

无混淆分配下的因果推断

慧航

2025年11月

匹配的假设

在Unconfoundedness假设条件下，可以方便的得到处理效应的识别。关键假设：

- ① Unconfoundedness假设（CIA假设）：

$$w_i \perp\!\!\!\perp (y_i(1), y_i(0)) | x$$

- ② 共同支撑假设（Common support assumption, CSA）：

$$0 < P(w_i = 1 | x_i) < 1$$

匹配的原理

CIA意味着均值独立，即：

$$\mathbb{E}(y_i(1) | x_i, w_i) = \mathbb{E}(y_i(1) | x_i)$$

$$\mathbb{E}(y_i(0) | x_i, w_i) = \mathbb{E}(y_i(0) | x_i)$$

而CSA需要对于相同的 x_i ，都有处理组和非处理组：经常需要trimming。

匹配的原理

由于:

$$\begin{aligned}\mathbb{E}(y_i|w_i = 1, x_i) - \mathbb{E}(y_i|w_i = 0, x_i) \\&= \mathbb{E}(y_i(1) | x_i, w_i = 1) - \mathbb{E}(y_i(0) | x_i, w_i = 0) \\&= \mathbb{E}(y_i(1) | x_i) - \mathbb{E}(y_i(0) | x_i) \\&= \mathbb{E}(y_i(1) - y_i(0) | x_i)\end{aligned}$$

因而

$$\mathbb{E}[\mathbb{E}(y_i|w_i = 1, x_i) - \mathbb{E}(y_i|w_i = 0, x_i)] = \mathbb{E}(y_i(1) - y_i(0))$$

同理:

$$\begin{aligned}\mathbb{E}[\mathbb{E}(y_i|w_i = 1, x_i) - \mathbb{E}(y_i|w_i = 0, x_i) | w_i = 1] = \\ \mathbb{E}(y_i(1) - y_i(0) | w_i = 1)\end{aligned}$$

无混淆分配下的推断：回归方法

方法一：回归
设定

$$\mathbb{E}(y_i | w_i = 1, x_i) = \mathbb{E}(y_i(1) | x_i) = \mu_1(x_i)$$

$$\mathbb{E}(y_i | w_i = 0, x_i) = \mathbb{E}(y_i(0) | x_i) = \mu_0(x_i)$$

平均处理效应：

$$\hat{\tau}_{reg} = \frac{1}{N} \sum_{i=1}^N [\hat{\mu}_1(x_i) - \hat{\mu}_0(x_i)]$$

① 简单线性回归：

$$y_i = \alpha + x_i' \beta + \tau \cdot w_i + \epsilon_i$$

或者：

$$y_i = \alpha + \dot{x}_i' \beta + \tau \cdot w_i + w_i \dot{x}_i' \delta + \epsilon_i$$

② 非参数回归

无混淆分配下的推断：匹配

或者：

- Nearest Neighbor Matching:

- ① 给定一个正的常数 M ，比如 $M = 1$
- ② 令 $d(\cdot, \cdot)$ 为一个距离函数，比如欧几里得距离：

$$d(x_i, x_j) = (x_i - x_j)'(x_i - x_j)$$

或者Mahalanobis距离：

$$d(x_i, x_j) = (x_i - x_j)' \Sigma_x^{-1} (x_i - x_j)$$

- caliper：距离小于一个临界值（caliper）即匹配成功

临近匹配

Nearest-neighbor matching: 对于任意处理组的 i , 从控制组中找到最近的 M 个控制组个体, 记:

$$J_M(i) = \{l_1(i), \dots, l_M(i)\}$$

定义

$$\hat{y}_i(0) = \frac{1}{M} \sum_{m \in J_M(i)} y_m$$

可以使用:

$$\frac{1}{N_1} \sum_{i|w_i=1} [y_i(1) - \hat{y}_i(0)]$$

匹配的细节

实践中，有不同的匹配方案：

- ① 选择 M ，一般而言如果控制组数量远远大于实验组数量，可以使用较多的 M
- ② 序贯/非序贯
 - 序贯：按顺序一个一个配对
 - 非序贯：所有的实验组和控制组放在一起考虑
- ③ 贪婪/非贪婪
 - 贪婪：有放回
 - 非贪婪：无放回
- ④ 先进行分组或者分层（stratification），组内进行匹配
- ⑤ 使用propensity score进行排序，进而匹配
- ⑥ Stata:
 - psmatch2
 - teffects nnmatch（推荐）

匹配的步骤

倾向得分匹配的步骤：

- ① 定义距离
- ② 匹配
- ③ 评估匹配结果：
 - ① balancing: t -test、Standardised Bias
 - ② unconfoundedness: 使用明显无效应的其他的Y
- ④ 评估政策效应
- ⑤ 敏感性分析



评估匹配结果：协变量

评估匹配结果：

① normalized difference:

$$\hat{\Delta}_{ct} = \frac{\bar{x}_t - \bar{x}_c}{\sqrt{\frac{s_c^2 + s_t^2}{2}}}$$

② t -stat:

$$T_{ct} = \frac{\bar{x}_t - \bar{x}_c}{\sqrt{\frac{s_c^2}{N_c} + \frac{s_t^2}{N_t}}}$$

Stata: `tebalance`

Balancing

Table 16: SUMMARY STATISTICS FOR NON-EXPERIMENTAL LALONDE DATA

Covariate	CPS controls ($N_c=15,992$)		trainees ($N_t=185$)		t-stat	nor-dif
	mean	(s.d.)	mean	(s.d.)		
Black	0.07	0.26	0.84	0.36	28.6	2.43
Hisp	0.07	0.26	0.06	0.24	-0.7	-0.05
Age	33.23	11.05	25.82	7.16	-13.9	-0.80
Married	0.71	0.45	0.19	0.39	-18.0	-1.23
Nodegree	0.30	0.46	0.71	0.46	12.2	0.90
Education	12.03	2.87	10.35	2.01	-11.2	-0.68
E'74	14.02	9.57	2.10	4.89	-32.5	-1.57
U'74	0.12	0.32	0.71	0.46	17.5	1.49
E'75	13.65	9.27	1.53	3.22	-48.9	-1.75
U'75	0.11	0.31	0.60	0.49	13.6	1.19

	Full Sample	Matched Sample	ratio of
	nor-dif	nor-dif	nor-dif
Black	2.43	0.00	0.00
Hispanic	-0.05	0.00	-0.00
Age	-0.80	-0.15	0.19
Married	-1.23	-0.28	0.22
Nodegree	0.90	0.25	0.28
Education	-0.68	-0.18	0.26
E'74	-1.57	-0.03	0.02
U'74	1.49	0.02	0.02
E'75	-1.75	-0.07	0.04



Matching

其他匹配方法:

- 1 Kernel matching
- 2 Radius matching
- 3 Stratification or interval matching
- 4 Propensity score matching

倾向得分匹配

倾向得分 (Propensity score) 方法: Rosenbaum and Rubin(1983)证明:

$$w_i \perp\!\!\!\perp (y_i(1), y_i(0)) | x_i \iff w_i \perp\!\!\!\perp (y_i(1), y_i(0)) | P(x_i)$$

因而控制倾向得分匹配就足够了。

倾向得分匹配

Rosenbaum and Rubin(1983)提出了三阶段的方法:

- ① 估计倾向得分:

$$P(w_i|x_i)$$

- ② 用 y_i 对 w_i 和 p_i 做回归, 得到 $\hat{e}(y_i|w_i, p_i)$

- ③ 估计ATT:

$$\frac{1}{N_1} \sum_{i|w_i=1} [y_i(1) - \hat{y}_i(0)]$$

注意在使用Propensity Score时, 一定要注意Common support假设:
trimming!

逆概率加权法

注意到，由于：

$$\begin{aligned}\mathbb{E}\left(\frac{w_i y_i}{P(x_i)}\right) &= \mathbb{E}\left(\frac{w_i y_i(1)}{P(x_i)}\right) \\ &= \mathbb{E}\left[\mathbb{E}\left(\frac{w_i y_i(1)}{P(x_i)} \mid x_i\right)\right] \\ &= \mathbb{E}\left[\frac{\mathbb{E}(w_i y_i(1) \mid x_i)}{P(x_i)}\right] \\ &= \mathbb{E}\left[\frac{\mathbb{E}(w_i \mid x_i) \mathbb{E}(y_i(1) \mid x_i)}{P(x_i)}\right] \\ &= \mathbb{E}[\mathbb{E}(y_i(1) \mid x_i)] = \mathbb{E}(y_i(1))\end{aligned}$$

同理：

$$\mathbb{E}\left(\frac{(1-w_i) y_i}{1-P(x_i)}\right) = \mathbb{E}(y_i(0))$$

逆概率加权法

因而平均处理效应：

$$\tau_{ATE} = \mathbb{E} \left[\frac{w_i y_i}{P(x_i)} - \frac{(1 - w_i) y_i}{1 - P(x_i)} \right]$$

可以使用：

$$\hat{\tau}_{ATE} = \frac{1}{N} \sum_{i=1}^N \left[\frac{w_i y_i}{P(x_i)} - \frac{(1 - w_i) y_i}{1 - P(x_i)} \right]$$

进行估计，称为Inverse Propensity Weighting(IPW)。其中 $P(x_i)$ 可以使用Logistic sieve估计量（Hirano, Imbens and Ridder, 2003）。

Stata: teffects ipw

双向稳健的处理效应评估方法

然而IPW方法对倾向得分非常敏感。可以考虑使用Robins等人提出的双向稳健 (Double robustness) 方法:

- ① 结合了回归方法和IPW
- ② 只需要 $P(x_i)$ 或者结果方程至少有一个设定正确 (双向稳健)

最小化:

$$\min_{\alpha_0, \beta_0} \sum_{i|w_i=0} \frac{[y_i - \alpha_0 - \beta_0'(x_i - \bar{x}_i)]^2}{1 - P(x_i; \hat{\gamma})}$$
$$\min_{\alpha_1, \beta_1} \sum_{i|w_i=1} \frac{[y_i - \alpha_1 - \beta_1'(x_i - \bar{x}_i)]^2}{P(x_i; \hat{\gamma})}$$

平均处理效应为:

$$\hat{\tau}_{ATE} = \hat{\alpha}_1 - \hat{\alpha}_0$$

Stata: `teffects aipw`

双向稳健的处理效应评估方法

- 不妨考虑一阶条件（对 α_1 求导）：

$$-2 \sum \frac{w_i [y_i - \alpha_1 - \beta'_1 (x_i - \bar{x})]}{P(x_i; \hat{\gamma})} = 0$$

- 考虑其总体形式

$$\begin{aligned}\mathbb{E} \left(\frac{w_i [y_i - \alpha_1 - \beta'_1 (x_i - \bar{x})]}{P(x_i; \hat{\gamma})} \right) &= \mathbb{E} \left[\mathbb{E} \left(\frac{w_i [y_i - \alpha_1 - \beta'_1 (x_i - \bar{x})]}{P(x_i; \hat{\gamma})} \middle| x_i \right) \right] \\ &= \mathbb{E} \left[\frac{\mathbb{E} (w_i [y_i - \alpha_1 - \beta'_1 (x_i - \bar{x})] | x_i)}{P(x_i; \hat{\gamma})} \right] \\ &= \mathbb{E} \left[\frac{\mathbb{E} (w_i [y_i (1) - \alpha_1 - \beta'_1 (x_i - \bar{x})] | x_i)}{P(x_i; \hat{\gamma})} \right] \\ &= \mathbb{E} \left[\frac{\mathbb{E} (w_i | x_i) \mathbb{E} (y_i (1) - \alpha_1 - \beta'_1 (x_i - \bar{x}) | x_i)}{P(x_i; \hat{\gamma})} \right]\end{aligned}$$

双向稳健的处理效应评估方法

- 总体一阶条件:

$$\mathbb{E} \left[\frac{\mathbb{E}(w_i | x_i) \mathbb{E}(y_i(1) - \alpha_1 - \beta'_1(x_i - \bar{x}) | x_i)}{P(x_i; \hat{\gamma})} \right] = 0$$

的两种情况:

- $P(x_i; \hat{\gamma})$ 正确设定: 那么 $\alpha_1 = \mathbb{E}[\mathbb{E}(y_i(1))] = \mathbb{E}(y_i(1))$
- $y_i(1)$ 函数形式设定正确: $\mathbb{E}(y_i(1) - \alpha_1 - \beta'_1(x_i - \bar{x}) | x_i) = 0$ 成立, α_1 得到一致估计。

Matching

其他方法：Imai and Ratkovic (2014): 解：

$$\frac{1}{N} \sum_{i=1}^N g_{\gamma}(w_i, x_i) = \frac{1}{N} \sum_{i=1}^N \left[\left(\frac{w_i}{P(x_i; \gamma)} - \frac{1 - w_i}{1 - P(x_i; \gamma)} \right) f(x_i) \right] = 0$$

仍然是双向稳健的。此外，Fan et al. (2016)做了推广。

DDML与因果推断

- 以上讨论的部分线性模型可以看做是对同质性处理效应的建模，即假设数据生成过程为：

$$y_i = \tau w_i + g(x_i) + u_i$$

其中 $w = 0/1$ 为处理变量。根据该设定，其反事实为

$$y_i(0) = g(x_i) + u_i$$

$$y_i(1) = \tau + g(x_i) + u_i$$

那么处理效应 $y_i(1) - y_i(0) = \tau$ ，从而平均处理效应与处理组平均处理效应相等，都为 τ 。

- 在无混淆分配的假设，即 $w_i \perp (y_i(0), y_i(1)) | x_i$ 的条件下，可以自然得到 $u_i \perp w_i | x_i$ ，从而我们可以使用双重机器学习的方法对以上问题进行估计。

异质性处理效应

- 然而以上模型对于处理效应同质性的假设仍然太强。为此我们不妨暂时放弃函数形式假设，先从识别层面探讨可能的异质性处理效应的识别问题。为此我们现引入如下假设：
 - ① 假设1. 无混淆分配假设： $w_i \perp\!\!\!\perp (y_i(0), y_i(1)) | x_i$
 - ② 假设2. 共同支撑假设：对于任意的 $x_i = x$ ，倾向得分 $p(x) \triangleq P(w_i = w | x_i = x) > 0, w = 0/1$
 - ③ 假设3. SUTVA假设： $y_i = y_i(w_i)$

条件平均处理效应

- 如此，如果记 $g(w, x) = \mathbb{E}(y_i | w_i = w, x_i = x)$ ，那么：

$$g(w, x) = \mathbb{E}(y_i | w_i = w, x_i = x) = \mathbb{E}(y_i(w) | w_i = w, x_i = x) = \mathbb{E}(y_i(w) | x_i = x)$$

- 以上等式意味着为了获得 $g(w, x)$ 的估计，我们可以使用根据 w 分组，使用 y 对 x 做回归分别得到 $g(0, x)$ 以及 $g(1, x)$ ，将两者相减就可以得到

$$g(1, x) - g(0, x) = \mathbb{E}(y_i(1) - y_i(0) | x_i = x) = \text{CATE}(x)$$

其中 $\text{CATE}(x)$ 为给定特征 x 的平均处理效应，或者条件平均处理效应（conditional average treatment effects）。

交互模型

- Chernozhukov等（2017）即考虑了这种数据生成过程：

$$y = g(w, x) + u$$



$$w = m(x) + v$$

其中无混淆分配假设即 $\mathbb{E}(u|w, x) = 0$ ，该设定实际上允许处理变量 w 与 x 之间任意的交互，或者说处理效应可以是 x 的任意函数，从而以上模型也被称为“交互模型”（interactive model）。

- 如果需要进一步得到ATE和ATT，可以计算

$$\text{ATE} = \mathbb{E}[g(1, x) - g(0, x)]$$

$$\text{ATT} = \mathbb{E}[g(1, x) - g(0, x) | w = 1]$$

逆概率加权

- 进一步，我们也可以将以上的识别方法写成逆概率加权的形式：

$$\begin{aligned}\mathbb{E}\left(\frac{w_i y_i}{p(x_i)} \middle| x_i = x\right) &= \frac{\mathbb{E}(w_i y_i | x_i = x)}{p(x)} = \frac{\mathbb{E}(w_i y_i(1) | x_i = x)}{p(x)} \\ &= \frac{\mathbb{E}(w_i | x_i = x) \mathbb{E}(y_i(1) | x_i = x)}{p(x)} \\ &= \mathbb{E}(y_i(1) | x_i = x)\end{aligned}$$

类似的，

$$\mathbb{E}\left[\frac{(1 - w_i) y_i}{1 - p(x_i)} \middle| x_i = x\right] = \mathbb{E}(y_i(0) | x_i = x)$$

- 从而条件平均处理效应可以使用

$$\text{CATE}(x) = \mathbb{E}\left[\frac{w_i y_i}{p(x_i)} - \frac{(1 - w_i) y_i}{1 - p(x_i)} \middle| x_i = x\right]$$

进行识别。

逆概率加权

- 而更进一步，我们可以证明

$$\mathbb{E}(y_i(1) | x_i = x) = \mathbb{E} \left[g(1, x_i) + \frac{w_i (y_i - g(1, x_i))}{p(x_i)} \middle| x_i = x \right]$$

$$\mathbb{E}(y_i(0) | x_i = x) = \mathbb{E} \left[g(0, x_i) + \frac{(1 - w_i) (y_i - g(0, x_i))}{1 - p(x_i)} \middle| x_i = x \right]$$

- 好处：在实证中， $g(\cdot, \cdot)$ 函数和 $p(x_i)$ 都需要通过模型进行估计，从而都可能会存在设定错误或者偏误。而这一方法的好处在于其是“双向稳健”（doubly robust）的，即只要 $g(\cdot, \cdot)$ 函数和 $p(x_i)$ 只要有一个估计准确，那么以上等式即成立。

DDML方法

- 基于此, Chernozhukov (2017) 提出可以通过定义

$$\psi(\tau, \eta; y_i, w_i, x_i) = g(1, x_i) - g(0, x_i) + \frac{w_i (y - g(1, x_i))}{p(x_i)} - \frac{(1 - w_i) (y - g(0, x_i))}{1 - p(x_i)} - \tau$$

并使用矩条件 $\mathbb{E}[\psi(\tau, \eta; y_i, w_i, x_i)] = 0$ 求解出平均处理效应 τ

- 其中 $\eta = (g(1, x), g(0, x), p(x))$ 为冗余参数。可以证明以上的矩条件是满足 Neyman 正交化条件的, 即

$$\partial_{\eta} \mathbb{E} \psi(\tau, \eta; y, w, x) |_{\eta=\eta_0} = 0$$

从而我们可以使用双重机器学习的方法对 τ 进行估计。

DDML方法

- 或者也可以对处理组平均处理效应进行评估。根据Farrell (2015)，有

$$\mathbb{E}(y_i(1) | w_i = 1) = \mathbb{E} \left[\frac{w_i y_i}{p_1} \right]$$

$$\mathbb{E}(y_i(0) | w_i = 1) = \mathbb{E} \left[\frac{w_i g(0, x_i)}{p_1} + \frac{p(x_i)}{p_1} \frac{(1 - w_i)(y_i - g(0, x_i))}{1 - p(x_i)} \right]$$

- 其中 p_1 为处理组样本量占总样本量的比例，从而处理组平均处理效应：

$$\mathbb{E}(y_i(1) - y_i(0) | w_i = 1) = \mathbb{E} \left[\frac{w_i (y_i - g(0, x_i))}{p_1} - \frac{p(x_i)}{p_1} \frac{(1 - w_i)(y_i - g(0, x_i))}{1 - p(x_i)} \right]$$

Chernozhukov (2017) 提出可以根据以上条件，定义

$$\psi(\tau, \eta; y_i, w_i, x_i) = \frac{w_i (y_i - g(0, x_i))}{p_1} - \frac{p(x_i)}{p_1} \frac{(1 - w_i)(y_i - g(0, x_i))}{1 - p(x_i)} - \tau \frac{w_i}{p_1}$$

其中 $\eta = (g(0, x), p(x), p_1)$ 为冗余参数。

DDML方法

NSW中的DDML

- 如上方法可以使用ddml命令直接进行估计，比如对于NSW项目的政策评估
- ddml_nsw.do

因果树

- 回归树通过不断划分特征空间的方法可以实现对 y 的预测或者对 w 的分类，这是一种“非参数”的方法：我们无需假设 y 或者 w 的数据生成过程，甚至也无需设置特征对 y 的影响的异质性，分类和回归树本身就可以发现这些“交互”作用。
- 那么是否可以将分类和回归树的方法直接用于处理效应的估计呢，从而解决异质性处理效应的估计问题呢？
- 如，我们可以构造一颗预测 y 的回归树，假设叶子结点的集合为 $\Pi = \{\ell_1, \dots, \ell_L\}$ ，我们可以仿照以上逆概率加权的方法，使用

$$\hat{\tau}_\ell = \frac{1}{\#\ell} \sum_{i \in \ell} \left[\frac{w_i y_i}{p(x_i)} - \frac{(1 - w_i) y_i}{1 - p(x_i)} \right]$$

对CATE进行估计。

- 然而以上方法存在很严重的问题。为了构建回归树，我们使用了逐步增加节点的纯度的方法，而纯度的增加就是节点内 y 的相似程度增加，而以上的估计本质上是在节点内对处理组和对照组的 y 进行加权比较，按照这样的算法，以上的比较结果将会是低估的，从而引入了偏差。

因果树

- Athey和Imbens (2016) 提出了适应因果推断的“因果树” (causal tree)，使用了一种“诚实方法” (honest approach) 构建树，从而达到对异质性处理效应的识别。
- 该方法的一个重要改进是将样本分为了两部分：训练集 I^{tr} 和估计集 I^{est} ，当然，为了选择超参数还可以多分出一个验证集。
- 重要的在于，在构建树的过程中仅仅使用训练集，而估计政策效应则使用估计集数据，因而这种树的构造方法也被称为“双样本树” (double-sample tree)。
- 此外，为了适应政策效应的评估，Athey和Imbens (2016) 还改进了构造树时的准则，使用期望的MSE作为准则估计，从而可以更好的估计政策效应。

因果森林

- 随后, Wager和Athey (2019) 进一步将因果树推广为因果森林 (causal forest)。他们提出了两种不同的方法:
 - 双样本树, 即使用Athey和Imbens (2016) 的方法, 每次从样本中进行有放回抽样, 在每个bootstrap样本中都进行双样本树的建模, 最后将每颗树得到的CATE平均得到最终的估计;
 - 倾向得分树: 不使用双样本的方法, 而是直接以 $w_{\{i\}}$ 作为训练目标构建树。
- Wager和Athey (2019) 证明以上因果森林的估计结果是渐近正态的, 且其渐近方差可以方便的估计出。
- Athey等 (2019) 又对以上方法做了更多拓展, 提出了“广义随机森林” (generalized random forest) 以解决更多的参数估计问题, 这里不再赘述。广义随机森林在R语言中可以使用grf包进行估计, 在Python中也可以使用EconML包进行分析。