

# TÉCNICAS APLICADAS DE INVESTIGAÇÃO EM GESTÃO

## 1. Regressão linear múltipla – estimação e inferência

- Modelo de regressão linear múltipla
- Estimador dos mínimos quadrados
  - Interpretação dos parâmetros
  - Propriedades
- Inferência:
  - Intervalos de confiança
  - Testes de hipóteses para um só parâmetro
  - Testes de hipóteses para uma restrição linear dos parâmetros
  - Testes F

# Motivação e interpretação

## ► Modelo de Regressão Linear Simples

1. Fertilidade:  $Filhos = \beta_0 + \beta_1 educ + u$

2. Peso de um bebé:  $peso = \beta_0 + \beta_1 cigs + u$

3. Salário:  $sal = \beta_0 + \beta_1 educ + u$

## ► Modelo de Regressão Linear Múltipla: análise *ceteris paribus*

1. Fertilidade:  $Filhos = \beta_0 + \beta_1 educ + \beta_2 idade + \beta_3 rend + u$

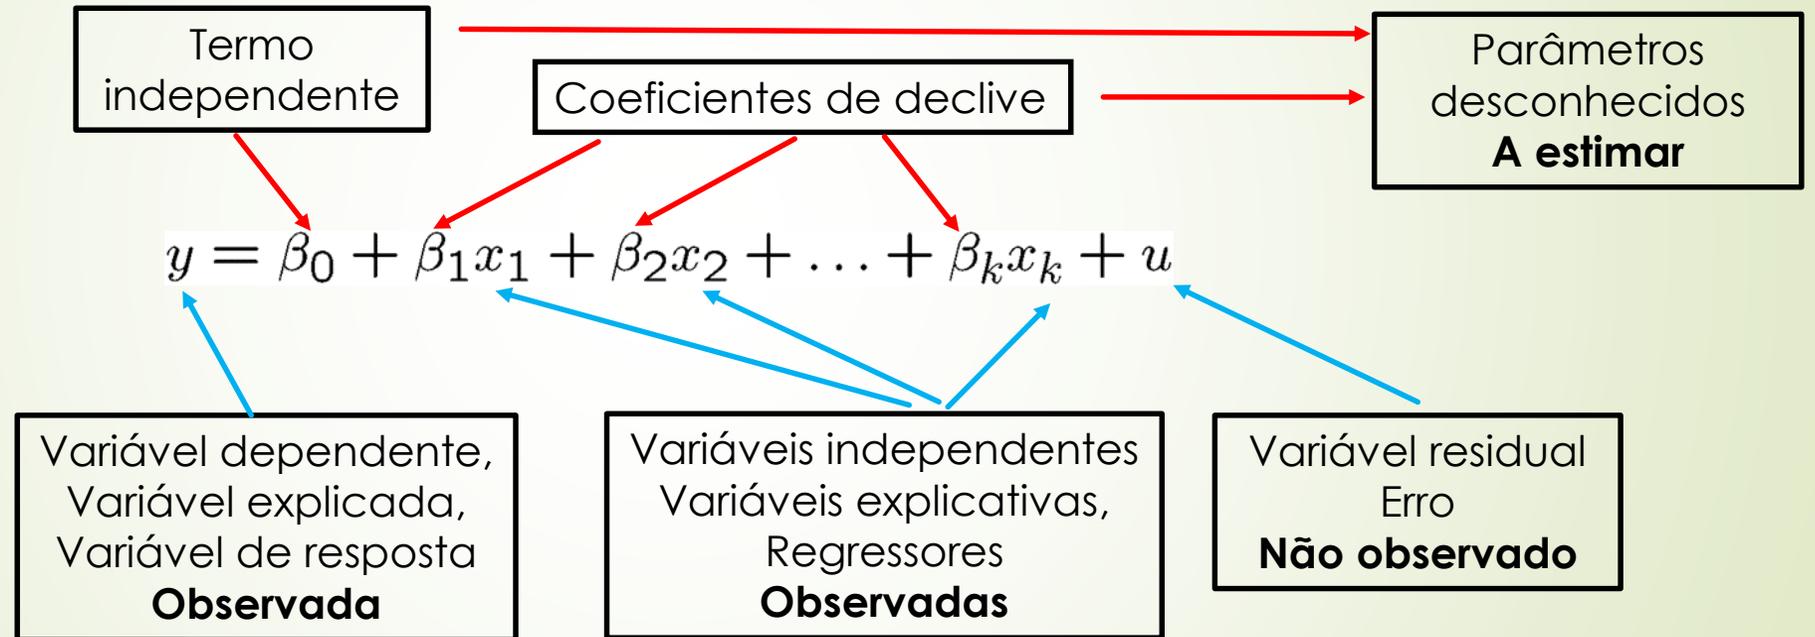
2. Peso de um bebé:  $peso = \beta_0 + \beta_1 cigs + \beta_2 educ + \beta_3 nconsul + u$

3. Salário:  $sal = \beta_0 + \beta_1 educ + \beta_2 exper + u$

# O método dos mínimos quadrados

## Formalização do Modelo de Regressão Linear Múltipla

O Modelo explica a variável  $y$  em função das variáveis  $x_1, x_2, \dots, x_k$



# O método dos mínimos quadrados (OLS)

## ► Estimação OLS

- Amostra aleatória

$$\{(x_{i1}, x_{i2}, \dots, x_{ik}, y_i) : i = 1, \dots, n\}$$

- Valores ajustados: considere-se as estimativas  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_k x_{ik}$$

- Resíduos

$$\hat{u}_i = y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik}$$

- Minimização da soma dos quadrados dos resíduos

$$\min \sum_{i=1}^n \hat{u}_i^2 \rightarrow \hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$$

# O método dos mínimos quadrados (OLS)

## ► Propriedades algébricas dos resíduos OLS

$$\hat{u}_i = y_i - \hat{y}_i \quad \text{com} \quad \hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_k x_{ik}$$

1. 
$$\sum_{i=1}^n \hat{u}_i = 0$$

2. 
$$\sum_{i=1}^n x_{ij} \hat{u}_i = 0$$

3. 
$$\bar{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x}_1 + \dots + \hat{\beta}_k \bar{x}_k$$

As médias observadas na amostra da variável explicada e das variáveis explicativas estão na regressão

# Estimação da variância da v. residual

## ► Estimação da variância da variável residual (erro)

►  $u$  é uma variável aleatória que verifica

–  $E(u) = 0$

–  $V(u) = \sigma^2$

Parâmetro a  
estimar

► Estimador da variância

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n \hat{u}_i^2}{n - k - 1}$$

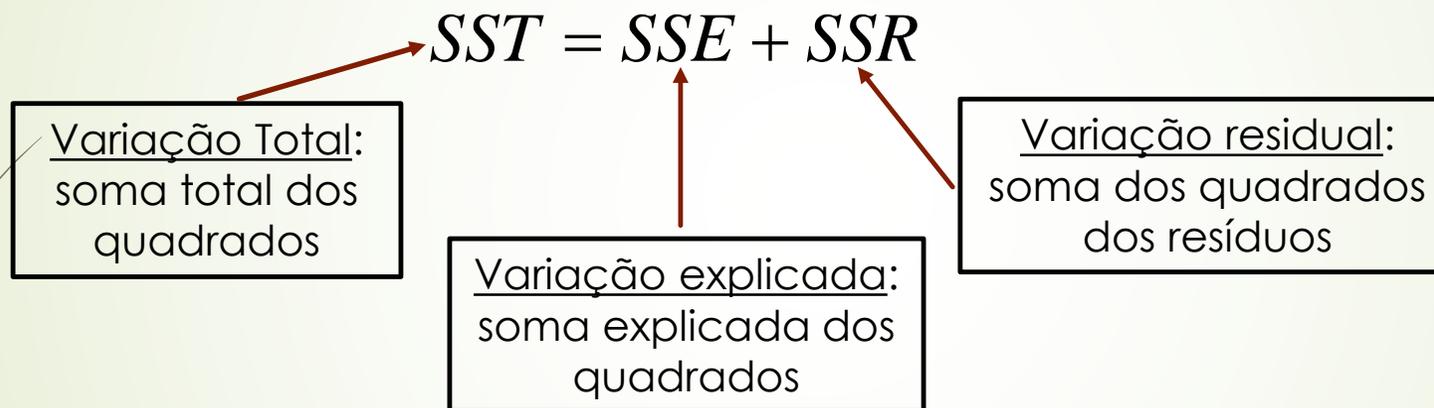
Graus de liberdade

Número de  
observações

Número de  
variáveis

# Coeficiente de determinação

- Coeficiente de determinação: medir a qualidade do ajustamento
  - Decomposição da variação total (supondo modelo com termo independente)



- Coeficiente de determinação ou  $R^2$

$$R^2 = SSE/SST = 1 - SSR/SST$$

# Coeficiente de determinação

## ► Observações

►  $0 \leq R^2 \leq 1$

► Sempre que se junta uma variável ao modelo o  $R^2$  aumenta mesmo que o poder explicativo desta var. seja irrelevante

► Não usar o  $R^2$  para comparar a capacidade explicativa de modelos com

1. diferente número de variáveis explicativas

2. variáveis dependentes definidas em escalas muito diferentes

Alternativa para  $R^2$  na situação 1:  $\Rightarrow \bar{R}^2$  ajustado

► o  $R^2$  é igual ao quadrado do coeficiente de correlação empírica entre os valores observados e os valores ajustados da variável dependente

# Coeficiente de determinação

## ► Observações (continuação)

- Um  $R^2$  elevado não significa que exista realmente uma relação causal entre as variáveis
- Um  $R^2$  baixo não é necessariamente um sintoma de que os efeitos parciais das variáveis não sejam estimados com precisão

## ► Cálculo do $\bar{R}^2$

$$R^2 = 1 - \frac{SSR}{SST} = 1 - \frac{(SSR/n)}{(SST/n)} \text{ é uma estimativa de } 1 - \frac{\sigma_u^2}{\sigma_y^2}$$

$R^2$  da população

$$\bar{R}^2 = 1 - \frac{(SSR/(n - k - 1))}{(SST/(n - 1))} = \text{adjusted } R^2$$

Correção dos graus de liberdade do numerador e do denominador

$$\bar{R}^2 = 1 - (1 - R^2)(n - 1)/(n - k - 1)$$

Pode ser negativo

# Forma funcional e interpretação dos parâmetros

## ► Interpretação de $\hat{\beta}_j$ em termos de efeito parcial depois de removido o efeito das outras variáveis

- Mostra-se que no MRLM  $\hat{\beta}_j$  pode ser obtido em 2 passos:

1) Regressão de  $x_j$  em termos de todas as outras variáveis explicativas



expurga de  $x_j$  a influência de todas as outras variáveis explicativas

2) Regressão de  $y$  em função dos resíduos da regressão anterior

- Os resíduos da 1ª regressão representam a parte de  $x_j$  que não depende das outras variáveis explicativas
- O coeficiente de declive da segunda regressão é igual a  $\hat{\beta}_j$  e representa assim o impacto de  $x_j$  depois de expurgados (removidos) os efeitos das outras variáveis

# Forma funcional e interpretação dos parâmetros

11

- Note-se que:  $\beta_j = \frac{\partial y}{\partial x_j}$

Mede a variação de  $y$  quando  $x_j$  varia de uma unidade mantendo tudo o resto constante

- O MRLM permite manter na análise o valor das outras variáveis explicativas fixo ou constante mesmo que sejam correlacionadas com a variável em análise



**Análise ceteris paribus**

- Tem que se admitir ainda que o erro não varia quando  $x_j$  varia

# Forma funcional e interpretação dos parâmetros

## ► Interpretação de $\hat{\beta}_j$

$$\hat{y}_I = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \dots + \hat{\beta}_k x_k \quad \text{e} \quad \hat{y}_F = \hat{\beta}_0 + \hat{\beta}_1 (x_1 + 1) + \hat{\beta}_2 x_2 + \dots + \hat{\beta}_k x_k$$

$$\hat{y}_F - \hat{y}_I = \Delta \hat{y} =$$

$$\hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_1 + \hat{\beta}_2 x_2 + \dots + \hat{\beta}_k x_k - \hat{\beta}_0 - \hat{\beta}_1 x_1 - \hat{\beta}_2 x_2 - \dots - \hat{\beta}_k x_k$$

Então

$$\hat{\beta}_j = \Delta \hat{y} \quad \text{if} \quad \Delta x_j = 1 \quad \textit{ceteris paribus}$$

## ► Variação total de $y$

$$\Delta \hat{y} = \hat{\beta}_1 \Delta x_1 + \hat{\beta}_2 \Delta x_2 + \dots + \hat{\beta}_k \Delta x_k$$

# Exemplo

Dependent Variable: PRICE

Method: Least Squares

Included observations: 88

| Variable           | Coefficient | Std. Error            | t-Statistic | Prob.    |
|--------------------|-------------|-----------------------|-------------|----------|
| C                  | -21.77031   | 29.47504              | -0.738601   | 0.4622   |
| ALOTE              | 0.022257    | 0.006912              | 3.220096    | 0.0018   |
| ACASA              | 1.321574    | 0.142486              | 9.275093    | 0.0000   |
| BDRMS              | 13.85252    | 9.010145              | 1.537436    | 0.1279   |
| R-squared          | 0.672362    | Mean dependent var    |             | 293.5460 |
| Adjusted R-squared | 0.660661    | S.D. dependent var    |             | 102.7134 |
| S.E. of regression | 59.83348    | Akaike info criterion |             | 11.06540 |
| Sum squared resid  | 300723.8    | Schwarz criterion     |             | 11.17800 |
| Log likelihood     | -482.8775   | Hannan-Quinn criter.  |             | 11.11076 |
| F-statistic        | 57.46023    | Durbin-Watson stat    |             | 2.109796 |
| Prob(F-statistic)  | 0.000000    |                       |             |          |

# Exemplo

Dependent Variable: LOG(PRICE)

Method: Least Squares

Sample: 1 88

Included observations: 88

| Variable           | Coefficient | Std. Error            | t-Statistic | Prob.     |
|--------------------|-------------|-----------------------|-------------|-----------|
| C                  | 0.765972    | 0.440114              | 1.740396    | 0.0855    |
| LOG(ALOTE)         | 0.167967    | 0.038281              | 4.387714    | 0.0000    |
| LOG(ACASA)         | 0.700232    | 0.092865              | 7.540306    | 0.0000    |
| BDRMS              | 0.036958    | 0.027531              | 1.342415    | 0.1831    |
| R-squared          | 0.642965    | Mean dependent var    |             | 5.633180  |
| Adjusted R-squared | 0.630214    | S.D. dependent var    |             | 0.303573  |
| S.E. of regression | 0.184603    | Akaike info criterion |             | -0.496833 |
| Sum squared resid  | 2.862563    | Schwarz criterion     |             | -0.384227 |
| Log likelihood     | 25.86066    | Hannan-Quinn criter.  |             | -0.451467 |
| F-statistic        | 50.42374    | Durbin-Watson stat    |             | 2.088996  |
| Prob(F-statistic)  | 0.000000    |                       |             |           |

# Exemplo

Dependent Variable: PRICE

Method: Least Squares

Sample: 1 88

Included observations: 88

| Variable           | Coefficient | Std. Error            | t-Statistic | Prob.    |
|--------------------|-------------|-----------------------|-------------|----------|
| C                  | -1345.801   | 141.4617              | -9.513543   | 0.0000   |
| LOG(ALOTE)         | 61.45707    | 12.30436              | 4.994739    | 0.0000   |
| LOG(ACASA)         | 224.9734    | 29.84882              | 7.537093    | 0.0000   |
| BDRMS              | 19.35056    | 8.849135              | 2.186718    | 0.0315   |
| R-squared          | 0.677797    | Mean dependent var    |             | 293.5460 |
| Adjusted R-squared | 0.666290    | S.D. dependent var    |             | 102.7134 |
| S.E. of regression | 59.33513    | Akaike info criterion |             | 11.04867 |
| Sum squared resid  | 295735.3    | Schwarz criterion     |             | 11.16128 |
| Log likelihood     | -482.1415   | Hannan-Quinn criter.  |             | 11.09404 |
| F-statistic        | 58.90179    | Durbin-Watson stat    |             | 2.241032 |
| Prob(F-statistic)  | 0.000000    |                       |             |          |

# Hipóteses e Propriedades estatísticas

- Hipótese DS.1: Modelo linear nos parâmetros

Na população, a relação entre  $y$  e os Coeficientes é linear

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$$

O modelo inclui uma variável residual (não observada)

- Hipótese DS.2: Amostragem aleatória

$$\{(x_{i1}, x_{i2}, \dots, x_{ik}, y_i) : i = 1, \dots, n\}$$

Os dados são constituem uma amostra puramente aleatória da população

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + u_i$$

Cada observação verifica o modelo da população

# Hipóteses e Propriedades estatísticas

- ▶ Hipótese DS.3: não existe multicolinearidade perfeita entre as variáveis explicativas
  - Nenhuma variável pode ser constante
  - Nenhuma variável pode ser uma combinação linear da outra
- ▶ Exemplo de multicolinearidade perfeita

$$voteA = \beta_0 + \beta_1 shareA + \beta_2 shareB + u$$

Votação em A num sistema bipartidário

Proporção de votos em A nas eleições anteriores

Proporção de votos em B nas eleições anteriores

$$shareA + shareB = 1$$

# Hipóteses e Propriedades estatísticas

## ► Hipótese DS.4

O valor das variáveis explicativas não deve conter informação sobre a média do erro

$$E(u_i | x_{i1}, x_{i2}, \dots, x_{ik}) = 0$$



$$\text{Corr}(u, x_j) = 0 \quad \forall j = 1, \dots, k$$

- Variáveis explicativas que são correlacionadas com o erro são consideradas endógenas
- Variáveis explicativas que não são correlacionadas com o erro são consideradas exógenas
- A hipótese DS.4 verifica-se quando todas as variáveis são exógenas

# Hipóteses e Propriedades estatísticas

## ► Teorema 1

Sob as hipóteses DS.1 a DS.4 demonstra-se que o estimador OLS é **centrado**:

$$E(\hat{\beta}_j) = \beta_j \quad j = 1, \dots, k$$

## ► Hipótese DS.5: Homocedasticidade

$$\text{Var}(u_i | x_{i1}, x_{i2}, \dots, x_{ik}) = \sigma^2$$

O valor das variáveis explicativas não pode conter qualquer informação sobre a variância do erro

A variância do erro não pode depender do valor das variáveis explicativas

# Hipóteses e Propriedades estatísticas

## ► Variância do estimador OLS

Sob as hipóteses DS.1 a DS.5 então,

$$Var(\hat{\beta}_j) = \frac{\sigma^2}{SST_j(1 - R_j^2)}, \quad j = 1, \dots, k$$

Variância do erro

Variação total na amostra  
da v. explicativa  $j$

$R^2$  da regressão da variável explicativa  $j$  sobre todas  
as outras variáveis explicativas (incluindo a constante)

$$\sum_{i=1}^n (x_{ij} - \bar{x}_j)^2$$

# Hipóteses e Propriedades estatísticas

## ► Desvios padrão e erros padrão de $\hat{\beta}_j$

### ► Desvio padrão de $\hat{\beta}_j$ (desconhecido)

$$sd(\hat{\beta}_j) = \sqrt{Var(\hat{\beta}_j)} = \sqrt{\sigma^2 / [SST_j(1 - R_j^2)]}$$

### ► Erro padrão de $\hat{\beta}_j$

$$se(\hat{\beta}_j) = \sqrt{\widehat{Var}(\hat{\beta}_j)} = \sqrt{\widehat{\sigma}^2} / [SST_j(1 - R_j^2)]$$

Valor dado pelos softwares.

# Hipóteses e Propriedades estatísticas

## ► Componentes da variância OLS

### 1. Variância do Erro

- Quando maior a variância do erro, menor a precisão com que se estimam os coeficientes (maior a variância do OLS) porque existe mais “distúrbio” no modelo
- A variância do erro não diminui aumentando o n° de observações na amostra

### 2. Variação total do regressor $j$

- Quanto maior a variação total de  $x_j$ , maior a precisão com que se estima  $\beta_j$
- a variação total de  $x_j$  pode aumentar quando aumenta a dimensão da amostra

# Hipóteses e Propriedades estatísticas

## 3. Correlação linear entre os regressores do modelo

- ▶ O  $R_j^2$  (coeficiente de determinação da regressão de  $x_j$  sobre todas as outras variáveis explicativas) é tanto maior quanto maior for a correlação entre  $x_j$  e as outras variáveis do modelo.
- ▶ Quanto maior for  $R_j^2$  menor a precisão com que se estima  $\beta_j$ .



Evitar de introduzir no modelo variáveis explicativas muito correlacionadas

- ▶ Quando a correlação entre as variáveis é muito elevada tem-se um problema de multicolinearidade, i.e. existe  $x_j : R_j \rightarrow 1$

# Hipóteses e Propriedades estatísticas

## ► O problema da Multicolienaridade

- Quando as variáveis estão muito correlacionadas torna-se difícil discriminar o efeito de cada uma delas.
- O problema da falta de precisão na estimação provocado pela multicolienaridade afeta a estimação dos efeitos parciais apenas das variáveis que têm multicolienaridade e não de todas as variáveis do modelo.
- A multicolienaridade não representa uma violação da hipótese DS.3
- Pode ser identificada através dos fatores VIF (*variance inflation factor*)

$$VIF_j = 1/(1 - R_j^2)$$

**VIF > 10**  **sintomas de multicolienaridade**

# Hipóteses e Propriedades estatísticas

## ► Teorema 2: Teorema de Gauss Markov

- Sob as hipóteses DS.1 a DS.5 o estimador OLS para os coeficientes do modelo  $\beta_j$   $j = 0, 1, \dots, k$  é o **mais eficiente** na classe dos estimadores centrados e lineares em  $y$ .

$$\text{Var}(\hat{\beta}_j) \leq \text{Var}(\tilde{\beta}_j) \quad j = 0, 1, \dots, k$$

Para qualquer  $\tilde{\beta}_j = \sum_{i=1}^n w_{ij} y_i$  que verifique  $E(\tilde{\beta}_j) = \beta_j, j = 0, \dots, k$

## ► Teorema 3:

- Sob as hipóteses DS.1 a DS.5  $E(\hat{\sigma}^2) = \sigma^2$

# Hipóteses e Propriedades estatísticas

## ► Inclusão de variáveis irrelevantes

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

$$x_3 \text{ irrelevante} \Rightarrow \beta_3 = 0$$

- como OLS centrado então

$$E(\hat{\beta}_3) = 0$$

- No entanto a inclusão de variáveis irrelevantes pode levar a que as **variâncias sejam maiores**

## ► Omissão de variáveis relevantes

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

$$x_2 \text{ relevante} \Rightarrow \beta_2 \neq 0$$

$$y = \alpha_0 + \alpha_1 x_1 + w$$

Modelo especificado: omissão de  $x_2$

Verdadeiro modelo

# Hipóteses e Propriedades estatísticas

## ► Enviesamento por omissão de variáveis

$$x_2 = \delta_0 + \delta_1 x_1 + v \quad \leftarrow \text{Se } x_2 \text{ estiver correlacionado com } x_1 \text{ pode assumir-se que verificam uma relação linear}$$

$$\Rightarrow y = \beta_0 + \beta_1 x_1 + \beta_2(\delta_0 + \delta_1 x_1 + v) + u \quad \leftarrow \text{Substituindo a relação no verdadeiro modelo obtém-se o modelo especificado}$$

$$= (\beta_0 + \beta_2 \delta_0) + (\beta_1 + \beta_2 \delta_1) x_1 + (\beta_2 v + u)$$

$\alpha_0$                        $\alpha_1$                        $w$

- Em conclusão: não se consegue estimar  $\beta_0, \beta_1$  e  $\beta_2$
- **Os coeficientes estimados são enviesados** para estimar os coeficientes do verdadeiro modelo quando a variável omitida está correlacionada com as outras variáveis do modelo

# Inferência - Introdução

## Exemplos

Peso de um bebé à  
nascença

$$\longrightarrow peso = \beta_0 + \beta_1 cigs + \beta_2 idade + \beta_3 educ + \beta_4 nconsul + u$$

- Será o rendimento uma variável relevante para explicar o peso?

$$H_0 : \beta_4 = 0 \quad H_1 : \beta_4 \neq 0$$

Teste de significância individual

- Será que se a mãe tiver mais uma consulta durante a gravidez compensa o efeito negativo no peso decorrente de fumar mais 2 cigarros?

$$H_0 : 2\beta_1 + \beta_4 = 0 \quad H_1 : 2\beta_1 + \beta_4 \neq 0$$

Teste de uma restrição linear sobre os parâmetros

- Será que o peso depende apenas do número de cigarros?

$$H_0 : \beta_2 = 0, \beta_3 = 0, \beta_4 = 0 \quad H_1 : \beta_2 \neq 0 \vee \beta_3 \neq 0 \vee \beta_4 \neq 0$$

Teste de significância conjunta  
Várias restrições em simultâneo

$$peso = \beta_0 + \beta_1 cigs + u$$

Modelo sob  $H_0$

$$peso = \beta_0 + \beta_1 cigs + \beta_2 educ + \beta_3 idade + \beta_4 nconsul + u$$

Modelo sob  $H_1$

# Inferência – Distribuição do estimador OLS

- Hipótese DS.6: Distribuição Normal dos erros

$$u_i \sim N(0, \sigma^2) \quad \text{Independente de } x_{i1}, x_{i2}, \dots, x_{ik}$$

- Teorema 1: Sob as hipóteses DS.1 a DS.6 prova-se que,

$$\hat{\beta}_j \sim N(\beta_j, \text{Var}(\hat{\beta}_j)) \quad \text{equivalentemente} \quad \frac{\hat{\beta}_j - \beta_j}{\text{sd}(\hat{\beta}_j)} \sim N(0, 1)$$

- Teorema 2: Sob as hipóteses DS.1 a DS.6 prova-se que,

$$\frac{\hat{\beta}_j - \beta_j}{\text{se}(\hat{\beta}_j)} \sim t_{n-k-1}$$

Estatística t

Note-se que  $\text{sd}(\hat{\beta}_j)$  depende de  $\sigma^2$  que é desconhecido enquanto que  $\text{se}(\hat{\beta}_j)$  depende de  $\hat{\sigma}^2$ . A substituição de  $\sigma^2$  por  $\hat{\sigma}^2$  altera a distribuição do rácio da  $N(0,1)$  para a distribuição t-student.

# Inferência - Intervalos de Confiança

30

## ► Intervalo de confiança para $\beta_j$

$\beta_j \in \left( \hat{\beta}_j - se(\hat{\beta}_j)t_{\alpha/2}; \hat{\beta}_j + se(\hat{\beta}_j)t_{\alpha/2} \right)$  com  $(1 - \alpha) \times 100\%$  de confiança

com  $t_{\alpha/2} : P(t(n - k - 1) > t_{\alpha/2}) = \frac{\alpha}{2}$

Esta probabilidade é igual a 0.025 para um nível de confiança de 95%

## ► Exemplo

Dependent Variable: PESO (gramas)

Method: Least Squares

Included observations: 1644 after adjustments

| Variable       | Coefficient | Std. Error         | t-Statistic | Prob.  |
|----------------|-------------|--------------------|-------------|--------|
| C              | 3170.187    | 115.8661           | 27.36079    | 0.0000 |
| CIGS           | -10.49749   | 3.338919           | -3.143977   | 0.0017 |
| IDADE          | 3.558060    | 3.130502           | 1.136578    | 0.2559 |
| EDUC           | 0.975131    | 7.147705           | 0.136426    | 0.8915 |
| NCONSUL        | 11.46307    | 3.765319           | 3.044381    | 0.0024 |
| R-squared      | 0.013998    | Mean dependent var | 3409.99     |        |
| Adj. R-squared | 0.011592    | S.D. dependent var | 570.58      |        |
| F-statistic    | 5.817211    | Prob(F-statistic)  | 0.00012     |        |

INTERVALO DE CONFIANÇA A 95% para  $\beta_1$

$\beta_1 \in (-10.50 - 1.96 \times 3.34 ; -10.50 + 1.96 \times 3.34)$

$\beta_1 \in (-17.05 ; -3.95)$  com 95% de confiança

# Inferência - Testes de hipóteses para um parâmetro

## ► Teste de significância individual

$$H_0 : \beta_j = 0 \quad H_1 : \beta_j \neq 0$$

A variável  $x_j$  não tem efeito na determinação de  $y$  depois de controlar pelo efeito de todas as outras variáveis explicativas (o efeito adicional é nulo)

## ► Estatística de teste sob $H_0$

$$t_j = \frac{\hat{\beta}_j}{se(\hat{\beta}_j)} \sim t(n - k - 1)$$

## ► Valor-p (p-value)

- é o menor nível de significância estatística para o qual ainda se rejeita  $H_0$
- Mede a evidência favorável a  $H_0$
- Depende da hipótese alternativa
- Alternativa bilateral:  $H_1 : \beta_j \neq 0$  então  $p = 2P(t(n - k - 1) > |t_{obsj}|)$
- Alternativa  $H_1 : \beta_j > 0$  então  $p = P(t(n - k - 1) > t_{obsj})$
- Alternativa  $H_1 : \beta_j < 0$  então  $p = P(t(n - k - 1) < t_{obsj})$

Rejeitar  $H_0$  sempre que  $p < \alpha$  com  $\alpha = 0.01$  ou  $0.05$  ou  $0.1$

# Inferência - Testes de hipóteses para um parâmetro

32

## ► Teste sobre um valor para $\beta_j$

$$H_0 : \beta_j = b$$

### ► Estatística de teste sob $H_0$

$$t = \frac{\hat{\beta}_j - b}{se(\hat{\beta}_j)} \sim t(n - k - 1)$$

### ► Valor-p (p-value) e região de rejeição a $\alpha \times 100\%$ , $W_\alpha$

$$H_1 : \beta_j \neq b \text{ então } p = 2P(t(n - k - 1) > |t_{obs}|); \quad W_\alpha = \{t : |t| > t_{\alpha/2}\}; \quad t_{\alpha/2} : P(t(n - k - 1) > t_{\alpha/2}) = \alpha / 2$$

$$H_1 : \beta_j > b \text{ então } p = P(t(n - k - 1) > t_{obs}); \quad W_\alpha = \{t : t > t_\alpha\}; \quad t_\alpha : P(t(n - k - 1) > t_\alpha) = \alpha$$

$$H_1 : \beta_j < b \text{ então } p = P(t(n - k - 1) < t_{obs}); \quad W_\alpha = \{t : t < -t_\alpha\}; \quad t_\alpha : P(t(n - k - 1) > t_\alpha) = \alpha$$

### ► Exemplo: $H_0 : \beta_1 \geq -10$ $H_1 : \beta_1 < -10$

valor observado da estatística de teste:  $t = \frac{-10.50 - (-10)}{3.34} = -0.150 > -1.645$

↑  
Não rejeitar  $H_0$

# Inferência - Testes para uma combinação linear dos parâmetros

33

►  $H_0 : c_1\beta_1 + c_2\beta_2 = b$

► Estatística de teste sob  $H_0$

$$t = \frac{c_1\hat{\beta}_1 + c_2\hat{\beta}_2 - b}{se(c_1\hat{\beta}_1 + c_2\hat{\beta}_2)} \sim t(n - k - 1)$$

► Cálculo do erro padrão

$$se(c_1\hat{\beta}_1 + c_2\hat{\beta}_2) = \sqrt{c_1^2\hat{Var}(\hat{\beta}_1) + c_2^2\hat{Var}(\hat{\beta}_2) + 2c_1c_2\hat{Cov}(\hat{\beta}_1, \hat{\beta}_2)}$$

► **Exemplo:** Wald Test:

| Test Statistic | Value     | df   | Probability |
|----------------|-----------|------|-------------|
| t-statistic    | -1.231046 | 1639 | 0.2185      |

Null Hypothesis:  $2 \cdot C(2) + C(5) = 0$

Null Hypothesis Summary:

| Normalized Restriction (= 0) | Value     | Std. Err. |
|------------------------------|-----------|-----------|
| $2 \cdot C(2) + C(5)$        | -9.531905 | 7.742929  |

# Inferência – Testes F

34

## ► Teste de significância global

- Estatística de teste sob  $H_0$

$$F = \frac{R^2}{1 - R^2} \times \frac{n - k - 1}{k} \sim F(k, n - k - 1) \quad \text{Com valor-p } p = P(F(k, n - k - 1) > F_{obs})$$

## ► Teste de $q$ restrições lineares sobre os parâmetros

- Estatística de teste sob  $H_0$

$$F \sim F(q, n - k - 1) \quad \text{Com valor-p } p = P(F(q, n - k - 1) > F_{obs})$$

- **Exemplo** Wald Test:

| Test Statistic               | Value    | df        | Probability |
|------------------------------|----------|-----------|-------------|
| F-statistic                  | 0.784908 | (2, 1639) | 0.4563      |
| Null Hypothesis: C(3)=C(4)=0 |          |           |             |
| Normalized Restriction (= 0) | Value    | Std. Err. |             |
| C(3)                         | 3.558060 | 3.130502  |             |
| C(4)                         | 0.975131 | 7.147705  |             |