



DCP098

Fundamentos para Avaliação Quantitativa de Políticas Públicas

Precisão das estimativas

Teste de hipótese

Aulas 11-12
09 e 11 de maio de 2022

Ana Paula Karruz

Dois desafios à análise estatística: aleatoriedade e endogeneidade

Fontes de incerteza quanto ao efeito estimado de X sobre Y

Sampling randomness: amostras de diferentes tamanhos geram coeficientes estimados diferentes; amostras diferentes de um mesmo tamanho também geram coeficientes estimados diferentes; na estatística frequentista, coeficiente populacional é fixo)

Modeled randomness: aleatoriedade e complexidade na formação de Y redundam em variáveis omitidas; nota: aqui não estamos falando de variáveis omitidas correlacionadas com X

Variáveis omitidas correlacionadas com X: existência dessas variáveis implica espuriedade

Aleatoriedade
(compromete a
precisão)

Endogeneidade
(compromete a
acurácia)


FOCO DE HOJE:
aleatoriedade

$\hat{\beta}_1$

(ou qualquer outro
coeficiente de
inclinação estimado)

Distribuição de densidade de β_1 hats se aproxima de uma normal

- **Fórmula** do β_1 hat pode ser **reescrita como uma média** (Bailey, 2016: 85, nota 8)
- Como tal, β_1 hat é uma **estatística amostral sujeita ao Teorema Central do Limite** (aka Teorema do Limite Central), segundo o qual:
 - A média amostral de qualquer variável aleatória segue uma distribuição normal
 - Quanto maior o tamanho da amostra, a distribuição amostral da média:
 - Será mais parecida com uma distribuição normal
 - Terá centro mais próximo da média populacional



<https://youtu.be/jvoxEYmQHNM>



<https://youtu.be/b5xQmk9veZ4>
<https://youtu.be/YAIJCEDH2uY>

[Pausa para um recordatório de Estatística]

Variância e desvio padrão

- A variância e o desvio padrão são medidas de dispersão: informam quão dispersos se encontram os valores de uma variável; quanto maior a variância, mais espalhados se encontram as observações (o mesmo vale para o desvio padrão)
- **Variância = (Desvio padrão)²**
- A **variância** (populacional) de uma variável (e.g., X) é dada por:

$$var(X) = \frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2$$

Fórmula assume que conhecemos a média populacional de X (i.e., o Xbarra)

- Para calcular a variância de X numa dada amostra, substituímos o N por N-1; o “- 1” é um ajuste pela perda de graus de liberdade incorrida no cálculo da média amostral; em amostras grandes, não importa se usamos n ou n – 1 no denominador, pois o ajuste não causará diferença material no valor da variância
- É útil “**desconstruir**” o que a formula da variância faz:
 - Para cada observação, obtenha o desvio em relação à média
 - Eleve cada desvio ao quadrado
 - Tire a media dos quadrados dos desvios
- Ao calcularmos a **raiz quadrada da variância (para obter o desvio padrão)** trazemos o resultado final **de volta à escala original da variável**

Desvio padrão e erro padrão

- A variância e o desvio padrão são medidas de dispersão: informam quão dispersos se encontram os valores de uma variável; quanto maior a variância, mais espalhados se encontram as observações (o mesmo vale para o desvio padrão)

- **Variância = (Desvio padrão)²**

- A **variância** (populacional) de uma variável (e.g., X) é dada por:

$$var(X) = \frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2$$

Fórmula assume que conhecemos a média populacional de X (i.e., o Xbarra)

- Para calcular a variância de X numa dada amostra, substituímos o N por N-1; o “- 1” é um ajuste pela perda de graus de liberdade incorrida no cálculo da média amostral; em amostras grandes, não importa se usamos n ou n – 1 no denominador, pois o ajuste não causará diferença material no valor da variância

- É útil “**desconstruir**” o que a formula da variância faz:

- Para cada observação, obtenha o desvio em relação à média
- Eleve cada desvio ao quadrado
- Tire a media dos quadrados dos desvios

O **desvio padrão** mede a dispersão de uma **variável** em uma população ou amostra. O **erro padrão** mede a **precisão de uma estimativa** (i.e., a dispersão da distribuição “teórica” de infinitas estimativas obtidas a partir de amostras de mesmo tamanho)

- Ao calcularmos a **raiz quadrada da variância (para obter o desvio padrão)** trazemos o resultado final **de volta à escala original da variável**

Distribuição normal

- Trata-se uma distribuição de probabilidade de variável aleatória contínua (digamos, X) baseada em dois parâmetros: μ (média populacional de X) e σ (desvio padrão populacional de X)

$$X \sim N(\mu, \sigma)$$

- Os valores da distribuição normal são dados pela fórmula abaixo; com ela, podemos “desenhar” uma distribuição, desde que conheçamos μ e σ

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$


- A distribuição normal é simétrica, centrada em sua média (μ) e apresenta forma de sino; o espalhamento da distribuição normal é definido por (σ)
- O pico (valor mais alto, localizado em $x = \mu$) é dado pela seguinte fórmula (obtida pela simples substituição de $x = \mu$ na fórmula acima):

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}}$$


- Para $X \sim N(0, 1)$, o valor máximo (pico ou cume) corresponde a aproximadamente 0,40:

$$f(0) = 1/(\sqrt{2\pi}) = 1/(\sqrt{6,283185}) = 0,398942$$


Função densidade de probabilidade para distribuições normais



Função densidade de probabilidade ACUMULADA para distribuições normais



A distribuição $N(0, 1)$ é conhecida como “normal padrão” ou distribuição Z



Curve	Position or shape (relative to standard normal distribution)
A ($M = 0, SD = 1$)	Standard normal distribution
B ($M = 0, SD = 0.5$)	Squeezed, because $SD < 1$
C ($M = 0, SD = 2$)	Stretched, because $SD > 1$
D ($M = 1, SD = 1$)	Shifted right, because $M > 0$
E ($M = -1, SD = 1$)	Shifted left, because $M < 0$

- Para “padronizar” uma distribuição normal (i.e., fazê-la ter média nula e desvio padrão unitário), aplicamos a seguinte fórmula:

$$Z = \frac{x - \mu}{\sigma}$$

em que:

x = qualquer valor da distribuição normal original (aquela que se quer padronizar)

μ = média da distribuição normal original

σ = desvio padrão da distribuição normal original

- Um **z-score** (valor de Z para um dado valor de X) positivo significa que x é maior que a média de X
 - $z\text{-score} > 0 \leftrightarrow x > \mu$
 - $z\text{-score} < 0 \leftrightarrow x < \mu$
 - $z\text{-score} = 0 \leftrightarrow x = \mu$
- Entre outras vantagens, **converter** uma distribuição normal **em uma distribuição normal padrão** permite:
 - Comparar pontuações em diferentes distribuições com diferentes médias e desvios padrão
 - Encontre a probabilidade de observações em uma distribuição caírem acima ou abaixo de um determinado valor

Probabilidade em intervalos de uma distribuição normal padrão

<https://homepage.divms.uiowa.edu/~mbognar/applets/normal.html>


Normal Distribution
 $X \sim N(\mu, \sigma)$

$\mu = 0$

$\sigma = 1$

$x = 1$

$P(-|x| < X < |x|) = 0.68268$



$\mu = E(X) = 0$ $\sigma = SD(X) = 1$ $\sigma^2 = Var(X) = 1$

Help

©2021 Matt Bognar
Department of Statistics and Actuarial Science
University of Iowa


Normal Distribution
 $X \sim N(\mu, \sigma)$

$\mu = 0$

$\sigma = 1$

$x = 1.96$

$P(-|x| < X < |x|) = 0.95$



$\mu = E(X) = 0$ $\sigma = SD(X) = 1$ $\sigma^2 = Var(X) = 1$

Help

©2021 Matt Bognar
Department of Statistics and Actuarial Science
University of Iowa


Normal Distribution
 $X \sim N(\mu, \sigma)$

$\mu = 0$

$\sigma = 1$

$x = 2$

$P(-|x| < X < |x|) = 0.9545$



$\mu = E(X) = 0$ $\sigma = SD(X) = 1$ $\sigma^2 = Var(X) = 1$

Help

©2021 Matt Bognar
Department of Statistics and Actuarial Science
University of Iowa


Normal Distribution
 $X \sim N(\mu, \sigma)$

$\mu = 0$

$\sigma = 1$

$x = 2.576$

$P(-|x| < X < |x|) = 0.99$



$\mu = E(X) = 0$ $\sigma = SD(X) = 1$ $\sigma^2 = Var(X) = 1$

Help

©2021 Matt Bognar
Department of Statistics and Actuarial Science
University of Iowa

Outras distribuições de probabilidade disponíveis em:

[https://homepageplets](https://homepage.divms.uiowa.edu/~mbognar/applets)

[Fim do recordatório de Estatística]

Distribuição de densidade de β_1 hats se aproxima de uma normal

- Para **amostras grandes** (digamos, 100+), β_1 hats são normalmente distribuídos
 - Se os erros do modelo (ε) forem normalmente distribuídos, então β_1 hats serão normalmente distribuídos independentemente do tamanho da amostra
- Portanto, enquanto normal, a **distribuição amostral (“teórica”) de β_1 hats**:
 - É simétrica, centrada em sua média (μ), e apresenta forma de sino
 - Tem “espalhamento” definido pela variância (σ^2)

Aleatoriedade, centralidade e dispersão de $\hat{\beta}_1$

- $\hat{\beta}_1$ s são aleatórios; conforme a sorte, podemos obter uma estimativa distante de β_1
- Além da **centralidade**, interessa considerar a **dispersão** da distribuição “teórica” de $\hat{\beta}_1$ s, para avaliarmos quão provável é que estimemos um coeficiente próximo do parâmetro populacional




FIGURE 3.6: Two Distributions with Different Variances of $\hat{\beta}_1$

Fonte: Bailey (2016: 94).

- Se a condição de **exogeneidade** estiver atendida, a **média dos $\hat{\beta}_1$ s é β_1**
- O que podemos dizer sobre a **variância de $\hat{\beta}_1$ hat?**

Numa regressão bivariada, a variância de $\beta_1\text{hat}^*$ é dada por:

[Obs.: A variância de $\beta_0\text{hat}$ é dada por outra fórmula.]

Erro padrão de $\beta_1\text{hat}$, o $\text{se}(\beta_1\text{hat})$ = Raiz quadrada da $\text{var}(\beta_1\text{hat})$

$$\text{var}(\hat{\beta}_1) = \frac{\hat{\sigma}^2}{N \times \text{var}(X)}$$

Variância da regressão = (Residual standard error)². Obtenha o residual standard error no output da regressão.

$\hat{\sigma}^2$

Variância da regressão

- Mede quão bem o modelo explica a variação de Y
- Seu cálculo baseia-se nos resíduos
- j = número de parâmetros estimados (incluindo o intercepto)
- É também uma estimativa da variância de ϵ
- **Intuição:** média do quadrado da distância entre valores observados e previstos de Y

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{N - j}$$

$$= \frac{\sum_{i=1}^N \hat{\epsilon}_i^2}{N - j}$$

N

Tamanho da amostra

- **Intuição:** mais dados implicam menor variância, pois a chance de o acaso nos levar às caudas da distribuição de $\beta_1\text{hat}$ é menor em amostras maiores (i.e., menor sampling randomness)

$\text{var}(X)$

Variância amostral de X

- Quanto mais X variar, mais precisa será a distribuição de $\beta_1\text{hat}$
- **Intuição:** se X varia pouco, não temos muita informação para estimar o efeito da variação de X sobre a variação de Y

$$\text{var}(X) = \frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2$$

Em amostras pequenas, divida o somatório por $N - 1$

* Fórmula de $\text{var}(\beta_1\text{hat})$ é mais complicada quando erros são correlacionados ou heteroscedásticos, mas as intuições sobre variância da regressão, tamanho da amostra e $\text{var}(X)$ se aplicam. Voltaremos a esse ponto em aulas futuras.




Ilustração: Comando para estimar regressão em R

```
Call:
lm(formula = dados$Weight..pounds. ~ dados$Donuts.per.week)

Residuals:
    Min       1Q   Median       3Q      Max
-92.731 -13.508   3.916  36.081  55.716

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)    121.613    16.593   7.329 1.49e-05 ***
dados$Donuts.per.week    9.224     1.959   4.707 0.000643 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 45.81 on 11 degrees of freedom
Multiple R-squared:  0.6683, Adjusted R-squared:  0.6381
F-statistic: 22.16 on 1 and 11 DF,  p-value: 0.0006426
```



Vide aula 05

Numa regressão bivariada, a variância de $\hat{\beta}_0$ é dada por:

Emo padrão do Intercepto na regressão SIMPLES

note:
 $\text{Var}(\hat{\beta}_0) = \text{Var}(Y - \hat{\beta}_1 X)$

$$EP(\hat{\beta}_0) = \text{residual standard error} * \sqrt{\frac{1}{n} + \frac{\bar{X}^2}{\sum (X - \bar{X})^2}}$$

$$\text{residual standard error} = \sqrt{\frac{\sum (Y - \hat{Y})^2}{Dof}}$$

Exemplo donuts:

residual standard error = 45,81

$n = 13$

$\bar{X}^2 = 29,66059$

$\sum (X - \bar{X})^2 = 546,67731$

$$EP(\hat{\beta}_0) = 45,81 * \sqrt{\frac{1}{13} + \frac{29,66059}{546,67731}}$$

Annotations: $\frac{1}{13} \rightarrow 0,0769231$; $\frac{29,66059}{546,67731} \rightarrow 0,0542561$; $0,0769231 + 0,0542561 \rightarrow 0,1311792$

$= 45,81 * 0,3621867$

$= 16,5917727$

$EP(\hat{\beta}_0) \text{ no R} = 16,593$




FIGURE 3.7: Four Scatterplots

Discussion Questions

1. Will the variance of $\hat{\beta}_1$ be smaller in panel (a) or panel (b) of Figure 3.7? Why?
2. Will the variance of $\hat{\beta}_1$ be smaller in panel (c) or panel (d) of Figure 3.7? Why?

Se a condição de exogeneidade for atendida, MQO produzirá estimador consistente de β_1




FIGURE 3.8: Distributions of $\hat{\beta}_1$ for different sample sizes

- Um estimador de β_1 é consistente se a respectiva distribuição de $\hat{\beta}_1$ se **aproxima** cada vez mais do verdadeiro β_1 à medida que o tamanho da **amostra aumenta**

- Formalmente, consistência é definida como

$$\text{plim } \hat{\beta}_1 = \beta_1$$

plim = limite de probabilidade

plim de um estimador = valor para o qual a sampling distribution da estimativa gerada pelo estimador converge à medida que o tamanho da amostra aumenta

As duas melhores coisas que você pode dizer sobre um estimador é que ele é **livre de viés e consistente**. Os estimadores OLS têm essas duas propriedades **quando o erro não está correlacionado com a variável independente**.

Bailey (2016: 101)

Qual a diferença entre acurácia (unbiasedness) e consistência?


Se a condição de exogeneidade for atendida, MQO produzirá estimadores consistentes de β_1

*Os livros didáticos às vezes não dão a devida atenção à **distinção entre ausência de viés [unbiasedness] e consistência**, mas a diferença pode ser importante na prática. **Ausência de viés** significa que o estimador tem uma distribuição amostral **centrada no parâmetro de interesse em uma amostra de qualquer tamanho**, enquanto **consistência** significa apenas que o estimador **converge para o parâmetro populacional à medida que o tamanho da amostra cresce**.*

Angrist e Krueger (2001: 4-5;
NBER Working Paper 8456;
<https://doi.org/10.3386/w8456>)

Conclusões sobre efeito de X em Y requerem tomada de decisão sobre o significado da evidência apurada

Teste de hipótese é rotina para essa tomada de decisão





DCP098

Fundamentos para Avaliação Quantitativa de Políticas Públicas

Precisão das estimativas

Teste de hipótese

Aulas 11-12
09 e 11 de maio de 2022

Ana Paula Karruz