

ACA228 - Modelos de Regressão e Previsão

Regressão Linear Multipla: Tópicos adicionais

Prof. Carlos Trucíos

carlos.trucios@facc.ufrj.br

ctruciosm.github.io

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

Aula 10

Não-Lineariedades

Comparação de modelos

Intervalos de Confiança / Previsão

Não-Lineariedades

Não-Lineariedades

Até agora, temos trabalhado com modelos da forma

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + u$$

Não-Lineariedades

Até agora, temos trabalhado com modelos da forma

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + u$$

Muitas vezes, para tentar capturar não-lineariedades, podemos estar interessados em incluir, por exemplo x_k^2 , $x_k^3 \dots$,

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_1^2 + \beta_3 x_2 + \beta_4 x_3 + \beta_5 x_4 + u$$

Não-Lineariedades

Até agora, temos trabalhado com modelos da forma

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + u$$

Muitas vezes, para tentar capturar não-lineariedades, podemos estar interessados em incluir, por exemplo x_k^2 , $x_k^3 \dots$,




$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_1^2 + \beta_3 x_2 + \beta_4 x_3 + \beta_5 x_4 + u$$

No contexto de MRLM podemos incluir termos polinomiais. O processo de estimativa continua sendo o mesmo mas devemos ter muito cuidado na **interpretação**.

Não-Lineariedades

```
uri <- "https://raw.githubusercontent.com/ctruciosm/ISLR/master/datasets/advertising.csv"
advertising <- read.csv(uri)
modelo1 <- lm(Sales ~ TV + Radio + Newspaper,
               data = advertising)
summary(modelo1)$adj.r.squared
## [1] 0.8956373
```

Não-Linearidades



Não-Lineariedades

```
modelo2 <- lm(Sales ~ TV + I(TV^2) + Radio + Newspaper,  
               data = advertising)  
summary(modelo1)$adj.r.squared
```

```
## [1] 0.8956373
```

```
summary(modelo2)$adj.r.squared
```

```
## [1] 0.9150029
```

Não-Lineariedades

```
round(summary(modelo2)$coef, 5)
```

| | Estimate | Std. Error | t value | Pr(> t) |
|----------------|----------|------------|----------|----------|
| ## (Intercept) | 1.27016 | 0.37447 | 3.39189 | 0.00084 |
| ## TV | 0.07847 | 0.00500 | 15.68980 | 0.00000 |
| ## I(TV^2) | -0.00011 | 0.00002 | -6.75694 | 0.00000 |
| ## Radio | 0.19256 | 0.00779 | 24.70605 | 0.00000 |
| ## Newspaper | 0.00089 | 0.00531 | 0.16784 | 0.86688 |

Não-Lineariedades

```
round(summary(modelo2)$coef, 5)
```

| | Estimate | Std. Error | t value | Pr(> t) |
|----------------|----------|------------|----------|----------|
| ## (Intercept) | 1.27016 | 0.37447 | 3.39189 | 0.00084 |
| ## TV | 0.07847 | 0.00500 | 15.68980 | 0.00000 |
| ## I(TV^2) | -0.00011 | 0.00002 | -6.75694 | 0.00000 |
| ## Radio | 0.19256 | 0.00779 | 24.70605 | 0.00000 |
| ## Newspaper | 0.00089 | 0.00531 | 0.16784 | 0.86688 |

O termo quadrático é significativo, mas será que podemos interpretar ele como estamos acostumados?

Não-Lineariedades: Interpretação

Termo Quadrático

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x + \hat{\beta}_2 x^2 \quad (1)$$

- ▶ Se estivermos interessados unicamente em predição, podemos usar diretamente (1)

Não-Lineariedades: Interpretação

Termo Quadrático

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x + \hat{\beta}_2 x^2 \quad (1)$$

- ▶ Se estivermos interessados unicamente em predição, podemos usar diretamente (1)
- ▶ Se estivermos interessados em conhecer o efeito de x sobre y precisamos **interpretar** o modelo.

Não-Lineariedades: Interpretação

Termo Quadrático

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x + \hat{\beta}_2 x^2 \quad (1)$$

- ▶ Se estivermos interessados unicamente em predição, podemos usar diretamente (1)
- ▶ Se estivermos interessados em conhecer o efeito de x sobre y precisamos **interpretar** o modelo.

Não-Lineariedades: Interpretação

Termo Quadrático

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x + \hat{\beta}_2 x^2 \quad (1)$$

- ▶ Se estivermos interessados unicamente em predição, podemos usar diretamente (1)
- ▶ Se estivermos interessados em conhecer o efeito de x sobre y precisamos **interpretar** o modelo.

Derivando w.r.t x , temos que $\frac{d\hat{y}}{dx} = (\hat{\beta}_1 + 2\hat{\beta}_2 x)$, então

$$\frac{\Delta \hat{y}}{\Delta x} \approx (\hat{\beta}_1 + 2\hat{\beta}_2 x)$$

Não-Lineariedades: Interpretação

... (continuação) Termo Quadrático

- ▶ Se $x = 0$, $\frac{\Delta \hat{y}}{\Delta x} \approx \hat{\beta}_1$, $\hat{\beta}_1$ pode ser interpretado como a inclinação aproximada na alteração de $x = 0$ para $x = 1$

Não-Lineariedades: Interpretação

... (continuação) Termo Quadrático

- ▶ Se $x = 0$, $\frac{\Delta \hat{y}}{\Delta x} \approx \hat{\beta}_1$, $\hat{\beta}_1$ pode ser interpretado como a inclinação aproximada na alteração de $x = 0$ para $x = 1$
- ▶ Para $x > 0$, $2\hat{\beta}_2x$ deve ser considerado na interpretação

Não-Lineariedades: Interpretação

... (continuação) Termo Quadrático

- ▶ Se $x = 0$, $\frac{\Delta \hat{y}}{\Delta x} \approx \hat{\beta}_1$, $\hat{\beta}_1$ pode ser interpretado como a inclinação aproximada na alteração de $x = 0$ para $x = 1$
- ▶ Para $x > 0$, $2\hat{\beta}_2x$ deve ser considerado na interpretação

Não-Linearidades: Interpretação

... (continuação) Termo Quadrático

- ▶ Se $x = 0$, $\frac{\Delta \hat{y}}{\Delta x} \approx \hat{\beta}_1$, $\hat{\beta}_1$ pode ser interpretado como a inclinação aproximada na alteração de $x = 0$ para $x = 1$
- ▶ Para $x > 0$, $2\hat{\beta}_2x$ deve ser considerado na interpretação

```
library(wooldridge)
coef(lm(wage ~ exper + I(exper^2), data = wage1))
```

```
## (Intercept)      exper    I(exper^2)
## 3.725405759  0.298100104 -0.006129887
```

- ▶ Como varia *wage* em função de *exper*?

$$\Delta \hat{y} \approx (0.2981 - 2 \times 0.0061x)\Delta x$$

... (continuação) Termo Quadrático

$$\Delta \hat{y} \approx (0.2981 - 2 \times 0.0061x)\Delta x$$

- ▶ O primeiro ano a experiência vale 0.2981 USD por hora

... (continuação) Termo Quadrático

$$\Delta \hat{y} \approx (0.2981 - 2 \times 0.0061x)\Delta x$$

- ▶ O primeiro ano a experiência vale 0.2981 USD por hora
- ▶ Depois do primeiro ano, o efeito de experiência começa a cair:

... (continuação) Termo Quadrático

$$\Delta \hat{y} \approx (0.2981 - 2 \times 0.0061x)\Delta x$$

- ▶ O primeiro ano a experiência vale 0.2981 USD por hora
- ▶ Depois do primeiro ano, o efeito de experiência começa a cair:
 - ▶ Para o segundo ano: $0.2981 - 2 \times 0.0061(1) = 0.2859$

... (continuação) Termo Quadrático

$$\Delta \hat{y} \approx (0.2981 - 2 \times 0.0061x)\Delta x$$

- ▶ O primeiro ano a experiência vale 0.2981 USD por hora
- ▶ Depois do primeiro ano, o efeito de experiência começa a cair:
 - ▶ Para o segundo ano: $0.2981 - 2 \times 0.0061(1) = 0.2859$
 - ▶ Para o terceiro ano: $0.2981 - 2 \times 0.0061(2) = 0.2737$

... (continuação) Termo Quadrático

$$\Delta \hat{y} \approx (0.2981 - 2 \times 0.0061x)\Delta x$$

- ▶ O primeiro ano a experiência vale 0.2981 USD por hora
- ▶ Depois do primeiro ano, o efeito de experiência começa a cair:
 - ▶ Para o segundo ano: $0.2981 - 2 \times 0.0061(1) = 0.2859$
 - ▶ Para o terceiro ano: $0.2981 - 2 \times 0.0061(2) = 0.2737$
 - ▶ Para o decimo ano: $0.2981 - 2 \times 0.0061(9) = 0.1883$

... (continuação) Termo Quadrático

$$\Delta \hat{y} \approx (0.2981 - 2 \times 0.0061x)\Delta x$$

- ▶ O primeiro ano a experiência vale 0.2981 USD por hora
- ▶ Depois do primeiro ano, o efeito de experiência começa a cair:
 - ▶ Para o segundo ano: $0.2981 - 2 \times 0.0061(1) = 0.2859$
 - ▶ Para o terceiro ano: $0.2981 - 2 \times 0.0061(2) = 0.2737$
 - ▶ Para o decimo ano: $0.2981 - 2 \times 0.0061(9) = 0.1883$
- ▶ Note que o **ponto de infleção** é $x^* = -\hat{\beta}_1/2\hat{\beta}_2$

... (continuação) Termo Quadrático


$$\Delta \hat{y} \approx (0.2981 - 2 \times 0.0061x)\Delta x$$

- ▶ O primeiro ano a experiência vale 0.2981 USD por hora
- ▶ Depois do primeiro ano, o efeito de experiência começa a cair:
 - ▶ Para o segundo ano: $0.2981 - 2 \times 0.0061(1) = 0.2859$
 - ▶ Para o terceiro ano: $0.2981 - 2 \times 0.0061(2) = 0.2737$
 - ▶ Para o decimo ano: $0.2981 - 2 \times 0.0061(9) = 0.1883$
- ▶ Note que o **ponto de infleção** é $x^* = -\hat{\beta}_1/2\hat{\beta}_2$
- ▶ No nosso caso: $x^* = 0.2981/(2 \times 0.0061) = 24.43$

Não-Lineariedades: Interpretação

... (continuação) Termo Quadrático

$$\hat{y} = 3.73 + 0.2981x - 0.0061x^2$$



Não-Lineariedades: Interpretação

... (continuação) Termo Quadrático

O que significa esse 24.43 anos?

- ▶ Se na amostra, apenas uma pequena fração dos dados apresentam idade > 24.43 , não devemos nos preocupar (mas....)

Não-Lineariedades: Interpretação

... (continuação) Termo Quadrático

O que significa esse 24.43 anos?

- ▶ Se na amostra, apenas uma pequena fração dos dados apresentam idade > 24.43 , não devemos nos preocupar (mas....)

```
prop.table(table(wage1$exper>24.43))
```

```
##  
##      FALSE      TRUE  
## 0.7205323 0.2794677
```

Não-Lineariedades: Interpretação

... (continuação) Termo Quadrático

O que significa esse 24.43 anos?

- ▶ Se na amostra, apenas uma pequena fração dos dados apresentam idade > 24.43 , não devemos nos preocupar (mas....)

```
prop.table(table(wage1$exper>24.43))
```

```
##  
##      FALSE      TRUE  
## 0.7205323 0.2794677
```

- ▶ É possível que o retorno de *exper* sobre *wage* seja negativo a partir de algum ponto, mas **cuidado com as variáveis omitidas!** (levam a estimadores viesados)

Não-Lineariedades: Interpretação

```
round(coef(modelo2),5)
```

```
## (Intercept)          TV      I(TV^2)       Radio    Newspaper
##     1.27016     0.07847   -0.00011     0.19256     0.00089
```

Não-Linearidades: Interpretação

```
round(coef(modelo2), 5)
```

```
## (Intercept)          TV      I(TV^2)        Radio    Newspaper
##       1.27016     0.07847   -0.00011     0.19256     0.00089
```

- ▶ Como varia *Sales* em função de *TV*?

$$\Delta y \approx (0.07847 - 2 \times 0.00011x)\Delta x$$

Não-Lineariedades: Interpretação

$$\Delta \hat{y} \approx (0.07847 - 2 \times 0.00011x) \Delta x$$

Não-Lineariedades: Interpretação

$$\Delta \hat{y} \approx (0.07847 - 2 \times 0.00011x)\Delta x$$

- ▶ O investimento inicial de 1K USD em TV geram, em média 0.07847 milhares de unidades vendidas (78.47 unidades vendidas).

Não-Lineariedades: Interpretação

$$\Delta \hat{y} \approx (0.07847 - 2 \times 0.00011x)\Delta x$$

- ▶ O investimento inicial de 1K USD em TV geram, em média 0.07847 milhares de unidades vendidas (78.47 unidades vendidas).
- ▶ Depois dos primeiros 1K USD investidos, o efeito começa a diminuir:

Não-Linearidades: Interpretação

$$\Delta \hat{y} \approx (0.07847 - 2 \times 0.00011x) \Delta x$$

- ▶ O investimento inicial de 1K USD em TV geram, em média 0.07847 milhares de unidades vendidas (78.47 unidades vendidas).
- ▶ Depois dos primeiros 1K USD investidos, o efeito começa a diminuir:
 - ▶ O investimento de 2K em TV geram:
$$0.07847 - 2 \times 0.00011(1) = 0.07825$$

Não-Lineariedades: Interpretação

$$\Delta \hat{y} \approx (0.07847 - 2 \times 0.00011x) \Delta x$$

- ▶ O investimento inicial de 1K USD em TV geram, em média 0.07847 milhares de unidades vendidas (78.47 unidades vendidas).
- ▶ Depois dos primeiros 1K USD investidos, o efeito começa a diminuir:
 - ▶ O investimento de 2K em TV geram:
 $0.07847 - 2 \times 0.00011(1) = 0.07825$
 - ▶ O investimento de 3K em TV geram:
 $0.07847 - 2 \times 0.00011(2) = 0.07803$

Não-Lineariedades: Interpretação

$$\Delta \hat{y} \approx (0.07847 - 2 \times 0.00011x) \Delta x$$

- ▶ O investimento inicial de 1K USD em TV geram, em média 0.07847 milhares de unidades vendidas (78.47 unidades vendidas).
- ▶ Depois dos primeiros 1K USD investidos, o efeito começa a diminuir:
 - ▶ O investimento de 2K em TV geram:
 $0.07847 - 2 \times 0.00011(1) = 0.07825$
 - ▶ O investimento de 3K em TV geram:
 $0.07847 - 2 \times 0.00011(2) = 0.07803$
 - ▶ O investimento de 10K em TV geram:
 $0.07847 - 2 \times 0.00011(9) = 0.07649$

Não-Lineariedades: Interpretação

$$\Delta \hat{y} \approx (0.07847 - 2 \times 0.00011x) \Delta x$$

- ▶ O investimento inicial de 1K USD em TV geram, em média 0.07847 milhares de unidades vendidas (78.47 unidades vendidas).
- ▶ Depois dos primeiros 1K USD investidos, o efeito começa a diminuir:
 - ▶ O investimento de 2K em TV geram:
 $0.07847 - 2 \times 0.00011(1) = 0.07825$
 - ▶ O investimento de 3K em TV geram:
 $0.07847 - 2 \times 0.00011(2) = 0.07803$
 - ▶ O investimento de 10K em TV geram:
 $0.07847 - 2 \times 0.00011(9) = 0.07649$
- ▶ Note que o **ponto de infleção** é $x^* = -\hat{\beta}_1 / 2\hat{\beta}_2$

Não-Lineariedades: Interpretação

$$\Delta \hat{y} \approx (0.07847 - 2 \times 0.00011x) \Delta x$$

- ▶ O investimento inicial de 1K USD em TV geram, em média 0.07847 milhares de unidades vendidas (78.47 unidades vendidas).
- ▶ Depois dos primeiros 1K USD investidos, o efeito começa a diminuir:
 - ▶ O investimento de 2K em TV geram:
 $0.07847 - 2 \times 0.00011(1) = 0.07825$
 - ▶ O investimento de 3K em TV geram:
 $0.07847 - 2 \times 0.00011(2) = 0.07803$
 - ▶ O investimento de 10K em TV geram:
 $0.07847 - 2 \times 0.00011(9) = 0.07649$
- ▶ Note que o **ponto de infleção** é $x^* = -\hat{\beta}_1 / 2\hat{\beta}_2$
- ▶ No nosso caso: $x^* = 0.07847 / (2 \times 0.00011) = 356.6818$

Não-Lineariedades: Interpretação

$$\log(price) =$$

$$\beta_0 + \beta_1 \log(nox) + \beta_2 \log(dist) + \beta_3 rooms + \beta_4 I(rooms^2) + \beta_5 stratio + u$$

Não-Lineariedades: Interpretação

$$\log(price) =$$

$$\beta_0 + \beta_1 \log(nox) + \beta_2 \log(dist) + \beta_3 rooms + \beta_4 I(rooms^2) + \beta_5 stratio + u$$

| | ## | Estimate | Std. Error | t value | Pr(> t) |
|----|-------------|-------------|------------|-----------|--------------|
| ## | (Intercept) | 13.38547708 | 0.56647307 | 23.629503 | 1.884304e-83 |
| ## | log(nox) | -0.90168178 | 0.11468692 | -7.862115 | 2.340671e-14 |
| ## | log(dist) | -0.08678134 | 0.04328071 | -2.005081 | 4.549288e-02 |
| ## | rooms | -0.54511291 | 0.16545413 | -3.294647 | 1.055357e-03 |
| ## | I(rooms^2) | 0.06226119 | 0.01280498 | 4.862265 | 1.556648e-06 |
| ## | stratio | -0.04759019 | 0.00585419 | -8.129254 | 3.423303e-15 |

Não-Lineariedades: Interpretação

- $\hat{\beta}_{log(nox)}$, $\hat{\beta}_{log(dist)}$ e $\hat{\beta}_{stratio}$ são interpretados como visto nas aulas anteriores.

$$\widehat{\Delta \log(price)} \approx (-0.545 + 2 \times 0.062 rooms) \Delta rooms$$

Não-Lineariedades: Interpretação

- ▶ $\hat{\beta}_{log(nox)}$, $\hat{\beta}_{log(dist)}$ e $\hat{\beta}_{stratio}$ são interpretados como visto nas aulas anteriores.
- ▶ Como interpretamos *rooms*?

$$\widehat{\Delta \log(price)} \approx (-0.545 + 2 \times 0.062 \Delta rooms) \Delta rooms$$

Não-Lineariedades: Interpretação

- ▶ $\hat{\beta}_{log(nox)}$, $\hat{\beta}_{log(dist)}$ e $\hat{\beta}_{stratio}$ são interpretados como visto nas aulas anteriores.
- ▶ Como interpretamos *rooms*?

$$\widehat{\Delta \log(price)} \approx (-0.545 + 2 \times 0.062 \Delta rooms) \Delta rooms$$

Não-Lineariedades: Interpretação

- ▶ $\hat{\beta}_{log(nox)}$, $\hat{\beta}_{log(dist)}$ e $\hat{\beta}_{stratio}$ são interpretados como visto nas aulas anteriores.
- ▶ Como interpretamos *rooms*?

$$\widehat{\Delta \log(price)} \approx (-0.545 + 2 \times 0.062 \text{rooms}) \Delta \text{rooms}$$

$$\widehat{\% \Delta price} \approx 100(-0.545 + 2 \times 0.062 \text{rooms}) \Delta \text{rooms}$$

Não-Linearidades: Interpretação

- ▶ $\hat{\beta}_{log(nox)}$, $\hat{\beta}_{log(dist)}$ e $\hat{\beta}_{stratio}$ são interpretados como visto nas aulas anteriores.
- ▶ Como interpretamos *rooms*?

$$\widehat{\Delta \log(price)} \approx (-0.545 + 2 \times 0.062 \text{rooms}) \Delta \text{rooms}$$

$$\% \widehat{\Delta price} \approx 100(-0.545 + 2 \times 0.062 \text{rooms}) \Delta \text{rooms}$$

$$\% \widehat{\Delta price} \approx (-54.5 + 12.4 \text{rooms}) \Delta \text{rooms}$$

Não-Lineariedades: Interpretação

$$\% \widehat{\Delta price} \approx (-54.5 + 12.4 rooms) \Delta rooms$$

Não-Lineariedades: Interpretação

$$\widehat{\% \Delta price} \approx (-54.5 + 12.4 rooms) \Delta rooms$$

- ▶ Um aumento em rooms de 5 para 6 aumenta o preço em aprox
 $-54.5 + 12.4 \times 5 = 7.5\%$

Não-Lineariedades: Interpretação

$$\widehat{\% \Delta price} \approx (-54.5 + 12.4 rooms) \Delta rooms$$

- ▶ Um aumento em rooms de 5 para 6 aumenta o preço em aprox
 $-54.5 + 12.4 \times 5 = 7.5\%$
- ▶ Um aumento em rooms de 6 para 7 aumenta o preço em aprox
 $-54.5 + 12.4 \times 6 = 19.9\%$

Não-Lineariedades: Interpretação

$$\% \widehat{\Delta price} \approx (-54.5 + 12.4 rooms) \Delta rooms$$

- ▶ Um aumento em rooms de 5 para 6 aumenta o preço em aprox
 $-54.5 + 12.4 \times 5 = 7.5\%$
- ▶ Um aumento em rooms de 6 para 7 aumenta o preço em aprox
 $-54.5 + 12.4 \times 6 = 19.9\%$
- ▶ Um aumento em rooms de 4 para 5 diminui o preço em aprox
 $-54.5 + 12.4 \times 4 = -4.9\%$

Não-Lineariedades: Interpretação

$$\widehat{\% \Delta price} \approx (-54.5 + 12.4 rooms) \Delta rooms$$

- ▶ Um aumento em rooms de 5 para 6 aumenta o preço em aprox
 $-54.5 + 12.4 \times 5 = 7.5\%$
- ▶ Um aumento em rooms de 6 para 7 aumenta o preço em aprox
 $-54.5 + 12.4 \times 6 = 19.9\%$
- ▶ Um aumento em rooms de 4 para 5 diminui o preço em aprox
 $-54.5 + 12.4 \times 4 = -4.9\%$
- ▶ Um aumento em rooms de 3 para 4 diminui o preço em aprox
 $-54.5 + 12.4 \times 3 = -17.3\%$

Não-Lineariedades: Interpretação

$$\widehat{\% \Delta price} \approx (-54.5 + 12.4 rooms) \Delta rooms$$

- ▶ Um aumento em rooms de 5 para 6 aumenta o preço em aprox
 $-54.5 + 12.4 \times 5 = 7.5\%$
- ▶ Um aumento em rooms de 6 para 7 aumenta o preço em aprox
 $-54.5 + 12.4 \times 6 = 19.9\%$
- ▶ Um aumento em rooms de 4 para 5 diminui o preço em aprox
 $-54.5 + 12.4 \times 4 = -4.9\%$
- ▶ Um aumento em rooms de 3 para 4 diminui o preço em aprox
 $-54.5 + 12.4 \times 3 = -17.3\%$


Não-Lineariedades: Interpretação

$$\widehat{\% \Delta price} \approx (-54.5 + 12.4 rooms) \Delta rooms$$

- ▶ Um aumento em rooms de 5 para 6 aumenta o preço em aprox
 $-54.5 + 12.4 \times 5 = 7.5\%$
- ▶ Um aumento em rooms de 6 para 7 aumenta o preço em aprox
 $-54.5 + 12.4 \times 6 = 19.9\%$
- ▶ Um aumento em rooms de 4 para 5 diminui o preço em aprox
 $-54.5 + 12.4 \times 4 = -4.9\%$
- ▶ Um aumento em rooms de 3 para 4 diminui o preço em aprox
 $-54.5 + 12.4 \times 3 = -17.3\%$


Faz sentido que aumentar o número de quartos cause uma diminuição no preço?

Não-Lineariedades: Interpretação



Ponto de infleção 4.3951613.

Não-Lineariedades: Interpretação



Ponto de infleção 4.3951613.

Lembre-se: Se na amostra, apenas uma pequena fração dos dados apresentam idade < 4.3951613 , não devemos nos preocupar.

Não-Lineariedades: Interpretação

```
summary(hprice2$rooms)
```

```
##      Min. 1st Qu. Median      Mean 3rd Qu.      Max.  
##    3.560    5.883    6.210    6.284    6.620    8.780
```

```
prop.table(table(hprice2$rooms<4.4))*100
```

```
##  
##      FALSE      TRUE  
## 99.0118577  0.9881423
```

Moral da historia

Faça uma boa EDA (exploratory data analysis), alguns resultados contraintuitivos podem desaparecer ao entendermos melhor os dados.

Comparação de modelos

Comparação de modelos

- ▶ Vimos que o R^2 nunca diminui quando incluimos mais variáveis independentes.

Comparação de modelos

- ▶ Vimos que o R^2 nunca diminui quando incluímos mais variáveis independentes.
- ▶ O R^2 -ajustado, penaliza o número de variáveis e fornece uma ferramenta para compararmos modelos.

Comparação de modelos

- ▶ Vimos que o R^2 nunca diminui quando incluímos mais variáveis independentes.
- ▶ O R^2 -ajustado, penaliza o número de variáveis e fornece uma ferramenta para compararmos modelos.

Comparação de modelos

- ▶ Vimos que o R^2 nunca diminui quando incluímos mais variáveis independentes.
- ▶ O R^2 -ajustado, penaliza o número de variáveis e fornece uma ferramenta para compararmos modelos.

R^2 -ajustado

$$R_{Adj}^2 = 1 - (1 - R^2) \frac{n - 1}{n - k - 1}$$

Comparação de modelos

- ▶ Vimos que o R^2 nunca diminui quando incluímos mais variáveis independentes.
- ▶ O R^2 -ajustado, penaliza o número de variáveis e fornece uma ferramenta para compararmos modelos.

R^2 -ajustado

$$R_{Adj}^2 = 1 - (1 - R^2) \frac{n - 1}{n - k - 1}$$

- ▶ Nos permite comparar modelos não aninhados

Comparação de modelos

- ▶ Vimos que o R^2 nunca diminui quando incluímos mais variáveis independentes.
- ▶ O R^2 -ajustado, penaliza o número de variáveis e fornece uma ferramenta para compararmos modelos.

R^2 -ajustado

$$R_{Adj}^2 = 1 - (1 - R^2) \frac{n - 1}{n - k - 1}$$

- ▶ Nos permite comparar modelos não aninhados
- ▶ **Cuidado com comparar modelos com variável dependente diferente**

Comparação de modelos

```
modelo1 = lm(salary~sales+roe, data = ceosal1)
modelo2 = lm(log(salary)~log(sales)+roe, data = ceosal1)
summary(modelo1)$adj.r.squared
```

```
## [1] 0.01974617
```

```
summary(modelo2)$adj.r.squared
```

```
## [1] 0.2750177
```

Comparação de modelos

```
modelo1 = lm(salary~sales+roe, data = ceosal1)
modelo2 = lm(log(salary)~log(sales)+roe, data = ceosal1)
summary(modelo1)$adj.r.squared
```

```
## [1] 0.01974617
```

```
summary(modelo2)$adj.r.squared
```

```
## [1] 0.2750177
```

Cuidado com comparar modelos com variável dependente diferente

Comparação de modelos

```
modelo1 = lm(salary~sales+roe, data = ceosal1)
modelo2 = lm(log(salary)~log(sales)+roe, data = ceosal1)
summary(modelo1)$adj.r.squared
```

```
## [1] 0.01974617
```

```
summary(modelo2)$adj.r.squared
```

```
## [1] 0.2750177
```

Cuidado com comparar modelos com variável dependente diferente

*R*²-ajustado não pode ser utilizado para comparar modelos que tem diferentes formas funcionais da variável dependente.

Comparação de modelos

Seja

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

Comparação de modelos

Seja

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

► $\widehat{\log(y)} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \hat{\beta}_3 x_3$

Comparação de modelos

Seja

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

- ▶ $\widehat{\log(y)} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \hat{\beta}_3 x_3$
- ▶ Uma primeira ideia seria fazer $\hat{y} = \exp(\widehat{\log(y)})$ (mas subestima o valor esperado y)

Comparação de modelos

Seja

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

- ▶ $\widehat{\log(y)} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \hat{\beta}_3 x_3$
- ▶ Uma primeira ideia seria fazer $\hat{y} = \exp(\widehat{\log(y)})$ (mas subestima o valor esperado y)
- ▶ Sabemos que $y = \underbrace{\exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + u)}_{\exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) \exp(u)}$

Comparação de modelos

Seja

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

- ▶ $\widehat{\log(y)} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \hat{\beta}_3 x_3$
- ▶ Uma primeira ideia seria fazer $\hat{y} = \exp(\widehat{\log(y)})$ (mas subestima o valor esperado y)
- ▶ Sabemos que $y = \underbrace{\exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + u)}_{\exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) \exp(u)}$
- ▶ Aplicando $\mathbb{E}(\cdot|x)$,

$$\mathbb{E}(y|X) = \exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3) \mathbb{E}(\exp(u)|X)$$

Comparação de modelos

- Se $u \sim N(0, \sigma^2)$, $\mathbb{E}(\exp(u)|X) = \exp(\sigma^2/2)$

$$\hat{y} = \exp(\hat{\sigma}^2/2) \exp(\underbrace{\hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \hat{\beta}_3 x_3}_{\widehat{\log(y)}}) = \exp(\hat{\sigma}^2/2) \exp(\widehat{\log(y)})$$

Comparação de modelos

- ▶ Se $u \sim N(0, \sigma^2)$, $\mathbb{E}(\exp(u)|X) = \exp(\sigma^2/2)$

$$\hat{y} = \exp(\hat{\sigma}^2/2) \exp(\underbrace{\hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \hat{\beta}_3 x_3}_{\widehat{\log(y)}}) = \exp(\hat{\sigma}^2/2) \exp(\widehat{\log(y)})$$

- ▶ Se não tivermos Normalidade,

$$\hat{y} = \hat{\alpha}_0 \exp(\widehat{\log(y)})$$

onde $\hat{\alpha}_0$ é uma estimativa de $\alpha_0 = \mathbb{E}(\exp(u)|X)$

Comparação de modelos

Como estimar α_0 ?

- ▶
$$\hat{\alpha}_0 = n^{-1} \sum_{i=1}^n \exp(\hat{u}_i) (>1)$$

Comparação de modelos

Como estimar α_0 ?

- ▶ $\hat{\alpha}_0 = n^{-1} \sum_{i=1}^n \exp(\hat{u}_i) (>1)$
- ▶ $\hat{\alpha}_0 = \left(\sum_{i=1}^n \hat{m}_i y_i \right) / \left(\sum_{i=1}^n \hat{m}_i^2 \right)$ onde $\hat{m}_i = \exp(\widehat{\log(y_i)})$

Comparação de modelos

Como estimar α_0 ?

- ▶ $\hat{\alpha}_0 = n^{-1} \sum_{i=1}^n \exp(\hat{u}_i) (>1)$
- ▶ $\hat{\alpha}_0 = \left(\sum_{i=1}^n \hat{m}_i y_i \right) / \left(\sum_{i=1}^n \hat{m}_i^2 \right)$ onde $\hat{m}_i = \exp(\widehat{\log(y_i)})$

Comparação de modelos

Como estimar α_0 ?

- ▶ $\hat{\alpha}_0 = n^{-1} \sum_{i=1}^n \exp(\hat{u}_i) (>1)$
- ▶ $\hat{\alpha}_0 = \left(\sum_{i=1}^n \hat{m}_i y_i \right) / \left(\sum_{i=1}^n \hat{m}_i^2 \right)$ onde $\hat{m}_i = \exp(\widehat{\log(y_i)})$

Comparar modelos

- ▶ $R^2 = [Cor(y, \hat{y})]^2$
- ▶ $R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{\alpha}_0 \hat{m}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$

Comparação de modelos

$$\hat{\alpha}_0 = n^{-1} \sum_{i=1}^n \exp(\hat{u}_i), \quad \hat{\alpha}_0 = \frac{\left(\sum_{i=1}^n \hat{m}_i y_i \right)}{\left(\sum_{i=1}^n \hat{m}_i^2 \right)}, \text{ onde } \hat{m}_i = \exp(\widehat{\log(y_i)})$$

```
modelo1 = lm(salary~sales+roe, data = ceosal1)
modelo2 = lm(log(salary)~log(sales)+roe, data = ceosal1)
uhat = residuals(modelo2)
alpha0_1 = mean(exp(uhat))
m = exp(fitted(modelo2))
alpha0_2 = sum(ceosal1$salary*m)/sum(m^2)
y = ceosal1$salary
```

Comparação de modelos

```
summary(modelo1)$r.squared  
  
## [1] 0.02917169  
  
yhat_1 = alpha0_1*m  
yhat_2 = alpha0_2*m  
c(cor(y, yhat_1)^2, cor(y, yhat_2)^2)  
  
## [1] 0.04882569 0.04882569  
  
1 - sum((y-yhat_1)^2)/sum((y-mean(y))^2)  
  
## [1] 0.04124148  
  
1 - sum((y-yhat_2)^2)/sum((y-mean(y))^2)  
  
## [1] 0.04258757
```

Intervalos de Confiança / Previsão

Intervalos de Confiança / Previsão

- ▶ Seja $x_0 = (x_{0,1}, x_{0,2}, \dots, x_{0,k})$ os valores observados de x

Intervalos de Confiança / Previsão

- ▶ Seja $x_0 = (x_{0,1}, x_{0,2}, \dots, x_{0,k})$ os valores observados de x
- ▶ O previsão de y dados os valores x_0 , são obtidos como

$$\hat{y} = \mathbb{E}(y|x_0) = \hat{\beta}_0 + \hat{\beta}_1 x_{0,1} + \dots + \hat{\beta}_k x_{0,k}$$

Intervalos de Confiança / Previsão

- ▶ Seja $x_0 = (x_{0,1}, x_{0,2}, \dots, x_{0,k})$ os valores observados de x
- ▶ O previsão de y dados os valores x_0 , são obtidos como

$$\hat{y} = \mathbb{E}(y|x_0) = \hat{\beta}_0 + \hat{\beta}_1 x_{0,1} + \dots + \hat{\beta}_k x_{0,k}$$

- ▶ E se quisermos medir a incerteza desse valor previsto?

Intervalos de Confiança / Previsão

- ▶ Seja $x_0 = (x_{0,1}, x_{0,2}, \dots, x_{0,k})$ os valores observados de x
- ▶ O previsão de y dados os valores x_0 , são obtidos como

$$\hat{y} = \mathbb{E}(y|x_0) = \hat{\beta}_0 + \hat{\beta}_1 x_{0,1} + \dots + \hat{\beta}_k x_{0,k}$$

- ▶ E se quisermos medir a incerteza desse valor previsto?
- ▶ Vamos construir **intervalos de confiança**

Intervalos de Confiança / Previsão

- ▶ Seja $x_0 = (x_{0,1}, x_{0,2}, \dots, x_{0,k})$ os valores observados de x
- ▶ O previsão de y dados os valores x_0 , são obtidos como

$$\hat{y} = \mathbb{E}(y|x_0) = \hat{\beta}_0 + \hat{\beta}_1 x_{0,1} + \dots + \hat{\beta}_k x_{0,k}$$

- ▶ E se quisermos medir a incerteza desse valor previsto?
- ▶ Vamos construir **intervalos de confiança**

Intervalos de Confiança / Previsão

- ▶ Seja $x_0 = (x_{0,1}, x_{0,2}, \dots, x_{0,k})$ os valores observados de x
- ▶ O previsão de y dados os valores x_0 , são obtidos como

$$\hat{y} = \mathbb{E}(y|x_0) = \hat{\beta}_0 + \hat{\beta}_1 x_{0,1} + \dots + \hat{\beta}_k x_{0,k}$$

- ▶ E se quisermos medir a incerteza desse valor previsto?
- ▶ Vamos construir **intervalos de confiança**

IC

Um IC assintótico 95% para $\mathbb{E}(y|x_0)$

$$\left(x_0 \hat{\beta} - 1.96 \sqrt{x_0 \hat{V}_{\hat{\beta}} x_0'} ; \quad x_0 \hat{\beta} + 1.96 \sqrt{x_0 \hat{V}_{\hat{\beta}} x_0'} \right)$$

onde $\hat{V}_{\hat{\beta}}$ é a matriz de variância-covariância de $\hat{\beta}$

Intervalos de Confiança / Previsão

```
modelo = lm(colgpa ~ sat + hsperc + hsize + I(hsize^2),  
           data = gpa2)  
round(coef(modelo), 5)  
  
## (Intercept)          sat        hsperc       hsize   I(hsize^2)  
##      1.49265     0.00149    -0.01386    -0.06088    0.00546  
  
x0 = data.frame(sat = 1200, hsperc = 30, hsize = 5)  
yhat = predict(modelo, newdata = x0)  
V_beta = vcov(modelo)
```

Intervalos de Confiança / Previsão

```
x= matrix(c(1,1200,30,5,25),ncol=5)
x

##      [,1] [,2] [,3] [,4] [,5]
## [1,]    1 1200   30     5    25
c(yhat - 1.96*sqrt(x%*%V_beta%*%t(x)),
  yhat + 1.96*sqrt(x%*%V_beta%*%t(x)))

## [1] 2.661115 2.739036
```

Intervalos de Confiança / Previsão

```
x= matrix(c(1,1200,30,5,25),ncol=5)
x

##      [,1] [,2] [,3] [,4] [,5]
## [1,]     1 1200    30     5    25
c(yhat - 1.96*sqrt(x%*%V_beta%*%t(x)),
  yhat + 1.96*sqrt(x%*%V_beta%*%t(x)))

## [1] 2.661115 2.739036

predict(modelo,newdata = x0, interval = "confidence")

##      fit      lwr      upr
## 1 2.700075 2.661104 2.739047
```

Intervalos de Confiança / Previsão

- ▶ Um IC da média não é a mesma coisa que um IC de uma unidade em particular

Intervalos de Confiança / Previsão

- ▶ Um IC da média não é a mesma coisa que um IC de uma unidade em particular
- ▶ IC para uma unidade em particular são conhecidos como **intervalos de previsão** e precisam incluir uma outra fonte de variação, *a variância do erro não observado*.

Intervalos de Confiança / Previsão

- ▶ Um IC da média não é a mesma coisa que um IC de uma unidade em particular
- ▶ IC para uma unidade em particular são conhecidos como **intervalos de previsão** e precisam incluir uma outra fonte de variação, *a variância do erro não observado*.

Intervalos de Confiança / Previsão

- ▶ Um IC da média não é a mesma coisa que um IC de uma unidade em particular
- ▶ IC para uma unidade em particular são conhecidos como **intervalos de previsão** e precisam incluir uma outra fonte de variação, *a variância do erro não observado*.

Sabemos que

$$y_{n+1} = \beta_0 + \beta_1 x_{n+1,1} + \cdots + \beta_k x_{n+1,k} + u_{n+1}$$

Então o **erro de previsão** é dado por,

$$\hat{u}_{n+1} = y_{n+1} - \hat{y}_{n+1} = \underbrace{x_{n+1}\beta + u_{n+1}}_{y_{n+1}} - \underbrace{x_{n+1}\hat{\beta}}_{\hat{y}_{n+1}} = x_{n+1}(\beta - \hat{\beta}) + u_{n+1}$$

Intervalos de Confiança / Previsão

$$\begin{aligned} V(\hat{u}_{n+1}|x_{n+1}) &= E(\hat{u}_{n+1}^2|x_{n+1}) \\ &= E[(x_{n+1}(\beta - \hat{\beta}) + u_{n+1})^2|x_{n+1}] \\ &= E[x_{n+1}(\beta - \hat{\beta})(\beta - \hat{\beta})'x'_{n+1} + u_{n+1}^2 + 2x_{n+1}(\beta - \hat{\beta})\hat{u}_{n+1}|x_{n+1}] \\ &= x_{n+1}V(\hat{\beta}|x_{n+1})x'_{n+1} + \underbrace{E(u_{n+1}^2|x_{n+1})}_{\sigma^2} \end{aligned} \tag{2}$$

IP

Um IP 95% (assumindo Normalidade) é dado por

$$\left(x_0 \hat{\beta} - 1.96 \sqrt{x_0 \hat{V}_{\hat{\beta}} x'_0 + \hat{\sigma}^2} \quad ; \quad x_0 \hat{\beta} + 1.96 \sqrt{x_0 \hat{V}_{\hat{\beta}} x'_0 + \hat{\sigma}^2} \right)$$

Intervalos de Confiança / Previsão

```
sigma2 = summary(modelo)$sigma^2
x= matrix(c(1,1200,30,5,25),ncol=5)
c(yhat - 1.96*sqrt(x%*%V_beta%*%t(x) + sigma2),
  yhat + 1.96*sqrt(x%*%V_beta%*%t(x) + sigma2))

## [1] 1.602051 3.798100
```

Intervalos de Confiança / Previsão

```
sigma2 = summary(modelo)$sigma^2
x= matrix(c(1,1200,30,5,25),ncol=5)
c(yhat - 1.96*sqrt(x%*%V_beta%*%t(x) + sigma2),
  yhat + 1.96*sqrt(x%*%V_beta%*%t(x) + sigma2))

## [1] 1.602051 3.798100

predict(modelo,newdata = x0, interval = "prediction")

##          fit      lwr      upr
## 1 2.700075 1.601749 3.798402
```

Leituras recomendadas

Leituras recomendadas

- ▶ Wooldridge, Jeffrey M. *Introdução à Econometria: Uma abordagem moderna.* (2016). Cengage Learning. – **Cap 6**
- ▶ Hansen, Bruce. *Econometrics.* (2020). – **Sec 7.14 e Sec 7.15**