

## Lista 01 - Estimação por MQO

### Exercício 01

- (a) Temos que o sinal esperado para  $\beta_1$  é negativo pois, dado que temos um número limitado de minutos na semana, se mantivermos todas as demais variáveis constantes, uma alocação de mais horas para o trabalho leva, conseqüentemente a uma alocação menor de horas para o sono.
- (b) Com relação a  $\beta_3$ , espera-se que esse seja positivo pois pessoas de mais idade tentem a alocar mais tempo para o sono que os jovens.

Com relação a  $\beta_2$ , espera-se que esse seja negativo, dado que para se obter anos de estudo deve-se alocar tempo para essa atividade e, mantendo tudo mais constante, isso leva a um menor tempo para o sono.

- (c) Dado que

$$\frac{\partial sleep}{\partial totwrk} = -0,148$$

Além disso, temos que  $5h = 300min$ , temos que

$$\Delta sleep = -0,148 * 300 = 44,3 \text{ min/semana}$$

### Exercício 02

- (a) Não, pois dado que estamos lidando com quantidade de minutos por semana de um aluno e essas são todas as atividades que esse aluno pode realizar durante a semana, não é possível aumentar a quantidade de minutos alocados em cada uma dessas atividades mantendo as demais constantes (*ceteris paribus*). Para que se possa aumentar a quantidade de minutos alocadas é necessário diminuir em mesmo montante a quantidade de minutos alocadas em outra atividade.
- (b) Esse modelo viola a hipótese de que a matriz  $X$  de regressores deve possuir posto coluna cheio pois temos que é possível encontrar uma relação linear entre as colunas.

Para o caso do modelo proposto pelo exercício, temos que essa relação linear é dada por:

$$\frac{\textit{sleep} + \textit{study} + \textit{work} + \textit{leisure}}{100\,080} = 1$$

Ou seja, a soma dessas variáveis dividida pela quantidade total de minutos existente na semana ( $60 \cdot 24 \cdot 7 = 100\,080$ ) resulta na coluna de 1's da matriz  $X$  responsável pela estimação do intercepto do modelo.

- (c) Uma das formas de se corrigir esse problema é omitindo uma atividade praticada por esse estudante.

### Exercício 03

Dado o modelo

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + u$$

Podemos reescreve-lo na forma matricial, sendo essa

$$Y = X\beta + u$$

Assim, temos que o estimador de mínimos quadrados ordinários é dado por:

$$\hat{b} = (X'X)^{-1}X'Y \quad \text{substituindo } Y, \text{ temos}$$

$$\hat{b} = (X'X)^{-1}X'[X\beta + u]$$

$$\hat{b} = (X'X)^{-1}X'X\beta + (X'X)^{-1}X'u$$

$$\hat{b} = \beta + (X'X)^{-1}X'u \quad \text{passado a esperança, temos}$$

$$E(\hat{b}|X) = E(\beta + (X'X)^{-1}X'u|X)$$

$$E(\hat{b}|X) = \beta + (X'X)^{-1}X'E(u|X) \quad \text{e como } E(u|X) = 0$$

$$E(\hat{b}|X) = \beta \quad \text{ou seja, não viesado.}$$

Assim, temos que

$\hat{\theta} = \hat{\beta}_1 + \hat{\beta}_2$  passando a esperança condicional, temos

$$E(\hat{\theta}|X) = E(\hat{\beta}_1 + \hat{\beta}_2|X)$$

$$E(\hat{\theta}|X) = E(\hat{\beta}_1|X) + E(\hat{\beta}_2|X)$$

Como garantimos que o estimador de MQO é não viesado, podemos

$$E(\hat{\theta}|X) = \beta_1 + \beta_2$$

Ou seja, temos que o estimador  $\hat{\theta}$  é não viesado para a soma dos betas.

#### Exercício 04

- (a) Heterocedasticidade: o estimador de MQO continua não-viesado porém temos que as estatísticas t e F deixam de ser confiáveis. Matematicamente, isso pode ser visto por:

$$\hat{b} = (X'X)^{-1}X'Y \quad \text{como já demonstrado, temos que}$$

$$\hat{b} = \beta + (X'X)^{-1}X'u$$

Utilizando da hipótese de normalidade mais que os erros são heterocedásticos, temos que  $u \sim N(0, \sigma^2 \Omega)$ . Assim, analisando os momentos de  $\hat{b}$ , temos

$$E(\hat{b}) = \beta \quad \text{como já demonstrado e}$$

$$Var(\hat{b}) = Var[\beta + (X'X)^{-1}X'u]$$

$$Var(\hat{b}) = Var[(X'X)^{-1}X'u]$$

$$\text{Var}(\hat{b}) = (X'X)^{-1}X'\sigma^2\Omega X(X'X)^{-1}$$

Assim, o estimador para a variância de  $\hat{b}$  torna-se viesado, comprometendo a inferência estatística.

- (b) Dado o modelo  $y = \beta_0 x_1 + \beta_2 x_2 + \epsilon$ , se estimarmos somente  $y = \beta_0 x_1 + \nu$ , temos que  $\nu = \beta_2 x_2 + \epsilon$ . Assim, passando a esperança nesse segundo erro, obtemos

$$E(\nu) = E(\beta_2 x_2 + \epsilon) = E(\beta_2 x_2) + 0 \neq 0$$

Ou seja, temos que a esperança dos erros é diferente de zero. Com isso, temos que

$$E(\hat{b}|X) = \beta + (X'X)^{-1}X'E(\nu|X)$$

Assim, o estimados de MQO torna-se viesado.

- (c) Como mostrado no Exercício 02, temos que a matriz  $X$  deixa de ser posto cheio na coluna e, conseqüentemente, também torna-se singular. Assim, temos que  $X$  torna-se não inversível, assim, temos que não é possível o cálculo da matriz  $(X'X)^{-1}$ , não se tornando possível o cálculo do estimador de MQO.

## Exercício 05

Podemos representar o modelo de mco em forma matricial. Pegando somente uma observação  $i$ , temos

$$y_i = \beta x_i + u_i$$

Onde a matriz  $x_i' = [1 \ x_{1i}]$  e  $\beta = [\beta_0 \ \beta_1]$ . Assim, podemos mostrar que o estimador é não viesado, pois temos que

$$E(\hat{\beta}|X) = E\left(\frac{\sum_{i=1}^n (z_i - \bar{z})y_i}{\sum_{i=1}^n (z_i - \bar{z})x_i}\right)$$

$$E(\hat{\beta}|X) = E\left(\frac{\sum_{i=1}^n (z_i - \bar{z})(\beta x_i + u_i)}{\sum_{i=1}^n (z_i - \bar{z})x_i}\right)$$

$$E(\hat{\beta}|X) = E\left(\frac{\beta \sum_{i=1}^n (z_i - \bar{z})x_i}{\sum_{i=1}^n (z_i - \bar{z})x_i}\right) + E\left(\frac{\sum_{i=1}^n (z_i - \bar{z})u_i}{\sum_{i=1}^n (z_i - \bar{z})x_i}\right)$$

$$E(\hat{\beta}|X) = \beta + \frac{\sum_{i=1}^n (z_i - \bar{z})}{\sum_{i=1}^n (z_i - \bar{z})x_i} E(u|X)$$

Como temos que  $E(u|X) = 0$ , temos o resultado final que  $E(\hat{\beta}) = \beta$ .

## Parte empírica

### Prática 01

Todo o Script colocado aqui é partido do pré-suposto que o aluno já setou a pasta de Work Directory pelo comando *setwd*. A resolução e explicação desse script foi realizada em aula.

Leitura dos dados:

```
dados = read.table("SLEEP75.txt", header=T, sep=" t", dec =",")
attach(dados)
```

(a) `item.a = lm(sleep ~ totwrk + educ + age)`

(b) `item.b.i = lm(sleep ~ educ + age)`

```
v.hat = item.b.i$residuals
```

```
item.b.iii = lm(totwrk ~ educ + age)
```

```
w.hat = item.b.iii$residuals
```

```
item.b.v = lm(v.hat ~ w.hat)
```