

# ACA228 - Modelos de Regressão e Previsão

Regressão Linear Multipla: variáveis qualitativas e efeito de interação

Prof. Carlos Trucíos  
carlos.trucios@facc.ufrj.br  
ctruciosm.github.io

Faculdade de Administração e Ciências Contábeis,  
Universidade Federal do Rio de Janeiro

Aula 11

Introdução

Variável independente binária

Efeito de interação

# Introdução

# Introdução

- ▶ Até agora temos trabalhando com variáveis explicativas de tipo quantitativo

# Introdução

- ▶ Até agora temos trabalhando com variáveis explicativas de tipo quantitativo
- ▶ No dia a dia, variáveis explicativas de tipo **qualitativo** podem também nos ajudar a explicar a variabilidade de  $y$

# Introdução

- ▶ Até agora temos trabalhando com variáveis explicativas de tipo quantitativo
- ▶ No dia a dia, variáveis explicativas de tipo **qualitativo** podem também nos ajudar a explicar a variabilidade de  $y$ 
  - ▶ sexo

# Introdução

- ▶ Até agora temos trabalhando com variáveis explicativas de tipo quantitativo
- ▶ No dia a dia, variáveis explicativas de tipo **qualitativo** podem também nos ajudar a explicar a variabilidade de  $y$ 
  - ▶ sexo
  - ▶ estado civil

# Introdução

- ▶ Até agora temos trabalhando com variáveis explicativas de tipo quantitativo
- ▶ No dia a dia, variáveis explicativas de tipo **qualitativo** podem também nos ajudar a explicar a variabilidade de  $y$ 
  - ▶ sexo
  - ▶ estado civil
  - ▶ raça



# Introdução

- ▶ Até agora temos trabalhando com variáveis explicativas de tipo quantitativo
- ▶ No dia a dia, variáveis explicativas de tipo **qualitativo** podem também nos ajudar a explicar a variabilidade de  $y$ 
  - ▶ sexo
  - ▶ estado civil
  - ▶ raça
  - ▶ religião

# Introdução

- ▶ Até agora temos trabalhando com variáveis explicativas de tipo quantitativo
- ▶ No dia a dia, variáveis explicativas de tipo **qualitativo** podem também nos ajudar a explicar a variabilidade de  $y$ 
  - ▶ sexo
  - ▶ estado civil
  - ▶ raça
  - ▶ religião
  - ▶ estado

# Introdução

- ▶ Até agora temos trabalhando com variáveis explicativas de tipo quantitativo
- ▶ No dia a dia, variáveis explicativas de tipo **qualitativo** podem também nos ajudar a explicar a variabilidade de  $y$ 
  - ▶ sexo
  - ▶ estado civil
  - ▶ raça
  - ▶ religião
  - ▶ estado
- ▶ Variáveis qualitativas no modelo não afetarão o processo de estimação mas levarão a uma interpretação diferente dos parâmetros do modelo.

# Introdução

- ▶ Até agora temos trabalhando com variáveis explicativas de tipo quantitativo
- ▶ No dia a dia, variáveis explicativas de tipo **qualitativo** podem também nos ajudar a explicar a variabilidade de  $y$ 
  - ▶ sexo
  - ▶ estado civil
  - ▶ raça
  - ▶ religião
  - ▶ estado
- ▶ Variáveis qualitativas no modelo não afetarão o processo de estimação mas levarão a uma interpretação diferente dos parâmetros do modelo.
- ▶ Como definimos a variável qualitativa nos ajudará na interpretação.

## Variável independente binária

## Variável independente binária (dummy)

Seja

$$wage = \beta_0 + \beta_1 female + \beta_2 educ + u$$

onde:

- ▶  $female = 1$  quando a pessoa for mulher
- ▶  $female = 0$  quando a pessoa for homem

0-1?

Variáveis binárias são recategorizadas como 0 e 1, essa codificação não é obrigatória mas é comum e ajuda na interpretação.

## Variável independente binária (dummy)

Seja

$$wage = \beta_0 + \beta_1 female + \beta_2 educ + u$$

onde:

- ▶  $female = 1$  quando a pessoa for mulher
- ▶  $female = 0$  quando a pessoa for homem

0-1?

Variáveis binárias são recategorizadas como 0 e 1, essa codificação não é obrigatória mas é comum e ajuda na interpretação.

- ▶  $\beta_1$  é a diferença no salário entre mulheres ( $female = 1$ ) e homens ( $female = 0$ ) quando todos os outros fatores permanecem fixos.

## Variável independente binária (dummy)

Seja

$$wage = \beta_0 + \beta_1 female + \beta_2 educ + u$$

onde:

- ▶  $female = 1$  quando a pessoa for mulher
- ▶  $female = 0$  quando a pessoa for homem

0-1?

Variáveis binárias são recategorizadas como 0 e 1, essa codificação não é obrigatória mas é comum e ajuda na interpretação.

- ▶  $\beta_1$  é a diferença no salário entre mulheres ( $female = 1$ ) e homens ( $female = 0$ ) quando todos os outros fatores permanecem fixos.
- ▶  $\beta_1$  nos dirá, por exemplo, se existe discriminação de gênero no salário.



## Variável independente binária (dummy)

```
library(wooldridge)
coef(lm(wage~female + educ, data = wage1))
```

```
## (Intercept)      female      educ
##  0.6228168  -2.2733619   0.5064521
```

$$wage = 0.6228168 - 2.2733619female + 0.5064521educ$$

## Variável independente binária (dummy)

```
library(wooldridge)
coef(lm(wage~female + educ, data = wage1))
```

```
## (Intercept)      female      educ
##  0.6228168  -2.2733619  0.5064521
```

$$wage = 0.6228168 - 2.2733619female + 0.5064521educ$$

- ▶ Quando a pessoa for homem ( $female = 0$ ),

$$\widehat{wage} = 0.6228168 + 0.5064521 educ$$

## Variável independente binária (dummy)

```
library(wooldridge)
coef(lm(wage~female + educ, data = wage1))
```

```
## (Intercept)      female      educ
##  0.6228168 -2.2733619  0.5064521
```

$$wage = 0.6228168 - 2.2733619female + 0.5064521educ$$


- ▶ Quando a pessoa for homem (female = 0),

$$\widehat{wage} = 0.6228168 + 0.5064521 educ$$

- ▶ Quando a pessoa for mulher (female = 1),

$$\widehat{wage} = \underbrace{0.6228168 - 2.2733619}_{-1.650545} + 0.5064521 educ$$

## Variável independente binária (dummy)



## Variável independente binária (dummy)

- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 1 = -1.144093$
- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 2 = -0.6376408$
- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 3 = -0.1311887$
- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 4 = 0.3752634$

## Variável independente binária (dummy)

- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 1 = -1.144093$
- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 2 = -0.6376408$
- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 3 = -0.1311887$
- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 4 = 0.3752634$

Mulheres com menos de 4 anos de educação tem salario negativo?

## Variável independente binária (dummy)

- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 1 = -1.144093$
- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 2 = -0.6376408$
- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 3 = -0.1311887$
- ▶  $\widehat{wage} = -1.650545 + 0.5064521 \times 4 = 0.3752634$

Mulheres com menos de 4 anos de educação tem salario negativo?

```
prop.table(table(wage1$educ[wage1$female == 1]<4))
```

```
##  
##          FALSE          TRUE  
## 0.992063492 0.007936508
```

### Cuidado!

Resultados contra intuitivos podem ser causados por falta de dados ou estimadores viesados!

## Variável independente binária (dummy)

- ▶ Temos usado female (0 e 1)



## Variável independente binária (dummy)

- ▶ Temos usado female (0 e 1)
- ▶ E se incluirmos também outra variável, digamos male (0 e 1)?

## Variável independente binária (dummy)

- ▶ Temos usado female (0 e 1)
- ▶ E se incluirmos também outra variável, digamos male (0 e 1)?
  - ▶ redundante

## Variável independente binária (dummy)

- ▶ Temos usado female (0 e 1)
- ▶ E se incluirmos também outra variável, digamos male (0 e 1)?
  - ▶ redundante
  - ▶  $\text{female} + \text{male} = 1$

## Variável independente binária (dummy)

- ▶ Temos usado female (0 e 1)
- ▶ E se incluirmos também outra variável, digamos male (0 e 1)?
  - ▶ redundante
  - ▶  $\text{female} + \text{male} = 1$

## Variável independente binária (dummy)

- ▶ Temos usado female (0 e 1)
- ▶ E se incluirmos também outra variável, digamos male (0 e 1)?
  - ▶ redundante
  - ▶  $\text{female} + \text{male} = 1$

```
wage1$male = ifelse(wage1$female == 0, 1, 0)
coef(lm(wage~female + male + educ, data = wage1))
```

```
## (Intercept)      female      male      educ
##  0.6228168  -2.2733619      NA  0.5064521
```

## Variável independente binária (dummy)

### Explicando a nota média no curso superior

$$colGPA = \beta_0 + \beta_1 PC + \beta_2 hsGPA + \beta_3 ACT + u$$

- ▶ colGPA = nota média no curso superior
- ▶ PC = 1 se a pessoa tem computador próprio e 0 c.c.
- ▶ hsGPA: high school GPA
- ▶ ACT: nota do teste de avaliação para ingresso no curso superior

## Variável independente binária (dummy)

```
summary(gpa1$colGPA)
```

##	Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
##	2.200	2.800	3.000	3.057	3.300	4.000

```
summary(gpa1$hsGPA)
```

##	Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
##	2.400	3.200	3.400	3.402	3.600	4.000

## Variável independente binária (dummy)

```
modelo = lm(colGPA~PC+hsGPA+ACT, data = gpa1)
round(summary(modelo)$coefficients,5)
```

```
##           Estimate Std. Error t value Pr(>|t|)
## (Intercept)  1.26352    0.33313  3.79292  0.00022
## PC           0.15731    0.05729  2.74596  0.00684
## hsGPA        0.44724    0.09365  4.77580  0.00000
## ACT          0.00866    0.01053  0.82199  0.41251
```

```
summary(modelo)$adj.r.squared
```

```
## [1] 0.2022918
```

- ▶ Como interpretamos  $\hat{\beta}_{hsGPA}$ ?



## Variável independente binária (dummy)

```
modelo = lm(colGPA~PC+hsGPA+ACT, data = gpa1)
round(summary(modelo)$coefficients,5)
```

```
##              Estimate Std. Error t value Pr(>|t|)
## (Intercept)  1.26352    0.33313  3.79292  0.00022
## PC           0.15731    0.05729  2.74596  0.00684
## hsGPA        0.44724    0.09365  4.77580  0.00000
## ACT          0.00866    0.01053  0.82199  0.41251
```

```
summary(modelo)$adj.r.squared
```

```
## [1] 0.2022918
```

- ▶ Como interpretamos  $\hat{\beta}_{hsGPA}$ ?
- ▶ Como interpretamos  $\hat{\beta}_{PC}$ ?

## Variável independente binária (dummy)

Quando nossa variável dependente é  $\log(y)$  o  $\beta$  associado à variável *dummy* tem uma interpretação percentual.

## Variável independente binária (dummy)

Quando nossa variável dependente é  $\log(y)$  o  $\beta$  associado à variável *dummy* tem uma interpretação percentual.

```
modelo = lm(log(price)~ log(lotsize) + log(sqrft) +  
            bdrms + colonial, data = hprice1)  
round(summary(modelo)$coefficients,5)
```

##	Estimate	Std. Error	t value	Pr(> t )
## (Intercept)	-1.34959	0.65104	-2.07297	0.04128
## log(lotsize)	0.16782	0.03818	4.39539	0.00003
## log(sqrft)	0.70719	0.09280	7.62045	0.00000
## bdrms	0.02683	0.02872	0.93409	0.35297
## colonial	0.05380	0.04477	1.20153	0.23296

## Variável independente binária (dummy)

$$\widehat{\log(\textit{price})} = -1.350 + 0.168\log(\textit{lotsize}) + 0.707\log(\textit{sqrft}) + 0.027\textit{bdrms} + 0.054\textit{colonial}$$

- ▶ *lotsize*: tamanho do lote em pés<sup>2</sup>
- ▶ *sqrft*: tamanho da casa em pés<sup>2</sup>
- ▶ *bdrms*: número de quartos
- ▶ *colonial*: =1 se a casa é de estilo colonial

1 metro = 3.2808 pés

## Variável independente binária (dummy)

$$\widehat{\log(\text{price})} = -1.350 + 0.168\log(\text{lotsize}) + 0.707\log(\text{sqrft}) + 0.027\text{bdrms} + 0.054\text{colonial}$$

### Como interpretamos... (ver aula 3)

- ▶  $\hat{\beta}_{\log(\text{lotsize})}$ : Quando o tamanho do lote aumenta em 1%, o preço do imóvel aumenta em 0.168%

## Variável independente binária (dummy)

$$\widehat{\log(\text{price})} = -1.350 + 0.168\log(\text{lotsize}) + 0.707\log(\text{sqrft}) + 0.027\text{bdrms} + 0.054\text{colonial}$$

### Como interpretamos... (ver aula 3)

- ▶  $\hat{\beta}_{\log(\text{lotsize})}$ : Quando o tamanho do lote aumenta em 1%, o preço do imóvel aumenta em 0.168%
- ▶  $\hat{\beta}_{\log(\text{sqrft})}$ : Quando o tamanho da casa aumenta em 1%, o preço do imóvel aumenta em 0.707%

## Variável independente binária (dummy)

$$\widehat{\log(\text{price})} = -1.350 + 0.168\log(\text{lotsize}) + 0.707\log(\text{sqrft}) + 0.027\text{bdrms} + 0.054\text{colonial}$$

### Como interpretamos... (ver aula 3)

- ▶  $\hat{\beta}_{\log(\text{lotsize})}$ : Quando o tamanho do lote aumenta em 1%, o preço do imóvel aumenta em 0.168%
- ▶  $\hat{\beta}_{\log(\text{sqrft})}$ : Quando o tamanho da casa aumenta em 1%, o preço do imóvel aumenta em 0.707%
- ▶  $\hat{\beta}_{\text{bdrms}}$ : A cada 1 quarto adicional, espera-se que a casa seja vendida por 2.7% ( $100 \times 0.027$ ) a mais

## Variável independente binária (dummy)

$$\widehat{\log(\text{price})} = -1.350 + 0.168\log(\text{lotsize}) + 0.707\log(\text{sqrft}) + 0.027\text{bdrms} + 0.054\text{colonial}$$

### Como interpretamos... (ver aula 3)

- ▶  $\hat{\beta}_{\log(\text{lotsize})}$ : Quando o tamanho do lote aumenta em 1%, o preço do imóvel aumenta em 0.168%
- ▶  $\hat{\beta}_{\log(\text{sqrft})}$ : Quando o tamanho da casa aumenta em 1%, o preço do imóvel aumenta em 0.707%
- ▶  $\hat{\beta}_{\text{bdrms}}$ : A cada 1 quarto adicional, espera-se que a casa seja vendida por 2.7% ( $100 \times 0.027$ ) a mais
- ▶  $\hat{\beta}_{\text{colonial}}$ : Um imóvel colonial espera-se ser vendido por 5.4% ( $100 \times 0.054$ ) a mais (ou em média casas de tipo colonial são 5.4% mais caras)



## Variável independente binária (dummy)

### Outro exemplo

```
modelo = lm(log(wage)~ female + educ + exper +  
            I(exper^2) + tenure + I(tenure^2), data = wage1)  
round(summary(modelo)$coefficients,4)
```

##		Estimate	Std. Error	t value	Pr(> t )
##	(Intercept)	0.4167	0.0989	4.2121	0.000
##	female	-0.2965	0.0358	-8.2812	0.000
##	educ	0.0802	0.0068	11.8682	0.000
##	exper	0.0294	0.0050	5.9159	0.000
##	I(exper^2)	-0.0006	0.0001	-5.4305	0.000
##	tenure	0.0317	0.0068	4.6330	0.000
##	I(tenure^2)	-0.0006	0.0002	-2.4934	0.013

## Variável independente binária (dummy)

$$\widehat{\log(wage)} = 0.4167 + -0.2965female + 0.0802educ + 0.0294exper - 0.0006exper^2 + 0.0317tenure + -0.0006tenure^2$$

- ▶ Mulheres ganham em média  $\approx 29.65\%$  a menos do que homens

## Variável independente binária (dummy)

$$\widehat{\log(wage)} = 0.4167 + -0.2965female + 0.0802educ + 0.0294exper - 0.0006exper^2 + 0.0317tenure + -0.0006tenure^2$$

- ▶ Mulheres ganham em média  $\approx 29.65\%$  a menos do que homens
- ▶ Se quisermos não a percentagem aproximada, mas a exata?

## Variável independente binária (dummy)

$$\widehat{\log(wage)} = 0.4167 + -0.2965female + 0.0802educ + 0.0294exper - 0.0006exper^2 + 0.0317tenure + -0.0006tenure^2$$

- ▶ Mulheres ganham em média  $\approx 29.65\%$  a menos do que homens
- ▶ Se quisermos não a percentagem aproximada, mas a exata?
- ▶  $\log(wage_F) - \log(wage_M) = \log(wage_F/wage_M) = -0.2965$

## Variável independente binária (dummy)

$$\widehat{\log(wage)} = 0.4167 + -0.2965female + 0.0802educ + 0.0294exper - 0.0006exper^2 + 0.0317tenure + -0.0006tenure^2$$

- ▶ Mulheres ganham em média  $\approx 29.65\%$  a menos do que homens
- ▶ Se quisermos não a percentagem aproximada, mas a exata?
- ▶  $\log(wage_F) - \log(wage_M) = \log(wage_F/wage_M) = -0.2965$
- ▶  $wage_F/wage_M = \exp(-0.2965)$

## Variável independente binária (dummy)

$$\widehat{\log(wage)} = 0.4167 + -0.2965female + 0.0802educ + 0.0294exper - 0.0006exper^2 + 0.0317tenure + -0.0006tenure^2$$

- ▶ Mulheres ganham em média  $\approx 29.65\%$  a menos do que homens
- ▶ Se quisermos não a percentagem aproximada, mas a exata?
- ▶  $\log(wage_F) - \log(wage_M) = \log(wage_F/wage_M) = -0.2965$
- ▶  $wage_F/wage_M = \exp(-0.2965)$
- ▶  $\underbrace{wage_F/wage_M - 1}_{\frac{wage_F - wage_M}{wage_M}} = \underbrace{\exp(-0.2965) - 1}_{-0.2565844}$

## Variável independente binária (dummy)

$$\widehat{\log(wage)} = 0.4167 + -0.2965female + 0.0802educ + 0.0294exper - 0.0006exper^2 + 0.0317tenure + -0.0006tenure^2$$

- ▶ Mulheres ganham em média  $\approx 29.65\%$  a menos do que homens
- ▶ Se quisermos não a percentagem aproximada, mas a exata?
- ▶  $\log(wage_F) - \log(wage_M) = \log(wage_F/wage_M) = -0.2965$
- ▶  $wage_F/wage_M = \exp(-0.2965)$
- ▶  $\underbrace{wage_F/wage_M - 1}_{\frac{wage_F - wage_M}{wage_M}} = \underbrace{\exp(-0.2965) - 1}_{-0.2565844}$
- ▶ O salário da mulher é, em média, 25.65% menor.

## Variável independente com múltiplas categorias

```
modelo = lm(log(wage)~ married + female + educ + exper +  
            I(exper^2) + tenure + I(tenure^2), data = wage1)  
round(summary(modelo)$coefficients,5)
```

##	Estimate	Std. Error	t value	Pr(> t )
## (Intercept)	0.41778	0.09887	4.22575	0.00003
## married	0.05292	0.04076	1.29850	0.19469
## female	-0.29018	0.03611	-8.03565	0.00000
## educ	0.07915	0.00680	11.63989	0.00000
## exper	0.02695	0.00533	5.06095	0.00000
## I(exper^2)	-0.00054	0.00011	-4.81350	0.00000
## tenure	0.03130	0.00685	4.56999	0.00001
## I(tenure^2)	-0.00057	0.00023	-2.44753	0.01471



## Variável independente com múltiplas categorias

- ▶ *married* não diferencia entre homem e mulher

## Variável independente com múltiplas categorias

- ▶ *married* não diferencia entre homem e mulher
- ▶ *female* não diferencia entre casado ou solteiro.

## Variável independente com múltiplas categorias

- ▶ *married* não diferencia entre homem e mulher
- ▶ *female* não diferencia entre casado ou solteiro.
- ▶ Vamos criar novos grupos *homemcasado*, *mulhercasada*, *homemsolteiro* e *mulhersolteira*

## Variável independente com múltiplas categorias

- ▶ *married* não diferencia entre homem e mulher
- ▶ *female* não diferencia entre casado ou solteiro.
- ▶ Vamos criar novos grupos *homemcasado*, *mulhercasada*, *homemsolteiro* e *mulhersolteira*

## Variável independente com múltiplas categorias

- ▶ *married* não diferencia entre homem e mulher
- ▶ *female* não diferencia entre casado ou solteiro.
- ▶ Vamos criar novos grupos *homemcasado*, *mulhercasada*, *homemsolteiro* e *mulhersolteira*

```
wage1 <- wage1 %>%  
  mutate(homemcasado = ifelse(female == 0 & married == 1, 1, 0),  
         mulhercasada = ifelse(female == 1 & married == 1, 1, 0),  
         homemsolteiro = ifelse(female == 0 & married == 0, 1, 0),  
         mulhersolteira = ifelse(female == 1 & married == 0, 1, 0))
```

## Variável independente com múltiplas categorias

$$\textit{homemcasado} + \textit{mulhercasada} + \textit{homemsolteiro} + \textit{mulhersolteira} = 1$$

## Variável independente com múltiplas categorias

$$\text{homemcasado} + \text{mulhercasada} + \text{homemsolteiro} + \text{mulhersolteira} = 1$$

```
table(wage1$homemcasado + wage1$mulhercasada +  
      wage1$homemsolteiro + wage1$mulhersolteira)
```

```
##
```

```
##    1
```

```
## 526
```

## Variável independente com múltiplas categorias

$$\text{homemcasado} + \text{mulhercasada} + \text{homemsolteiro} + \text{mulhersolteira} = 1$$

```
table(wage1$homemcasado + wage1$mulhercasada +  
      wage1$homemsolteiro + wage1$mulhersolteira)
```

```
##
```

```
##    1
```

```
## 526
```

Se temos  $p$  categorias, incluímos  $p - 1$  variáveis *dummy* no modelo!.



## Variável independente com múltiplas categorias

```
modelo = lm(log(wage) ~ homemcasado + mulhercasada + mulhersolteira +  
educ + exper + I(exper^2) + tenure + I(tenure^2), data = wage1)  
round(summary(modelo)$coefficients, 5)
```

##	Estimate	Std. Error	t value	Pr(> t )
## (Intercept)	0.32138	0.10001	3.21349	0.00139
## homemcasado	0.21268	0.05536	3.84188	0.00014
## mulhercasada	-0.19827	0.05784	-3.42813	0.00066
## mulhersolteira	-0.11035	0.05574	-1.97966	0.04827
## educ	0.07891	0.00669	11.78733	0.00000
## exper	0.02680	0.00524	5.11183	0.00000
## I(exper^2)	-0.00054	0.00011	-4.84710	0.00000
## tenure	0.02909	0.00676	4.30161	0.00002
## I(tenure^2)	-0.00053	0.00023	-2.30555	0.02153

## Variável independente com múltiplas categorias

$$\widehat{\log(\text{wage})} = 0.32138 + 0.21268hc - 0.19827mc - 0.11035ms + \dots$$

### Quando temos várias categorias, devemos saber qual é o grupo base

- ▶ Grupo base: homem-solteiro
- ▶ Homens casados ganham em média 21.27% mais do que homens solteiros
- ▶ Mulheres casadas ganham em média 19.83% menos que homens solteiros
- ▶ Mulheres solteiras ganham em média 11.03% menos que homens solteiros

## Variável independente com múltiplas categorias

$$\widehat{\log(\text{wage})} = 0.32138 + 0.21268hc - 0.19827mc - 0.11035ms + \dots$$

### Quando temos várias categorias, devemos saber qual é o grupo base

- ▶ Grupo base: homem-solteiro
- ▶ Homens casados ganham em média 21.27% mais do que homens solteiros
- ▶ Mulheres casadas ganham em média 19.83% menos que homens solteiros
- ▶ Mulheres solteiras ganham em média 11.03% menos que homens solteiros

Note que antes *married* não era estatisticamente significativo, mas quando separamos em grupos agora todas as categorias são estatisticamente significativas.

# Variável independente ordinal

## **Variável independente ordinal:**

- ▶ Se temos poucas categorias podemos criar variáveis dummy

# Variável independente ordinal

## **Variável independente ordinal:**

- ▶ Se temos poucas categorias podemos criar variáveis dummy
- ▶ Quando a variavel ordinal tem muitas categorias podemos trabalhar com ela como se fosse uma variável quantitativa ou recategoriza-la e então utilizar variáveis dummy

# Variável independente ordinal

## **Variável independente ordinal:**

- ▶ Se temos poucas categorias podemos criar variáveis dummy
- ▶ Quando a variável ordinal tem muitas categorias podemos trabalhar com ela como se fosse uma variável quantitativa ou recategoriza-la e então utilizar variáveis dummy
- ▶ Trade-off entre interpretabilidade e proporção da variável dependente sendo explicada.

## Efeito de interação

## Efeito de interação

- ▶ No exemplo anterior, tivemos que criar as variáveis *homemcasado*, *mulhercasada*, *homemsolteiro* e *mulhersolteira* pois as variáveis *married* e *female* separadas, não consideravam o efeito de alguma **interação**



## Efeito de interação

- ▶ No exemplo anterior, tivemos que criar as variáveis *homemcasado*, *mulhercasada*, *homemsolteiro* e *mulhersolteira* pois as variáveis *married* e *female* separadas, não consideravam o efeito de alguma **interação**
- ▶ Efeitos de interação são interessante quando suspeitamos que o efeito parcial de uma variável explicativa depende da magnitude de **outra** variável explicativa.

## Efeito de interação

- ▶ No exemplo anterior, tivemos que criar as variáveis *homemcasado*, *mulhercasada*, *homemsolteiro* e *mulhersolteira* pois as variáveis *married* e *female* separadas, não consideravam o efeito de alguma **interação**
- ▶ Efeitos de interação são interessante quando suspeitamos que o efeito parcial de uma variável explicativa depende da magnitude de **outra** variável explicativa.
- ▶ Analisaremos casos de efeitos de interação entre

## Efeito de interação

- ▶ No exemplo anterior, tivemos que criar as variáveis *homemcasado*, *mulhercasada*, *homemsolteiro* e *mulhersolteira* pois as variáveis *married* e *female* separadas, não consideravam o efeito de alguma **interação**
- ▶ Efeitos de interação são interessante quando suspeitamos que o efeito parcial de uma variável explicativa depende da magnitude de **outra** variável explicativa.
- ▶ Analisaremos casos de efeitos de interação entre
  - ▶ 2 variáveis qualitativas

## Efeito de interação

- ▶ No exemplo anterior, tivemos que criar as variáveis *homemcasado*, *mulhercasada*, *homemsolteiro* e *mulhersolteira* pois as variáveis *married* e *female* separadas, não consideravam o efeito de alguma **interação**
- ▶ Efeitos de interação são interessante quando suspeitamos que o efeito parcial de uma variável explicativa depende da magnitude de **outra** variável explicativa.
- ▶ Analisaremos casos de efeitos de interação entre
  - ▶ 2 variáveis qualitativas
  - ▶ 1 qualitativa e 1 quantitativa

## Efeito de interação

- ▶ No exemplo anterior, tivemos que criar as variáveis *homemcasado*, *mulhercasada*, *homemsolteiro* e *mulhersolteira* pois as variáveis *married* e *female* separadas, não consideravam o efeito de alguma **interação**
- ▶ Efeitos de interação são interessante quando suspeitamos que o efeito parcial de uma variável explicativa depende da magnitude de **outra** variável explicativa.
- ▶ Analisaremos casos de efeitos de interação entre
  - ▶ 2 variáveis qualitativas
  - ▶ 1 qualitativa e 1 quantitativa
  - ▶ 2 quantitativas

## Efeito de interação

```
modelo = lm(log(wage)~ married + female + educ + exper +  
            I(exper^2) + tenure + I(tenure^2), data = wage1)  
round(summary(modelo)$coefficients,5)
```

##		Estimate	Std. Error	t value	Pr(> t )
##	(Intercept)	0.41778	0.09887	4.22575	0.00003
##	married	0.05292	0.04076	1.29850	0.19469
##	female	-0.29018	0.03611	-8.03565	0.00000
##	educ	0.07915	0.00680	11.63989	0.00000
##	exper	0.02695	0.00533	5.06095	0.00000
##	I(exper^2)	-0.00054	0.00011	-4.81350	0.00000
##	tenure	0.03130	0.00685	4.56999	0.00001
##	I(tenure^2)	-0.00057	0.00023	-2.44753	0.01471

## Efeito de interação

```
modelo = lm(log(wage)~ married + female + married*female +  
educ + exper + I(exper^2) + tenure + I(tenure^2), data = wage1)  
round(summary(modelo)$coefficients,5)
```

##	Estimate	Std. Error	t value	Pr(> t )
## (Intercept)	0.32138	0.10001	3.21349	0.00139
## married	0.21268	0.05536	3.84188	0.00014
## female	-0.11035	0.05574	-1.97966	0.04827
## educ	0.07891	0.00669	11.78733	0.00000
## exper	0.02680	0.00524	5.11183	0.00000
## I(exper^2)	-0.00054	0.00011	-4.84710	0.00000
## tenure	0.02909	0.00676	4.30161	0.00002
## I(tenure^2)	-0.00053	0.00023	-2.30555	0.02153
## married:female	-0.30059	0.07177	-4.18846	0.00003

## Efeito de interação

```
coef(modelo)
```

```
##      (Intercept)          married          female          educ
##  0.3213780953    0.2126756752   -0.1103502102    0.0789102812
##      I(exper^2)          tenure      I(tenure^2) married:female
## -0.0005352452    0.0290875220   -0.0005331425   -0.3005930681
```



## Efeito de interação

```
coef(modelo)
```

```
##      (Intercept)          married          female          educ
##  0.3213780953    0.2126756752   -0.1103502102    0.0789102812
##      I(exper^2)          tenure      I(tenure^2) married:female
## -0.0005352452    0.0290875220   -0.0005331425   -0.3005930681
```

- ▶ Qual é o *grupo base*? female = 0 e married = 0 (homem solteiro)

## Efeito de interação

```
coef(modelo)
```

```
##      (Intercept)          married          female          educ
##  0.3213780953    0.2126756752   -0.1103502102    0.0789102812
##      I(exper^2)          tenure      I(tenure^2) married:female
## -0.0005352452    0.0290875220   -0.0005331425   -0.3005930681
```

- ▶ Qual é o *grupo base*? female = 0 e married = 0 (homem solteiro)
- ▶ Uma mulher solteira (female = 1 e married = 0) ganha 11% menos do que um homem solteiro

## Efeito de interação

```
coef(modelo)
```

```
##      (Intercept)          married          female          educ
##  0.3213780953    0.2126756752   -0.1103502102    0.0789102812
##      I(exper^2)          tenure      I(tenure^2) married:female
## -0.0005352452    0.0290875220   -0.0005331425   -0.3005930681
```

- ▶ Qual é o *grupo base*? female = 0 e married = 0 (homem solteiro)
- ▶ Uma mulher solteira (female = 1 e married = 0) ganha 11% menos do que um homem solteiro
- ▶ Uma mulher casada (female = 1 e married = 1) ganha 19.8% (0.2126-0.1103-0.3005) menos do que um homem solteiro

## Efeito de interação

```
coef(modelo)
```

```
##      (Intercept)          married          female          educ
##  0.3213780953    0.2126756752   -0.1103502102    0.0789102812
##      I(exper^2)          tenure      I(tenure^2) married:female
## -0.0005352452    0.0290875220   -0.0005331425   -0.3005930681
```

- ▶ Qual é o *grupo base*? female = 0 e married = 0 (homem solteiro)
- ▶ Uma mulher solteira (female = 1 e married = 0) ganha 11% menos do que um homem solteiro
- ▶ Uma mulher casada (female = 1 e married = 1) ganha 19.8% (0.2126-0.1103-0.3005) menos do que um homem solteiro
- ▶ Um homem casado (female = 0 e married = 1) ganha 21% a mais do que um homem solteiro

## Efeito de interação

**Interação também pode acontecer entre uma dummy e uma quantitativa**

```
modelo = lm(log(wage)~female + educ + female*educ, data = wage1)
round(coef(modelo),5)
```

```
## (Intercept)      female      educ female:educ
##      0.82595     -0.36006     0.07723     -0.00006
```

**Como mudam as retas de regressão?**

- ▶ Intercepto para o homem (female = 0) é 0.82595

## Efeito de interação

**Interação também pode acontecer entre uma dummy e uma quantitativa**

```
modelo = lm(log(wage)~female + educ + female*educ, data = wage1)
round(coef(modelo),5)
```

```
## (Intercept)      female      educ female:educ
##      0.82595    -0.36006    0.07723    -0.00006
```

**Como mudam as retas de regressão?**

- ▶ Intercepto para o homem ( $female = 0$ ) é 0.82595
- ▶ Intercepto para a mulher é  $0.82595 - 0.36006 = 0.46589$

## Efeito de interação

**Interação também pode acontecer entre uma dummy e uma quantitativa**

```
modelo = lm(log(wage)~female + educ + female*educ, data = wage1)
round(coef(modelo),5)
```

```
## (Intercept)      female      educ female:educ
##      0.82595      -0.36006      0.07723      -0.00006
```

**Como mudam as retas de regressão?**

- ▶ Intercepto para o homem (female = 0) é 0.82595
- ▶ Intercepto para a mulher é  $0.82595 - 0.36006 = 0.46589$
- ▶ Inclinação para o homem (female = 0) é 0.07723

## Efeito de interação

**Interação também pode acontecer entre uma dummy e uma quantitativa**

```
modelo = lm(log(wage)~female + educ + female*educ, data = wage1)
round(coef(modelo),5)
```


```
## (Intercept)      female      educ female:educ
##      0.82595    -0.36006    0.07723    -0.00006
```

**Como mudam as retas de regressão?**


- ▶ Intercepto para o homem ( $female = 0$ ) é 0.82595
- ▶ Intercepto para a mulher é  $0.82595 - 0.36006 = 0.46589$
- ▶ Inclinação para o homem ( $female = 0$ ) é 0.07723
- ▶ Inclinação para a mulher é  $0.07723 - 0.00006 = 0.07717$




# Efeito de interação



# Efeito de interação



# Efeito de interação



# Efeito de interação

## Duas variáveis quantitativas

```
modelo = lm(log(wage)~female + educ + exper+ tenure + exper*tenure  
round(summary(modelo)$coefficients,5)
```

##	Estimate	Std. Error	t value	Pr(> t )
## (Intercept)	0.48172	0.10019	4.80820	0e+00
## female	-0.29638	0.03660	-8.09802	0e+00
## educ	0.08293	0.00689	12.03537	0e+00
## exper	0.00765	0.00173	4.40802	1e-05
## tenure	0.04772	0.00738	6.46207	0e+00
## exper:tenure	-0.00097	0.00022	-4.47592	1e-05

```
summary(modelo)$adj.r.squared
```

```
## [1] 0.4091884
```

## Efeito de interação

$$\widehat{\log(wage)} = 0.4817 - 0.2964female + 0.0829educ + 0.0076exper + 0.0477tenure - 0.0010exper \times tenure$$

▶  $\Delta \log(wage) = 0.0076\Delta exper - 0.0010tenure\Delta exper$

## Efeito de interação

$$\widehat{\log(wage)} = 0.4817 - 0.2964female + 0.0829educ + 0.0076exper + 0.0477tenure - 0.0010exper \times tenure$$

- ▶  $\Delta \log(wage) = 0.0076\Delta exper - 0.0010tenure\Delta exper$
- ▶  $\frac{\% \Delta wage}{\Delta exper} \approx \frac{100\Delta \log(wage)}{\Delta exper} = 0.76 - 0.1tenure$

## Efeito de interação

$$\widehat{\log(wage)} = 0.4817 - 0.2964female + 0.0829educ + 0.0076exper + 0.0477tenure - 0.0010exper \times tenure$$

- ▶  $\Delta \log(wage) = 0.0076\Delta exper - 0.0010tenure\Delta exper$
- ▶  $\frac{\% \Delta wage}{\Delta exper} \approx \frac{100\Delta \log(wage)}{\Delta exper} = 0.76 - 0.1tenure$
- ▶  $\% \Delta wage = (0.76 - 0.1tenure)\Delta exper$

# Resumo

- ▶ Variáveis qualitativas podem ser incluídas no modelo
- ▶ O processo de estimação não muda
- ▶ A interpretação dos betas muda
- ▶ Quando temos uma variável categórica com  $p$  categorias, utilizamos  $p - 1$  variáveis *dummy*
- ▶ Quando a variável dependente é  $\log(y)$  a variável *dummy* tem uma interpretação percentual
- ▶ Efeitos de interação precisam ser analisados cuidadosamente



# Leituras recomendadas

## Leituras recomendadas

- ▶ Wooldridge, Jeffrey M. *Introdução à Econometria: Uma abordagem moderna*. (2016). Cengage Learning. – **Cap 6.2** e **Cap 7**
- ▶ Hansen, Bruce. *Econometrics*. (2020). – **Sec 7.14** e **Sec 7.15**