

LATE

令：

$$\begin{aligned} Y_i &= Y_i(0) + W_i(Y_i(1) - Y_i(0)) \\ &= \mathbb{E}(Y_i(0)) + W_i\mathbb{E}(Y_i(1) - Y_i(0)) + \zeta_i + \eta_i W_i \end{aligned}$$

其

中 $\zeta_i = Y_i(0) - \mathbb{E}(Y_i(0))$, $\eta_i = Y_i(1) - Y_i(0) - \mathbb{E}(Y_i(1) - Y_i(0))$ 。如果存在一个工具变量 Z_i , 使得 $\text{Cov}(Z_i, W_i) \neq 0$,且 $Z_i \perp\!\!\!\perp (Y_i(0), Y_i(1))$, 且 $Z = 0/1$ 那么IV估计：

$$\text{plim} \tau_{IV} = \frac{\text{Cov}(Y, Z)}{\text{Cov}(W, Z)} = \frac{\mathbb{E}(Y|Z=1) - \mathbb{E}(Y|Z=0)}{P(W|Z=1) - P(W|Z=0)}$$

- 一个简单的例子： Y_i 为对数收入， W_i 为是否上高中， Z_i 为 5km 范围内有没有高中

LATE

工具变量识别了什么？

① 当存在同质的处理效应时，经典的IV估计了同质的处理效应

- $Y_i = Y_i(0) + W_i(Y_i(1) - Y_i(0)) + \epsilon_i + \eta_i W_i = Y_i(0) + W_i \tau_{ATE} + v_i$
- 关键在 η_i ，如果 $\eta_i = 0$ ，同质的处理效应

② 当存在异质性的处理效应时，经典IV识别出的参数不可解释

③ 如果加入某些假设条件，经典IV的确可以识别出可以解释的参数

Imbens and Angrist(1994)建立了经典IV的识别条件以及经典IV识别的参数解释。

LATE

如果给定一个工具变量 Z_i 为0/1变量，我们记：

$$W_i(Z_i) = Z_i W_i(1) + (1 - Z_i) W_i(0) = \begin{cases} W_i(1) & Z_i = 1 \\ W_i(0) & Z_i = 0 \end{cases}$$

可以看成是关于内生变量的反事实。两个变量将总体分为四类人：

		$W_i(0)$	
		0	1
$W_i(1)$	0	never-taker	defier
	1	complier	always-taker

ITT

定义intention-to-treat (ITT), 即工具变量估计的分子:

$$\tau_{ITT} = \mathbb{E}(Y_i | Z_i = 1) - \mathbb{E}(Y_i | Z_i = 0)$$

将其分解:

$$\begin{aligned}\tau_{ITT} &= \mathbb{E}(Y_i | Z_i = 1) - \mathbb{E}(Y_i | Z_i = 0) \\ &= \mathbb{E}(Y_i(0) + W_i(Y_i(1) - Y_i(0)) | Z_i = 1) \\ &\quad - \mathbb{E}(Y_i(0) + W_i(Y_i(1) - Y_i(0)) | Z_i = 0) \\ &= \mathbb{E}(W_i(Y_i(1) - Y_i(0)) | Z_i = 1) - \mathbb{E}(W_i(Y_i(1) - Y_i(0)) | Z_i = 0) \\ &= \mathbb{E}(W_i(1)(Y_i(1) - Y_i(0)) | Z_i = 1) - \mathbb{E}(W_i(0)(Y_i(1) - Y_i(0)) | Z_i = 0) \\ &= \mathbb{E}(W_i(1)(Y_i(1) - Y_i(0))) - \mathbb{E}(W_i(0)(Y_i(1) - Y_i(0))) \\ &= \mathbb{E}((W_i(1) - W_i(0))(Y_i(1) - Y_i(0)))\end{aligned}$$

LATE

进一步使用全概率公式：

$$\begin{aligned}\tau_{ITT} &= \mathbb{E}((W_i(1) - W_i(0))(Y_i(1) - Y_i(0))) \\ &= \mathbb{E}((Y_i(1) - Y_i(0)) | W_i(1) - W_i(0) = 1) P(W_i(1) - W_i(0) = 1) \\ &\quad - \mathbb{E}((Y_i(1) - Y_i(0)) | W_i(1) - W_i(0) = -1) P(W_i(1) - W_i(0) = -1) \\ &= \mathbb{E}((Y_i(1) - Y_i(0)) | W_i(1) = 1, W_i(0) = 0) P(W_i(1) = 1, W_i(0) = 0) \\ &\quad - \mathbb{E}((Y_i(1) - Y_i(0)) | W_i(1) = 0, W_i(0) = 1) P(W_i(1) = 0, W_i(0) = 1)\end{aligned}$$

如果额外额外假设： $P(W_i(1) = 0, W_i(0) = 1) = 0$ （单调性）
那么：

$$\tau_{ITT} = \mathbb{E}((Y_i(1) - Y_i(0)) | W_i(1) = 1, W_i(0) = 0) P(W_i(1) = 1, W_i(0) = 0)$$

LATE

由于：

$$\begin{aligned} P(W_i = 1|Z_i = 1) - P(W_i = 1|Z_i = 0) &= P(W_i(1) = 1) - P(W_i(0) = 1) \\ &= P(W_i(1) = 1, W_i(0) = 0) \end{aligned}$$

进而，工具变量估计了：

$$\begin{aligned} LATE &= \tau_{IV} = \frac{\tau_{ITT}}{P(W = 1|Z = 1) - P(W = 1|Z = 0)} \\ &= \mathbb{E}((Y_i(1) - Y_i(0)) | W_i(1) = 1, W_i(0) = 0) \end{aligned}$$

即如果假设 $P(W_i(1) = 0, W_i(0) = 1) = 0$ （不存在 defier），那么工具变量识别了 complier 的平均处理效应，即 **Local Average Treatment Effects, LATE**。

LATE实例：OHIE数据

OHIE实验

在美国，Medicaid是真对穷人的健康保险计划。在2008年时，俄勒冈州计划回复Medicaid中的OHP Standard计划。由于预计申请人数非常多，因而州政府推出了一个按照抽签分配名额的方法。个人一旦被抽中，整个家庭都可以享受该计划。在个人被抽中后，州政府会联系申请人参加计划，然而由于种种原因，并非所有抽中的人最终都参加了该计划。

LATE实例：OHIE数据

OHIE实验

Finkelstein等人（2012）根据这个计划研究了健康保险对医疗资源使用、健康等方面的影响。其主要的估计方程为：

$$y_{ih} = \beta_0 + \beta_1 \times Insurance_{ih} + x'_{ih}\eta + u_{ih}$$

而第一阶段方程为：

$$Insurance_{ih} = \delta_0 + \delta_1 \times Lottery_{ih} + x'_{ih}\zeta + \mu_{ih}$$

而ITT为：

$$y_{ih} = \gamma_0 + \gamma_1 \times Lottery_{ih} + x'_{ih}\xi + \epsilon_{ih}$$

从而 $\gamma_1 = \beta_1 \times \delta_1$ 。代码：ohie_qje.do

工具变量、LATE及边际处理效应

回忆：

$$Y_i = Y_i(0) + W_i(Y_i(1) - Y_i(0)) + \epsilon_i + \eta_i W_i = Y_i(0) + W_i \tau_{ATE} + v_i$$

其

中 $\epsilon_i = Y_i(0) - \mathbb{E}(Y_i(0))$, $\eta_i = Y_i(1) - Y_i(0) - \mathbb{E}(Y_i(1) - Y_i(0))$;

- 异质性在处理效应中非常非常重要：工具变量估计不可用
- LATE解决了工具变量估计的可解释性问题，但是只能得到局部解释
 - 外部有效性不足
- 如何使用工具变量帮助识别ATE?

LATE

以上讨论的工具变量取值范围为 $Z = 0/1$ ，如果 Z 可以取多个值，比如 $Z = z_0, \dots, z_K$ ，需要重新排列使得：

$$\mathbb{E}(W_i | Z_i = z_{k-1}) \leq \mathbb{E}(W_i | Z_i = z_k), k = 1, \dots, K$$

假设：

$$\mathbb{E}[g(Z_i) W_i] = 0$$

那么工具变量估计：

$$\tau_{IV} = \frac{\text{Cov}(g(Z_i), Y_i)}{\text{Cov}(g(Z_i), W_i)} = \sum_{k=0}^K \lambda_k \tau_{z_k, z_{k-1}}$$

其中 $\tau_{z_k, z_{k-1}} = \mathbb{E}[Y_i(1) - Y_i(0) | W_i(z_k) = 1, W_i(z_{k-1}) = 0]$ 。其中 $g(\cdot)$ 函数决定了权重。

LATE

如果工具是连续的，那么可以定义：

$$\tau_z = \lim_{z' \downarrow z, z'' \uparrow z} \tau_{z', z''}$$

Vytlacil (2002)证明，如果工具变量的假设对于所有的 z', z'' 成立，那么实际上只需要假设一个潜在的index结构：

$$W_i = 1 \{h(Z_i) \geq U_i\}$$

我们可以将 U_i 标准化为均匀分布 $U_i \sim U[0, 1]$ 。

边际处理效应

定义边际处理效应 $\tau(u)$:

$$\tau(u) = \mathbb{E}(Y_i(1) - Y_i(0) | U_i = u)$$

实际上边际处理效应可以看成LATE, 即由于:

$$\begin{aligned}\tau_z &= \lim_{z' \downarrow z, z'' \uparrow z} \mathbb{E}[Y_i(1) - Y_i(0) | W_i(z') = 1, W_i(z'') = 0] \\ &= \lim_{z' \downarrow z, z'' \uparrow z} \mathbb{E}[Y_i(1) - Y_i(0) | h(z') \geq U_i, h(z'') < U_i] \\ &= \mathbb{E}(Y_i(1) - Y_i(0) | h(z) = U_i)\end{aligned}$$

因而:

$$\tau(u) = \tau_z, u = h(z)$$

而平均处理效应:

$$\tau_{ATE} = \int_0^1 \tau(u) du$$

边际处理效应的含义

一个例子。Mincer方程：

$$\ln(wage_i) = \alpha + \beta W_i + \gamma_1 exp_i + \gamma_2 exp_i^2 + u_i$$

然而，方程中我们忽略了一些因素，比如动力（motivation）：

$$\ln(wage_i) = \alpha + \beta W_i + \gamma_1 exp_i + \gamma_2 exp_i^2 + mot_i + u_i$$

进而，教育回报对于motivation可能是异质性的：

$$\ln(wage_i) = \alpha + \beta W_i + \gamma_1 exp_i + \gamma_2 exp_i^2 + mot_i + \theta \cdot W_i \cdot mot_i + u_i$$

动力越高， W_i 越容易偏向于1，而潜在工资可能越高：
selection-on-unobservable。

边际处理效应的含义

倾向得分:

$$p_i = P(W_i | Z_i)$$

假设 Z_i 为连续的。对Mincer方程求期望:

$$\mathbb{E}(\ln(wage_i) | exp_i, Z_i) = K(p_i, mot_i) = K(p_i)$$

其中第二个等号由于 Z_i 的外生性。MTE:

$$MTE = \frac{\partial \mathbb{E}(\ln(wage_i) | exp_i, Z_i)}{\partial p_i} = K'(p)$$

如果motivation能观察到:

$$MTE = \beta + \theta \cdot mot_i$$

MTE设定

一般设定:

$$Y(1) = \mu_1(X, U_1)$$

$$Y(0) = \mu_0(X, U_0)$$

注意, 这里允许 X 与 U_0, U_1 相关。处理效应:

$$\Delta = Y(1) - Y(0) = \mu_1(X, U_1) - \mu_0(X, U_0)$$

MTE与自选择

特例：广义Roy模型：

$$Y_1 = \mu_1(X) + U_1$$

$$Y_0 = \mu_0(X) + U_0$$

$$W = 1 \{Y_1 - Y_0 - C \geq 0\}$$

其中成本：

$$C = \mu_c(Z) + U_C$$

因而：

$$\begin{aligned} W &= 1 \{ \mu_1(X) - \mu_0(X) - \mu_c(Z) \geq U_C + U_0 - U_1 \} \\ &= 1 \{ \mu(Z) \geq V \} \\ &= 1 \{ F_V^{-1}(\mu(Z)) \geq U_W \} \end{aligned}$$

MTE

MTE被定义为:

$$MTE(u) = \mathbb{E}(Y_1 - Y_0 | U_W = u)$$

- 如前所述，与LATE关系密切
- 提供了 U_W 的不同分位数上的平均效应
 - 也就是不同的Propensity Score上的平均效应
- 反映了选择与处理效应异质性之间的关系

MTE与其他处理效应的关系

其他的处理效应可以写为MTE的函数：

$$ATE = \mathbb{E}(Y_1 - Y_0) = \int_0^1 MTE(u_W) du_W$$

$$TT = \mathbb{E}(Y_1 - Y_0 | W = 1) = \int_0^1 MTE(u_W) \omega_{TT}(u_W) du_W$$

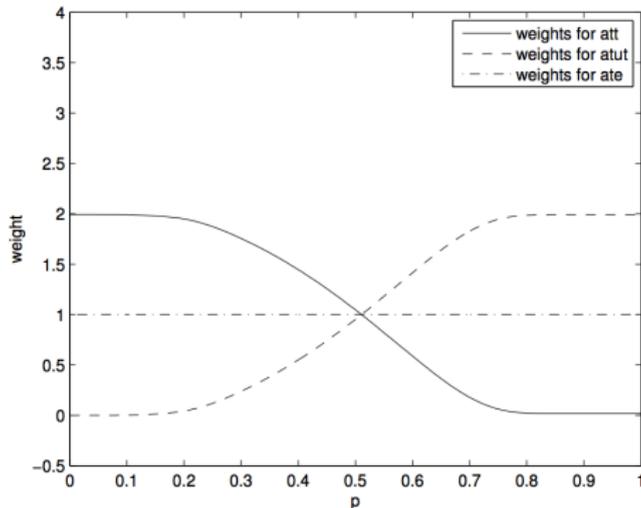
$$TUT(x) = \mathbb{E}(Y_1 - Y_0 | W = 0) = \int_0^1 MTE(u_W) \omega_{TUT}(u_W) du_W$$

$$PRTE = \mathbb{E}(Y_{a'}) - \mathbb{E}(Y_a) = \int_0^1 MTE(u_W) \omega_{PRTE}(u_W) du_W$$

$$IV_J = \int_0^1 \Delta^{MTE}(u_W) \omega_{IV}^J(u_W) du_W \quad \text{given instruments } J(Z)$$

MTE

Weights on MTE for Alternative Parameters



(a) ATT, ATUT, and ATE

Source: "Beyond LATE with a Discrete Instrument: Heterogeneity in the Quantity-Quality Interaction of Children", by Brinch, Mogstad, and Wiswall (JPE, 2016, forthcoming).

MTE的识别

识别:

$$\begin{aligned}\mathbb{E}(Y|P(Z) = p) &= \mathbb{E}(WY(1) + (1 - W)Y(0) | P(Z) = p) \\ &= \mathbb{E}(Y(0)) + \mathbb{E}(W(Y(1) - Y(0)) | P(Z) = p) \\ &= \mathbb{E}(Y(0)) \\ &\quad + \mathbb{E}(W(Y(1) - Y(0)) | W = 1, P(Z) = p) P(W = 1 | P(Z) = p) \\ &= \mathbb{E}(Y(0)) + \int_0^p \mathbb{E}(W(Y(1) - Y(0)) | U_W = u) du\end{aligned}$$

从而:

$$\frac{\partial \mathbb{E}(Y|P(Z) = p)}{\partial p} = \mathbb{E}(W(Y(1) - Y(0)) | U_W = p)$$

实例：OHIE

OHIE实验的边际处理效应与外部有效性

Taubman(2014)使用OHIE的数据验证了保险可能会导致紧急医疗资源的使用（如急诊室），而Kowalski(2015)重复了其结果，发现其结果对于控制变量等比较敏感。由于LATE只能够识别compliers的平均处理效应，外部有效性有所欠缺，为此Kowalski(2015)使用MTE重新评估了保险对于紧急医疗资源的使用，发现对于某一些人来说，该作用是正的，但是对于另一些人来说作用是负的，其结果可以总结为下图：

```
/home/aragorn/Working/Econometrics/pic/OHIE_MTE.png
```

(ohie_science.do)