

# 局部平均处理效应

慧航

上海对外经贸大学

2025年9月

## 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 $\mathbb{C}(z_i, w_i) \neq 0$ , 且 $z_i \perp\!\!\!\perp (y_i(0), y_i(1))$ , 且 $z = 0/1$ 那么IV估计：

$$\text{plim}\tau_{IV} = \frac{\mathbb{C}(y, z)}{\mathbb{C}(w, z)} = \frac{\mathbb{E}(y|z=1) - \mathbb{E}(y|z=0)}{P(w|z=1) - P(w|z=0)}$$

- 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 $\eta_i$ ，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。

## ITT

如果记  $z_i = 0/1$  为实际分组变量,  $w_i$  为实际被处理变量, 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

关键假设:

- ①  $z_i \perp\!\!\!\perp (y_i(1), y_i(0), w_i(1), w_i(0))$
- ②  $P(w_i = 1|z_i)$  取决于  $z_i$

## ITT

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

$$\tau_{\text{ITT}} = \mathbb{E}(y_i | z_i = 1) - \mathbb{E}(y_i | z_i = 0)$$

将其分解:

$$\begin{aligned}\tau_{\text{ITT}} &= \mathbb{E}(y_i | z_i = 1) - \mathbb{E}(y_i | z_i = 0) \\&= \mathbb{E}(y_i(0) + w_i(y_i(1) - y_i(0)) | z_i = 1) \\&\quad - \mathbb{E}(y_i(0) + w_i(y_i(1) - y_i(0)) | z_i = 0) \\&= \mathbb{E}(w_i(y_i(1) - y_i(0)) | z_i = 1) - \mathbb{E}(w_i(y_i(1) - y_i(0)) | z_i = 0) \\&= \mathbb{E}(w_i(1)(y_i(1) - y_i(0)) | z_i = 1) - \mathbb{E}(w_i(0)(y_i(1) - y_i(0)) | z_i = 0) \\&= \mathbb{E}(w_i(1)(y_i(1) - y_i(0))) - \mathbb{E}(w_i(0)(y_i(1) - y_i(0))) \\&= \mathbb{E}((w_i(1) - w_i(0))(y_i(1) - y_i(0)))\end{aligned}$$

## LATE

进一步使用全概率公式：

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

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

$$\tau_{\text{ITT}} = \mathbb{E}((t_i(1) - t_i(0)) | w_i(1) = 1, w_i(0) = 0) P(w_i(1) = 1, w_i(0) = 0)$$

# LATE

由于：

$$\begin{aligned} P(w_i = 1|z_i = 1) - P(w_i = 1|z_i = 0) &= P(w_i(1) = 1) - P(x_i(0) = 1) \\ &= P(x_i(1) = 1, w_i(0) = 0) \end{aligned}$$

进而，工具变量估计了：

$$\begin{aligned} \text{LATE} = \tau_{IV} &= \frac{\tau_{ITT}}{P(w = 1|z = 1) - P(w = 1|z = 0)} \\ &= \mathbb{E}((y_i(1) - y_i(0)) | w_i(1) = 1, w_i(0) = 0) \end{aligned}$$

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。

# 随机实验中的非遵从

- 理想情况下，个体实际是否被处理应该由随机分组完全决定
- 然而现实情况可能不一样：非遵从（noncompliance）
  - 有的被分到处理组可能（自己）选择不被处理（单边非遵从，one-sided noncompliance）
  - 有的被分到控制组可能自己选择被处理
  - 上面两种都有：双边非遵从（two-sided noncompliance）
- 除此之外，还有些实验是这样设计的：
  - 通过疫苗广告宣传打疫苗，疫苗广告是随机分组的，打不打疫苗是自己决定的

# 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：

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

而第一阶段方程为：

$$\text{Insurance}_{ih} = \delta_0 + \delta_1 \times \text{Lottery}_{ih} + x'_{ih}\zeta + \mu_{ih}$$

而ITT为：

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

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：

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

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：

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

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

# 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-unobservabe.

# 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：

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

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

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

其中成本：

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

因而：

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

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：

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

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


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

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

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

## 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:

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

- 估计方法：
  - ① 计算propensity score:  $p = p(x, z)$
  - ② 使用 $y$ 对 $x$ 和 $p$ 做回归
    - 注意 $Y$ 对 $p$ 应该是非线性函数：多项式、半参数估计
    - 检查common support
  - ③ 计算ATE、ATT等处理效应
- stata命令: `margte`