

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

# ENDOGENEITY-MEASUREMENT ERROR

سمینار درس مدل های خطی ۱

ارائه دهنده: فرزانه بیگی

دی ۹۷

## روش حداقل مربعات معمولی

در آمار حداقل مربعات معمولی روشی است برای برآورد پارامترهای مجهول در مدل رگرسیون خطی از طریق کمینه کردن اختلاف بین مقدار واقعی و مقدار مشاهده شده است.

$$y_i = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki} + u_i$$

مدل زیر را در نظر بگیرید:

فرضیاتی که برای مدل رگرسیون خطی وجود دارند به قرار زیر است .

$$E(u_i) = 0$$

**فرض ۱.** میانگین  $u_i$  ها صفر است .

**فرض ۲.** عدم وجود خود همبستگی بین  $u$  ها

$$\text{cov}(u_i, u_j) = E(u_i u_j) = 0$$

$$\text{var}(u_i) = \delta^2$$

فرض ۳. یکسانی واریانس

$$\text{cov}(u_i, x_i) = E(u_i x_i) = 0$$

$u_i, x_i$

فرض ۴. کوواریانس صفر بین

برای کاربرد روش حداقل مربعات معمولی در مدل رگرسیون خطی هیچ فرضی در مورد توزیع احتمالی جزء خطا ارائه نکردیم. تنها فرضی که در مورد  $u_i$  مد نظر قرار گرفت عبارت بودند از اینکه اجزاء مذکور دارای امید صفر و عدم همبستگی و واریانس ثابت است.

درون زایی در مدل رگرسیون چند گانه رخ می دهد. اگر حداقل یکی از متغیرهای مستقل مدل رگرسیونی درون زا باشند.

اگر متغیر درون زا در مدل وجود داشته باشد مشکل درون زایی رخ میدهد  
**فرض ۴** نقض می شود .

$$E(u_i x_i) \neq 0$$

یعنی این جمله با خطا وابستگی خواهد داشت.

**متغیر برون ز ا (مستقل):** متغیری است که هیچگونه تاثیری از سایر متغیرهای موجود در مدل دریافت نمی کند.

**متغیر درونزا (وابسته):** متغیری است که از جانب سایر متغیرهای موجود در مدل تاثیر می پذیرد.

تا به حال تمام متغیرهای مدل های رگرسیونی برون ز ا بودند.

$$\text{cov}(x_i, e_i) \neq 0$$



اگر  $x$  درون زا باشد

$$\text{cov}(x_i, e_i) = 0$$



اگر  $x$  برون زا باشد



عوامل درون زایی (باعث می شود  $X$  با  $e_i$  همبسته شود)

1. OMITTED VARIABLES

2. MEASUREMENT ERROR

3. SIMULTANEITY IN SIMULTANEOUS EQUATIONS MODELS

حضور متغیرهای درون زا در مدل‌های آماری ناسازگاری و آریبی برآورد  
گرهای معمول پارامترهای مدل را به دنبال دارد. روش‌های متعددی در این  
حالت ارائه شد که مشکل ناسازگاری و آریبی را تنها در حالت بزرگ نمونه  
ای حل کرده اند. یکی از این روش‌ها مبتنی بر استفاده متغیرهای ابزار و  
روش حداقل مربعات دو مرحله ای است که باعث حذف درون زایی  
متغیر مورد نظر است. [1]

وقتی متغیر درون را در مدل داشته باشیم در این صورت برآوردهای *OLS* اریب خواهند شد مثلاً

$$y = \beta_0 + \beta_1 x + \beta_2 T + \tau$$

$$X = \gamma_0 + \gamma_1 T + \varepsilon$$

پس با خطا در رابطه است پس با خطا همبستگی دارد پس

$$T = \frac{Y - \beta_0 - \beta_1 X - \varepsilon}{\beta_2}$$

$$X = \gamma_0 + \gamma_1 \frac{Y - \beta_0 - \beta_1 X - \tau}{\beta_2} + \varepsilon$$

## ارایی و سازگاری OLS

$$y_i = b_0 + b_1 x_i + e_i$$

$$\hat{b}_1 = \frac{S_{xy}}{S_{xx}} = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^N (x_i - \bar{x})^2} = \frac{\text{cov}(x_i, y_i)}{\text{var}(x_i)}$$

$$= \frac{\text{cov}(x_i, b_0 + b_1 x_i + e_i)}{\text{var}(x_i)} \Rightarrow \hat{b}_1 = b_1 + \frac{\text{cov}(x_i, e_i)}{\text{var}(x_i)}$$

$$\frac{\text{cov}(x_i, [b_0 + b_1 x_i + e_i])}{\text{var}(x_i)} = \frac{\text{cov}(x_i, b_0) + \text{cov}(x_i, b_1 x_i) + \text{cov}(x_i, e_i)}{\text{var}(x_i)}$$

$$\frac{0 + b_1 \text{var}(x_i) + \text{cov}(x_i, e_i)}{\text{var}(x_i)} = \frac{0}{\text{var}(x_i)} + \frac{b_1 \text{var}(x_i)}{\text{var}(x_i)} + \frac{\text{cov}(x_i, e_i)}{\text{var}(x_i)}$$

$$= b_1 + \frac{\text{cov}(x_i, e_i)}{\text{var}(x_i)}$$

$$\hat{b}_1 = b_1 + \frac{\text{cov}(x_i, e_i)}{\text{var}(x_i)}$$

به دنبال این معادله

است که برای اینکه *OLS* سازگار باشد باید

$$\text{cov}(x_i, e_i) = 0$$

برقرار باشد اما

$$\text{cov}(x_i, e_i) \neq 0$$



$$\hat{b}_1 = b_1 + \frac{\text{cov}(x_i, e_i)}{\text{var}(x_i)}$$

# 1. MEASUREMENT ERROR AN IN INDEPENDENT

مدل رگرسیون ساده را در نظر بگیرید

$$y_i = \beta_0 + \beta_1 X_i + u_i$$

$$\hat{X}_i = X_i + e_i$$

$x_i$  باخطاها اندازه گیری می شود. در این صورت به جای  $X_i$

$$E(X_i e_i) = 0$$

را داریم. فرض می کنیم  $x_i$  و  $e_i$  ناهمبسته است. یعنی

بنابراین معادلات رگرسیون به صورت زیر است.

$$Y_i = \beta_0 + \beta_1 \hat{X}_i + u_i - \beta_1 e_i$$



در این صورت درون زایی رخ می دهد

$$= \beta_0 + \beta_1 X_i + v_i$$

درون زا بودن متغیرها باعث اریبی و

$$E(X_i V_i) = E((X_i + e_i)(u_i - \beta_1 e_i))$$

سازگاری برآورد گر حاصل از روش برآورد کمترین توانهای دوم معمولی *OLS* می شود

$$= \beta_1 \text{var}(e_i) \neq 0$$

برآورد گر OLS از  $\beta_1$

$$\beta_1 = \beta_1 + \frac{\sum_{i=1}^N (\hat{X}_i - \bar{X})(u_i - \beta_1 e_i)}{\sum_{i=1}^N (\hat{X}_i - \bar{X})}$$

$$\xrightarrow{P} \beta_1 - \beta_1 \frac{\text{var}(e)}{\text{var}(X) + \text{var}(e)}$$

$$p \lim(\hat{\beta}_1) = \beta_1 \frac{\text{var}(x)}{\text{var}(X) + \text{var}(e)} \leq \beta_1$$

بنابراین برآورد گر *OLS* ناسازگار است

## 1. MEASUREMENT ERROR IN DEPENDENT VARIABLE

$$y = b_0 + b_1x + u$$

*true*

فرض کنید که

$$y = y^{true} + e$$

*observe*

یعنی متغیر وابسته با خطا اندازه گیری می شود

$$y - e = b_0 + b_1x + u$$

$$y = b_0 + b_1x + u + e$$

$$y = b_0 + b_1x + v$$

$$st \quad v = u + e$$

$$E(e) = E(u) = 0$$

با جایگذاری معادله (۲) در (۱) داریم

$$\text{cov}(\mathbf{x}, \mathbf{u}) = \text{cov}(\mathbf{x}, \mathbf{e}) = 0$$

$$E(y_i e_i) \neq 0$$

بنابراین تخمین *OLS* نادرست هستند و واریانس

$$\text{var}(\hat{\beta}) = \frac{\sigma_u^2}{N \text{var}(x)} \quad \text{true}$$

$$\text{var}(\hat{\beta}) = \frac{\sigma_u^2 + \sigma_e^2}{N \text{var}(x)} \quad \text{estimate}$$

## 2.simultaity

یعنی علاوه بر اینکه متغیر پاسخ درون را است حداقل یکی از متغیر های مستقل مدل هم درون را است . برای حل این مشکل باید متغیر درون را با خطا همبستگی نداشته باشد پس از روش متغیر ابزاری برای برآورد پارامتر ها استفاده می کنیم.

فرض کنید  $x, y$  دو متغیر با هم تعریف می شوند که هر کدام از یکدیگر تاثیر

می گیرند. فرض کنید که دو معادله ساختاری وجود دارد.

$$y_i = \beta_1 X_i + \gamma_1 Z_i + u_i$$

$$Z_i = \beta_2 X_i + \gamma_2 y_i + v_i$$

$$E(Z_i u_i) \neq 0$$

برآورد هر دو معادله منجر به درون زایی می شود. در اولین معادله ساختاری

را داریم . برای به دست آوردن  $Z_i$  فرض می کنیم که

$$1 - \gamma_1 \gamma_2 \neq 0$$



$$z_i = \frac{\beta_2 + \gamma_2 \beta_1}{1 - \gamma_1 \gamma_2} X_i + \frac{1}{1 - \gamma_1 \gamma_2} v_i + \frac{\gamma_2}{1 - \gamma_1 \gamma_2} u_i$$

فرض کنید  $X_i, v_i$  با  $u_i$  ناهمبسته هستند بنابراین داریم:

$$E(Z_i u_i) = \frac{\gamma_2}{1 - \gamma_1 \gamma_2} E(u_i u_i) \neq 0$$

### 3. OMITTED VARIABLE

$$Y_t = b_1 x_t + b_2 w_t + e_t$$

*True*

فرض کنیم داده  $x_2$  از مدل حذف شده در این صورت مدل زیر را تخمین بزنید

$$Y_t = b_1 x_t + v_t$$

*we estimate*

که  $v_t = b_1 w_t + v_t$  است. در این صورت

$$\text{cov}(x, w) \neq 0$$

اگر

$$\text{cov}(x, v) \neq 0$$

بنابراین

راهکار برای حل این مشکل استفاده از متغیر ابزاری و روش حداقل مربعات دو مرحله ای است. (می توانند برآوردگرهای سازگار تولید کنند)

متغیر ابزاری برای تخمین اثر تصادفی تعدادی از متغیرهای  $x$  روی متغیر دیگری مثل  $y$  یک ابزار سومی است مانند  $z$  است

*instrument* relevance :  $\text{cov}(Z_i, X_i) \neq 0$

دو شرط برای متغیر ابزاری

*instrument* exogeneity :  $\text{cov}(z_i, e_i) = 0$

برای مدل زیر

$$y_i = \beta_0 + \beta_1 X_i + u_i$$

متغیر ابزاری  $z_i$  را در نظر بگیرید. به طوری که

$$\text{cov}(z, x) \neq 0$$

$$\text{cov}(z, u) = 0$$

برآوردگر iv

$$\begin{aligned} 0 &= \text{cov}(z, u) = \text{cov}(z, y - \beta_0 - \beta_1 X_i) \\ &= \text{cov}(z, y) - \beta_1 \text{cov}(z, x) \end{aligned}$$

و بنابراین داریم

$$\hat{\beta}_{1,IV} = \frac{\text{cov}(z, y)}{\text{cov}(z, x)}$$

$$\hat{\beta}_{1,IV} = \beta_1 + \frac{\sum_{i=1}^N (Z_i - \bar{z}) u_i}{\sum_{i=1}^N (Z_i - \bar{z})(x_i - \bar{x})}$$

بنابراین برآوردگر IV سازگار است.

$$\frac{\sum_{i=1}^N (z_i - \bar{z}) u_i}{N} \xrightarrow{P} 0 \text{ as } N \rightarrow \infty$$
$$P \lim(\hat{\beta}_{1,iv}) = \beta_1$$

واریانس جانبی برآورد کننده IV به صورت زیر است.

$$\text{var}(\hat{\beta}_{1,iv}) \approx \sigma_u^2 \frac{\text{var}(z)}{N \cdot \text{cov}(z, x)^2}$$



با مقایسه با  $\beta_1^{ols} = \frac{\text{cov}(x, y)}{\text{var}(x)}$  برآورد کننده *iv* سازگار است در

حالی که برآورد کننده *OLS* ناسازگار است.

روش دیگری برای برآورد پارامترهای مدل های درون زا روش کمترین توان

های دوم دو مرحله ای است که دقت بهتری نسبت به روش کمترین توان های

دوم معمولی دارد اما برآوردگرهای حاصل از این روش نیز تنها در حالت

بزرگ نمونه ای ناریب و سازگار است

یکی از روش‌هایی که می‌توانیم به کار ببریم روش حداقل مربعات دو مرحله ای  $2sls$  است. در مرحله اول هر یک از متغیرهای درون‌زا در معادله هدف روی همه متغیرهای برون‌زا در مدل رگرسیون می‌شود و مقدارپیش‌بینی شده از این رگرسیون به دست می‌آید. بخشی از  $x$  که با  $e$  ناهمبسته است را

جدا می‌کنیم

$$x_i = b_0 + b_1 z_i + v_i$$

مرحله ۱. رگرسیون کردن  $x$  روی  $z$

$$\tilde{x} = p_z X$$

و سپس ارزش پیش بینی شده را ذخیره می کنیم.

در مرحله دوم رگرسیون هدف به صورت معمول تخمین زده

می شود و هر یک از متغیرهای برون را با ارزش پیش بینی شده از اولین

مرحله مدل جایگزین می شود



روش های آزمون

ENDOGENEITY

# Endogeneity

## روش های آزمون

	oLs	iv
X not endogenous	Consistent&Efficient	<b>Consistent &amp; inefficient</b>
X endogenous	Inconsistent	<b>consistent</b>

## HAUSMAN TEST آزمون

$$H_0 : \text{cov}(x, u) = 0$$

$\beta_{IV}$  and  $\beta_{ols}$  are similar

$$H_1 : \text{cov}(x, u) \neq 0$$

$\beta_{IV}$  and  $\beta_{ols}$  are different

## آزمون STATISTIC

$$H = (\hat{\beta}^{ols} - \hat{\beta}^{Iv})' (v(\hat{\beta}^{ols} - \hat{\beta}^{Iv}))^{-1} (\hat{\beta}^{ols} - \hat{\beta}^{Iv}) \sim \chi_k^2$$

K که تعداد متغیرهای رگرسیونی است.



## منابع:

- 1.[BLACK,BERGER,ANDSCOTT(1998)].BOUNDINGPARAMETERESTIMATESWITHNONCLASSICALMEASUREMENTERROR,„JOURNALOFTHEAMERICANSTATISTICALASSOCIATION95,739-748.
- 2.[HYSLOPANDIMBENS(2001)].BIASFROMCLASSICALANDOTHERFORMSOFMEASUREMENTERROR,„JOURNALOFBUSINESSANDECONOMICSTATISTICS19,475-481
- 3.[AIGNER(1973)].REGRESSIONWITHABINARYINDEPENDENTVARIABLESUBJECTTOERRORSOF OBSERVATION,„JOURNALOFECONOMETRICS1,49-60

با تشکر از توجه شما