

Chapter 2

Økonometrisk model for kriminalitet:

$$Crime = \beta_0 + \beta_1 othinc + \beta_2 freqarr + u$$

u består af uobseverede faktorer såsom, lønnen for kriminelalitet, morale, osv.

Konstanterne β er paramternene for den økonometriske model og beskriver retningen og styrken af forholdet mellem kriminalitet og faktorerne der bestemmer kriminalitet i modellen.

Regression analyse:

$$p_i = \beta_0 + \beta_1 m2_i + \beta_3 location + \beta_4 agentowned + \epsilon_i$$

p: observeret data

m2: husets størrelse

location: afstand til centrum

agentowned: ejet af ejendomsmægler

ϵ : fejlledd

β_4 er den forventede prisforskel mellem huse der ejes af mægler og andre hus.

Datatyper

Tværsnitsdata (cross sections):

Bruges når vi har med engelkurver at gøre: y_i i=1,...,n. i kan være personer.

Regressionsmodellen for tværsnitsdata er:

$$s_i = \beta_0 + \beta_1 \log(income) + \epsilon_i$$

Tidsrække data:

Det er mere makro data eller finansielle data som lønudviklingen i dk. y_t t=1,2,...,T.
T er tiden

Paneldata:

Kombination af tværsnit og tidsrække; f.eks. ser vi på landes arbejdsløshed over tid: y_{it} , i=1,...,n, t=1,...,T

Definition af simpel regressions model

Simpel lineær regression model:

$$y = \beta_0 + \beta_1 x + u$$

Hvor y er en afhængig variabel og x er uafhængig.
 u står for ubekendte.

Hvis u holdes konstant har x en lineær effekt på y .

$$E(u|x) = E(u)$$

Dette fortæller os at den gennemsnitlige værdi for u er den samme for alle stykker af populationen sommer er besluttet af x . Når ovenstående holder, siger vi at u er "strenget uafhængig" på x .

Population regression function (PRF)

$$E(y|x) = \beta_0 + \beta x$$

Fortæller hvordan den gennemsnitlige værdi af y skifter med x .

Ordinary least squares (OLS)

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Dette er ols estimater for β_0, β_1

OLS regression line eller Sample regression function (SRF)

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x}$$

hat, betyder at det er et estimat

Total sum of squares (SST)

$$SST \equiv \sum_{i=1}^n (y_i - \bar{y})^2$$

a measure of the total sample variation in the y_i ; that is, it measures how spread out the y_i are in the sample.

(SSE)

$$SSE \equiv \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

SSE measures the sample variation in the y^i (where we use the fact that $\bar{y} = \bar{y}$)

SSR)

$$SSR \equiv \sum_{i=1}^n \hat{u}_i^2$$

SSR measures the sample variation in the u^i

$$SST = SSE + SSR$$

Godness of fit:

$$R^2 = \frac{SSE}{SST}$$

Jo højere R^2 desto mindre variation er der mellem punkterne i et skatter plot og desto mere bliver der forklaret af variationen.

Coefficient of determination (R-squared)

$$R^2 = SSE/SST = 1 - SSR/SST$$

Assumption SLR.5

$$Var(u|x) = \sigma^2$$

σ^2 is often called the error variance. Kvadratroden af dette er standard deviation

Sampling variances of the ols estimators

$$Var(\hat{\beta}_1) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2} = \sigma^2 / SST_x$$

og

$$Var(\hat{\beta}_0) = \frac{\sigma^2 n^{-1} \sum_{i=1}^n x_i^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Dette er standard formlerne for simpel regressions analyse. Det er relevant for konfudsintervaller og hypotese testning

Standard error of $\hat{\beta}_1$

$$se(\hat{\beta}_1) = \hat{\sigma} / \sqrt{SST_x} = \hat{\sigma} / \left(\sum_{i=1}^n (x_i - \bar{x})^2 \right)^{1/2}$$

Regression through the origin

$$\tilde{y} = \tilde{\beta}_1 x$$

Passes through x=0 and $\tilde{y} = 0$

Antigelser for den simple lineære regressionsmodel

SLR.1: Lineær i paremtrene

$$y = \beta_0 + \beta_1 x + u$$

SLR.2: Tilfældig udvælgelse. Oberservationerne skal være uafhængige.

SLR.3: Variation i x. x må i datasættet i antage den samme værdi for alle observationer.

SLR.4: Den betingede middelværdi af fejleddet skal være 0: $E(u|x) = 0$

Homodeskasticitet

Det betyder at variansen er konstant (ikke afhænger af x).

Det gælder at:

$$Var(u|x) = \sigma^2$$

Og at:

$$\sigma^2 = Var(u)$$

Variansen af OLS estimatoren

$$Var(\hat{\beta}_1|x) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

hvor variansen kan estimeres som:

$$\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{u}_i^2 = \frac{SSR}{n-2}$$

Kapitel 3

$$SSR/SST + SSE/SST = 1$$

Multiple lineære regressionsmodel på matrix form:

$$Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, X = \begin{pmatrix} 1 & x_{11} & \dots & x_{1k} & u_1 & \beta_0 \\ 1 & x_{21} & \dots & x_{2k} & \vdots & \beta_1 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & \dots & x_{nk} & u_n & \beta_k \end{pmatrix}, u = \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{pmatrix}, \beta = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix}$$

Omitted variable bias:

$$E(\tilde{\beta}_1) = \beta_1 + \beta_3 \frac{\sum_{i=1}^n (x_{i1} - \bar{x}_1)x_{i3}}{\sum_{i=1}^n (x_{i1} - \bar{x}_1)^2}$$

Sampling Variances of the OLS Slope Estimator

$$\text{var}(\hat{\beta}_j) = \frac{\sigma^2}{SST_j(1 - R_j^2)}$$

, a larger s2 means larger sampling variances for the OLS estimators.

we see that the larger the total variation in xj is, the smaller is $\text{Var}(\hat{\beta}_j)$

When SSTj is small, $\text{Var}(\hat{\beta}_j)$ can get very large, but a small SSTj is not a violation of Assumption MLR.3. Technically, as SSTj goes to zero, $\text{Var}(\hat{\beta}_j)$ approaches infinity

R^2 close to one indicates that x2 explains much of the variation in x1 in the sample. This means that x1 and x2 are highly correlated. As R^2 increases to one, $\text{Var}(\hat{\beta}_1)$ gets larger and larger.

Variance inflation factor

$$VIF_j = 1/(1 - R_j^2)$$

MLR.1

Lineær i paremtrene og modellen kan skrives på matrixform.

MLR.2

Tilfældig udvælgelse:

Vi har tilfældigt udvalgte observationer fra en population. Det betyder, at observationerne er uafhængige.

MLR.3

Ingen perfekt multikolinaritet mellem de forklarende variable: I datasættet må ingen af x'erne antage den samme værdi for alle observationer, og der må ikke være en lineær relation mellem de forklarende variable. Dette vil medføre, at X har fuld rang.

MLR.4

Den betingede middelværdi af fejlledet skal være lig 0: $E(u|x, \dots, x_k) = 0$. På matrixform skriver vi det som $E(u|X) = 0$.

Hvis MLR.4 er opfyldt er de forklarende variable eksogene. Hvis x_j er korreleret med u kaldes x_j for endogen.

Vi husker at $Bias = \beta_i \cdot \frac{cov(x_i, u)}{var(x_i)}$

MLR

OLS er middelret:

Teorem 3.1 OLS er middelret: Hvis antagelserne MLR.1-MLR.4 er opfyldt, så er OLS estimatoren middelret:

$$E(\hat{\beta}_j) = \beta_j$$

for alle værdier af β_j .

At den er middelret betyder at,

OLS estimatoren vil i "gennemsnit" give den rigtige værdi af parametrerne.

Hvis vi kunne gentage estimation på forskellige tilfældige datasæt, vil vi i gennemsnit få den rigtige værdi.

For den enkelte realisation kan der være afvigelser.

OLS estimator

$$\hat{\beta} = (X'X)^{-1}X'y$$

Bevis'

$$\hat{\beta} = (X'X)^{-1}X'y = (X'X)^{-1}X'(X\beta + u)$$

$$= (X'X)^{-1}X'X\beta + (X'X)^{-1}X'u$$

$$= I\beta + (X'X)^{-1}X'u$$

$$= \beta + (X'X)^{-1}X'u$$

Trin 2

$$E(\hat{\beta}|X) = \beta + E(((X'X)^{-1}X'u|X)$$

$$= \beta + (X'X)^{-1}X'E(u|X)$$

MLR.4

$$= \beta + (X'X)^{-1}X' * 0$$

$$= \beta$$

For den ubetingede middelværdi fældet det at:

$$E(\hat{\beta}_j) = \beta_j$$

Middelværdien af estimatoren

$$E(\tilde{\beta}|x) = \beta_1 + \beta_2 \frac{cov(x_2, x_1)}{Var(x_1)}$$

Summary of Bias in $\tilde{\beta}_1$ when x_2 is Omitted i estimation equation

$\beta_2 > 0$: positve bias if $Corr(x_1, x_2) > 0$ and negative $Corr(x_1, x_2) < 0$

$\beta_2 < 0$: positve bias if $Corr(x_1, x_2) < 0$ and negative $Corr(x_1, x_2) > 0$

Størrelsen på bias er besluttet ud fra stærrelsen af β_2 og $\tilde{\delta}_1$

MLR.5

Variansen af fejlleddet er konstant

$$Var(u|x_1, \dots, x_k) = \sigma^2$$

Variansen af OLS estimatoren

$$Var(\hat{\beta}|X) = \sigma^2(X'X)^{-1}$$

$$Var(\hat{\beta}_j) = \frac{\sigma^2}{SST_j(1 - R_j^2)}$$

$$\hat{\beta} = \beta + (X'X)^{-1}X'u$$

bevis for variansen af OLS estimatoren

$$Var(\hat{\beta}|X) = Var((X'X)^{-1}X'u|X)$$

$$= AVar(u|X)A'$$

MLR.2

MLR-5

$$(X'X)^{-1}X'\sigma^2IX(X'X)^{-1}$$

$$\sigma^2(X'X)^{-1}X'IX(X'X)^{-1}$$

$$\sigma^2(X'X)^{-1}X'X(X'X)^{-1}$$

$$X'X(X'X)^{-1} = I$$

$$\sigma^2(X'X)^{-1}$$

$$B = X'X$$

$$B' = X'X''$$

Estimation af σ^2

$$\hat{\sigma}^2 = \frac{SSR}{n - k - 1}$$

antallet af observationer minus antallet af obeserverede variationer (k) minus 1 er nævneren.

Ovenstående ligning er gældende hvis antagelserne MLR.1-MLR.5 holder.

$$E(\hat{\sigma}^2|X) = \sigma^2$$

OLS estimatoren

$$\hat{\beta}_1 = \sum_{i=1}^n w_i y_i$$

OLS estimatoren kan skrives som en vægtet sum af y'erne hvor $w_i = \frac{x_i - \bar{x}}{SST_1}$
For vægtene gælder det

$$\begin{aligned}\sum_{i=1}^n w_i &= 0 \\ \sum_{i=1}^n w_i x_i &= 1\end{aligned}$$

Bevis for $\hat{\beta}_1$ er en middelret estimator: $E(\tilde{\beta}_1) = \beta_1$

Ingredienser:

- MLR 1: $y = \beta_0 + \beta_1 x + u$
- MLR 3 (særlig variason)
- MLR 4: $E(u|X) = 0$
- Den alternative $\tilde{\beta} = \frac{y_1 - y_n}{x_1 - x_n}$

Bevis

- Trin 1: Udtryk $\tilde{\beta}$ som en sum af β_1 og et led som afhænger af u og x.

Anvende MLR.1.

- Trin 2: Udregn $E(\tilde{\beta}_1|x)$ og anvend MLR.4. og regnereglen for betingede middelværdier

$$\begin{aligned}
\tilde{\beta}_1 &= \frac{y_1 - y_n}{x_1 - x_n} \\
&\frac{\beta_0 + \beta_1 x_1 + u_1 - \beta_0 + \beta_1 x_n + u_n}{x_1 - x_n} \\
&= \beta_1 \frac{u_1 - u_n}{x_1 - x_n}
\end{aligned}$$

Trin 2

$$E(\tilde{\beta}|x) = \beta_1 + E\left[\frac{u_1 - u_n}{x_1 - x_n}|x\right] = \beta_1$$

Gauss-Markov Teoremet: Bevis

1. Rengørgler

Gauss-Markov Teoremet:

Ingredienser til bevis

- ❶ Regneregler (A og B matricer, x stok. vektor, c skalar)

- ❶ $cAB = AcB = ABc$
- ❷ $(AB)' = B'A'$ og $(A')' = A$
- ❸ $AA^{-1} = I$ og $A^{-1}A = I$
- ❹ $Var(Ax) = AVar(x)A'$
- ❺ $Var(y)" > "Var(x)$ hvis $Var(y) - Var(x)$ er positiv semi definit (p.s.d.)
- ❻ Def: En kvadratisk symmetrisk matrix A er positiv semi definit hvis $x'Ax \geq 0$
- ❼ Hvis B har fuld rang så er $B'B$ og BB' positiv semi definit (p.s.d.)

- ❽ Antagelser

- ❶ MLR.1: Model $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$
- ❷ MLR.3: \mathbf{X} fuld rang
- ❸ MLR.4: $E(\mathbf{u}|\mathbf{X}) = \mathbf{0}$
- ❹ MLR.2 og MLR.5: $Var(\mathbf{u}|\mathbf{X}) = \sigma^2 \mathbf{I}$

- ❽ Variansen af OLS Estimator: $Var(\hat{\boldsymbol{\beta}}|\mathbf{X}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$

Bevis

Trin1(opstil alternativ lineær middelret estimator $\tilde{\beta}$)

Lineær estimator:

$$\tilde{\beta} = Ay = A(X + \beta + u) = AX\beta + Au$$

2. Lighedstegn følger af MLR.1

$$E(\tilde{\beta}|X) = E(AX\beta + Au|X) = AX\beta + AE(u|X) = AX\beta + A0 = AX\beta$$

4. lighedstegn følger af MLR.4

Hvis $\tilde{\beta}$ skal være middelret, må det gælde at $AX = I$ (identitetsmatricen)

Trin 2 (udregn variansen af $\tilde{\beta}$)

$$Var(\beta + Au|X)$$

$$= AVar(u|X)A' = A\sigma^2 IA' = \sigma^2 AA'$$

Vi benytter regneregel (4) og (1) og MLR.2 og MLR.5

Trin 3 (sammenligning af variansen $\tilde{\beta}$ og OLS estimatoren):

$$Var(\tilde{\beta}|X) - Var(\tilde{\beta}|X) = \sigma^2 AA' - \sigma^2 (X'X)^{-1}$$

$$= \sigma^2 (AA' - (X'X)^{-1})$$

$$\sigma^2 (AA' - (AX)(X'X)^{-1}(X'A'))$$

$$= \sigma^2 A(I - X(X'X)^{-1}X')A'$$

$$\sigma^2 AMA'$$

$$\text{hvor } M = (I - X(X'X)^{-1}X')$$

Vi skal vise at AMA' er en postiv semi-definit matrix jvf regneregel (5). Til det skal vi vise at $M=M'$

$$M' = (I - X(X'X)^{-1}X')' = I'X''[(X'X)^{-1}]'X'$$

$$= (I - X(X'X)^{-1}X') = M$$

Vi benytter regneregel (2).

Vi skal vise at $MM=M$:

$$MM = (I - X(X'X)^{-1}X')(I - X(X'X)^{-1}X')$$

$$= I - 2X(X'X)^{-1}X' + X(X'X)^{-1}X' = M$$

$$Var(\tilde{\beta}|X) - Var(\tilde{\beta}|X) = \sigma^2 AMA' = \sigma^2 AMMA' = \sigma^2 (AM)M'A'$$

$$= \sigma^2 (AM)(AM)'$$

Sidste lighedstegn følger af (2). Ved at benytte regneregel (7) kan vi slutte at $Var(\tilde{\beta}|X) - Var(\tilde{\beta}|X)$ er postiv semi-definit

Kapitel 4

MLR.6

Normalitet funktions: $U \sim Normal(0, \sigma^2)$
 $E(u) = 0$ og $Var(u) = \sigma^2$

t statistic

$$y_{\hat{\beta}_j} \equiv \hat{\beta}_j / se(\hat{\beta}_j)$$

Testent other hypotheses about beta j

$$t = (\hat{\beta}_j - a_j) / se(\hat{\beta}_j)$$

Konfidensinterval

$$\hat{\beta}_j + -c * se(\hat{\beta}_j)$$

F statistic

$$F \equiv \frac{(SSR_r - SSR_{ur})/q}{SSR_{ur}/(n - k - 1)}$$

R-squared form of the F statistic

$$F = \frac{(R_{ur}^2 - R_r^2)/q}{(1 - R_{ur}^2)/df_{ur}}$$

Opsummering fra kap 3 og 4

Hvis MLR.1-4 gælder såer er OLS middelret

Hvis MLR.1-5 gælder så er OLS BLUE

HVIS MLR.1-6 gælder så er OLS normalfordelt, og vi kan lave inferens med t- og F-test.

Kapitel 5

Eksempler på multiple hypoteser

$$H_0 : \beta_3 = 1 \text{ (en restriktion)}$$

Antallet af lighedstegn er lig antallet af restriktioner.

Teststørrelsen for multiple hypoteser

$$F = \frac{(SSR_r - SSR_{ur})/q}{SSR_{ur}/(n - k - 1)}$$

Tælleren er altid positiv.

q er antal restriktioner

n-k-1 er antal frihedsgrader i den urestikterede model.

Hvis MLR.1-MLR.6 er opfyldt så gælder følgende:

$$F = \frac{(SSR_r - SSR_{ur})/q}{SSR_{ur}/(n - k - 1)} \sim F(1, n - k - 1)$$

Definition af konsistens

$$P(|W_n - \theta| > \epsilon) \rightarrow 0, n \rightarrow \infty$$

Hvis dette ikke gælder sig vi at Wn er inkonsistent.

Vi kræver normalt for en estimator at den skal være konsistent for at give mening.

Store tals lov

Se appendix C-3

$$p\lim \bar{Y}_n = \mu$$

Regnerelger for konvergencens i sandsynlighed:

For en kontinuert funktion g gælder:

$$p\lim g(W_n) = g(p\lim(W_n))$$

Hvis $p\lim(G_n) = \alpha$ og $p\lim(W_n) = \beta$ så

$$p\lim(G_n + W_n) = \alpha + \beta$$

$$p\lim(G_n W_n) = \alpha \beta$$

$$p\lim(G_n/W_n) = \alpha/\beta$$

Bevis for at OLS estimatoren er konsistent

Under antalge MLR.1-4 er OLS estimatoten $\hat{\beta}_j$ en konsistent estimatore for β_j

Ingredienser:

OLS estimatoren er konsistent:

Ingredienser til bevis.

① Regneregler:

- ① Hvis $p \lim(G_n) = \alpha$ og $p \lim(W_n) = \beta$, så gælder $p \lim(G_n/W_n) = \alpha/\beta$.
- ② Store tals lov: $p \lim(\frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})^2) = \text{Var}(Y)$ og $p \lim(\frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})(X_i - \bar{X})) = \text{cov}(Y, X)$.
- ③ $\sum_{i=1}^n x_i(x_i - \bar{x}) = \sum_{i=1}^n (x_i - \bar{x})^2 = SST_x$.
- ④ $\sum_{i=1}^n (x_i - \bar{x}) = 0$.

② Antagelser:

- ① MLR.1: Model $y = \beta_0 + \beta_1 x_1 + u$.
- ② Tilfældigt datasæt med n uafhængige observationer (dvs. u' erne er uafhængige).
- ③ MLR.3: Variation i x .
- ④ MLR.4: $E(u|x) = 0 \implies \text{cov}(u, x) = 0$.

③ OLS Estimator: $\hat{\beta}_1 = \frac{\sum_{i=1}^n y_i(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$

Trin i beviset

OLS estimatoren er konsistent:

Trin i beviset:

- ① Vis at $\hat{\beta}_1 = \frac{\sum_{i=1}^n y_i(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \dots = \beta_1 + \frac{\frac{1}{n} \sum_{i=1}^n u_i(x_i - \bar{x})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$ (benyt MLR.3 og MLR.1 og regneregel 1.3 og 1.4)
- ② Regn på $p \lim \hat{\beta}_1 = \dots = \beta_1 + \frac{\text{Cov}(u, x)}{\text{Var}(x)}$ (Benyt MLR.2 og regneregel 1.1 og 1.2)
- ③ Benyt MLR.4 til at vise at $p \lim \hat{\beta}_1 = \beta_1$

Vi starter med at vise at

$$\hat{\beta}_1 = \beta_1 + \frac{\frac{1}{n} \sum_{i=1}^n u_i(x_i - \bar{x})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$

Benytter MLR.1

$$\begin{aligned}
&= \frac{\sum_{i=1}^n y_i(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \\
&= \frac{\sum_{i=1}^n (\beta_0 + \beta_1 x_i + u_i)(x_i - \bar{x})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \\
&= \frac{\beta_0 \sum_{i=1}^n (x_i - \bar{x}) + \beta_1 \sum_{i=1}^n x_i(x_i - \bar{x}) + \sum_{i=1}^n u_i(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}
\end{aligned}$$

Benytter RR3 og 4

$$\begin{aligned}
&\beta_0 0 + \beta_1 \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} + \frac{\sum_{i=1}^n u_i(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \\
&= \beta_1 + \frac{\frac{1}{n} \sum_{i=1}^n u_i(x_i - \bar{x})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}
\end{aligned}$$

Trin 2 (udregn i $\hat{\beta}_1$)

$$p \lim \hat{\beta}_1 = p \lim \left(\beta_1 + \frac{\frac{1}{n} \sum_{i=1}^n u_i(x_i - \bar{x})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \right)$$

Benytter RR1

$$\beta_1 + \frac{p \lim \left(\frac{1}{n} \sum_{i=1}^n u_i(x_i - \bar{x}) \right)}{p \lim \left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right)}$$

bENYTTER rr2 OG mlr.2

$$\beta_1 + \frac{Cov(u, x)}{Var(x)}$$

OLS er inkonsistent

Detter gælder hvis $E(u) \neq 0$ eller $Cov(u, x) \neq 0$

Inkonsistensen eller asymptotisk bias er givet ved

$$p \lim(\hat{\beta}_1) - \beta_1 = \frac{cov(u, x)}{Var(x)}$$

Trin 3 (viser at $p \lim \hat{\beta}_1 = \beta_1$
bruger MLR.4

$$\begin{aligned}
p \lim(\hat{\beta}_1) &= \beta_1 + \frac{cov(u, x)}{Var(x)} \\
p \lim(\hat{\beta}_1) &= \beta_1 + \frac{0}{Var(x)} = \beta_1
\end{aligned}$$

OLS er asymptotisk normalfordelt

Når MLR.1-5 er opfyldt gælder

$$\sqrt{n}(\hat{\beta}_j - \beta_j) \sim^a N(0, \sigma^2/a^2)$$

Den asymptotiske varians for OLS

$$Var(\hat{\beta}_j) = \frac{\hat{\sigma}^2}{SST_j(1 - R_j^2)}$$

LM -test (Lagrange Multiplier)

Test for multiple lineære restriktioner

F-test

Lagrange Multiplier test.

Procedueren er:

Estimer den restikterede model

Udregn residualerende fra den restrikterede model

Hjælpemodel med residualerne (oftest anvendes R^2 fra hjælpemodellen).

Kapitel 6

Adjusted R^2

$$R^2 = 1 - (SSR/n)/(SST/n)$$

Population R-bar-squared:

$$\rho^2 = 1 - \sigma_u^2/\sigma_y^2$$

$$\bar{R}^2 = 1 - (SSR/n - k - 1)/(SST/n - 1) = 1 - \hat{\sigma}^2/(SST/(n - 1))$$

$$\bar{R}^2 = 1 - (1 - R^2(n - 1))/(n - k - 1)$$

Kapitel 7

$$F = \frac{[SSR_p - (SSR_1 - SSR_2)]}{SSR_1 + SSR_2} * \frac{[n - 2(k + 1)]}{k + 1}$$

$$F_{chow} = \frac{\frac{[SSR_p - (SSR_1 + SSR_2 + \dots + SSR_m)]}{(m - 1)(k + 1)}}{\frac{SSR_1 + SSR_2 + \dots + SSR_m}{n - (m(k + 1))}}$$

Kapitel 8

$$Var(\hat{\beta}_1) = \frac{\sum_{i=1}^n (x_i - \bar{x})\sigma_i^2}{SST_x^2}$$

Heterodesktacity-robust t statistic

$$t = \frac{estimate - hypothesized\ value}{standard\ error}$$

F statistik

$$F = \frac{R_{\hat{u}}^2/k}{(1 - R_{\hat{u}}^2)/(n - k - 1)}$$

LM statistik

$$LM = n * R_{\hat{u}}^2$$

The Heteroskedasticity is known up to a multiplicative constant

$$Var(u|x) = \sigma^2 h(x)$$

h(x) er en funktion for de forklarende variable der bestemmet heteskedasticity.

The Heteroskedasticity Function Must Be Estimated: FGLS

$$\hat{h}_i = exp(\hat{g}_i)$$

Prediction intervals with Heteroskedasticity

$$E(y|x) = exp(\beta_0 + x\beta + exp(\delta_0 + x\delta)/2)$$

$$\hat{y}_i = exp(log y_i + \hat{\sigma}^2 \hat{h}_i/2)$$

Linear probability model

$$Var(y|x) = p(x)[1 - p(x)]$$

$$\hat{h}_i = \hat{y}_i(1 - \hat{y}_i)$$

Weighted Least Squares (WLS)

$$\frac{y_i}{\sqrt{h_i}} = \beta_0 \frac{1}{\sqrt{h_i}} + \beta_1 \frac{x_{j1}}{\sqrt{h_i}} + \dots + \frac{u_j}{\sqrt{h_i}}$$

Kapitel 9

$$E(X_3^*|x_1, x_2, x_3) = \delta_0 + \delta_3 x_3$$

Potential outcomes and proxy variables

$$E[v(0)|w, x] = E[v(0)|x] = (x - \eta)\beta_0$$

$$E[v(1)|w, x] = E[v(1)|x] = (x - \eta)\beta_1$$

Measurement Error in Explanatory Variable

$$\text{plim}(\hat{\beta}_1) = \beta_1 + \frac{\text{Cov}(x_1, u - \beta_1 e)}{\text{Var}(x_1)} = \beta_1 \left(\frac{\sigma_{e_1}^{2*}}{\sigma_{x_1}^2 + \sigma_{e_1}^2} \right)$$

Kapitel 15

Bevis for IV estimationen er konsistent

IV estimation i en simple regressionsmodel:

Egenskaber ved IV estimatoren:

- IV estimatoren er konsistent.
- IV estimatoren er asymptotisk normalfordelt.
- IV estimatoren vil have påne asymptotiske egenskaber.
 - IV estimatoren er ikke middelret (ikke god med små datasæt).
 - IV estimatoren har ofte større varians.
 - IV estimatoren kan være biased, hvis vi har svage instrumenter dvs.
 $\text{Cov}(x, z) \approx 0$.

IV estimatoren er konsistent, hvis MLR.1-3 er opfyldt og $\text{Cov}(u, z) = 0$, $\text{Cov}(x, z) \neq 0$: $\text{plim } \hat{\beta}_1^{IV} = \beta_1$
Ingredienser til bevis:

Bevis for IV estimationen er konsistent:

IV estimatoren er konsistent, hvis MLR.1-MLR.3 er opfyldt, og

$$\text{Cov}(u, z) = 0, \text{Cov}(x, z) \neq 0 : p\lim \hat{\beta}_1^{IV} = \beta_1$$

Ingredienser til bevis

- IV estimatoren: $\hat{\beta}_1^{IV} = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})(z_i - \bar{z}) / \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(z_i - \bar{z})$.

• Antagelser:

- Model: MLR.1: $y = \beta_0 + \beta_1 x + u$.
- MLR.2: uafhængige og identiske fordele observationer.
- Gyldigt instrument: $\text{Cov}(u, z) = 0, \text{Cov}(x, z) \neq 0$.

• Regneregler:

- $\sum_{i=1}^n (w_i - \bar{w})(z_i - \bar{z}) = \sum_{i=1}^n (w_i)(z_i - \bar{z})$.
- Hvis $p\lim a_n = a$ og $p\lim b_n = b$ så er $p\lim(\frac{a_n}{b_n}) = \frac{a}{b}$ hvis $b \neq 0$
- $p\lim \left[\frac{1}{n} \sum_{i=1}^n (w_i - \bar{w})(v_i - \bar{v}) \right] = \text{Cov}(w, v)$, hvis vi har uafhængige observationer.

Trin 1 bruger regneregel 1:

$$\hat{\beta}_1^{IV} = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})(z_i - \bar{z})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(z_i - \bar{z})} = \frac{\frac{1}{n} \sum_{i=1}^n (y_i)(z_i - \bar{z})}{\frac{1}{n} \sum_{i=1}^n (x_i)(z_i - \bar{z})}$$

Benytter MLR.1

$$\begin{aligned} & \frac{\frac{1}{n} \sum_{i=1}^n (\beta_0 + \beta_1 x_i + u_i)(z_i - \bar{z})}{\frac{1}{n} \sum_{i=1}^n (x_i)(z_i - \bar{z})} \\ &= \beta_0 \frac{\frac{1}{n} \sum_{i=1}^n (z_i - \bar{z})}{\frac{1}{n} \sum_{i=1}^n (x_i)(z_i - \bar{z})} + \beta_1 \frac{\frac{1}{n} \sum_{i=1}^n (x_i)(z_i - \bar{z})}{\frac{1}{n} \sum_{i=1}^n (x_i)(z_i - \bar{z})} + \frac{\frac{1}{n} \sum_{i=1}^n (u_i)(z_i - \bar{z})}{\frac{1}{n} \sum_{i=1}^n (x_i)(z_i - \bar{z})} \\ & \hat{\beta}_1^{IV} = \beta_0 * 0 + \beta_1 * 1 + \frac{\frac{1}{n} \sum_{i=1}^n (u_i)(z_i - \bar{z})}{\frac{1}{n} \sum_{i=1}^n (x_i)(z_i - \bar{z})} \end{aligned}$$

$$= \beta_1 + \frac{\frac{1}{n} \sum_{i=1}^n (u_i)(z_i - \bar{z})}{\frac{1}{n} \sum_{i=1}^n (x_i)(z_i - \bar{z})}$$

Trin 2 find grænsen i sandsynlighed

$$p \lim \hat{\beta}_1^{IV} = \beta_1 + p \lim \left(\frac{\frac{1}{n} \sum_{i=1}^n (u_i)(z_i - \bar{z})}{\frac{1}{n} \sum_{i=1}^n (x_i)(z_i - \bar{z})} \right)$$

Bruge regneregel 2

$$= \beta_1 + \frac{p \lim \left(\frac{1}{n} \sum_{i=1}^n (u_i)(z_i - \bar{z}) \right)}{p \lim \left(\frac{1}{n} \sum_{i=1}^n (x_i)(z_i - \bar{z}) \right)}$$

Bruge regneregel 3 + MLR.2

$$= \beta_1 + \frac{cov(u, z)}{cov(x, z)}$$

Antagelser om z

$$= \beta_1 + \frac{0}{cov(x, z)} = \beta_1$$

Instrumental variables (IV) estimator of β_1

$$\hat{\beta}_1^{IV} = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})(z_i - \bar{z})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(z_i - \bar{z})}$$

Structural equation

$$y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + u$$

Bevise af IV Estmiator

IV antagelser:

IV estimatoren er defineret og konsistent, hvis følgende antagelser gælder:

- Instrumenterne er ukorreleret med fejlleddet:

$$p \lim \left(\frac{1}{n} \sum_{i=1}^n z_{ij} u_i \right) = 0 \Leftrightarrow p \lim \frac{1}{n} Z' u = \mathbf{0}$$

- Instrumenterne er korreleret med de endogene variable:

$$p \lim \frac{1}{n} Z' X = \Sigma_{ZX} \text{ har fuld rang}$$

- Ingen perfekt multikollinearitet mellem instrumenterne:

$$p \lim \frac{1}{n} Z' Z = \Sigma_{ZZ} \text{ har fuld rang}$$

Udledning af IV estimator (eksakt identificeret):

- Eksakt identifikation: / instrumenter.
- Vi tager udgangspunkt i den teoretiske betingelse:

$$\begin{aligned} p \lim \frac{1}{n} Z' u &= \mathbf{0} \\ p \lim \left(\frac{1}{n} Z' (y - X\beta) \right) &= \mathbf{0} \\ p \lim \left(\frac{1}{n} (Z'y - Z'X\beta) \right) &= \mathbf{0} \end{aligned}$$

- Hvis vi erstatter de teoretiske momenter med datamomenter, får vi:

$$\begin{aligned} Z'y - Z'X\hat{\beta}^{IV} &= \mathbf{0} \\ Z'y &= Z'X\hat{\beta}^{IV} \\ \hat{\beta}^{IV} &= (Z'X)^{-1}(Z'y) \end{aligned}$$

- IV estimatoren er konsistent.

Bevis for IV er konstisten

IV er konsistent:

Bevis at IV estimatoren er konsistent:

Benyt (nogle af) følgende dele til at vise at IV estimatoren er konsistent.

Sæt delene sammen i rigtig rækkefølge:

M $E(u|X)$

O $p\lim$

S $\hat{\beta}^{IV} = (Z'X)^{-1}(Z'y)$

G $p\lim \frac{1}{n}Z'u = \mathbf{0}$

U $Var(u|x) = \sigma^2$

R $y = X\beta + u$

T Σ_{ZX} har fuld rang

N $p\lim(M_n W_n) = MW$

IV er konsistent:

Bevis for at IV estimatoren er konsistent:

Trin 1:

$$\begin{aligned}\hat{\beta}^{IV} &= (Z'X)^{-1}(Z'y) \\ &= (Z'X)^{-1}(Z'(X\beta + u)) \\ &= (Z'X)^{-1}Z'X\beta + (Z'X)^{-1}(Z'u) \\ &= \beta + (Z'X)^{-1}(Z'u)\end{aligned}\tag{S-}$$

Trin 2

$$\begin{aligned}p\lim(\hat{\beta}^{IV}) &= \beta + p\lim((Z'X)^{-1}(Z'u)) \\ &= \beta + p\lim\left(\frac{1}{n}(Z'X)^{-1}\right)p\lim\left(\frac{1}{n}(Z'u)\right) \\ &= \beta + \Sigma_{ZX} \cdot \mathbf{0} \\ &= \beta\end{aligned}$$

Bevis for at 2SLS er konsistent:

Konsistens:

2SLS er konsistent, når IV antagelserne holder.

Ingredienser til bevis:

Antagelser:

- ① $p \lim \frac{1}{n} Z' u = \mathbf{0}$
- ② $p \lim \frac{1}{n} Z' X = \Sigma_{ZX}$ har fuld rang.
- ③ $p \lim \frac{1}{n} Z' Z = \Sigma_{ZZ}$ har fuld rang.

2SLS estimatoren:

$$\hat{\beta}^{2SLS} = (X' P_Z X)^{-1} (X' P_Z y)$$

Regneregel:

- ① $p \lim(A_n B_n) = AB$ når $p \lim(A_n) = A$ og $p \lim(B_n) = B$
- ② $p \lim(A_n^{-1}) = A^{-1}$ når $p \lim(A_n) = A$

Konsistens-Bevis:

Trin 2 (Grænse i sandsynlighed):

Først ser vi på leddene

$$\begin{aligned} p \lim\left(\frac{1}{n}(X' P_Z X)\right) &= p \lim\left(\frac{1}{n}(X' Z(Z' Z)^{-1} Z' X)\right) \quad (\text{Regneregel 1 og 2}) \\ &= p \lim\left(\frac{1}{n}(X' Z)\right) \left[p \lim\left(\frac{1}{n}(Z' Z)\right)\right]^{-1} p \lim\left(\frac{1}{n} Z' X\right) \\ &\quad (\text{Antagelse 2 og 3}) \\ &= \Sigma_{XZ} \Sigma_{ZZ}^{-1} \Sigma'_{XZ} \end{aligned}$$

$$\begin{aligned} p \lim\left(\frac{1}{n} X' P_Z u\right) &= p \lim\left(\frac{1}{n} X' Z(Z' Z)^{-1} Z' u\right) \quad (\text{Regneregel 1 og 2}) \\ &= p \lim\left(\frac{1}{n} X' Z\right) \left[p \lim\left(\frac{1}{n} Z' Z\right)\right]^{-1} p \lim\left(\frac{1}{n} Z' u\right) \\ &\quad (\text{Antagelse 1, 2 og 3}) \\ &= \Sigma_{XZ} \Sigma_{ZZ}^{-1} \mathbf{0} = \mathbf{0} \end{aligned}$$

Konsistens-Bevis:

Så følger at

$$p \lim(\hat{\beta}^{2SLS}) = \beta + (\Sigma_{XZ}\Sigma_{ZZ}^{-1}\Sigma'_{XZ})^{-1}\mathbf{0} = \beta$$

W.10-11

Definition for svag stationaritet

En tidsrække er svagt stationær hvis:

$$E(y_t) = \mu$$

$$v(y_t) = E((y_t - \mu)^2) = \gamma_0$$

$$Cov(y_t, y_{t-h}) = E(y_t - \mu)(y_{t-h} - \mu) = \gamma_h$$

Man kan gøre en tidsrække stationær ved:

$$\log(prod_t) = \delta + \gamma t + \kappa_t$$

Fjerne trenden ved:

$$\hat{\kappa}_t = \log(prod_t) - \hat{\delta} - \hat{\gamma}t$$

Man kan fjerne niveauskift ved at lave en dummy variabel der er 1.

$$pandora_t = \delta + \gamma 1_{\{t < T_0\}} + \kappa_t$$

Kointegration

Er en lineær kombination af ikke-stationære tidsrækker, som er stationære

Den lineære regressionsmodel:

Antagelse 1: MLR.1

Antagelse 2: Prædetermineret:

Fejlledet i modellen skal opfylde

$$E(\epsilon_t | x_t) = 0$$

Denne antagelse erstatter antagelse MLR.4

Autoregressive distributed lag model:

Dynamisk model med laggede variable af den afhængige variabel

$$y_t = \theta y_{t-1} + \epsilon_t$$

Dette kaldes en univariat model, fordi den afhængige variabel kun afhænger af sig selv.

Udledning af OLS estimatoren:

$$E(X_t \epsilon_t) = E(X_t(y_t - X'_t \beta)) = 0$$

$$E(X_t y_t) - E(X_t X'_t) \beta = 0$$

Hvis $E(X_t X'_t)$ har fuld rang så gælder at:

$$\beta = [E(X_t X'_t)]^{-1} E(X_t y_t)$$

Antagelse 3 ingen perfekt multikollinearitet:

Samme som MLR.3

Estimatoren bliver:

$$\hat{\beta} = [\frac{1}{T} \sum_{t=1}^T X_t X'_t]^{-1} [\frac{1}{T} \sum_{t=1}^T X_t y_t]$$

Antagelse 4:

Stationaritet og svag afhængighed.

OLS estimatoren er konsistent under antagelsen 1-4 er opfyldt.

Bevis for OLS estimatoren er konsisten

OLS estimatoren:

- Sætning 1: OLS estimatoren er konsistent:
Under antagelse af at **antagelserne 1-4 er opfyldt**, er **OLS estimatoren konsistent**:

$$p \lim_{T \rightarrow \infty} \hat{\beta} = \beta$$

- Antagelser:

- Antagelse 1: $y_t = x_t\beta + \varepsilon_t$.
- Antagelse 2: $E(\varepsilon_t | x_t) = 0 \Rightarrow E(x_t \varepsilon_t) = 0$.
- Antagelse 3: Ingen perfekt multikollinearitet.
- Antagelse 4: Stationaritet og svag afhængighed
 $\Rightarrow p \lim \left[\frac{1}{T} \sum_{t=1}^T x_t^2 \right] = E(x_t^2)$ og $p \lim \left[\frac{1}{T} \sum_{t=1}^T x_t \varepsilon_t \right] = E(x_t \varepsilon_t)$.

OLS estimatoren er konsistent:

Bevis::

Trin 1: OLS estimatoren:

$$\begin{aligned}\hat{\beta} &= \frac{\frac{1}{T} \sum x_t y_t}{\frac{1}{T} \sum_{t=1}^T x_t^2} && \text{(Antagelse 1)} \\ &= \frac{\frac{1}{T} \sum x_t (x_t \beta + \varepsilon_t)}{\frac{1}{T} \sum_{t=1}^T x_t^2} = \frac{\frac{1}{T} \sum x_t^2 \beta + \frac{1}{T} \sum x_t \varepsilon_t}{\frac{1}{T} \sum_{t=1}^T x_t^2} \\ &= \beta + \frac{\frac{1}{T} \sum x_t \varepsilon_t}{\frac{1}{T} \sum_{t=1}^T x_t^2}\end{aligned}$$

OLS estimatorene er konsistent

- Trin 2:

$$\begin{aligned} p\lim \hat{\beta} &= \beta + p\lim \left(\frac{\frac{1}{T} \sum x_t \epsilon_t}{\frac{1}{T} \sum_{t=1}^T x_t^2} \right) && (\text{Regneregel 1}) \\ &= \beta + \frac{p\lim(\frac{1}{T} \sum x_t \epsilon_t)}{p\lim(\frac{1}{T} \sum_{t=1}^T x_t^2)} && (\text{Antagelse 4}) \\ &= \beta + \frac{E(x_t \epsilon_t)}{E(x_t^2)} && (\text{Antagelse 2}) \\ &= \beta + \frac{0}{E(x_t^2)} = \beta \end{aligned}$$

OLS er middel under antagelse 5

Antagelse 5: strengt eksogenitet.

$$E(\epsilon | x_1 \dots x_t) = 0$$

Bevis for middelrethed

Middelrethed:

- Sætning 2: **OLS er middelret.**
- Hvis antagelse 1, 3, 4 og 5 er opfyldt, er OLS middelret

$$E(\hat{\beta}) = \beta.$$

- Ingredienser til bevis (simpel lineær regressionsmodel):

- OLS estimatoren:

$$\hat{\beta} = \frac{\frac{1}{T} \sum x_t y_t}{\frac{1}{T} \sum_{t=1}^T x_t^2}$$

- Antagelser:

- Antagelse 1: $y_t = x_t \beta + \varepsilon_t$.
- Antagelse 3: Ingen perfekt multikollinearitet.
- Antagelse 4: Stationaritet og svag afhængighed.
- Antagelse 5: $E(\varepsilon_t | x_1, x_2, \dots, x_T) = 0$.

Bevis for middelrethed:

Trin 1: OLS estimatoren:

$$\begin{aligned}\hat{\beta} &= \frac{\frac{1}{T} \sum x_t y_t}{\frac{1}{T} \sum_{t=1}^T x_t^2} && (\text{Antagelse 1}) \\ &= \frac{\frac{1}{T} \sum x_t (x_t \beta + \varepsilon_t)}{\frac{1}{T} \sum_{t=1}^T x_t^2} = \frac{\frac{1}{T} \sum x_t^2 \beta + \frac{1}{T} \sum x_t \varepsilon_t}{\frac{1}{T} \sum_{t=1}^T x_t^2} \\ &= \beta + \frac{\frac{1}{T} \sum x_t \varepsilon_t}{\frac{1}{T} \sum_{t=1}^T x_t^2}\end{aligned}$$

Bevis for middelrethed:

Trin 2:

$$\begin{aligned} E(\hat{\beta}|x_1, x_2, \dots, x_T) &= \beta + E\left(\frac{\frac{1}{T} \sum x_t \varepsilon_t}{\frac{1}{T} \sum_{t=1}^T x_t^2} | x_1, x_2, \dots, x_T\right) \\ &= \beta + \frac{E\left(\frac{1}{T} \sum x_t \varepsilon_t | x_1, x_2, \dots, x_T\right)}{\frac{1}{T} \sum_{t=1}^T x_t^2} \\ &= \beta + \frac{\frac{1}{T} \sum x_t E(\varepsilon_t | x_1, x_2, \dots, x_T)}{\frac{1}{T} \sum_{t=1}^T x_t^2} \text{ (Antagelse 5)} \\ &= \beta + \frac{\frac{1}{T} \sum x_t 0}{E(x_t^2)} = \beta \end{aligned}$$

Så følger at

$$E(\hat{\beta}) = E(E(\hat{\beta}|x_1, x_2, \dots, x_T)) = \beta$$

Gentagende tværsnitsdata og paneldata

w.14.1-14.2