

כל פרק (פרק)
כל פרק (פרק)
כל פרק (פרק)
כל פרק (פרק)

$$Y_i = \alpha + \beta X_i + \varepsilon_i$$

מטרה: למצוא את $\hat{\alpha}$ ו- $\hat{\beta}$

$$\text{Min } \sum \hat{\varepsilon}_i^2$$

$$\rightarrow \textcircled{1} \sum \hat{\varepsilon}_i = 0$$

$$\textcircled{2} \sum \hat{\varepsilon}_i X_i = 0$$

$$\hat{\alpha} = \bar{Y} - \hat{\beta} \bar{X} \Rightarrow \text{כאשר } \bar{X} \text{ ו- } \bar{Y} \text{ הם הממוצעים}$$

$$\hat{\beta} = \frac{\text{Cov}(X, Y)}{\text{Var}(X)}$$

שלושה תנאים (שלושה תנאים)

כל פרק (פרק) : כל פרק (פרק)

הנחות

הנחות : 1. $E(\varepsilon_i) = 0 \forall i$

$$\textcircled{1} E(\varepsilon_i) = 0 \forall i$$

$$\forall i \neq j \quad \text{Cov}(\varepsilon_i, \varepsilon_j) = 0 \quad \textcircled{2}$$

$$\text{Var}(\varepsilon_i) = \sigma_\varepsilon^2 \quad \forall i \quad \textcircled{3}$$

$$\varepsilon \sim N \quad \textcircled{4}$$

$$\text{Cov}(\varepsilon_i, X) = 0 \quad \textcircled{5}$$

כל פרק (פרק)

$$\hat{\beta} = \beta + \frac{\sum (X_i - \bar{X}) \varepsilon_i}{\sum (X_i - \bar{X})^2} \rightarrow E(\hat{\beta}) = \beta$$

$$\rightarrow \text{Var}(\hat{\beta}) = \frac{\sigma_\varepsilon^2}{\sum (X_i - \bar{X})^2}$$

$$\hat{\alpha} = \alpha + \sum \left[\left(\frac{1}{N} - \frac{\bar{X}(X_i - \bar{X})}{\sum (X_i - \bar{X})^2} \right) \varepsilon_i \right] \rightarrow E(\hat{\alpha}) = \alpha$$

$$\rightarrow \text{Var}(\hat{\alpha}) = \frac{\sigma_\varepsilon^2 \sum X_i^2}{n \cdot \sum (X_i - \bar{X})^2}$$


הנחות : כל פרק (פרק)

הנחות

$$\sigma_\varepsilon^2 = ? \quad \hat{\sigma}_\varepsilon^2 = \frac{\sum \hat{\varepsilon}_i^2}{n-2}$$

למה? כי זה לא נכון
לומר ש $\text{Cov}(\hat{\beta}_1, \hat{\beta}_2) < 0$

התוצאה



הוא לא נכון $\text{Cov}(\hat{\beta}_1, \hat{\beta}_2) < 0$ כי זה לא נכון לומר ש

$$\text{Cov}(\hat{\beta}_1, \hat{\beta}_2) = E(\hat{\beta}_1 - E(\hat{\beta}_1))(\hat{\beta}_2 - E(\hat{\beta}_2))$$

$$= E\left(\underbrace{\sum \frac{(x_i - \bar{x})}{\sum (x_i - \bar{x})^2}}_{w_i} \underbrace{\left(\sum \frac{1}{n} \cdot \frac{\bar{x}(x_i - \bar{x})}{\sum (x_i - \bar{x})^2}\right)}_{h_i} \varepsilon_i\right)$$

$$= E\left(\sum h_i \varepsilon_i\right)\left(\sum w_i \varepsilon_i\right) = E\left(\sum h_i w_i \varepsilon_i^2 + \sum \sum h_i w_j \varepsilon_i \varepsilon_j\right)$$

$$= \sum h_i w_i E(\varepsilon_i^2) + \sum \sum h_i w_j E(\varepsilon_i \varepsilon_j)$$

$$= \sigma_\varepsilon^2 \sum h_i w_i$$

$$= \sigma_\varepsilon^2 \cdot \sum_{i=1}^n \underbrace{\left[\frac{1}{n} \cdot \frac{\bar{x}(x_i - \bar{x})}{\sum (x_i - \bar{x})^2}\right]}_{h_i} \underbrace{\left[\frac{(x_i - \bar{x})}{\sum (x_i - \bar{x})^2}\right]}_{w_i}$$

$$= \sigma_\varepsilon^2 \cdot \left[\frac{\sum (x_i - \bar{x})}{\sum (x_i - \bar{x})^2} \cdot \frac{1}{n}\right] - \sigma_\varepsilon^2 \cdot \frac{\bar{x} \sum (x_i - \bar{x})^2}{[\sum (x_i - \bar{x})^2]^2}$$

$$\Rightarrow \text{Cov}(\hat{\beta}_1, \hat{\beta}_2) = \boxed{-\frac{\sigma_\varepsilon^2 \cdot \bar{x}}{\sum (x_i - \bar{x})^2}}$$

BLUE זה OLS הוא
 (כאשר β, α ידועים)
 הם זהו השער המינימלי, אומרים עליו
 שזה האומדן המינימלי

← Gauss Markov Theorem

הוכחה:

אנליזה

① נגד $\hat{\beta}$ אנליזה מסתמך על זה

$$\hat{\beta} = \sum a_i y_i$$

השער ω_i של x (משקל) מניין עליו סכום.

$$\hat{\beta} = \sum \omega_i y_i = \frac{\sum (y_i - \bar{y})(x_i - \bar{x})}{\sum (x_i - \bar{x})^2}$$

$$y_i = \frac{1}{\alpha + \beta x_i}$$

אנליזה של α ו- β סטטיסטיים:

② חסר חשיבות ← השער.

שם ההוכחה: נניח α ו- β ידועים. אנליזה של חסר חשיבות.
 נגד $\hat{\beta}$ OLS זהו זהו השער המינימלי.
 (כאשר α ידוע ו- β אינו ידוע).

$$\tilde{\beta} = \sum q_i y_i \quad \text{השער המינימלי}$$

$$= \sum (\omega_i + \Delta_i) y_i = \sum (\omega_i + \Delta_i) (\alpha + \beta x_i + \varepsilon_i)$$

השער המינימלי של $\tilde{\beta}$ הוא זה.

$$= \sum (\omega_i \alpha) + \beta \sum \omega_i x_i + \sum \omega_i \varepsilon_i + \sum \Delta_i \alpha + \beta \sum \Delta_i x_i + \sum \Delta_i \varepsilon_i$$

$$\Rightarrow \hat{\beta} = \beta + \alpha \sum \Delta_i + \beta \sum \Delta_i x_i + \sum (\Delta_i + \omega_i) \varepsilon_i$$

$$E(\hat{\beta}) = E(\beta) + E(\alpha \sum \Delta_i) + E(\beta \sum \Delta_i x_i) + E(\sum (\Delta_i + \omega_i) \varepsilon_i)$$

השער המינימלי

הצגת המודל כמספר

$$E(\hat{\beta}) = \beta + \kappa \sum \Delta_i + \beta \sum \Delta_i x_i = \beta$$

$\delta'_{\text{הצגה}}$

$$\begin{cases} \sum \Delta_i = 0 \\ \sum \Delta_i x_i = 0 \end{cases}$$

הצגה

* הצגת המודל כמספר

$$\kappa \sum \Delta_i = -\beta \sum \Delta_i x_i$$

הצגת המודל כמספר

$$\hat{\beta} = \sum \Delta_i x_i$$
$$\sum \Delta_i = 0$$
$$\sum \Delta_i x_i = 0$$

הצגת המודל כמספר

$$\begin{aligned} \text{Var}(\hat{\beta}) &= E(\hat{\beta} - \beta)^2 = E\left(\sum (\Delta_i + w_i) \varepsilon_i\right)^2 \\ &= E\left(\sum (\Delta_i + w_i)^2 \varepsilon_i^2 + 2 \sum \sum (w_i + \Delta_i)(w_j + \Delta_j) \varepsilon_i \varepsilon_j\right) \\ &= \sigma_\varepsilon^2 \sum (\Delta_i + w_i)^2 \\ &= \sigma_\varepsilon^2 \left(\sum \Delta_i^2 + \sum w_i^2 + 2 \sum w_i \Delta_i \right) \\ &= \sigma_\varepsilon^2 \cdot \left[\frac{\sum (x_i - \bar{x})^2}{(\sum (x_i - \bar{x})^2)^2} + \sum \Delta_i^2 + \frac{2 \sum (x_i - \bar{x}) \Delta_i}{\sum (x_i - \bar{x})^2} \right] \\ &= \frac{\sigma_\varepsilon^2}{\sum (x_i - \bar{x})^2} = \sigma_\varepsilon^2 \cdot \sum \Delta_i^2 \Rightarrow \hat{\beta} = \hat{\beta}_{OLS} \end{aligned}$$

הצגת המודל כמספר
של Δ_i בע
הצגת המודל כמספר

אם $P_{\text{מ}} = P_{\text{מ}} + P_{\text{מ}} + P_{\text{מ}}$ אז
 (אם $P_{\text{מ}} = P_{\text{מ}} + P_{\text{מ}} + P_{\text{מ}}$)
 (אם $P_{\text{מ}} = P_{\text{מ}} + P_{\text{מ}} + P_{\text{מ}}$)

אם $P_{\text{מ}} = P_{\text{מ}} + P_{\text{מ}} + P_{\text{מ}}$ אז (I)

$$\min_{\hat{\beta}} \sum \hat{\epsilon}_i^2 = \sum (y_i - \hat{\beta} x_i)^2$$

$$\frac{d}{d\hat{\beta}} \Rightarrow -2 \sum_{i=1}^n (y_i - \hat{\beta} x_i) x_i = 0$$

$$\Rightarrow \sum y_i x_i = \hat{\beta} \sum x_i^2 \Rightarrow \hat{\beta} = \frac{\sum x_i y_i}{\sum x_i^2}$$

* אם $\bar{x} = 0$ אז $\bar{y} = 0$ אז $\hat{\beta} = 0$

אם $y = c \cdot x$ אז $\hat{\beta} = c$ (II)
 אם $y = c \cdot x$ אז $\hat{\beta} = c$

אם $y = c \cdot x$ אז $\hat{\beta} = c$

$$(cy) = \hat{\alpha}' + \hat{\beta}'(c'x) + \hat{\epsilon}'$$

$$\hat{\beta}' = \frac{\text{Cov}(c'x, cy)}{\text{Var}(c'x)} = \frac{c' \cdot c \cdot \text{Cov}(x, y)}{c' \cdot c \cdot \text{Var}(x)} = \frac{c}{c'} \hat{\beta} \rightarrow \text{אם } c = c' \text{ אז } \hat{\beta} = \hat{\beta}$$

אם $c = c'$ אז $\hat{\beta} = \hat{\beta}$ אז $\hat{\beta} = \hat{\beta}$


$$\hat{\alpha}' = (cy) - \hat{\beta}'(c'x) \Rightarrow \hat{\alpha}' = c \cdot \bar{y} - \frac{c}{c'} \hat{\beta} \cdot c' \bar{x}$$

* אם $c = c'$ אז $\hat{\beta} = \hat{\beta}$
 * אם $c = c'$ אז $\hat{\beta} = \hat{\beta}$

$$\Rightarrow c(\bar{y} - \hat{\beta} \bar{x}) = c \cdot \hat{\alpha}$$

R² וגם סב היתאמה : (אז "אילת האמה")

המגד מזהה כמה מתק, והשוקק א המלמד הילד ז מלומד
 אומדני המלמד - המלמד הילד (באומד)



הק בומד ב אומד יור סב ביון לומד א המלמד
 סב לול יור

האומד לומד א

$$\begin{aligned} \frac{\sum (\hat{y}_i - \bar{y})^2}{n-1} &= \frac{\sum (\hat{y}_i + \hat{\epsilon}_i - \bar{y})^2}{n-1} = \frac{\sum (\hat{y}_i - \bar{y})^2 + \sum \hat{\epsilon}_i^2 + 2\sum (\hat{y}_i - \bar{y}) \hat{\epsilon}_i}{n-1} \\ &= \frac{\sum (\hat{y}_i - \bar{y})^2}{n-1} + \frac{\sum (\hat{\epsilon}_i^2)}{n-1} + \frac{2\sum (\hat{y}_i - \bar{y}) \hat{\epsilon}_i}{n-1} \end{aligned}$$

אין המלמד
 סב לול
 אומד
 המלמד

$$= \downarrow + \downarrow + 2\hat{\beta} \sum (x_i - \bar{x}) \hat{\epsilon}_i$$

0

$$\Rightarrow \underbrace{\sum (\hat{y}_i - \bar{y})^2}_{TSS} = \underbrace{\sum (\hat{y}_i - \bar{y})^2}_{Reg\ Sum\ of\ squares} + \underbrace{\sum (\hat{\epsilon}_i^2)}_{Error\ Sum\ of\ squares} \quad | : TSS$$

$$1 = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (\hat{y}_i - \bar{y})^2} + \frac{\sum (\hat{\epsilon}_i^2)}{\sum (\hat{y}_i - \bar{y})^2}$$

R² ≤

סב לול
 א לול סב לול
 א לול סב לול

* אומד סב לול
 * אומד תרין מלמד
 אומד א סב לול
 א 2009 סב לול
 סב לול

* $R^2 = 0.8$ (אנחנו יודעים ש- R^2 הוא תמיד בין 0 ל-1) (אנחנו יודעים ש- R^2 הוא תמיד בין 0 ל-1)

* R^2 הוא תמיד בין 0 ל-1 (אנחנו יודעים ש- R^2 הוא תמיד בין 0 ל-1)

* R^2 הוא תמיד בין 0 ל-1 (אנחנו יודעים ש- R^2 הוא תמיד בין 0 ל-1)

חשוב

* R^2 הוא תמיד בין 0 ל-1 (אנחנו יודעים ש- R^2 הוא תמיד בין 0 ל-1)

$$R^2 = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2} = \frac{\sum (\hat{x} + \hat{\beta} x_i - \hat{x} - \hat{\beta} \bar{x})^2}{\sum (y_i - \bar{y})^2}$$

$$= \frac{\hat{\beta}^2 \sum (x_i - \bar{x})^2}{\sum (y_i - \bar{y})^2} = \frac{\hat{\beta}^2 \hat{\sigma}_x^2}{\hat{\sigma}_y^2} \rightarrow \text{אנחנו יודעים ש-} \frac{\hat{\sigma}_x^2}{\hat{\sigma}_y^2} \text{ הוא תמיד בין 0 ל-1}$$

(אנחנו יודעים ש- $\hat{\beta}^2$ הוא תמיד בין 0 ל-1)

$$R^2 = \frac{(\hat{\sigma}_{xy})^2}{(\hat{\sigma}_x^2)^2} \cdot \frac{\hat{\sigma}_x^2}{\hat{\sigma}_y^2} = \frac{\hat{\sigma}_{xy}^2}{\hat{\sigma}_x^2 \hat{\sigma}_y^2} = \underline{\underline{\hat{\rho}^2}}$$

אנחנו יודעים ש- $\hat{\rho}^2$ הוא תמיד בין 0 ל-1
 ↓
 זהו תמיד בין 0 ל-1
 זהו תמיד בין 0 ל-1

$R^2_{xy} = R^2_{yx}$ (אנחנו יודעים ש- R^2 הוא תמיד בין 0 ל-1)

$\hat{y} = \hat{x} + \hat{\beta} x$ $\hat{x} = \hat{y} - \hat{\beta} y$

אם יש לנו 2 משתנים x ו- y ויש לנו נתונים
נניח $y = \beta_0 + \beta_1 x + \epsilon$ ונרצה להעריך את β_0 ו- β_1
בשיטה של LS . נניח $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$ ונרצה למצוא את $\hat{\beta}_0$ ו- $\hat{\beta}_1$ כך ש-

TSS יהיה מינימלי.

* המטרה שלנו

1/1 $y_i = \beta_0 + \beta_1 x_i + \epsilon_i$ מודל רגרסיה

השגיאה $(y_i - \hat{y}_i) = \epsilon_i = \delta + \lambda x_i$

המודל עם שגיאה ϵ_i הוא LS שונה.

הצגת שגיאת התאם ופיתוח
של LS ופיתוח OLS



רגרסיות לוגיות

$$Y_i = e^{\alpha + \beta X_i + \varepsilon_i}$$

(יו"ש של השר מהצורה הבאה)

זהו השר לא ליניארי. אבל - באמצעות

טכניקות @ המשתמשות בלוגיקה וקדם לטכניקה וזוהי אנליזה סטטיסטית קודם לא ליניארית.





למה צריך לטפל

כי (כדי) לרגרסיות לוגיות הן הסתברותיות (קודם):

$$\ln(Y_i) = \alpha + \beta X_i + \varepsilon_i$$

אם הוסיף זהו:



אבל! ניתן לבצע רגרסיות לוגיות רק עבור ערכים $0 < Y$.

פרשני אהבה: (הקשרות אהבה)

* טג - הנה יונאי סמטרי אל אי אנהי האנה
 ↓
 אין סמט

$$x_1, x_2 > 0$$

$$\log(x_1 x_2) = \log(x_1) + \log(x_2)$$

$$\log\left(\frac{x_1}{x_2}\right) = \log(x_1) - \log(x_2)$$

$$\log(x_1^c) = c \log(x_1)$$

$$\log(x_1) - \log(x_0) \approx \frac{x_1 - x_0}{x_0} = \frac{\Delta x}{x_0}$$

→ $\frac{\Delta \log x}{\log x}$

$$100 \Delta \log x \approx \frac{\Delta x}{x_0}$$

↓
100% $\Delta \log x$

ה' \log x $\Delta \log x$
100% $\Delta \log x$

$$\log(y) = \beta_0 + \beta_1 x$$

$$\beta_1 = \frac{\Delta \log y}{\Delta x} \rightarrow \approx \frac{\Delta y}{y_0} = 0.08$$

↓
1 = $\frac{\Delta y}{y_0}$

ה' \log x $\Delta \log x$
100% $\Delta \log x$

$$\log(y) = \beta_0 + \beta_1 \log(x) \rightarrow \beta_1 = \frac{\Delta \log y}{\Delta \log x}$$

$$\approx \frac{\frac{\Delta y}{y_0}}{\frac{\Delta x}{x_0}} \rightarrow \frac{0.08}{0.01} = 8$$

'je G E
 sine 1 ~
 when y, x ~
 .nir $\frac{\beta_1}{100}$ ~

$$y = \beta_0 + \beta_1 \log(x)$$

$$\beta_1 = \frac{\Delta y}{\Delta \log x} = \frac{\Delta y}{\left(\frac{\Delta x}{x_0}\right)}$$

'je
 n/nd ~
 $1 = \frac{\Delta x}{x_0} \leftarrow \text{since}$
