

# 系数的解释及控制变量

司继春

2025年11月



# 核心解释变量与控制变量

- 外生性通常是一个非常难以成立的假设
- 而在微观实证中，通常我们仅仅关心一个核心解释变量对于被解释变量的影响，此时回归方程可以写为：

$$y = \gamma \cdot w + \tilde{x}'\tilde{\beta} + u$$

其中 $w$ 为我们关心的核心解释变量，而 $\tilde{x}$ 为其他控制变量（control variables），记 $x = [w, \tilde{x}]'$ 。

- 如果只关注 $\gamma$ 的识别和估计，我们可以放弃外生性假设这个比较强的假设，转而使用稍微弱一点的假设

# 条件外生性

## 条件外生性

在线性回归模型：

$$y = \gamma \cdot w + \tilde{x}'\tilde{\beta} + u$$

中，假设在给定 $\tilde{x}$ 的条件下，误差项 $u$ 与核心解释变量 $w$ 均值独立，即：

$$\mathbb{E}(u|w, \tilde{x}) = \mathbb{E}(u|\tilde{x})$$



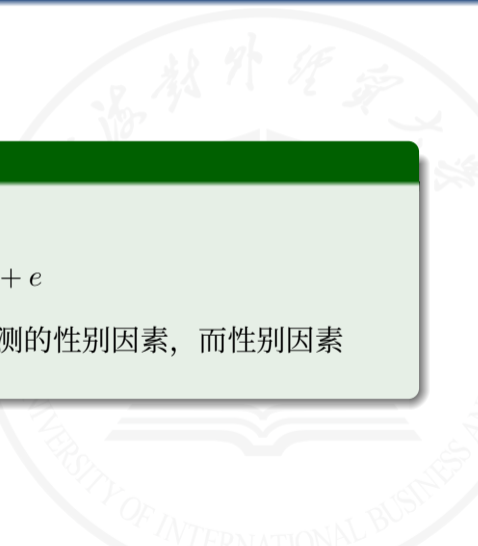
# 条件外生性

## 锻炼身体与寿命

- 在辛普森悖论的例子中，回归方程式

$$y = \beta_0 + \beta \cdot \text{exer} + e$$

中的 $\text{exer}$ 和 $e$ 之间相关的，因为 $u$ 中含有不可观测的性别因素，而性别因素与 $\text{exer}$ 是相关的。



# 条件外生性

## 锻炼身体与寿命

- 然而，如果我们把性别sex作为控制变量：

$$y = \beta_0 + \beta \cdot \text{exer} + \beta_1 \cdot \text{sex} + u$$

那么根据数据生成过程， $e$ 为一个纯随机的扰动，意味着给定sex， $\text{exer}$ 与 $u$ 无关，即：

$$\mathbb{E}(u | \text{exer}, \text{sex}) = \mathbb{E}(u | \text{sex})$$

或者说 $\text{exer}$ 对误差项 $u$ 没有预测能力，从而条件外生性成立。

- 在这个问题中，条件外生性可以认为是给定性别相同的条件下， $u$ 与 $\text{exer}$ 无关，即对于男性（女性），锻炼身体的人与不锻炼身体的人平均而言 $u$ 是相同的，那么条件外生性即满足。

# 条件外生性

- 如果记  $u^\perp = u - \mathbb{E}(u|\tilde{x})$ , 即  $u$  中不与  $\tilde{x}$  相关的部分, 那么以上假设意味着:

$$\begin{aligned}\mathbb{E}(u^\perp | w, \tilde{x}) &= \mathbb{E}[u - \mathbb{E}(u|\tilde{x}) | w, \tilde{x}] \\ &= \mathbb{E}(u | w, \tilde{x}) - \mathbb{E}(u|\tilde{x}) \\ &= \mathbb{E}(u|\tilde{x}) - \mathbb{E}(u|\tilde{x}) \\ &= 0\end{aligned}$$

从而我们有:  $\mathbb{E}(w \cdot u^\perp) = 0$ , 即  $w$  与  $u^\perp$  不相关。



# 条件外生性

## 能力的代理变量

- 在例教育回报中，如果我们可以观察到另外一个变量，如初中时某次考试分数 $s$ ，并将其作为控制变量：

$$\ln \text{income} = \gamma \cdot \text{edu} + x' \beta + \delta \cdot s + u$$

其中 $u = \text{ability} + \epsilon$ ，并假设 $\mathbb{E}(\epsilon | \text{edu}, x, s) = 0$ ，即内生性只来自于不可观测的能力。

- 此时 $s$ 被称为ability的代理变量 (proxy variable)
- 如果我们将能力ability对 $s$ 和其他特征做投影，即：

$$\text{ability} = \eta \cdot s + x' \zeta + e$$

其中 $\mathbb{E}(e | s, x) = 0$

# 条件外生性

## 能力的代理变量

• 此时：

$$\begin{aligned}
\mathbb{E}(u|\text{edu}, x, s) &= \mathbb{E}(\text{ability} + \epsilon|\text{edu}, x, s) \\
&= \mathbb{E}(\text{ability}|\text{edu}, x, s) \\
&= \mathbb{E}(\eta \cdot s + x'\zeta + e|\text{edu}, x, s) \\
&= \eta \cdot s + x'\zeta + \mathbb{E}(e|\text{edu}, x, s)
\end{aligned}$$

而注意到

$$\begin{aligned}
\mathbb{E}(u|x, s) &= \mathbb{E}(\text{ability} + \epsilon|x, s) \\
&= \mathbb{E}(\text{ability}|x, s) \\
&= \eta \cdot s + x'\zeta
\end{aligned}$$

# 条件外生性

## 能力的代理变量

- 从而条件独立性成立的条件为： $\mathbb{E}(e|\text{edu}, x, s) = \mathbb{E}(e|s, x) = 0$ 。
- 即：
  - 如果初中考试分数 $s$ 和其他 $x$ 相同的人，其能力的差异不会影响受教育程度，那么条件外生性就是成立的，我们仍然可以得到 $\gamma$ 的识别。
  - 然而，即使 $s$ 相同，能力的差异也许会影响受更高程度教育的可能，此时高考分数相同的人也会因为能力的不同而导致不同的 $\text{edu}$ ，从而 $\mathbb{E}(e|\text{edu}, x, s) \neq 0$ ，那么条件外生性也就不满足了。

# 条件外生性下的估计

- 如果，我们仅仅假设条件外生性假设，不妨记  $x = [w, \tilde{x}]'$ ,  $\beta = [\gamma, \tilde{\beta}]'$
- 两边分别对  $\tilde{x}$  做条件期望，得到：

$$\mathbb{E}(y|\tilde{x}) = \gamma \cdot \mathbb{E}(w|\tilde{x}) + \tilde{x}'\tilde{\beta} + \mathbb{E}(u|\tilde{x})$$

相减，得到：

$$y - \mathbb{E}(y|\tilde{x}) = \gamma \cdot [w - \mathbb{E}(w|\tilde{x})] + [u - \mathbb{E}(u|\tilde{x})]$$

简记为

$$y^\perp = \gamma \cdot w^\perp + u^\perp$$

- 在以上步骤中，我们分别将被解释变量  $y$  和核心解释变量  $w$  中有关  $\tilde{x}$  的部分剔除，从而也被称为“排除”（partialing-out）估计。





# 条件外生性下的估计

## 线性函数假设

### 假设

$$\mathbb{E}(y|\tilde{x}) = \tilde{x}'\delta, \mathbb{E}(w|\tilde{x}) = \tilde{x}'\eta$$

此时，根据线性投影的性质，有

$$\mathbb{L}(y|\tilde{x}) = \mathbb{L}[\mathbb{E}(y|\tilde{x})|\tilde{x}] = \tilde{x}'\delta$$

$$\mathbb{L}(w|\tilde{x}) = \mathbb{L}[\mathbb{E}(w|\tilde{x})|\tilde{x}] = \tilde{x}'\eta$$

可以直接使用线性回归对 $\mathbb{L}(y|\tilde{x})$ ,  $\mathbb{L}(w|\tilde{x})$ 进行估计。

# 条件外生性下的估计

- 结合以上，我们可以使用如下步骤对 $\gamma$ 进行估计：
  - ① 使用 $y$ 对 $\tilde{x}$ 做线性回归，得到残差 $y^\perp$
  - ② 使用 $w$ 对 $\tilde{x}$ 做线性回归，得到残差 $w^\perp$
  - ③ 使用 $y^\perp$ 对 $w^\perp$ 做回归，得到 $\hat{\gamma}$
- 注意以上步骤与分步回归完全一致。因而实际上，我们可以直接使用 $y$ 对 $w$ 和 $\tilde{x}$ 做线性回归：

$$y = \gamma \cdot w + \tilde{x}'\tilde{\beta} + u = x'\beta + u$$

即可。只不过在这里，我们只关注 $\gamma$ 的估计，所以我们使用的假设也更弱了。



# 系数的解释：总论

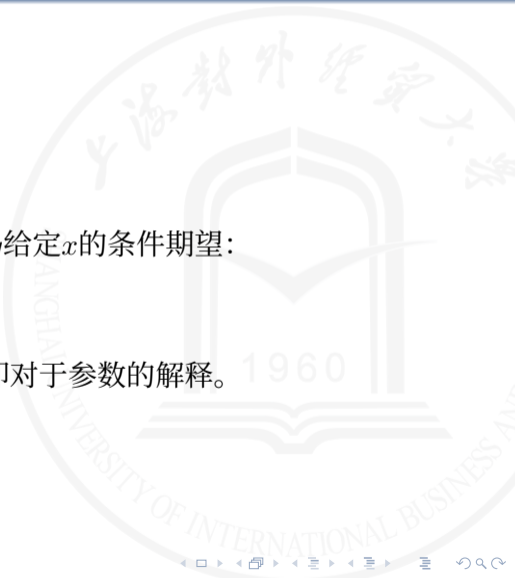
在回归方程

$$y = x'\beta + u$$

中，由于我们假设了外生性： $\mathbb{E}(u|x) = 0$ ，那么 $y$ 给定 $x$ 的条件期望：

$$\mathbb{E}(y|x) = x'\beta$$

我们可以使用条件期望函数将参数 $\beta$ 表达出来，即对于参数的解释。



# 系数的解释：虚拟变量情形

- 在离散情况下，我们通常可以使用差分作为工具，将所关心的参数使用条件期望函数表示出来。
- 比如，在模型：

$$y = \gamma \cdot w + \tilde{x}'\tilde{\delta} + u$$

中若 $w = 0/1$ ，且外生性满足，那么：

$$\begin{aligned} \gamma &= (\gamma + \tilde{x}'\tilde{\delta}) - (\tilde{x}'\tilde{\delta}) \\ &= \mathbb{E}(y|w = 1, \tilde{x}) - \mathbb{E}(y|w = 0, \tilde{x}) \end{aligned}$$

因而 $\gamma$ 可以解释为：

- 其他条件 ( $\tilde{x}$ ) 相同的条件下， $w$ 从0到1所导致的 $y$ 的绝对值变化
- 或者其他条件 ( $\tilde{x}$ ) 相同的条件下， $w = 1$ 组比 $w = 0$ 组的均值高 $\gamma$ 。

# 系数的解释：虚拟变量（对数）情形

- 很多时候回归中会加入取对数后的变量而非其绝对值。如果被解释变量取对数，即

$$\ln y = \gamma \cdot w + \tilde{x}'\tilde{\delta} + u$$

其中 $w = 0/1$ ，那么 $\gamma$ 可以表示为：

$$\gamma = \mathbb{E}(\ln y | w = 1, \tilde{x}) - \mathbb{E}(\ln y | w = 0, \tilde{x})$$

- 一般而言，对数之差可以解释为变动率。由于当 $\frac{y_1 - y_0}{y_0} \approx 0$ 时：

$$\ln y_1 - \ln y_0 = \ln\left(\frac{y_1}{y_0}\right) = \ln\left(1 + \frac{y_1 - y_0}{y_0}\right) \approx \frac{y_1 - y_0}{y_0}$$

即 $y_0$ 到 $y_1$ 的百分比变化，因而通常我们也将 $\gamma$ 解释为 $w$ 从0到1导致的 $y$ 的百分比变化的期望

- 这一解释的前提是 $|\gamma|$ 比较小，如果 $|\gamma|$ 较大，那么可以采用：

$$\ln\left(\frac{y_1}{y_0}\right) = \gamma \Rightarrow y_1 = e^\gamma y_0$$

进行解释。



## 系数的解释：虚拟变量（对数）情形

## 边界之谜

	(1)	(2)
$y_i$	1.3 (0.06)	1.21 (0.03)
$y_j$	0.96 (0.06)	1.06 (0.03)
$\text{dist}_{ij}$	-1.52 (0.10)	-1.42 (0.06)
Dummy $_{ij}$		3.09 (0.13)
样本量	90	683
调整的 $R^2$	0.890	0.811

## 系数的解释：虚拟变量（对数）情形

### McCallum(1995)

在这个结果中，我们最关注的是第(2)列的结果， $Dummy_{ij}$ 的系数为3.09，且是显著的，那么意味着其他条件不变的情况下，加拿大的省内贸易比加拿大省份和美国州之间的跨国贸易额的对数大3.09，即加拿大省内贸易是跨国贸易额的 $e^{3.09} \approx 22$ 倍。

# 系数的解释：虚拟变量（交叉项）情形

如果  $d = 0/1$  也为二元变量 ( $w = 0/1$  依然为二元变量) 比如:

- $w = 1$  代表上过大学,  $w = 0$  代表没有上过大学
- $d = 1$  代表男性,  $d = 0$  代表女性
- $y$  代表对数收入

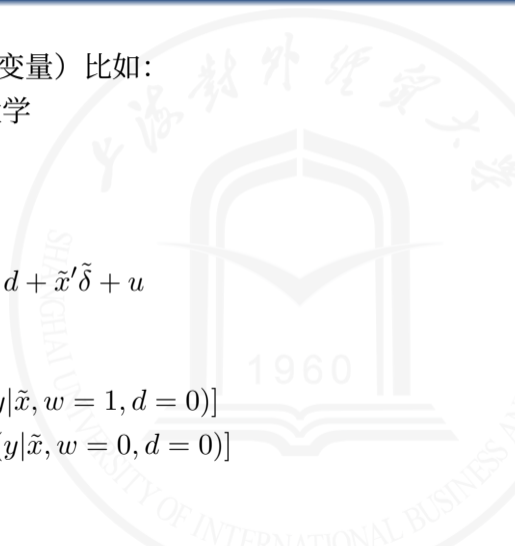
如果

$$y = \tau \cdot w + \eta \cdot d + \gamma \cdot w \cdot d + \tilde{x}'\tilde{\delta} + u$$

则

$$\begin{aligned} \gamma = & [\mathbb{E}(y|\tilde{x}, w = 1, d = 1) - \mathbb{E}(y|\tilde{x}, w = 1, d = 0)] \\ & - [\mathbb{E}(y|\tilde{x}, w = 0, d = 1) - \mathbb{E}(y|\tilde{x}, w = 0, d = 0)] \end{aligned}$$

why?



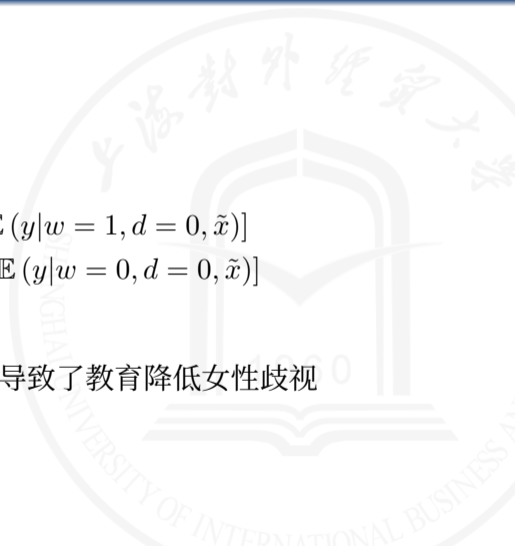


# 系数的解释：虚拟变量（交叉项）情形

- 而同时注意到， $\gamma$ 也可以表示为：

$$\begin{aligned} \gamma = & [\mathbb{E}(y|w = 1, d = 1, \tilde{x}) - \mathbb{E}(y|w = 1, d = 0, \tilde{x})] \\ & - [\mathbb{E}(y|w = 0, d = 1, \tilde{x}) - \mathbb{E}(y|w = 0, d = 0, \tilde{x})] \end{aligned}$$

- $\gamma$ 也度量了不同教育程度的性别歧视程度
- 两者是等价的：正是因为女性教育回报高，导致了教育降低女性歧视



# 系数的解释：虚拟变量（交叉项）情形

## 锻炼身体效果的异质性

在辛普森悖论的例子中，如果我们的数据生成过程为：

$$\begin{aligned} y_{1i} &= 83 - 10d_i + u_{1i} \\ y_{0i} &= 80 - 10d_i + u_{0i} \end{aligned}$$

假设 $u_{1i} = u_{0i} = u$ ，那么我们可以将其写为：

$$y = w \cdot y_1 + (1 - w) \cdot y_0 = 80 - 10 \times d + 3 \times w + u$$

然而，如果数据生成过程为：

$$\begin{aligned} y_{1i} &= 83 - 8d_i + u_{1i} \\ y_{0i} &= 80 - 10d_i + u_{0i} \end{aligned}$$

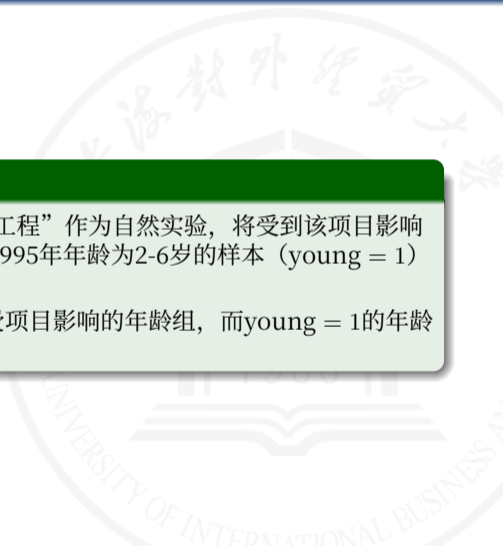
即锻炼身体对男性和女性的效果不同，那么我们可以将其写为：

$$y = w \cdot y_1 + (1 - w) \cdot y_0 = 80 - 10 \times d + 3 \times w + 2 \times d \times w + u$$

# 系数的解释：虚拟变量（交叉项）情形

## 扶教育之贫

- 汪德华、邹杰和毛中根（2019）借助1995年的“义新工程”作为自然实验，将受到该项目影响的县作为处理组（ $program = 1$ ），于此同时区分了1995年年龄为2-6岁的样本（ $young = 1$ ）以及16-20岁（ $young = 0$ ）的样本。
- 由于该项目主要针对义务教育，从而 $young = 0$ 为不受项目影响的年龄组，而 $young = 1$ 的年龄组在整个义务教育阶段都受到了该项目的影



# 系数的解释：虚拟变量（交叉项）情形

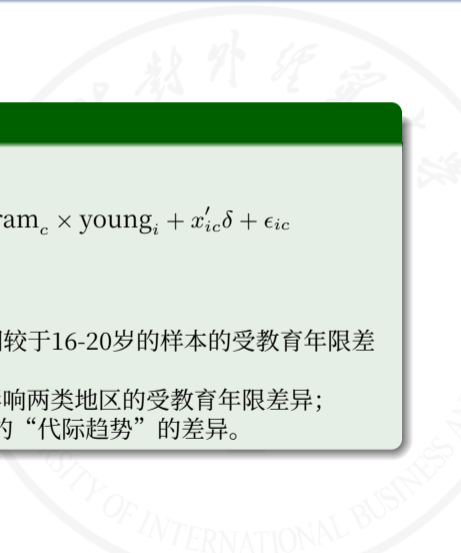
## 扶教育之贫

- 作者设定了如下模型：

$$y_{ic} = \beta \times \text{young}_i + \delta \times \text{program}_c + \lambda \times \text{program}_c \times \text{young}_i + x'_{ic}\delta + \epsilon_{ic}$$

其中 $c$ 为县， $i$ 为个体， $y$ 为受教育年限。

- 从而：
  - $\beta$ 度量了未受到项目影响的县中，95年2-6岁的样本相较于16-20岁的样本的受教育年限差异，或者“代际趋势”；
  - $\delta$ 则度量了95年16-20岁的样本在受到和未受到项目影响两类地区的受教育年限差异；
  - 而 $\lambda$ 实际上度量了受到和没有受到项目影响两类地区的“代际趋势”的差异。



# 系数的解释：连续情况

对于连续变量，可以使用微分代替差分：

$$\frac{\partial \mathbb{E}(y|x)}{\partial x_j}$$

即所谓偏效应（partial effects）。比如，对于模型：

$$y = \gamma \cdot w + \tilde{x}'\beta + u$$

那么：

$$\gamma = \frac{\partial \mathbb{E}(y|x)}{\partial w}$$

即当 $w$ 增加一单位时， $y$ 平均增加 $\gamma$ 。



# 系数的解释：对数情况

同样，如果模型为：

$$\ln y = \gamma \cdot w + \tilde{x}'\beta + u$$

那么：

$$\gamma = \frac{\partial \mathbb{E}(\ln y | w, \tilde{x})}{\partial w} = \mathbb{E} \left( \frac{\partial \ln y}{\partial w} \middle| w, \tilde{x} \right) = \mathbb{E} \left( \frac{1}{y} \frac{\partial y}{\partial w} \middle| w, \tilde{x} \right)$$

即此时 $\gamma$ 可以解释为 $w$ 增加1单位时， $y$ 的百分比变化。

- 比如，如果 $\gamma = 0.01$ ，意味着1单位的 $w$ 增加会导致 $y$ 的1%增加

# 系数的解释：对数的情况

同理，如果模型为：

$$\ln y = \gamma \cdot \ln w + \tilde{x}'\beta + u$$

那么此时

$$\gamma = \mathbb{E} \left( \frac{\partial \ln y}{\partial \ln w} \middle| w, \tilde{x} \right)$$

此时 $\gamma$ 可以解释为 $w$ 增加百分之一时， $y$ 的百分比变化，即所谓的弹性（elasticity）。

- 如果 $\gamma = 1$ ，那么当 $w$ 增加1%（从而 $\ln w$ 增加0.01）时， $\ln y$ 增加 $0.01 \times \gamma = 0.01$ ，从而 $y$ 相应增加1%。
- 那么如果：

$$y = \beta_1 \ln x_1 + \tilde{x}'\delta + u$$

该如何解释？

# 实例：引力模型

## 边界之谜

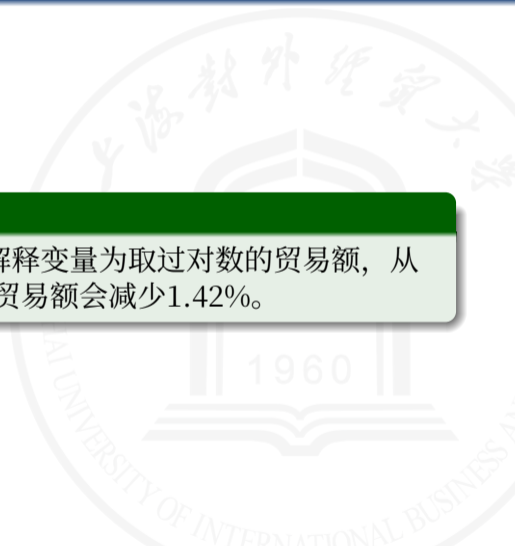
其结果如下：

	(1)	(2)
$y_i$	1.3 (0.06)	1.21 (0.03)
$y_j$	0.96 (0.06)	1.06 (0.03)
$dist_{ij}$	-1.52 (0.10)	-1.42 (0.06)
Dummy $_{ij}$		3.09 (0.13)
样本量	90	683
调整的 $R^2$	0.890	0.811

# 实例：引力模型

## 边界之谜

上例中， $dist_{ij}$ 为取过对数的地区间距离，而被解释变量为取过对数的贸易额，从而-1.42可以理解为当距离增加1%时，地区间的贸易额会减少1.42%。



# 偏效应

- 如果模型中存在着解释变量的非线性函数形式，我们通常也是使用偏导：

$$\frac{\partial \mathbb{E}(y|x)}{\partial w}$$

进行解释，此时通常该效应并非常数，而是存在着异质性的影响，我们通常将以上偏导称之为偏效应（partial effects）。

- 由于影响是异质性的，即对于每个个体都是不同的，我们通常会计算偏效应的期望：

$$\mathbb{E} \left[ \frac{\partial \mathbb{E}(y|x)}{\partial w} \right]$$

我们称之为平均偏效应（average partial effects, APE）。

# 系数的解释：平方项

在模型中加入平方项一般可以建模影响的非线性性，特别是边际递增、递减等特征，有的时候甚至还能表达U型、倒U型关系。

- 加入平方项：

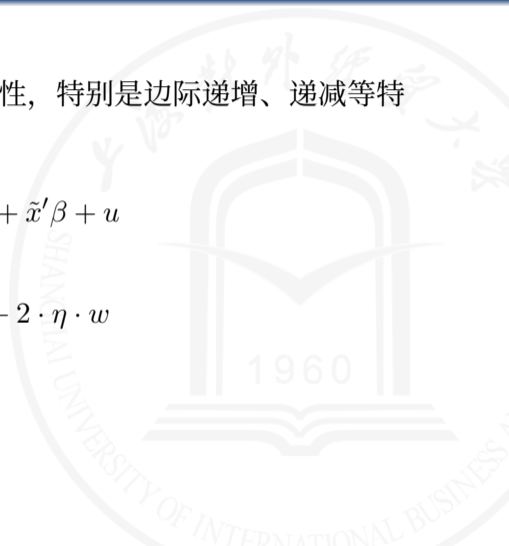
$$y = \gamma \cdot w + \eta \cdot w^2 + \tilde{x}'\beta + u$$

那么偏效应为：

$$\frac{\partial \mathbb{E}(y|w, \tilde{x})}{\partial w} = \gamma + 2 \cdot \eta \cdot w$$

此时 $w$ 对 $y$ 的影响是：

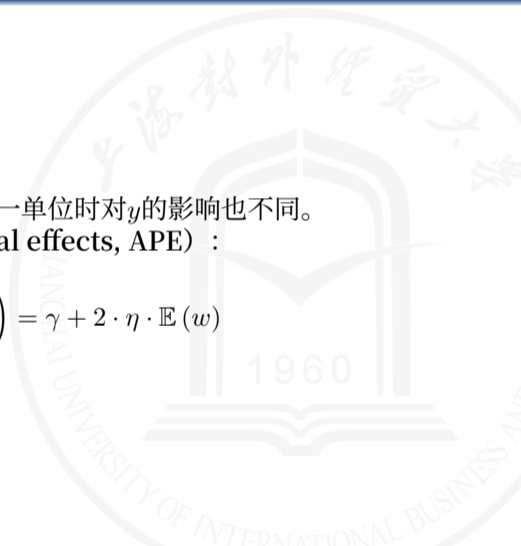
- 异质性的
- 非线性的



# 系数的解释：平方项

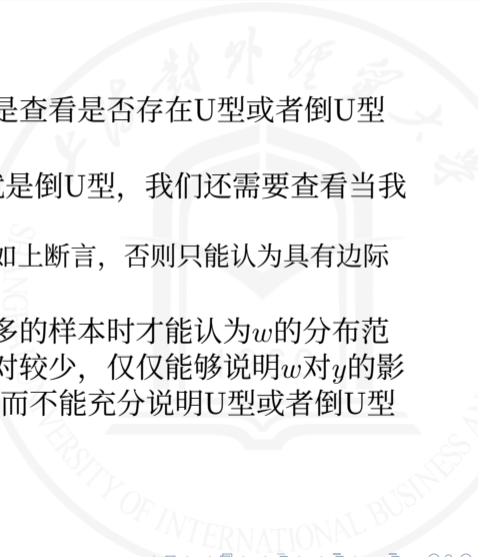
- 异质性：
  - 每个人的 $w$ （比如年龄）不同，那么 $w$ 增加一单位时对 $y$ 的影响也不同。
  - 此时可以计算平均偏效应（average partial effects, APE）：

$$\text{APE} = \mathbb{E} \left( \frac{\partial \mathbb{E}(y|w, \tilde{x})}{\partial w} \right) = \gamma + 2 \cdot \eta \cdot \mathbb{E}(w)$$



# 系数的解释：平方项

- 需要注意的是，一个常见的加入平方项的目的是查看是否存在U型或者倒U型的关系
- 然而，并非 $\eta > 0$ 就是U型，或者反过来 $\eta < 0$ 就是倒U型，我们还需要查看当我们查看对称轴 $-\gamma/2\eta$ 与 $w$ 的分布范围：
  - 只有当 $w$ 的分布范围包含了对称轴时，才能做如上断言，否则只能认为具有边际递增/递减的特性。
- 需要额外注意的是，只有当对称轴两边有足够多的样本时才能认为 $w$ 的分布范围包含了对称轴，如果对称轴的一侧样本量相对较少，仅仅能够说明 $w$ 对 $y$ 的影响存在非线性性，或者边际递增/递减的特性，而不能充分说明U型或者倒U型关系。



# 系数的解释：平方项

## 对称轴

在quadratic.do中，我们模拟了如下的函数形式：

$$y = 2 - e^{-\frac{x}{2}} + u$$

从而

$$\frac{\partial \mathbb{E}(y|x)}{\partial x} = \frac{1}{2} e^{-\frac{x}{2}} > 0$$

即一个单调递增但是边际递减的影响。然而如果我们假设


$$\frac{x}{2} \sim \chi^2(1), u \sim \mathcal{N}(0, 4)$$

的情况下做模拟，使用回归

$$y = \alpha + \beta x + \delta x^2 + u$$

# 系数的解释：平方项

## 对称轴



# 系数的解释：连续变量交乘项

- 有时我们也会设置交叉项：

$$y = \gamma \cdot w + \eta \cdot h + \tau \cdot w \cdot h + \tilde{x}'\beta + u$$

那么偏效应：

$$\frac{\partial \mathbb{E}(y|w, h, \tilde{x})}{\partial w} = \gamma + \tau \cdot h$$

- $w$ 对 $y$ 的影响受到另外一个变量 $h$ 的影响，其平均偏效应为：

$$\mathbb{E}\left(\frac{\partial \mathbb{E}(y|w, \tilde{x})}{\partial w}\right) = \gamma + \tau \cdot \mathbb{E}(h)$$

# 系数的解释：连续变量与虚拟变量交乘项

- 有时参与交乘的两项并非都是连续变量，而是将一个虚拟变量与连续变量相乘，即

$$y = \gamma \cdot w + \eta \cdot d + \tau \cdot w \cdot d + \tilde{x}'\beta + u$$

其中 $d$ 为虚拟变量， $w$ 为连续变量，此时可以计算偏效应：

$$\frac{\partial \mathbb{E}(y|w, d, \tilde{x})}{\partial w} = \gamma + \tau \cdot d = \begin{cases} \gamma & d = 0 \\ \gamma + \tau & d = 1 \end{cases}$$

从而：

- $\tau$ 度量了 $d = 1$ 组与 $d = 0$ 组之间 $w$ 对 $y$ 的影响的异质性，而 $\gamma$ 则度量了 $d = 0$ 这一组 $w$ 对 $y$ 影响的偏效应。
- 如果考虑 $d$ 对 $y$ 的影响，有

$$\mathbb{E}(y|d = 1, w, \tilde{x}) - \mathbb{E}(y|d = 0, w, \tilde{x}) = \eta + \tau \cdot w$$

则意味着 $d = 1$ 组与 $d = 0$ 组之间 $y$ 的平均差异随着 $w$ 的变化而变化。

# 实例：交叉项的解释

## 财政教育支出与城乡收入差距

贾婷月、王笑涵和司继春（2024）通过匹配个体初中时的城市财政教育支出，讨论了财政教育支出对于城乡收入差距的影响，其主要结果为

$$\ln \text{Income}_{ic} = -0.256 \times \text{hukou}_i \times \ln \text{PEE}_{ic} + 0.507 \times \text{hukou}_i + 0.254 \times \ln \text{PEE}_{ic} + \tilde{x}'\beta + u_{ic}$$

其中交乘项的系数有两种解释：

- ① 财政教育支出对于农村和城市的个体收入影响是不同的：教育公共支出每增加1%，会使得农村居民收入增加约0.254%，而对于城市这一效应为 $(0.254 - 0.256)\% \approx 0$ ；
- ② 城乡之间的收入差距应为 $0.507 - 0.256 \times \ln \text{PEE}_{ic}$ ，随着财政教育支出的增加，城乡之间的收入差距会逐渐缩小。



# 估计平均偏效应：中心化

- 令  $w_i^* = w_i - \bar{w}$ ,  $h_i^* = h_i - \bar{h}$ , 如果使用回归方程:

$$y = \gamma^* \cdot w^* + \eta^* \cdot h^* + \tau^* \cdot w^* \cdot h^* + \tilde{x}'\beta + u$$

那么平均偏效应为:

$$\mathbb{E} \left( \frac{\partial \mathbb{E}(y|w^*, \tilde{x})}{\partial w^*} \right) = \gamma^* + \tau^* \cdot \mathbb{E}(h^*) = \gamma^*$$

从而如果将  $h$  中心化, 那么同样, 回归系数  $\gamma^*$  可以解释为  $w$  对  $y$  影响的平均偏效应。

# 实例：中心化

## 企业进入退出与生产率

文件demean.do做了如下回归：

$$\ln \text{Pollution} = c + \beta \ln \text{pgdp} + \gamma (\ln \text{pgdp})^2 + u$$

即观察污染（二氧化硫）排放是否随着人均GDP先增加后减少。

- 我们首先进行了不去平均的回归，得到的回归系数为 $\gamma = -0.342$ ,  $\beta = 7.976$ ，而人均GDP的均值为0.702，可以计算平均偏效应应为 $7.976 - 2 \times 0.342 \times 0.702 = 0.863$ 。
- 紧接着使用egen计算人均GDP的平均，然后进行去平均操作，得到 $\beta = 0.863$ ,  $\gamma = -0.342$ 。注意到两组回归的 $\gamma$ 估计是完全相同的，而去平均之后的 $\beta$ 具有了平均偏效应的解释。

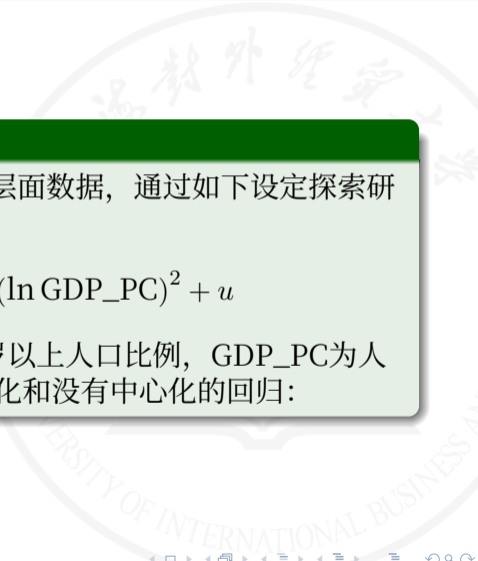
# 实例：中心化

## 老龄化

Cravino、Levchenko和Rojas（2022）使用国家层面数据，通过如下设定探索研究了人口老龄化与经济结构转变的关系：

$$\omega = \alpha + \beta \text{Age} + \gamma_1 \ln \text{GDP\_PC} + \gamma_2 (\ln \text{GDP\_PC})^2 + u$$

其中 $\omega$ 为农业、制造业、服务业的比例，Age为65岁以上人口比例，GDP\_PC为人均GDP。以制造业为例，如下代码展示了使用中心化和没有中心化的回归：





# 实例：中心化

## 老龄化

- 如果不对人均GDP做中心化，得到的回归方程为

$$\omega = \alpha - 0.84 \times \text{Age} + 1.24 \times \ln \text{GDP\_PC} - 0.07 \times (\ln \text{GDP\_PC})^2 + u$$

而如果进行中心化，得到的回归方程为

$$\omega = \alpha - 0.84 \times \text{Age} - 0.07 \times \ln \text{GDP\_PC} - 0.07 \times (\ln \text{GDP\_PC})^2 + u$$

其中 $\ln \text{GDP\_PC}$ 为中心化的对数GDP。

- 可以看到，如果没有做中心化处理，一次项系数为正；然而实际上，随着人均GDP的增加，制造业的就业比重平均而言应该是下降的。

# 固定效应

如果假设数据生成过程：

$$y_i = \alpha + \beta \cdot w_i + \gamma \cdot d_i + u_i$$

其中 $d_i = 0/1$ 。按照分步回归的步骤：

- ① 用 $w_i$ 和 $y_i$ 对 $d_i$ 做回归，得到残差。注意由于 $d_i$ 为0-1变量，因而实际结果是 $w_i$ 和 $y_i$ 被分组去均值。
- ② 用 $e_y$ 对 $e_w$ 做回归，得到 $\beta$ 的估计。

注意在以上步骤中，实际使用的variation是被去掉组均值的残差，因而不同组别之间没有variation，是一个「组内」估计量。

## 分步回归

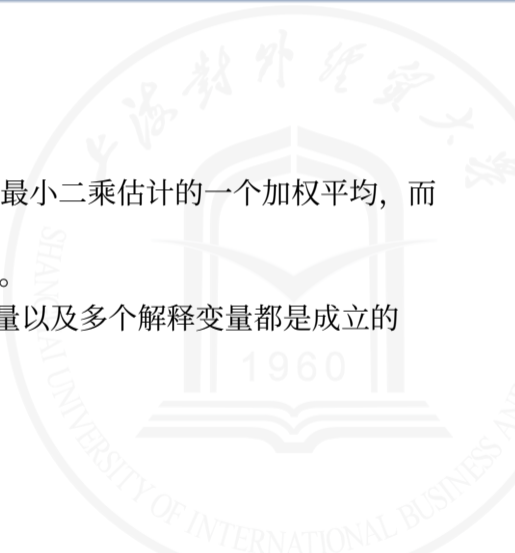
实际上，以上 $\beta$ 的最小二乘估计为：

$$\begin{aligned} \hat{\beta} &= \frac{\sum_{i=1}^N d_i (w_i - \bar{w}_1) y_i + \sum_{i=1}^N (1 - d_i) (w_i - \bar{w}_0) y_i}{\sum_{i=1}^N \left[ d_i (w_i - \bar{w}_1)^2 + (1 - d_i) (w_i - \bar{w}_0)^2 \right]} \\ &= \frac{\hat{\beta}_1 \left[ \sum_{i=1}^N d_i (w_i - \bar{w}_1)^2 \right] + \hat{\beta}_0 \left[ \sum_{i=1}^N (1 - d_i) (w_i - \bar{w}_0)^2 \right]}{\sum_{i=1}^N \left[ d_i (w_i - \bar{w}_1)^2 \right] + \sum_{i=1}^N \left[ (1 - d_i) (w_i - \bar{w}_0)^2 \right]} \quad (1) \\ &\triangleq \hat{\beta}_1 \omega_1 + \hat{\beta}_0 \omega_0 \end{aligned}$$

其中 $\omega_1 + \omega_0 = 1$ 为一个权重， $\hat{\beta}_1$ 和 $\hat{\beta}_0$ 分别为对应 $d_i = 1/0$ 两个组中，使用 $y$ 对 $w$ 做回归得到的回归系数。

# 组内估计量

- 最小二乘估计 $\hat{\beta}$ 是在 $d_i = 0/1$ 的不同组内进行最小二乘估计的一个加权平均，而不涉及不同组之间的比较
- 因而 $\hat{\beta}$ 是一个组内（within-group）估计量。
- 实际上，以上结论对任意多个组别的虚拟变量以及多个解释变量都是成立的



# 固定效应

## Simpson悖论

我们使用Stata模拟了Simpson悖论的数据:

- $y = 80 - 10 \times d + 3 \times w + u$
- $d = 1$ : 男性,  $w = 1$ : 锻炼
- $P(w = 1 | d = 1) = 0.8$
- $P(w = 1 | d = 0) = 0.3$







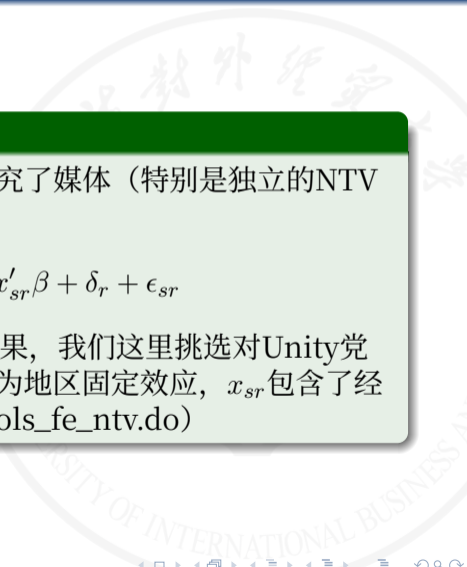
# 固定效应

## NTV与俄罗斯大选

Enikolopov、Petrova和Zhuravskaya (2011) 研究了媒体（特别是独立的NTV电视台）对于俄罗斯大选的影响，他们的设定如下：

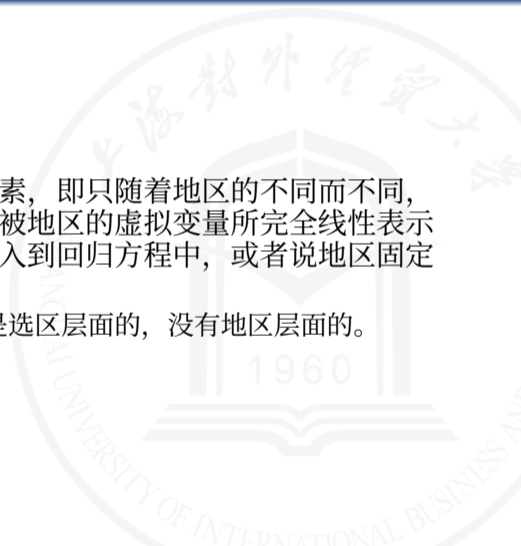
$$\text{vote}_{sr,1999} = \beta_0 + \beta_1 \text{NTV}_{sr,1999} + x'_{sr} \beta + \delta_r + \epsilon_{sr}$$

其中 $\text{vote}_{sr,1999}$ 为地区 $r$ 的选区 $s$ 在1999年选举中的结果，我们这里挑选对Unity党的投票结果； $\text{NTV}_{sr,1999}$ 为估计的电视台覆盖率， $\delta_r$ 为地区固定效应， $x_{sr}$ 包含了经济社会控制变量以及4年前上一届选举的结果变量 (ols\_fe\_ntv.do)



# 固定效应

- 注意到根据这一设定，所有的地区层面的因素，即只随着地区的不同而不同，但是同一个地区所有个体都相同的变量都会被地区的虚拟变量所完全线性表示出，从而所有这些地区层面的变量都无需加入到回归方程中，或者说地区固定效应控制了所有地区层面的因素。
  - 从而在上例中，控制变量中的所有变量都是选区层面的，没有地区层面的。



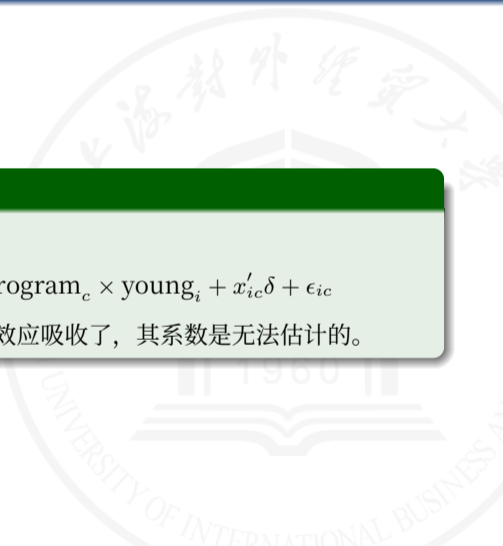
# 固定效应

## 扶教育之贫

- 在汪德华、邹杰和毛中根（2019）的设定中：

$$y_{ic} = \beta \times \text{young}_i + \delta \times \text{program}_c + \lambda \times \text{program}_c \times \text{young}_i + x'_{ic}\delta + \epsilon_{ic}$$

作者加入了县的固定效应，从而 $\text{program}_c$ 被县的固定效应吸收了，其系数是无法估计的。



## 固定效应

- 有的时候不同的分类变量可能出现嵌套的情况：
  - 城市属于特定省份、细分行业属于特定的三类产业等。
  - 比如，在上例中，在选区和地区之间，还存在城市这一分类：每个地区有多个城市，每个城市有1-2个选区。
- 此时，我们可以控制更“高”层次的固定效应（比如地区），也可以控制更“低”层次的固定效应（比如城市）
- 而由于高层次的虚拟变量可以被低层次的虚拟变量表示出，从而低层次的固定效应是更加严格的控制。
- 当然，虽然理论上固定效应控制的越细越好，但是也需要考虑自由度（ $N - K$ ）的问题
  - 更细致的固定效应可能会导致自由度快速耗散，能够使用的变异很小，导致回归结果不精确、不稳定，也更容易犯第II类错误。

# 固定效应

## NTV与俄罗斯大选

- 在上例中，如果我们把absorb(region)换成更细的absorb(city\_id)，可以发现在剔除了缺失值之后，只有137个城市、274个选区（如何观察？）的数据被使用，其他数据都因为一个城市只有一个选区，无法参与比较被剔除了，相较于absorb(region)，观测数少了1450个。
- 大量的样本被剔除导致自由度大大降低，这会大大增加第II类错误的概率，从而造成核心解释变量“错误的”不显著。可能由于这个原因，作者最终还是将聚类层级放在地区层面而非城市层面。

# 固定效应

- 此外，如果我们有两个分类变量（比如地区地区和行业），那么可以同时加入两个分类变量的虚拟变量进行控制：

$$y_i = x'_i\beta + \sum_{r=1}^{R-1} (\delta_r \times d_{ir}) + \sum_{m=1}^{M-1} (\gamma_m \times d_{im}) + u_i$$

其中 $d_{ir}$ 为第一个分类变量的固定效应， $d_{im}$ 为第二个分类变量的固定效应。

- 以上回归方程经常被简写为：

$$y_{irm} = x'_i\beta + \delta_r + \gamma_m + u_{irm}$$

注意我们在加入这些固定效应时，都删掉了一个虚拟变量以保证矩阵可逆。

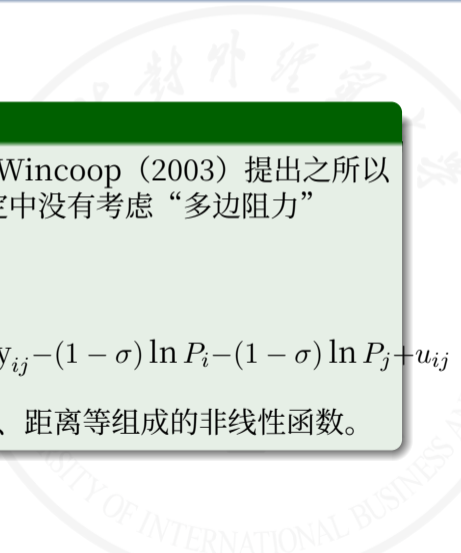
# 固定效应

## 边界之谜续

- 在之前的例子中介绍了边界之谜，Anderson和Wincoop（2003）提出之所以有边界之谜，是因为McCallum（1995）的设定中没有考虑“多边阻力”（multilateral resistance）。
- 他们通过理论推导得到了如下的回归方程：

$$x_{ij} = a + y_i + y_j + (1 - \sigma) \text{dist}_{ij} + (1 - \sigma) \rho \text{Dummy}_{ij} - (1 - \sigma) \ln P_i - (1 - \sigma) \ln P_j + u_{ij}$$

其中 $\ln P_i, \ln P_j$ 为两个多边阻力，是一个由价格、距离等组成的非线性函数。





# 固定效应

- 或者，我们可以使用两个分类变量定义一个新的分类变量，只有当两个分类变量同时成立时才= 1，并将其作为固定效应在回归中加以控制：

$$y_{irm} = x_i' \beta + \sum_{r,m} (\eta_{rm} \times d_{irm}) + u_{irm}$$

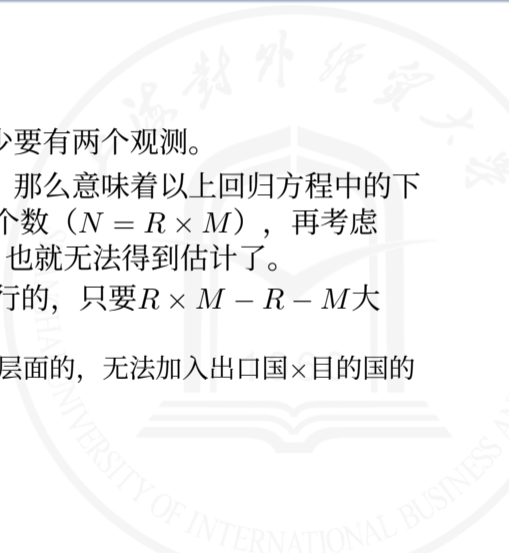
或者：

$$y_{irm} = x_i' \beta + \eta_{rm} + u_{irm}$$

- 这是一种比同时加入两组虚拟变量更为严格的控制方式，相当于将比较限制在同一地区且同一行业水平进行比较。

# 固定效应

- 当然，这么做的前提是在 $r, m$ 的组合中，至少要有两个观测。
- 如果在所有的 $r, m$ 组合中，都不足两个观测，那么意味着以上回归方程中的下角标 $i$ 是多余的，此时样本量甚至等于 $d_{rm}$ 的个数 ( $N = R \times M$ )，再考虑到 $x$ 的维度，自由度 $N - K < 0$ 被完全耗光，也就无法得到估计了。
- 但是此时，分别加入两种固定效应是完全可行的，只要 $R \times M - R - M$ 大于 $x$ 的维数即可。
  - 边界之谜的例子中，数据是出口国 $\times$ 目的国层面的，无法加入出口国 $\times$ 目的国的固定效应。



# 固定效应

- 比同时加入两组虚拟变量更为严格，之前的设定假设了：

$$\eta_{rm} = \delta_r + \gamma_m$$

- 该假设意味着不可观测的地区因素和行业因素的影响是独立的、可加，显然这一假设并不一定成立，因而使用 $\eta_{rm}$ 控制的更加严格。
- 该假设既可以是对 $y$ 的数据生成过程的，也可以是对 $x$ 的（习题）

# 固定效应

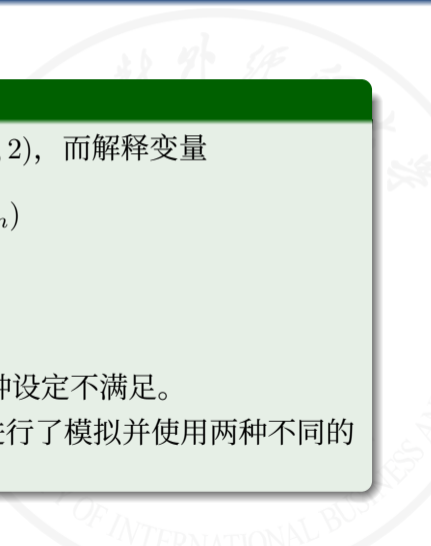
## 固定效应的模拟

- 考虑如下数据生成过程： $\delta_r \sim \mathcal{N}(0, 1)$ ,  $\gamma_m \sim \mathcal{N}(0, 2)$ ，而解释变量

$$x_{irm} = h_i + \max(\delta_r, \gamma_m)$$

其中 $h_i \sim \mathcal{U}(0, 1)$ 。考虑如下两种不同的设定：

- ①  $y_{irm} = 1 + 2 \times x_{irm} + \delta_r + \gamma_m + u_{irm}$
- ②  $y_{irm} = 1 + 2 \times x_{irm} + \delta_r \gamma_m + u_{irm}$
- 可见第1种设定中， $\eta_{rm} = \delta_r + \gamma_m$ 的设定，而第2种设定不满足。
- simulate\_fe.do对以上两种不同的数据生成过程进行了模拟并使用两种不同的固定效用控制方法进行了回归





# 固定效应

## 财政教育支出与城乡收入差距

jia2014.do重复了例贾婷月、王笑涵和司继春（2024）中的结果

### 代码 2: 固定效应使用示例

```

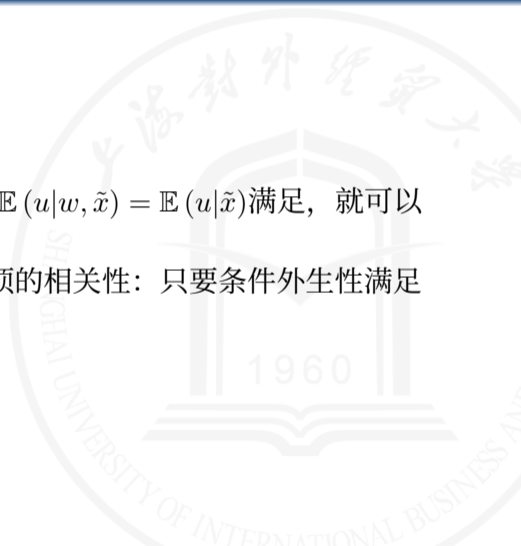
1 // jia2024.do
2 clear
3 use datasets/Jia_Wang_Si2024.dta
4 // 取对数
5 gen lnPEE=log(PEE)
6 // 去平均
7 egen m_lnPEE=mean(lnPEE)
8 gen dm_lnPEE=lnPEE-m_lnPEE
9 // 交乘项
10 gen hukou_dm_lnPEE=hukou*dm_lnPEE
11 // 回归
12 local controls "gender nation married parents_edu"
13 reg lnIncome hukou_dm_lnPEE hukou lnPEE `controls'

```



# 控制变量

- 在以上的讨论中，我们发现只要条件外生性 $\mathbb{E}(u|w, \tilde{x}) = \mathbb{E}(u|\tilde{x})$ 满足，就可以保证 $w$ 的回归系数的一致
- 这也意味着我们部分允许控制变量 $\tilde{x}$ 与误差项的相关性：只要条件外生性满足即可。



# 控制变量的内生性

## 条件外生性

考虑如下DGP:

$$x = u + e, w = x + h$$

其中 $u, e, h$ 相互独立, 那么此时

$$\mathbb{E}(u|w, x) = \mathbb{E}(u|x, h) = \mathbb{E}(u|x)$$

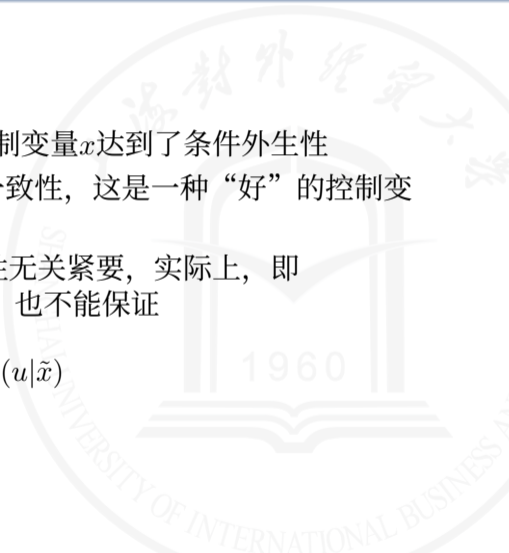
从而条件外生性是满足的, 虽然 $x$ 与 $u$ 是相关的。



# 控制变量的内生性

- 以上例子中，在回归方程中加入“内生”控制变量 $x$ 达到了条件外生性
- 即使 $x$ 与 $u$ 相关，但是加入 $x$ 保证了 $w$ 系数的一致性，这是一种“好”的控制变量。
- 然而，以上论述不意味着控制变量 $\tilde{x}$ 的内生性无关紧要，实际上，即使 $\mathbb{E}(u|w) = 0$ 从而 $w$ 是一个外生随机的变量，也不能保证

$$\mathbb{E}(u|w, \tilde{x}) = \mathbb{E}(u|\tilde{x})$$



# 控制变量的内生性

## 坏控制

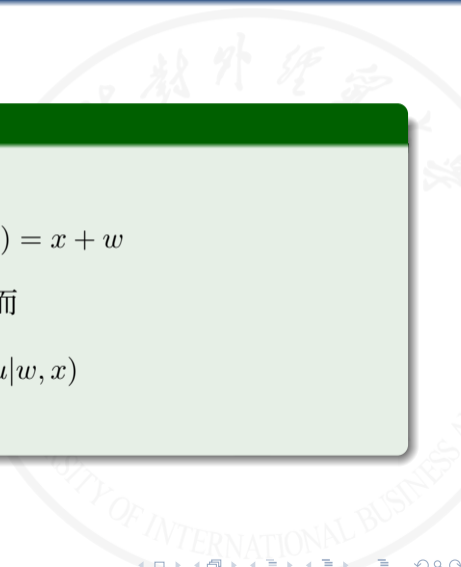
- 考虑如下DGP:  $w \perp\!\!\!\perp u$ ,  $x = u - w$ , 那么:

$$\mathbb{E}(u|w, x) = \mathbb{E}(u|w, u - w) = x + w$$

显然 $\mathbb{E}(u|x)$ 应该为 $x$ 的函数而不应该包含 $w$ , 从而

$$\mathbb{E}(u|x) \neq x + w = \mathbb{E}(u|w, x)$$

从而条件外生性不满足。



# 控制变量的内生性

## 坏控制

- 此时，如果我们使用回归：

$$y = \alpha + \gamma \cdot w + \beta x + u$$

那么自然有 $\mathbb{L}(w|x) = -x$ ，从而 $w - \mathbb{L}(w|x) = w + x = u$ ，一定与 $u$ 是相关的。

- 此时不管 $y$ 真实的数据生成过程是什么（从而 $\gamma$ 的真值可以是任何值），都会得到 $\text{plim} \hat{\gamma} = 1$ ，这显然是错误的结果。
- 此时，如果在回归方程中加入控制变量，反而会使得估计不再一致，这是一种“坏控制”（bad control）。

# 控制变量的内生性

- 比较以上两个例子，两者的区别在于：
  - 在第1个例子中，控制变量 $x$ 是 $w$ 的原因
  - 而在第2个例子中， $x$ 是 $w$ 的一个结果。
- 我们可以使用Pearl (2009) 的“因果图” (causal diagrams) 来表达。
  - 因果图是一种表示因果影响的有向无环图 (directed acyclic graphs)，使用箭头表示因果的方向，实心点●代表可观测变量，空心点○代表不可观测变量。

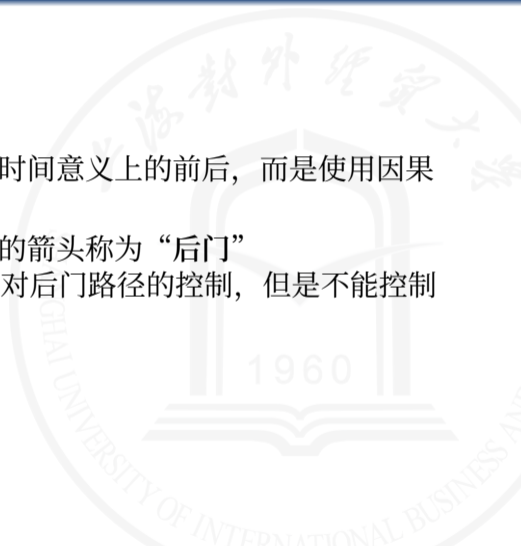






# 控制变量

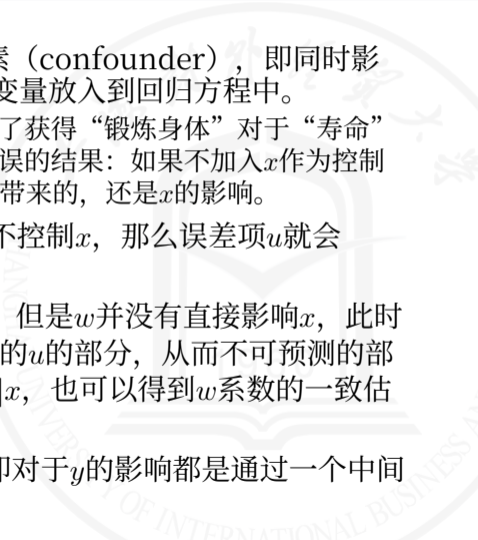
- 注意以上的“事前”、“事后”并非严格的时间意义上的前后，而是使用因果影响的方向定义的前后。
- 在因果图中，我们可以将指向核心解释变量的箭头称为“后门”（back-door）路径，从而好的控制应该是对后门路径的控制，但是不能控制核心解释变量指向的变量。
- 接下来我们介绍一些常见的情况。





# 必须控制情形

- (a)中的 $x$ 会同时影响 $w$ 和 $y$ ，此时 $x$ 作为混淆因素 (confounder)，即同时影响核心解释变量和被解释变量，必须作为控制变量放入到回归方程中。
  - 这也就是我们在“辛普森悖论”中提到的，为了获得“锻炼身体”对于“寿命”的影响，必须要控制性别，否则可能会得到错误的结果：如果不加入 $x$ 作为控制变量，我们无法区分出来 $w$ 的系数 $\gamma$ 到底是由 $w$ 带来的，还是 $x$ 的影响。
- (b)中，作为后门路径， $x$ 也需要被控制，如果不控制 $x$ ，那么误差项 $u$ 就会与 $x$ 相关，从而导致条件外生性不满足。
- (c)中的 $x$ 并没有指向 $w$ ， $w, x$ 都受到了 $u$ 的影响，但是 $w$ 并没有直接影响 $x$ ，此时如果将 $w$ 对 $x$ 做投影，可以被预测的部分即共同的 $u$ 的部分，从而不可预测的部分就排除了共同因素 $u$ 的影响，从而给定 $w \perp u|x$ ，也可以得到 $w$ 系数的一致估计。
- (d)-(f)则分别代表了(a)-(c)的“中介”版本，即对于 $y$ 的影响都是通过一个中间变量 $m$ 实现的，此时原理与(a)-(c)相同

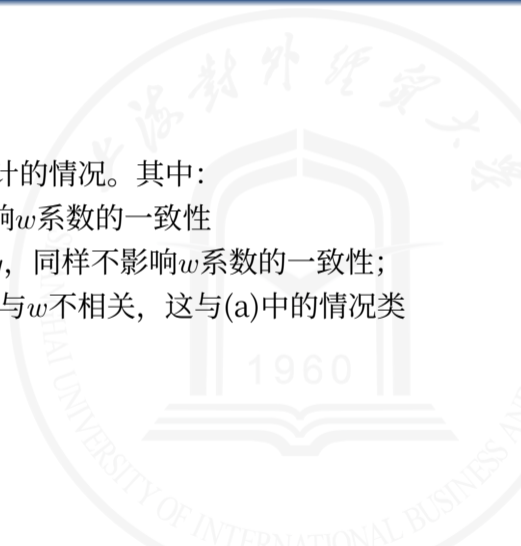




# 可控制可不控制

上图展示了一些控制变量不影响 $w$ 系数的一致估计的情况。其中：

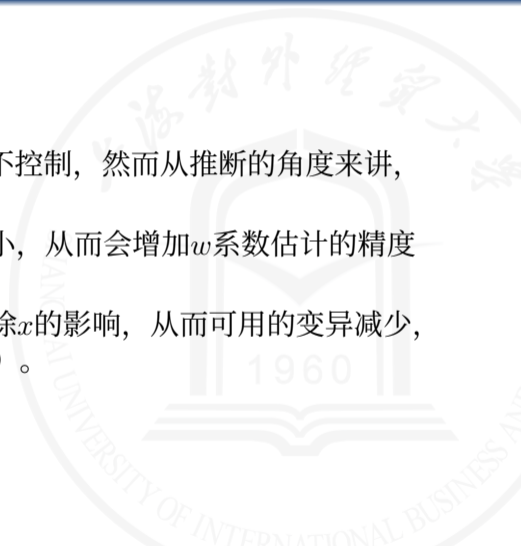
- (a)中的 $x$ 与 $w$ 不相关，从而控制与否都不影响 $w$ 系数的一致性
- (b)中的 $x$ 虽然与 $w$ 相关，但是其本身不影响 $y$ ，同样不影响 $w$ 系数的一致性；
- (c)中 $x$ 和 $w$ 是中介变量 $m$ 的共同原因，但是 $x$ 与 $w$ 不相关，这与(a)中的情况类似，也是可以不控制的。



# 可控制可不控制

虽然以上情况中的 $x$ 从识别的角度来讲可控制可不控制，然而从推断的角度来讲，会影响 $w$ 的系数的估计的精度

- (a)和(c)中如果控制了 $x$ ，会使得 $y$ 的残差变小，从而会增加 $w$ 系数估计的精度（标准误降低）；
- (b)的情况，如果控制 $x$ ，那么需要在 $w$ 中排除 $x$ 的影响，从而可用的变异减少，从而会降低 $w$ 系数估计的精度（标准误变大）。





# 不能控制的情形

当 $x$ 是 $w$ 甚至 $y$ 的结果时， $x$ 作为“坏”控制，控制 $x$ 反而会导致给定 $x$ 的情况下 $w$ 与 $u$ 相关，此时就不能控制了。

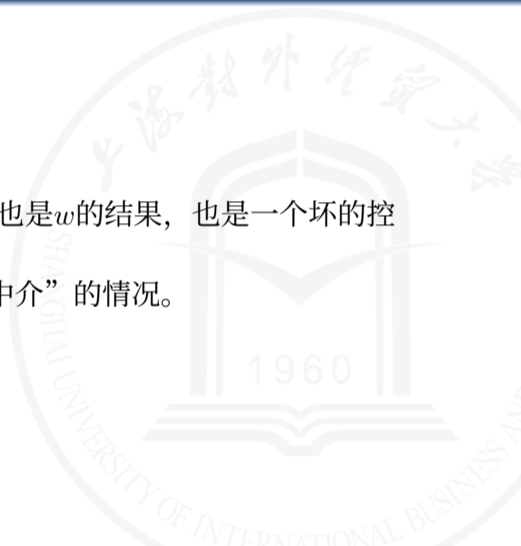
- (a)意味着 $x$ 本身是结果变量 $y$ 的一个结果，给定 $x$ 会导致严重的偏误。

## 经济发展与身高

- Floud、Watcher和Gregory (1990) 使用英国、美国19世纪部队的的数据研究了儿童时期营养 ( $w$ ) 与身高 ( $y$ ) 的关系
- 他们发现随着人均GDP的增加，成年人的身高甚至在降低。
- 实际上，这很可能是由于坏控制的原因 (Schneider, 2020) 。
  - 是否参与部队 ( $x$ ) 本身可能是身高的一个结果，使用部队数据实际上控制了是否参与部队这一变量
  - 身高高的人本身有更多的就业机会，这会导致会参与部队的身高普遍比较矮，在经济增长时期更是如此，所以才会导致如此奇怪的结果。

# 不能控制的情形

- (b)展示的即 $x$ 作为一个“中介变量”，同样也是 $w$ 的结果，也是一个坏的控制。
- 图(c)与(b)类似，即存在一个不客观测的“中介”的情况。



# 不能控制的情形

## 出生体重悖论

- Hernández-Díaz、Schisterman和Hernán (2006) 讨论了“出生体重悖论”，即一般而言，吸烟者 ( $w$ ) 生的婴儿死亡率 ( $y$ ) 大于不吸烟者生的婴儿死亡率
- 然而，如果将样本限制在出生体重 ( $x$ ) 比较低的样本，会发现以上的关系反转了。
- 为了解释这一现象，可以考虑图(b)的因果图：
  - 出生时的体重实际上是父母吸烟的一个结果
  - 而出生时体重以及婴儿死亡率肯定会受到同样的不可观测的因素  $u$  的影响。
  - 如果将样本限制在出生体重比较低的样本，实际上就是控制了  $x$ ，从而得到了错误结果。
  - 可以想象，不吸烟的父母如果出生的小孩体重很轻，很可能是有其他的更加严重的问题 ( $u$ )，导致了更高的死亡率

# 不能控制的情形

- (d)展示了一种比较特殊的情况，虽然看起来 $x$ 像是一个“事前”变量，然而此时控制 $x$ 会导致 $w$ 系数的不一致（M-bias）。

- 比如，如果考虑

$$x = u_1 + u_2, \quad w = h + u_1$$

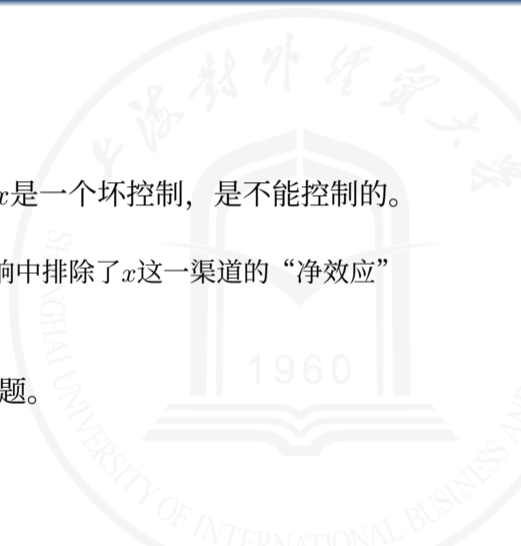
那么 $\mathbb{L}(w|x) = x$ ，从而 $w - \mathbb{L}(w|x) = h + u_1 - x = h - u_2$

- 而 $u_2$ 是 $y$ 的误差项，从而 $w - \mathbb{L}(w|x)$ 与 $y$ 的误差项相关，导致条件外生性不满足。
- 该例子也可以看出，因果图只是作为一个思维导向作用，如果有可能，最好可以详细研究核心解释变量和被解释变量的数据生成过程。



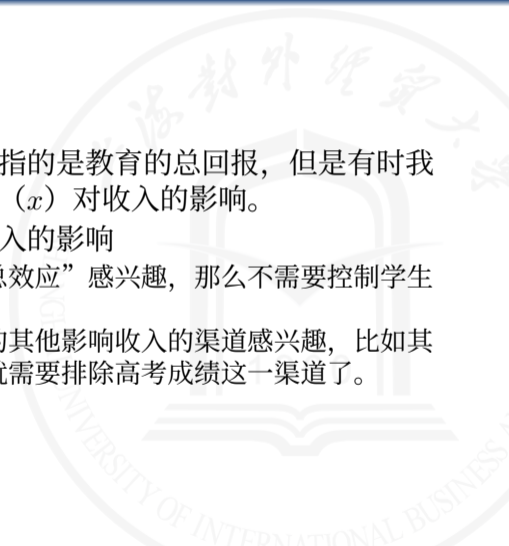
# 中介效应与识别

- 在以上情况中， $x$ 作为 $w$ 的结果，同时影响 $y$
- 此时 $x$ 作为 $w$ 影响 $y$ 的中间渠道，如前所述， $x$ 是一个坏控制，是不能控制的。
- 然而：
  - 有的时候我们真正感兴趣的是 $w$ 对于 $y$ 的影响中排除了 $x$ 这一渠道的“净效应”
  - 或者感兴趣的是 $x$ 这一渠道的影响
- 而非包含所有渠道影响的“总效应”。
- 此时，干净的识别可能是一个非常困难的问题。



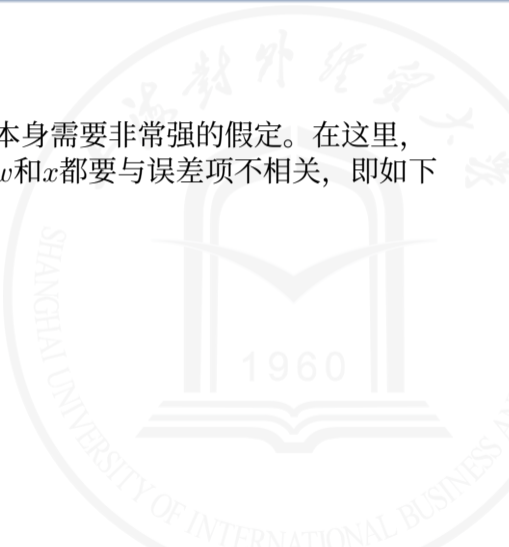

# 中介效应与识别

- 比如，当我们考虑教育的回报时，一般我们指的是教育的总回报，但是有时我们也关心羊皮纸效应，即有没有拿到学位证 ( $x$ ) 对收入的影响。
- 再比如，如果我们需要研究私立高中对于收入的影响
  - 如果我们仅仅是对私立高中对于收入的“总效应”感兴趣，那么不需要控制学生的考试成绩；
  - 而如果我们对于私立高中除了考试成绩之外的其他影响收入的渠道感兴趣，比如其他的兴趣爱好、交流能力的提升等，此时就需要排除高考成绩这一渠道了。




# 中介效应与识别

使用线性回归这一工具区分以上不同渠道的影响本身需要非常强的假定。在这里，我们不能仅仅依靠条件外生性假设了，而是需要 $w$ 和 $x$ 都要与误差项不相关，即如下图所示：



# 中介效应与识别

然而，实际中以上“干净”的外生性往往是不存在的，真实的情况往往是这样的：



此时， $x$ 与误差项相关，且 $x$ 与 $w$ 也相关，这会导致不仅 $x$ 的系数不一致，而且 $w$ 的系数也不一致。

