear simples para cada grupo determinado pelo gênero.

```
> install.packages(c("stats", "nlme", "Hmisc", "lattice"))
> library(nlme)
> attach(Orthodont)
> fit.lm<-lm(distance~ age)
> summary(fit.lm)
> plot(age,distance,pch=16)
> abline(fit.lm)
```

 Certifique-se que os comandos foram passados corretamente para o R.

Exemplo de ajuste: modelo de regressão linear simples

Dados ortodônticos

```
> summary(fit.lm)

Call:
lm(formula = distance ~ age)

Residuals:
    Min       1Q   Median       3Q      Max
-6.5037 -1.5778 -0.1833  1.3519  6.3167

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  16.7611     1.2256   13.676 < 2e-16 ***
age           0.6602     0.1092    6.047 2.25e-08 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2.537 on 106 degrees of freedom
Multiple R-squared:  0.2565,    Adjusted R-squared:  0.2495
F-statistic: 36.56 on 1 and 106 DF,  p-value: 2.248e-08

> |
```

Exercício: como interpretar o modelo ajustado?


Exemplo de ajuste: modelo de regressão linear simples

O modelo ajustado para Y (distância) usando como covariável x (idade) é dado por

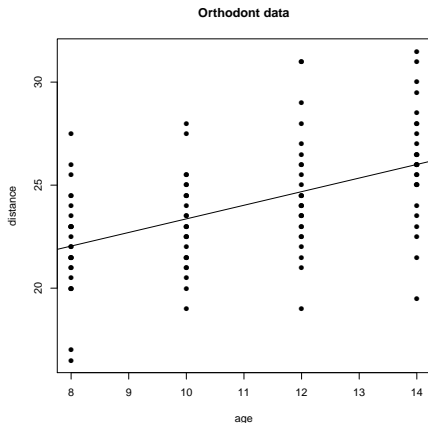
$$\hat{Y}_i = 16,7611 + 0,6602x_i, \quad 1, \dots, n.$$

A interpretação das estimativas dos parâmetros é

- A estimativa da distância em uma criança com idade 0 é 16,7611 $(\hat{\beta}_0)^*$.
- O aumento estimado na distância é de 0,6602 quando se aumenta 1 ano de idade.


 *** Importante:** Deve-se tomar cuidado com a interpretação de $\hat{\beta}_0$, pois não se deve extrapolar o modelo de regressão para intervalos distantes dos valores da covariável. A relação entre as duas variáveis pode mudar de comportamento longe dos valores de x .

Exemplo de ajuste: modelo de regressão linear simples



Modelo de regressão linear simples ajustado aos dados ortodônticos

Exemplo de ajuste: modelo de regressão linear simples



Resíduos do modelo de regressão linear simples ajustado aos dados ortodônticos

Exercício: um modelo para cada gênero

Dados ortodônticos: Suponha que não soubéssemos que os dados são correlacionados mas quiséssemos ajustar um modelo de regressão linear simples para os dados de cada grupo.

```
> attach(Orthodont)
> fit.Sex<-lmList(distance~ age|Sex,Orthodont)
> coef(fit.Sex)
> coef(fit.Sex)[1,]
> coef(fit.Sex)[2,]
> intervals(fit.Sex)
> plot(intervals(fit.Sex))
> plot(fit.Sex)
```



Certifique-se que os comandos foram passados corretamente para o R.

O que é correlação?

Correlação ou coeficiente de correlação é uma ferramenta utilizada em Probabilidade e Estatística para medir o grau de **relacionamento linear** entre duas variáveis aleatórias sem implicar relação de causalidade.

Correlação

Seja W uma variável aleatória contínua (unidimensional) com f. d. p. $f(w)$.

Momentos populacionais: O k -ésimo momento de $g(W)$ é definido como

$$E(g(W)^k) = \int_{-\infty}^{\infty} [g(w)]^k f(w) dw$$

desde que a integral acima exista.

Valor esperado de W : $E(W) = \mu^1 = \mu = \int_{-\infty}^{\infty} wf(w)dw.$

Variância de W : $Var(W) = E(W - \mu)^2 = \int_{-\infty}^{\infty} (w - \mu)^2 f(w)dw.$

Correlação

Seja W uma variável aleatória contínua com f. d. p. $f_w(w)$ e Z uma variável aleatória contínua com f. d. p. $f_z(z)$, e suponha que a f. d. p. conjunta de (W, Z) seja $f(w, z)$. Defina-se

Valor esperado de W : $E(W) = \mu_w$

Valor esperado de Z : $E(Z) = \mu_z$

Variância de W : $Var(W) = \sigma_w^2$.

Variância de Z : $Var(Z) = \sigma_z^2$.

Covariância entre W e Z : $Cov(W, Z) = E((W - \mu_w)(Z - \mu_z)) = \sigma_{WZ}$.

Coeficiente de correlação entre W e Z : $\rho_{W,Z} = \frac{\sigma_{WZ}}{\sqrt{\sigma_w^2} \sqrt{\sigma_z^2}}$.

Correlação - caso multidimensional

Seja vetor aleatório

$$\mathbf{W} = \begin{bmatrix} W_1 \\ \vdots \\ W_n \end{bmatrix},$$

ou seja, cada elemento W_i é uma variável aleatória, $i = 1, \dots, n$ com f. d. p. $f_i(w_i)$.

Correlação - caso multidimensional

Valor esperado de \mathbf{W} :

$$E(\mathbf{W}) = \boldsymbol{\mu} = \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_n \end{bmatrix}$$

em que $\mu_i = E(W_i) = \int_{-\infty}^{\infty} w_i f_i(w_i) dw_i$.

Correlação - caso multidimensional

Variância de \mathbf{W} :

$$\text{Var}(\mathbf{W}) = E[(\mathbf{W} - \boldsymbol{\mu})(\mathbf{W} - \boldsymbol{\mu})']$$

$$= E \left(\begin{pmatrix} W_1 - \mu_1 \\ \vdots \\ W_n - \mu_n \end{pmatrix} \begin{bmatrix} W_1 - \mu_1 & \dots & W_n - \mu_n \end{bmatrix} \right) =$$

$$= E \begin{pmatrix} (W_1 - \mu_1)^2 & (W_1 - \mu_1)(W_2 - \mu_2) & \dots & (W_1 - \mu_1)(W_n - \mu_n) \\ (W_2 - \mu_2)(W_1 - \mu_1) & (W_2 - \mu_2)^2 & \dots & (W_2 - \mu_2)(W_n - \mu_n) \\ \vdots & \vdots & \ddots & \vdots \\ (W_n - \mu_n)(W_1 - \mu_1) & (W_n - \mu_n)(W_2 - \mu_2) & \dots & (W_n - \mu_n)^2 \end{pmatrix}$$

Matriz de variâncias e covariâncias

Variância de W :

$$\Sigma = \text{Var}(\mathbf{W}) = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \dots & \sigma_{nn} \end{pmatrix}.$$

Matriz de correlação

Matriz de correlação de W :

$$R = \text{Cor}(\mathbf{W}) = \begin{pmatrix} \rho_{11} & \rho_{12} & \cdots & \rho_{1n} \\ \rho_{21} & \rho_{22} & \cdots & \rho_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{n1} & \rho_{n2} & \cdots & \rho_{nn} \end{pmatrix}$$

com $\rho_{ij} = \frac{\sigma_{ij}}{\sqrt{\sigma_{ii}}\sqrt{\sigma_{jj}}}$ para $i, j = 1, \dots, n$.

Propriedades:

- $-1 \leq \rho_{ij} \leq 1$, para $i, j = 1, \dots, n$.
- $\rho_{jj} = 1$, para $j = 1, \dots, n$.

Matrizes de variâncias e covariâncias e correlações amostrais

Em geral Σ e R são desconhecidas, mas podemos estimá-las obtendo a matriz de variância e covariâncias amostral e a matriz de correlações amostrais.

Matriz de variâncias e covariâncias amostrais (não viesada para Σ)

$$s = \text{var}(\mathbf{W}) = \begin{pmatrix} s_{11} & s_{12} & \dots & s_{1n} \\ s_{21} & s_{22} & \dots & s_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ s_{n1} & s_{n2} & \dots & s_{nn} \end{pmatrix}$$

$$\text{com } s_{ij} = \frac{\sum_{k=1}^n (w_{ki} - \bar{w}_i)(w_{kj} - \bar{w}_j)}{n - 1}$$

Matrizes de variâncias e covariâncias e correlações amostrais

Matriz de correlações amostrais

$$r = \text{cor}(\mathbf{W}) = \begin{pmatrix} 1 & r_{12} & \dots & r_{1n} \\ r_{21} & 1 & \dots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ r_{n1} & r_{n2} & \dots & 1 \end{pmatrix}$$

com $r_{ij} = \frac{s_{ij}}{\sqrt{s_{ii}}\sqrt{s_{jj}}}$ para $i, j = 1, \dots, n$.

Distribuição normal multivariada

Definição

O vetor p -dimensional \mathbf{U} tem distribuição normal multivariada se, e somente se, toda combinação linear de \mathbf{U} tem distribuição normal univariada.

$$\mathbf{U} \sim N_p \iff \mathbf{t}'\mathbf{U} \sim N_1 \quad \forall \mathbf{t} \in \mathbb{R}^p.$$

Observação: Distribuição normal multivariada

Propriedades

- 1 A média $E(U) = \boldsymbol{\mu}$ e $Var(U) = \boldsymbol{\Sigma}$ existem. Notação: $U \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$.
- 2 Fixado $\mathbf{t} \in R^p$ um vetor de constantes, $\mathbf{t}'U \sim N(\mathbf{t}'\boldsymbol{\mu}, \mathbf{t}'\boldsymbol{\Sigma}\mathbf{t})$.
- 3 Se $\mathbf{U} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ e $r(\boldsymbol{\Sigma}) = p$ então a função densidade de probabilidades de \mathbf{U} é dada por

$$f(\mathbf{u}) = \frac{1}{(2\pi)^{p/2} |\boldsymbol{\Sigma}|^{1/2}} \exp \left\{ -\frac{(\mathbf{u} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{u} - \boldsymbol{\mu})}{2} \right\}, \quad \boldsymbol{\mu} \in R^p$$

Observação: Distribuição normal multivariada

Consequências

1 $U \sim N_p(\mu, \Sigma)$ é tal que $\mathbf{U} = \begin{bmatrix} U_1 \\ U_2 \\ \vdots \\ U_p \end{bmatrix}$.

Se Σ é diagonal, então U_1, \dots, U_p são v.a.independentes, cada uma com distribuição normal univariada.

Observação: Distribuição normal multivariada

Consequências

2 Se $\mathbf{U} = \begin{bmatrix} \mathbf{U}_1 \\ \mathbf{U}_2 \end{bmatrix}$ com $Var(\mathbf{U}) = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma'_{12} & \Sigma_{22} \end{bmatrix}$ em que

$$\Sigma_{11} = Var(\mathbf{U}_1), \Sigma_{22} = Var(\mathbf{U}_2), \Sigma_{12} = Cov(\mathbf{U}_1, \mathbf{U}_2).$$

Então \mathbf{U}_1 é independente de \mathbf{U}_2 se, e somente se, $\Sigma_{12} = 0$.

Observação: Distribuição normal multivariada

Propriedades


① $\mathbf{U} \sim N_p(\boldsymbol{\mu}, \Sigma)$ é particionada como $\mathbf{U} = \begin{bmatrix} \mathbf{U}_1 \\ \mathbf{U}_2 \end{bmatrix}$,

com a partição adequada para o vetor de médias e a matriz de variâncias e covariâncias

$$\boldsymbol{\mu} = \begin{bmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \end{bmatrix} \text{ e } \Sigma = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma'_{12} & \Sigma_{22} \end{bmatrix}.$$

Então $\mathbf{U}_1 \sim N(\boldsymbol{\mu}_1, \Sigma_{11})$ e $\mathbf{U}_2 \sim N(\boldsymbol{\mu}_2, \Sigma_{22})$ têm distribuição normal multivariada com as dimensões dos vetores \mathbf{U}_1 e \mathbf{U}_2 .


Contornos elípticos da normal bivariada (elementos não correlacionados)



Distribuição normal (elementos correlacionados)

Definindo os parâmetros da distribuição Normal (μ , Σ),

com $\mu = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$ e $\Sigma = \begin{bmatrix} 2 & 1 \\ 1 & 1 \end{bmatrix}$:



Modelar dados correlacionados

Qual a forma mais simples de modelar dados correlacionados?

Modelo de regressão multivariada

Um modelo de regressão linear multivariado é da forma

$$\mathbf{Y}_i = X_i\boldsymbol{\beta} + \boldsymbol{\epsilon}_i$$

onde

- $\mathbf{Y}_i = \begin{bmatrix} Y_{1i} \\ \vdots \\ Y_{ni} \end{bmatrix}$ é o vetor de respostas do i -ésimo indivíduo
- X_i é uma matriz de planejamento
- $\boldsymbol{\beta}$ é um vetor de parâmetros
- $\boldsymbol{\epsilon}_i = \begin{bmatrix} \epsilon_{1i} \\ \vdots \\ \epsilon_{ni} \end{bmatrix}$

Suposição comum: $\boldsymbol{\epsilon}_i \stackrel{i.i.d.}{\sim} N(\mathbf{0}, \Sigma)$

Modelo de regressão multivariada

Uma possibilidade é reescrever o modelo de forma multivariada como

$$\mathbf{Y} = X\boldsymbol{\beta} + \boldsymbol{\epsilon}$$

com matrizes adequadas \mathbf{Y} , X , $\boldsymbol{\beta}$ e $\boldsymbol{\epsilon}$.

Pode-se obter $\hat{\boldsymbol{\beta}}_i = (X_i'X_i)^{-1}X_i'\mathbf{y}_i$, em que \mathbf{y}_i é o valor observado de \mathbf{Y}_i para $i = 1, \dots, n$ e

$\hat{\boldsymbol{\beta}} = [\hat{\boldsymbol{\beta}}_1, \hat{\boldsymbol{\beta}}_2, \dots, \hat{\boldsymbol{\beta}}_n]$, o que é equivalente a fazer

$$\hat{\boldsymbol{\beta}} = (X'X)^{-1}X'\mathbf{y}.$$

Modelo de regressão multivariada

Comandos em R:


```
> library(nlme)
> attach(Orthodont)
> X<-cbind(1,matrix(age,ncol=1) [1:4])
> Y<-matrix(distance,nrow=4,byrow=F)
> Betachapeu<-solve(t(X)%*%X)%*%t(X)%*%Y
> Betachapeu
```



Certifique-se que os comandos foram passados corretamente para o R, especialmente o *.

Modelo multivariado

Exemplo: Dados ortodônticos



Modelo com efeitos mistos

Neste curso, vamos considerar os modelos com efeitos mistos, que permitem fazer previsões específicas para cada unidade experimental, e ao mesmo tempo identificar padrões similares entre as observações.

Próxima aula

Modelos lineares com efeitos mistos