

双重差分模型

违背Unconfoundedness假设，但是有面板数据的条件下：双重差分模型（Difference-in-differences）。


一般设定：

- ① 分组变量： $g_i = 1$ ：处理组； $g_i = 0$ ：控制组。
 - 比如实施最低工资
 - unilateral divorce law
- ② 时间变量： $d_t = 0/1$
- ③ 处理 $w_{it} = d_t \cdot g_i$
- ④ Outcome： y_{it}

w_{it}	$g_i = 0$	$g_i = 1$
$d_t = 0$	0	0
$d_t = 1$	0	1

共同趋势假设

关键假设：共同趋势 (Common trend)



双重差分模型

双重差分模型：

- ① 第一次差分：对于两个不同的分组，分别计算：

$$\Delta_1 = \mathbb{E}(y_{it}|g_i = 1, d_t = 1) - \mathbb{E}(y_{it}|g_i = 1, d_t = 0)$$

$$\Delta_0 = \mathbb{E}(y_{it}|g_i = 0, d_t = 1) - \mathbb{E}(y_{it}|g_i = 0, d_t = 0)$$

- ② 第二次差分：处理效应：

$$\tau = \Delta_1 - \Delta_0$$

双重差分模型

实践中，等价于使用回归：

$$y_{it} = c + \lambda \cdot d_t + \gamma \cdot g_i + \tau \cdot d_t \cdot g_i + u_{it}$$

即第一次差分:

$$\Delta_1 = \mathbb{E}(y_{it}|g_i = 1, d_t = 1) - \mathbb{E}(y_{it}|g_i = 1, d_t = 0) = \lambda + \tau$$

$$\Delta_0 = \mathbb{E}(y_{it}|g_i = 0, d_t = 1) - \mathbb{E}(y_{it}|g_i = 0, d_t = 0) = \lambda$$

第二次差分:

$$\tau = \Delta_1 - \Delta_0$$

双重差分模型中的控制变量

- 使用反事实的框架，处理效应为： $y_{i1}(1) - y_{i1}(0) = \tau_i$ ，相应的处理组平均处理效应为：

$$\tau_{ATT} = \mathbb{E}(y_{i1}(1) - y_{i1}(0) | g_i = 1)$$

问题： $\mathbb{E}(y_{i1}(0) | g_i = 1)$ 不可观测！

- （平行趋势）假设：

$$\mathbb{E}(y_{i1}(0) - y_{i0}(0) | g_i = 1) = \mathbb{E}(y_{i1}(0) - y_{i0}(0) | g_i = 0)$$

- 那么：

$$\begin{aligned} \mathbb{E}(y_{i1}(0) | g_i = 1) &= \mathbb{E}(y_{i0}(0) | g_i = 1) \\ &\quad + \mathbb{E}(y_{i1}(0) - y_{i0}(0) | g_i = 0) \end{aligned}$$

双重差分模型

- 假设

$$\mathbb{E}(y_{it}(0) | x_{it}) = \alpha_i + \gamma_t + x'_{it}\beta$$

- 加入了时间和个体的虚拟变量 (TWFE)
- 并没有给定分组, 因而控制组和处理组都满足以上方程。
- 由于: $\tau_{ATT} = \mathbb{E}(y_{i1}(1) - y_{i1}(0) | g_i = 1, x_{it})$, 从而:

$$\mathbb{E}(y_{i1}(1) | g_i = 1, x_{it}) = \tau_{ATT} + \mathbb{E}(y_{i1}(0) | g_i = 1, x_{it})$$

从而设定:

$$\begin{aligned} y_{it} &= \alpha_i + \gamma_t + x'_{it}\beta + \tau_{ATT}w_{it} + u_{it} \\ &= \alpha_i + \gamma_t + x'_{it}\beta + \tau_{ATT} \cdot d_t \cdot g_i + u_{it} \end{aligned}$$

- 以上为标准设定: 加入控制变量、双向固定效应使得共同趋势假设成立。

双重差分：一定要面板数据吗？

- 传统上，双重差分模型一般需要面板数据
- 但是实际上，不使用面板数据有时也可以使用双重差分模型：
 - Duflo(2001) 关于教育回报的研究中，比较cohorts
 - Archibong and Annan(2017)关于疾病与人力资本投资
 - 设定为：

$$\text{edu} = \beta \cdot \text{MEMIN} \cdot \text{female} + \cdots + u$$

- MEMIN为流行性脑膜炎的严重程度，为实际上的双重差分变量
- DID_disease.do

平行趋势检验

检验：

- ① Placebo test: 提前冲击发生的时间
- ② 平行趋势假设检验: 若冲击发生时间为 $t = \tilde{T}$, 设定:

$$y_{it} = \alpha_i + \lambda_t + \sum_{\ell=-p, \ell \neq -1}^q \tau_\ell \cdot \mathbb{1}\{t = \tilde{T} + \ell\} \cdot g_i + x'_{it}\beta + u_{it}$$

- ③ 标准:
- ① τ_ℓ 当 $\ell < 0$ 时 (leads) 不显著
 - ② τ_ℓ 当 $\ell \geq 0$ 时 (lag) 显著

平行趋势检验




FIG. 3.—Estimated impact of implied contract exception on log state temporary help supply industry employment for years before, during, and after adoption, 1979–95.

多期DID的静态设定

- 传统做法：将 $d_t \cdot G_i$ 替换为 w_{it} ，其中 w_{it} 指第 t 期第 i 个个体是否接受处理：

$$w_{it} = \begin{cases} 1 & \text{个体}i\text{在时间}t\text{接受处理} \\ 0 & else \end{cases}$$

设定模型 (TWFE) :

$$y_{it} = \alpha_i + \lambda_t + \tau \cdot w_{it} + x'_{it}\beta + u_{it}$$

静态设定的问题

一般的DID使用如上的静态估计（双向固定效应）：

$$y_{it} = \alpha_i + \gamma_t + x'_{it}\beta + \tau_{ATT}w_{it} + u_{it}$$

Goodman-Bacon(2021) 指出，以上设定：可以写成所有 2×2 的DID结果的加权平均，但是会有负的权重，从而识别失败

Goodman-Bacon分解

- 首先考虑没有控制变量的简单情况， 2×2 的情况即最简单的只有处理组、对照组以及事前事后的设定：

$$y_{it} = c + \lambda \cdot d_t + \gamma \cdot g_i + \tau^{2 \times 2} \cdot d_t \cdot g_i + u_{it}$$

从而

$$\hat{\tau}^{2 \times 2} = \left(\bar{y}_{\text{Treat}}^{\text{Post}} - \bar{y}_{\text{Treat}}^{\text{Pre}} \right) - \left(\bar{y}_{\text{Control}}^{\text{Post}} - \bar{y}_{\text{Control}}^{\text{Pre}} \right)$$

- 然而对于多期DID, 每个个体接受处理的时间 t_i 是不同的, TWFE估计量:

$$y_{it} = \alpha_i + \lambda_t + \tau \cdot w_{it} + u_{it}$$

分步回归得到:

$$\hat{\tau} = \frac{\hat{\mathbb{C}}(y_{it}, \tilde{w}_{it})}{\hat{\mathbb{V}}(\tilde{w})} = \frac{\frac{1}{NT} \sum_i \sum_t y_{it} \tilde{w}_{it}}{\frac{1}{NT} \sum_i \sum_t \tilde{w}_{it}^2}$$

其中 $\tilde{w}_{it} = (w_{it} - \bar{w}_i) - (\bar{w}_t - \bar{\bar{w}})$, 即使用 w 对 α_i, λ_t 双向固定效应回归得到的残差。

Goodman-Bacon分解

DID分解定理（续）

其中 $n_k = \sum_i \mathbb{1}\{t_i=k\}/N$, $\bar{w}_k = \sum_t \mathbb{1}\{t \geq k\}/T$, 此外

$$\hat{V}_{kl}^{w,k} = n_{kl} (1 - n_{kl}) \frac{\bar{w}_k - \bar{w}_l}{1 - \bar{w}_l} \frac{1 - \bar{w}_k}{1 - \bar{w}_l}$$

$$\hat{V}_{kl}^{w,l} = n_{kl} (1 - n_{kl}) \frac{\bar{w}_l}{\bar{w}_k} \frac{\bar{w}_k - \bar{w}_l}{\bar{w}_k}$$

且 $\sum_{j \neq u} s_{k\infty} + \sum_{k \neq \infty} \sum_{l > k} [s_{kl}^k + s_{kl}^l] = 1$ 。

Goodman-Bacon分解

- 如果有 K 个不同的处理组cohort:
 - 有 K 个 $\hat{\tau}_{j\infty}^{2 \times 2}$
 - 有 $K^2 - K$ 个 $\hat{\tau}_{kl}^{2 \times 2, k}$ 以及 $\hat{\tau}_{kl}^{2 \times 2, l}$
 - 总共有 K^2 个不同的 2×2 DID估计量。
- 问题：这样做可以识别什么？



TWFE的识别问题

- 记潜在结果 $y_{it}(k)$ 为一个属于 k 的cohort的个体 i 在第 t 期如果被处理的处理效应，从而 $y_{it}(t_i)$ 为实际看到的结果，记没有受到处理的潜在结果为 $y_{it}(\infty)$ ，如果 $t < t_i$ ，那么 $y_{it}(t_i) = y_{it}(\infty)$ 。
- 观察到的结果为：

$$y_{it} = w_{it}y_{it}(t_i) + (1 - w_{it})y_{it}(\infty)$$

- 定义cohort k 在 $t \geq k$ 的ATT：

$$\text{ATT}_k(t) = \mathbb{E}[y_{it}(k) - y_{it}(\infty) | t_i = k]$$

- 对于某个时间段 $\mathcal{T}$ ，定义这一时间段的平均处理效应：

$$\text{ATT}_k(\mathcal{T}) = \frac{1}{|\mathcal{T}|} \sum_{t \in \mathcal{T}} \mathbb{E}[y_{it}(k) - y_{it}(\infty) | t_i = k]$$

TWFE的识别问题

- 记两个时间段假设未处理的潜在结果之差：

$$\Delta y_k^\infty(\mathcal{T}_1, \mathcal{T}_0) = \frac{1}{|\mathcal{T}_1|} \sum_{t \in \mathcal{T}_1} \mathbb{E}[y_{it}(\infty) | t_i = k] - \frac{1}{|\mathcal{T}_0|} \sum_{t \in \mathcal{T}_0} \mathbb{E}[y_{it}(\infty) | t_i = k]$$

- 那么对于 $j = k, l$:

$$\begin{aligned} \beta_{j\infty}^{2 \times 2} &= \left(\frac{1}{|\text{Post}(j)|} \sum_{t \in \text{Post}(j)} \mathbb{E}(y_{it}(k) | t_i = k) - \frac{1}{|\text{Pre}(j)|} \sum_{t \in \text{Pre}(j)} \mathbb{E}(y_{it}(\infty) | t_i = k) \right) \\ &\quad - \left(\frac{1}{|\text{Post}(j)|} \sum_{t \in \text{Post}(j)} \mathbb{E}(y_{it}(\infty) | t_i = \infty) - \frac{1}{|\text{Pre}(j)|} \sum_{t \in \text{Pre}(j)} \mathbb{E}(y_{it}(\infty) | t_i = \infty) \right) \\ &= \text{ATT}_k(\text{Post}(j)) \\ &\quad + [\Delta y_k^\infty(\text{Post}(j), \text{Pre}(j)) - \Delta y_\infty^\infty(\text{Post}(j), \text{Pre}(j))] \end{aligned}$$

TWFE的识别问题

- 同理：

$$\beta_{kl}^{2 \times 2, k} = ATT_k(\text{Mid}(k, l)) \\ + [\Delta y_k^\infty(\text{Mid}(k, l), \text{Pre}(k)) - \Delta y_l^\infty(\text{Mid}(k, l), \text{Pre}(k))]$$

$$\beta_{kl}^{2 \times 2, l} = ATT_k(\text{Post}(l)) \\ + [\Delta y_l^\infty(\text{Post}(l), \text{Mid}(k, l)) - \Delta y_k^\infty(\text{Post}(l), \text{Mid}(k, l))] \\ - [ATT_k(\text{Post}(l)) - ATT_k(\text{Mid}(k, l))]$$

TWFE的识别问题

最终，TWFE估计量识别了：

$$\hat{\tau} \xrightarrow{p} \text{VWATT} + \text{VWCT} - \Delta\text{ATT}$$

其中：

- 第一项：方差加权的ATT

$$\begin{aligned} \text{VWATT} = & \sum_{j \neq u} \sigma_{k\infty} \text{ATT}_k(\text{Post}(j)) \\ & + \sum_{k \neq \infty} \sum_{l > k} \left[\sigma_{kl}^k \text{ATT}_k(\text{Mid}(k, l)) + \sigma_{kl}^l \text{ATT}_k(\text{Post}(l)) \right] \end{aligned}$$

TWFE的识别问题

- 第二项：方差加权的平行趋势

$$\begin{aligned} \text{VWCT} = & \sum_{j \neq u} \sigma_{k\infty} [\Delta y_k^\infty (\text{Post}(j), \text{Pre}(j)) - \Delta y_\infty^\infty (\text{Post}(j), \text{Pre}(j))] \\ & + \sum_{k \neq \infty} \sum_{l > k} \{ \sigma_{kl}^k [\Delta y_k^\infty (\text{Mid}(k, l), \text{Pre}(k)) - \Delta y_l^\infty (\text{Mid}(k, l), \text{Pre}(k))] \\ & + \sigma_{kl}^l [\Delta y_l^\infty (\text{Post}(l), \text{Mid}(k, l)) - \Delta y_k^\infty (\text{Post}(l), \text{Mid}(k, l))] \} \end{aligned}$$

- 接下来假设平行趋势满足，从而 $\text{VWCT} = 0$ 。
- 第三项：处理效应异质性：

$$\Delta \text{ATT} = \sum_{k \neq \infty} \sum_{l > k} \sigma_{kl}^l [\text{ATT}_k (\text{Post}(l)) - \text{ATT}_k (\text{Mid}(k, l))]$$

识别：个体异质性但无时间异质性的处理效应

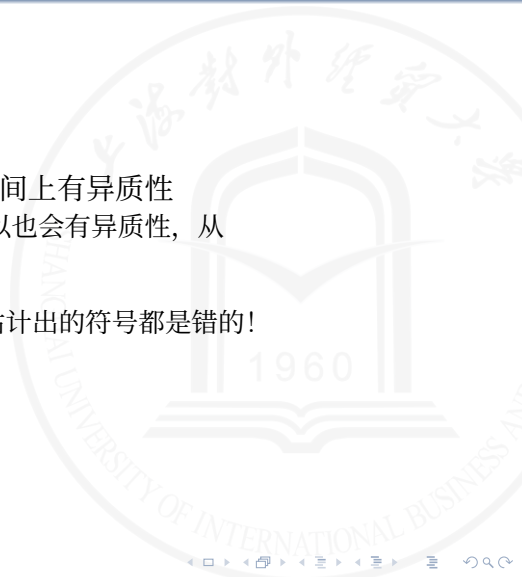
- 第一种情况：个体有异质性，但没有时间异质性，从而 $ATT_k(\mathcal{T}) = ATT_k$
 - 此时 $\Delta ATT = 0$
 - 识别了：

$$VWATT = \sum_{k \neq \infty} ATT_k \overbrace{\left[\sigma_{k\infty} + \sum_{j=1}^{k-1} \sigma_{jk}^k + \sum_{j=k+1}^K \sigma_{kj}^k \right]}^{\omega_k^T}$$


- 一般 $\omega_k^T \neq n_k$ ，从而没有识别ATT。与ATT的差距取决于：
 - 处理效应异质性的尺寸
 - 处理的timing
 - 研究权重 ω_k^T 或者直接加权（如Sun和Abraham，2021等）

识别：个体同质性、时间异质性的处理效应

- 第二种情况：个体处理效应同质，但是在时间上有异质性
 - 由于不同的 $\beta^{2 \times 2}$ 都在时间上计算平均，所以也会有异质性，从而VWATT与ATT不相等
 - $\Delta ATT \neq 0!$
 - 由于 ΔATT 前面的系数是负的，可能导致估计出的符号都是错的！



时间异质性的处理效应



动态设定

- 动态设定:

$$y_{it} = \alpha_i + \lambda_t + \sum_{\ell=-p, \ell \neq -1}^q \tau_{\ell} \cdot \mathbb{1}\{t = t_i + \ell\} + u_{it}$$

- Sun和Abraham (2021) 对这一设定进行了分析, 同样发现这一设定在异质性存在的情况下识别可能是有问题的
- 定义cohort的ATT (CATT) :

$$\text{CATT}_{k,\ell} = \mathbb{E}[y_{i,k+\ell}(k) - y_{i,k+\ell}(0) | t_i = k]$$

动态设定的潜在假定

平行趋势假定

对于 $s \neq t$, 对于所有的 w , 有 $\mathbb{E}[y_{it}(\infty) - y_{is}(\infty) | t_i = k]$ 都相等。

- 实证中: $w = \infty$, 即控制组 (never treated) 可能不满足这一假定, 那么需要控制组排除
- Goodman-Bacon: 加权版本的平行趋势, 比这里的条件弱

动态设定的潜在假定

处理前不可预见假设 (no anticipatory behavior prior to treatment)

在处理之前没有处理效应，即对于所有的 k 和 $\ell < 0$ ，
有 $\mathbb{E}[y_{i,k+\ell}(k) - y_{i,k+\ell}(\infty) | t_i = k] = 0$

- 不会根据对未来的预见调整行为
- 最好是个体根本不能预见整个的路径
- Goodman-Bacon: 假定如果 $t < t_i$ ，那么 $y_{it}(t_i) = y_{it}(\infty)$ ，更强

动态设定的潜在假定

处理效应相对时间同质性

对于每个 ℓ , $CATT_{k,\ell}$ 与 k 无关, 从而 $CATT_{k,\ell} = ATT_{\ell}$.

- 每个个体都有相同的处理效应路径 (而不管是哪个cohort)

静态与动态设定

- 令 $w_{it}^{\ell} = \mathbb{1}\{t = t_i + \ell\}$, 从而

$$w_{it} = \sum_{\ell \geq 0} w_{it}^{\ell}$$

- 那么静态设定为:

$$y_{it} = \alpha_i + \lambda_t + \tau \sum_{\ell \geq 0} w_{it}^{\ell} + u_{it}$$

- 动态设定为:

$$y_{it} = \alpha_i + \lambda_t + \sum_{\ell=-P}^{-2} \tau_{\ell} w_{it}^{\ell} + \sum_{\ell=0}^L \tau_{\ell} w_{it}^{\ell} + u_{it}$$

- 完全动态设定, 考虑事前超过 P 期、事后超过 L 期的情况:

$$y_{it} = \alpha_i + \lambda_t + \tau_{-Pb} \sum_{\ell < -P} w_{it}^{\ell} + \sum_{\ell=-P}^{-2} \tau_{\ell} w_{it}^{\ell} + \sum_{\ell=0}^L \tau_{\ell} w_{it}^{\ell} + \tau_{Lf} \sum_{\ell > L} w_{it}^{\ell} + u_{it}$$

统一设定

将以上设定统一为

$$y_{it} = \alpha_i + \lambda_t + \sum_{g \in \mathcal{G}} \tau_g \cdot \mathbb{1}\{t - t_i \in g\} + u_{it}$$

其中需要有一个组被排除，记为 $g^{\text{excl}} = \{\ell : \ell \notin \mathcal{G}\}$ 。

- 静态设定： $g = [0, T], g^{\text{excl}} = [-T, -1]$
- 动态设定： $g^{\text{excl}} = \{-T, \dots, -K - 1, -1, L + 1, \dots, T\}$
- 完全动态： $g^{\text{excl}} = \{-1\}$

识别

回归系数的识别

使用如上设定，系数识别了：

$$\begin{aligned}\tau_g = & \sum_{\ell \in g} \sum_{k \neq \infty} \omega_{k,\ell}^g [\mathbb{E}(y_{i,k+\ell} - y_{i,0}(\infty) | t_i = k) - \mathbb{E}(y_{i,k+\ell}(\infty) - y_{i,0}(\infty))] \\ & + \sum_{g' \neq g, g' \in \mathcal{G}} \sum_{\ell \in g'} \sum_{k \neq \infty} \omega_{k,\ell}^{g'} [\mathbb{E}(y_{i,k+\ell} - y_{i,0}(\infty) | t_i = k) - \mathbb{E}(y_{i,k+\ell}(\infty) - y_{i,0}(\infty))] \\ & + \sum_{\ell \in g^{excl}} \sum_{k \neq \infty} \omega_{k,\ell}^g [\mathbb{E}(y_{i,k+\ell} - y_{i,0}(\infty) | t_i = k) - \mathbb{E}(y_{i,k+\ell}(\infty) - y_{i,0}(\infty))] \\ & + \sum_t \omega_{\infty,t}^g [\mathbb{E}(y_{it} - y_{i,0}(\infty) | t_i = \infty) - \mathbb{E}(y_{it}(\infty) - y_{i,0}(\infty))]\end{aligned}$$

- τ_g 不仅仅含有 $\ell \in g$ 的部分，还有 $\ell \in \mathcal{G} - g$ 的部分以及 $\ell \in g^{excl}$ 的部分！
- $\omega_{w,\ell}^g$ 可以通过估计：

$$w_{it}^\ell \cdot \mathbb{1}\{t_i = k\} = \alpha_i + \lambda_t + \sum \omega_{w,\ell}^g \cdot \mathbb{1}\{t - t_i \in g\} + v_{it}$$

权重

- 对于 $\ell \in g$, 相应的权重:

$$\sum_{\ell \in g} \sum_k \omega_{k,\ell}^g = 1$$

- 对于 $\ell \in g', \ell \in \mathcal{G} - g$, 权重:

$$\sum_{\ell \in g'} \sum_k \omega_{k,\ell}^g = 0$$

- 对于排除组, 权重:

$$\sum_{\ell \in g^{excl}} \sum_k \omega_{k,\ell}^g = -1$$

识别+共同趋势假设

- 如果假设共同趋势，那么以上所有的

$$\begin{aligned} & \mathbb{E}(y_{i,k+l} - y_{i,0}(\infty) | t_i = k) - \mathbb{E}(y_{i,k+l}(\infty) - y_{i,0}(\infty)) \\ &= \mathbb{E}(y_{i,k+l} - y_{i,0}(\infty) | t_i = k) - \mathbb{E}(y_{i,k+l}(\infty) | t_i = k) + \mathbb{E}(y_{i,k+l}(\infty) | t_i = k) \\ & \quad - \mathbb{E}(y_{i,k+l}(\infty) - y_{i,0}(\infty)) \\ &= \text{CATT}_{w,\ell} + \mathbb{E}(y_{i,k+l}(\infty) - y_{i,0}(\infty) | t_i = k) - \mathbb{E}(y_{i,k+l}(\infty) - y_{i,0}(\infty)) \\ &= \text{CATT}_{w,\ell} \end{aligned}$$

- 从而

$$\begin{aligned} \tau_g &= \sum_{\ell \in g} \sum_k \omega_{k,\ell}^g \text{CATT}_{w,\ell} \\ &+ \sum_{g' \neq g, g' \in \mathcal{G}} \sum_{\ell \in g'} \sum_k \omega_{k,\ell}^{g'} \text{CATT}_{w,\ell} \\ &+ \sum_{\ell \in g^{excl}} \sum_{k \neq \infty} \omega_{k,\ell}^g \text{CATT}_{w,\ell} \end{aligned}$$

识别+共同趋势假设+其他假设

- 如果额外假设无预见，那么对于 $\ell < 0$, $\mathbb{E}(y_{i,k+\ell} - y_{i,k+\ell}(\infty) | t_i = k) = 0$, 从而:

$$\tau_g = \sum_{\ell \in g, \ell \geq 0} \sum_k \omega_{k,\ell}^g \text{CATT}_{w,\ell} + \sum_{g' \neq g, g' \in \mathcal{G}} \sum_{\ell \in g', \ell \geq 0} \sum_k \omega_{k,\ell}^g \text{CATT}_{w,\ell} + \sum_{\ell \in g^{\text{excl}}, \ell \geq 0} \sum_{k \neq \infty} \omega_{k,\ell}^g \text{CATT}_{w,\ell}$$

- 如果额外假设处理效应相对时间同质性假设:

$$\tau_g = \sum_{\ell \in g} \omega_{\ell}^g \text{CATT}_{\ell} + \sum_{g' \neq g, g' \in \mathcal{G}} \sum_{\ell \in g'} \omega_{\ell}^g \text{CATT}_{\ell} + \sum_{\ell \in g^{\text{excl}}} \omega_{\ell}^g \text{CATT}_{\ell}$$

其中 $\omega_{\ell}^g = \sum_k \omega_{k,\ell}^g$, 可以通过估计:

$$w_{it}^{\ell} = \alpha_i + \lambda_t + \sum_{g \in \mathcal{G}} \omega_{\ell}^g \cdot \mathbb{1}\{t - t_i \in g\} + v_{it}$$

得到 (eventstudyweights)

- 完全动态设定:

$$\tau_{\ell} = \text{ATT}_{\ell} + \sum_{\ell' \in g^{\text{excl}}} \omega_{\ell'}^{\ell} \text{ATT}_{\ell'}$$

即使完全动态设定, 得到的结果也会被排除组所污染 (contaminated)

异质性处理效应

放弃处理效应的相对时间同质性假设，Sun和Abraham（2021）提出使用如下回归：

$$Y_{it} = \alpha_i + \lambda_t + \sum_{k \notin C} \sum_{\ell \neq -1} \delta_{k,\ell} \cdot \mathbb{1}\{t_i = k\} \cdot \mathbb{1}\{t = t_i + \ell\} + u_{it}$$

其中：

- $\mathbb{1}\{t_i = k\}$ 为cohort虚拟变量
- $\mathbb{1}\{t = t_i + \ell\}$ 为政策发生时间之后期数的虚拟变量
- C 为控制组（从未受到处理的组），或者最晚受到处理的组

如此， $\delta_{k,\ell}$ 估计了 $CATT_{k,\ell}$ 。接下来，使用 $CATT_{k,\ell}$ 的加权平均：

$$\hat{v}_g = \frac{1}{|g|} \sum_{\ell \in g} \sum_k \hat{\delta}_{k,\ell} \times w_k$$

其中 w_k 为cohort k 的比例。以上成为交互加权估计量（interaction-weighted estimator）

Callaway和San' t Anna (2021)

Callaway和San' t Anna (2021) 使用了另外的处理方法，但是极其类似：

- 非参数识别（使用never group）：

$$ATT(k, t; \delta) = \mathbb{E} \left[\left(\frac{w_{it}^g}{\mathbb{E}[w_{it}^g]} - \frac{\frac{p_k(X)C}{1-p_k(X)}}{\mathbb{E}\left[\frac{p_k(X)C}{1-p_k(X)}\right]} \right) (y_t - y_{g-\delta-1}) \right]$$

- 可以扩展到doubly robust
- 命令：csdid

CIC模型

非线性DID: CIC (Athey and Imbens, 2006)

假设:

- ① $Y_i(0) = h(U_i, T_i)$, 其中 $h(\cdot, \cdot)$ 对 U_i 为单调的函数, T_i 为时间
- ② $U \perp\!\!\!\perp T | G$, 即给定分组, U 的分布与时间独立
- ③ support 假设

关键结论:

$$F_{Y^{N,11}}(y) = F_{Y,10} \left(F_{Y,00}^{-1} (F_{Y,01}(y)) \right)$$

其中 $F_{Y,gt}$ 为分布函数。进而处理效应:

$$\tau_{CIC} = \mathbb{E}(Y_{11}) - \mathbb{E}(F_{01}^{-1}(F_{00}(Y_{10})))$$

合成控制法

- 在一些比较宏观的问题上，处理组个体非常少（甚至只有一个）——DID失效。
- 可能的解决办法：通过控制组个体的凸组合来构造反事实。
- 假设 $i = 0, 1, \dots, N$ 个个体， $i = 0$ 被处理，其他未被处理。
- 假设 $T = 1, \dots, T$ ， $i = 0$ 被处理的时间为 T_0
- 通过因子模型理解：如果未经过处理的个体数据生成过程为：

$$Y_{it}(0) = F_t' \lambda_i + Z_i' \zeta_t + u_{it}$$

那么可以使用控制组的Y预测处理组的Y

合成控制法

- 令 X_0 为 T_0 之前的 $i = 0$ 个体的 k 个特征（如 Y_1 以及 Z_1 ）；相应的， $X_{J \times k}$ 为 T_0 之前的其他 J 个个体的特征
- 为 J 个个体赋予不同权重： $w_1, \dots, w_J$ ， $w_1 + \dots + w_J = 1$ 且 $w_j \geq 0$ （凸组合）
- 给定一个半正定矩阵 V ，选取权重：

$$w^* = \arg \min_w (X_0 - X'w)' V (X_0 - X'w)$$

- 特殊情况，如果 $X_0 = [Y_{00}, \dots, Y_{0, T_0-1}]$ ，那么即使用处理组 Y_0 对控制组 Y_j 做时间序列回归
- 则处理效应：

$$\tau_{0t} = Y_{0t} - \sum_{j=1}^J w_j^* Y_{jt}$$

HCW方法中的Lasso

Li和Bell(2017)推荐使用Lasso方法作为HCW方法中的模型选择

- 实例：中欧班列开通对于陕西省出口的影响：hew_lasso.do

