

בילור הנחה קלאסית ① $E(\varepsilon_i) \neq 0$


אבל! 2 הנחות: ② $E(\varepsilon_i) = k$ קבוע כלשהו k

③ $E(\varepsilon_i) = \varepsilon_i$

2 הנחות פועלים בחוסר חשיבות. ④ ε_i בחוסר החלטה. ⑤ החוק k .

⑥ ε_i הוא המרחק ממוצע. ולא השונה לא מניח.

הנחה ⑦ ε_i לא נכונה:



① חוק מרחב כללי ε_i

② השפעת (שאר כלל) חשיבות

$$y = (k+k) + \beta_1 x_i + (\varepsilon_i - k)$$

ואם כן מרחב
לא כן

③ ε_i סולח בשונה מניח

הנחה ⑧: כפי שהנחה

באמצעות ההנחה ⑧ הולכת נכונה:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \varepsilon_i \rightarrow E(\varepsilon_i) = 0$$

$$y_i = \beta_0' + \beta_1' x_{i1} + \varepsilon_i' \rightarrow E(\varepsilon_i') = \beta_2 x_{i2} + E(\varepsilon_i)$$

- תחילה להוכיח כי β_2 הוא המרחק בין ε_i ל-0
- הפעולה השנייה מניחה את β_2 כי יש x שונה מ-0.

$$E(\hat{\beta}_1') = \beta_1 + \beta_2 \cdot \frac{Cov(x_1, x_2)}{Var(x_1)}$$

הם קבועים ו/או
שונים אחדות השנייה.

בסור התנה 5 - חסר סטטיסטיק (x לא מקרי)

לא התנה לא העלססא. אובלן לא צריכים אתנה - מספר זה"ח

מה קורה כאשר x משתנה מקרי: $E(u/x) = 0$
(נ"ן לא חסר הס"ח)
אבל

מסבאים בין 2 מקרים:

⑥ $0 = cov(x_i, \varepsilon_i)$ - אומדן

⑦ $0 = cov(y_i, \varepsilon_i)$ - אומדן משה לא קורה

"הקליבט" - בעולם השמתי אין כמעט אומדן חסר הס"ח.

מסבאים בין אומדן סקרנים ראשי סקרנים.

$$E(\hat{\beta}) = \beta + E\left(\frac{\sum (x_i - \bar{x}) \varepsilon_i}{\sum (x_i - \bar{x})^2}\right)$$

זהו איבר

המלא חתום

x' לא קטועים.

$$\hat{cov}(x, \varepsilon)$$

כל בל נראה
מה קורה
כאשר
 $n \rightarrow \infty$

$$E(\hat{\beta}) = \beta + E\left(\frac{\sum (x_i - \bar{x}) (\varepsilon_i - \bar{\varepsilon})}{\sum (x_i - \bar{x})^2}\right)$$

הסכום הזה

שואל $cov(x, \varepsilon)$

כאשר $n \rightarrow \infty$


הגדרה 8 סקרנים אומדן (מקור) חסר הס"ח (לא צריכה)

① הסיוח של האומדן - 0 כאשר $n \rightarrow \infty$

② התפלגות של האומדן מתכווצת סביב הסיוח.

כאשר $n \rightarrow \infty$

לבי סביב הסיוח נהיה שווה.



עלול אסטמט' $Var(\hat{\beta}) \rightarrow 0$
 $n \rightarrow \infty$

יפ"ד

ב האומדן β ויחידות
אסימטריות

$$\text{Cov}(x_i, \varepsilon_i) = 0 \quad \text{כל } i$$

(א)

$$E(\hat{\beta}) \rightarrow \beta$$

$n \rightarrow \infty$

ב האומדן β מוסיף ויחידות

$$E(\hat{\beta}) \rightarrow \beta + \frac{\text{Cov}(x_i, \varepsilon_i)}{\text{Var}(x_i)} \quad \text{(ב)}$$

מה הפסד? $\text{Cov}(x_i, \varepsilon_i) \neq 0$ כלומר לא סתם

מבנה מודל

$$y_i = \alpha + \beta x_i + \varepsilon_i \quad \text{הצורה הכללית}$$

קטגוריה

$$\hat{\alpha}, \hat{\beta}, \hat{\varepsilon}_i$$

אנחנו רוצים להבין

האם $\text{Cov}(x_i, \varepsilon_i) = 0$, איכן לא

$$\hat{\varepsilon}_i = y_i - \hat{\alpha} - \hat{\beta} x_i$$

האם $\text{Cov}(x_i, \hat{\varepsilon}_i) = 0$?

$$\text{Cov}(x_i, \varepsilon_i) = 0 \quad ?$$

ההתקפות של כלל הזה $\text{Cov}(x, \varepsilon) = 0$ היא בעצם בטלית של טקס
סטטיסטיקה שלילית רצויה האם יתכן והטקסני השלילי:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \varepsilon_i$$

אנחנו רוצים להבין

כל מה שקשור בפרטים אנחנו רוצים להבין

$$\Rightarrow \text{Cov}(x_i, \varepsilon_i) \neq 0 \rightarrow \hat{\beta}_1$$

מה עושים?? גביר ב זה במידה IV

סיכומי:

$\text{Cov}(x, \varepsilon) \neq 0$ - אומדן
מוסיף, רגוע
לא שווה

$\text{Cov}(x, \varepsilon) = 0$ - אומדן

קטנים

אשר מושג


אם אתם לא יכולים להשיג את ה-OLS אז אתם צריכים להסתפק

- ① הסימן של $\hat{\beta}$ הוא
- ② ההתפלגות המשותפת

① זהו ה-OLS

If you can't get it right as

$n \rightarrow \infty$, you shouldn't be in this business



$$\hat{\beta}_n = \frac{\sum (x_i - \bar{x}) y_i}{\sum (x_i - \bar{x})^2} = \beta_1 + \frac{\sum (x_i - \bar{x}) (y_i - \bar{y})}{\sum (x_i - \bar{x})^2}$$

ההתפלגות המשותפת של x ו- y היא t state

אם אתם לא יכולים להשיג את ה-OLS אז אתם צריכים להסתפק

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

β_{OLS}


אם אתם לא יכולים להשיג את ה-OLS אז אתם צריכים להסתפק

$$plim \hat{\beta} = \beta_1 + \frac{Cov(x, y)}{Var(x)}$$

התפלגות המשותפת של x ו- y היא t state

$$plim(\hat{\beta}) = E(z) = Cov(x, y)$$

ההתפלגות המשותפת של x ו- y היא t state



$$E(\hat{\beta}) \neq \beta ; plim \hat{\beta} = \beta$$

אם אתם לא יכולים להשיג את ה-OLS אז אתם צריכים להסתפק

Heteroscedasticity: הטרוסקדסטיות

6

3) הומוסקדסטיות

Homosce.

$$\text{Var}(\epsilon_i) = \sigma^2 \quad \forall i$$

באופן: $\text{Var}(\epsilon_i) = \sigma_i^2$ ← גודל: $\text{Var}(\epsilon_i) = \sigma^2 \cdot \pi_i^2$

1) גודל: אם מסתכלים ב-5 חברות גודלן נמוך קטן

הוצאה ϵ_i של חברת גודלן יפה גודל של חברת קטנה

(בגודל: מידת בטחון גודלן דווקא לא תהיה פחות)

2) גודל נמוך: הוצאה של חברת גודלן גבוהה

הוצאה גבוהה נמוכה - סביר שהוצאה לא תהיה

הוצאה גבוהה באופן יחסי

$$\text{expenditure} = f(\text{size}) + \epsilon_i$$

$$\pi_i = f(x_i)$$



3) גודל גבוה נמוך: Group Data = אולי עם חילוקי

הוצאה א קטנה ולא דברים בגודל: הוצאה א גודל גבוה נמוך:

$$\bar{y}_i = \beta_0 + \beta_1 \bar{x}_i + \bar{\epsilon}_i$$

$$\bar{y}_i = \frac{\sum_{j=1}^{n_i} y_{ij}}{n_i} \quad i=1, \dots, n$$

הכנסה מחולקת ב"ש"ב

$$\text{Var}(\bar{\epsilon}_i) = \text{Var}\left(\frac{\sum_{j=1}^{n_i} \epsilon_{ij}}{n_i}\right) = \frac{1}{n_i^2} \cdot E(\sum_{j=1}^{n_i} \epsilon_{ij}^2) = \frac{n_i \cdot \sigma_\epsilon^2}{n_i^2}$$

$$= \frac{\sigma_\epsilon^2}{n_i}$$

כאשר - ברמת הסתם אין בעיה של שגיאת שגיאה

השגיאה קטנה לא תהיה ברמת הסתם יחסית. עם יותר תצפיות ברמת הסתם.

4) גודל א גבוה נמוך: אולי שגיאה א גבוה נמוך

גודל (א) נשים - גודלן
הסכום ל"א"ס (א)

א גבוה
א גבוה
א גבוה

8)

2) מבחנים סטטיסטיים לקראת שני שנים:

מבחן Goldfeld-Quandt
 מנצח את המבחן הזה יוצא את
 הסדר לפיו שני ה- σ^2 שונים
 $Var(\epsilon_i) = \sigma^2 x_i^2$ כפי שמקרה
 x_i סדר

לפיכך:

- 1) מבחנים את המבחן בסדר קטן לפי x_i (נוני חתך).
- 2) מתקנים את המבחן ל-3 חלקים - x_i גבוה, בינוני ונמוך.
- 3) צורך את הקטלוג המצטבר (בין $\frac{1}{2}$ אלף ממוצע) של sample ומוצאים שטחים 2 ו-3 הקטלוג הקטן ביותר.

4) מוצאים 2 חסמים וסדרם 2 ו-3 חסמים ESS_1, ESS_2 מוחלפים
 Error Sum of sq.

H_0 : Homoscedast.

H_1 : Heter.

5) מבחן F:

$$F_{stat} = \frac{ESS_2 / \frac{n-m-2k-2}{2}}{ESS_1 / \frac{n-m-2k-2}{2}}$$

$F_{(1-\alpha)} \left(\frac{n-m-2k-2}{2}, \dots \right)$

אם $F_{stat} > F_{crit}$ אז יש להפוך את המבחן האסמטי \leftarrow חזק
 בדיקה א שני
 שנים.

9

מבחן בלוי יורי - מבחן White

בג' לא יוצא מה מקור הבקשה הסינתטית (π_i^2)

א) מבחן : $y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \epsilon_i$

שלב 1: אומדנים ראשוניים

שלב 2: חישובים של השגיאות $\hat{\epsilon}_i^2 = (y_i - \hat{y}_i)^2$

שלב 3: מניחים את המודל:

$$\hat{\epsilon}_i^2 = \gamma_0 + \gamma_1 x_{1i} + \gamma_2 x_{2i} + \gamma_3 x_{1i}^2 + \gamma_4 x_{2i}^2 + \gamma_5 x_{1i} x_{2i} + \gamma_i$$

שלב 4: אומדים את R^2 א המודל של N - נקודות נתונות.
מחשבים $N \cdot R^2$

שלב 5: מנסים את H_0 של התאמה מלאה של $\gamma_1 = \gamma_2 = \dots = \gamma_5 = 0$

$H_0: \gamma_1 = \gamma_2 = \dots = \gamma_5 = 0$

אם $N R^2 > \chi^2_{crit(s)}$ אז $N R^2 \sim \chi^2_{(p)}$ (*)

מבחן White בקופה:

* בחלק א' של הסרט
white res. ← residual tests
test
with * combination

* א prob 0.05 סיכוי

משקל שונה

GLS ← בעל ביטוי רגולר ← תוצאה שונה משקל
(משקל של תצפית נהיה בעל משקל) π_i^2

← מקרה שבו GLS ← WLS
← משקל זה הופך משקל ב π_i

$$\text{Var}(\varepsilon_i) = \sigma^2 \cdot \pi_i^2$$

$$Y_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_K X_{Ki} + \varepsilon_i$$

$$|: \pi_i \Rightarrow \frac{Y_i}{\pi_i} = \dots + \beta_K \frac{X_{Ki}}{\pi_i} + \frac{\varepsilon_i}{\pi_i}$$

$$E\left(\frac{\varepsilon_i}{\pi_i}\right) = 0; \text{Var}\left(\frac{\varepsilon_i}{\pi_i}\right) = \frac{1}{\pi_i^2} \cdot \sigma^2 \pi_i^2 = \sigma^2$$

תוצאה של
משקל

משקל

$$\frac{Y_i}{\sigma_i} = \left(\frac{\beta_0}{\sigma_i}\right) + \beta_1 \left(\frac{X_{1i}}{\sigma_i}\right) + \frac{\varepsilon_i}{\sigma_i}$$

$$\text{כל } \sigma_i! \quad \pi_i^2 = \sigma_i^2 \quad (1)$$

$$\text{Var}\left(\frac{\varepsilon_i}{\sigma_i}\right) \quad E\left(\frac{\varepsilon_i}{\sigma_i}\right) = \frac{1}{\sigma_i^2} \cdot \sigma_i^2 = 1 \rightarrow \text{שונה}$$

שונה

$$\frac{Y_i}{X_i} = \beta_0 \frac{1}{X_i} + \beta_1 \cdot 1 + \frac{\varepsilon_i}{X_i}$$

(2) שונה משקל משקל משקל

$$\pi_i = X_i \rightarrow \sigma_i^2 = \sigma^2 X_i^2$$

$$\text{Var}\left(\frac{\varepsilon_i}{X_i}\right) = \sigma^2$$

$$\frac{y_i}{\sqrt{x_i}} = \beta_0 \frac{1}{\sqrt{x_i}} + \beta_1 \sqrt{x_i} + \frac{\varepsilon_i}{\sqrt{x_i}} \quad \pi_i = \sqrt{x_i} \quad \text{ניסוח: (3) (1)}$$



אם כן, נחזיר את המודל

* אם מודלים של חוק → המודל של קליין

* אם לא → נבדוק את המודל של קליין

באופן זה אנו יכולים לראות:

דוגמה: white

(1) המודל של קליין

מודלים של קליין

$$\hat{\varepsilon}_i^2 = \hat{\sigma}_0 + \hat{\sigma}_1 x_{1i} + \hat{\sigma}_2 x_{2i} + \hat{\sigma}_3 x_{3i}^2 + \hat{\sigma}_4 x_{4i}^2 + \hat{\sigma}_5 x_{1i} x_{2i}$$

אם כן, ה $\hat{\varepsilon}_i^2$ חזרים על עצמם מחדש:

$$T_i = \frac{1}{\sqrt{\hat{v}_i}}$$

$$\hat{v}_i = \hat{\varepsilon}_i^2 - \hat{\varepsilon}_i^2$$

היחס בין
מודל קליין
למודל קליין
הוא זהה

(3) אם T_i מודלים
באופן זה אנו יכולים לראות:

(4) מודלים קליין