

断点回归

断点回归 (Regression discontinuity) 用于政策变量仅仅取决于一个连续变量 x (running variable), 且在某个点 $x = c$ 处, 参与概率有跳跃的情况。

① Sharp RD:

$$W_i = 1 (X_i \geq c)$$

② Fuzzy RD

$$\lim_{x \downarrow c} P(W_i | X_i = c) \neq \lim_{x \uparrow c} P(W_i | X_i = c)$$

- 优点: 识别干净
- 缺点: 外部有效性
- 例子: 退休前后的消费情况

Sharp RD

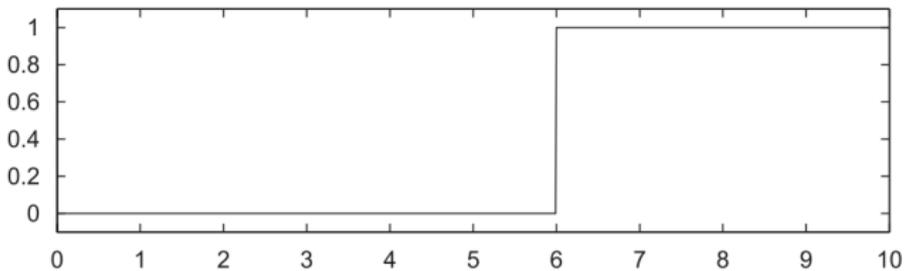


Fig. 1. Assignment probabilities (SRD).

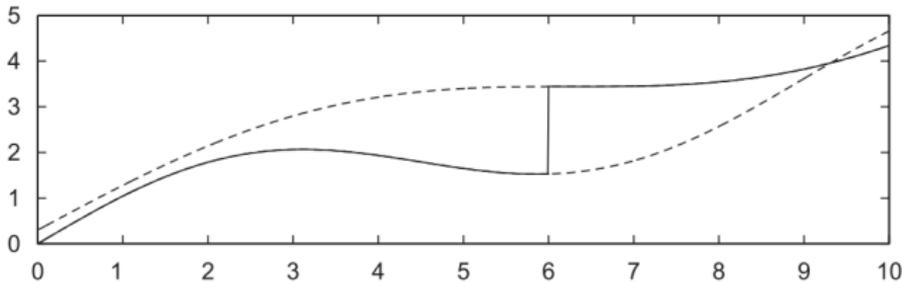


Fig. 2. Potential and observed outcome regression functions.

Sharp RD

政策效应:

$$\tau_{SRD} = \lim_{x \downarrow c} \mathbb{E}(Y_i | X_i = c) - \lim_{x \uparrow c} \mathbb{E}(Y_i | X_i = c)$$

估计:

- ① 参数方法×
- ② 非参数方法:
 - ① 在 $X = c$ 两边取两个小邻域计算均值
 - ② Local constant
 - ③ Local polynomial (Local linear): 使用多项式在 $X = c$ 两边 $((c - h, c + h))$ 对outcome进行拟合

Sharp RD

令 $S_i = 1 \{X_i \geq c\}$, 对于Sharp RD, 即 $S_i = W_i$, 对于设定:

$$\begin{aligned} Y_i &= \alpha + \tau \cdot S_i + S_i f_r(X_i - c) + (1 - S_i) f_l(X_i - c) + u_i \\ &= \alpha + \tau \cdot S_i + S_i \cdot f_r(X_i - c) + [1 - S_i] f_l(X_i - c) + u_i \end{aligned}$$

- 当 $X_i < c$ 时: $Y_i = \alpha + f_l(X_i - c) + u_i$
 - 若 $X_i \rightarrow c$, 由于 $f_l(0) = 0$, 从而在 $X_i = c$ 处的截距项为 α
- 当 $X_i > c$ 时: $Y_i = \alpha + \tau + f_r(X_i - c) + u_i$
 - 若 $X_i \rightarrow c$, 由于 $f_r(0) = 0$, 从而在 $X_i = c$ 处的截距项为 $\alpha + \tau$
- 因而 τ 就是在 $X = c$ 处的 jump, 即此处的处理效应

Fuzzy RD

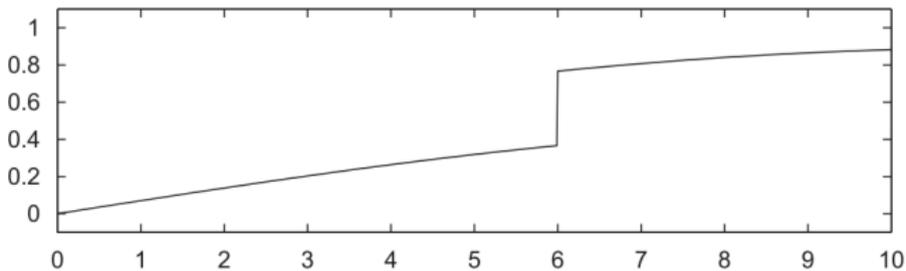


Fig. 3. Assignment probabilities (FRD).

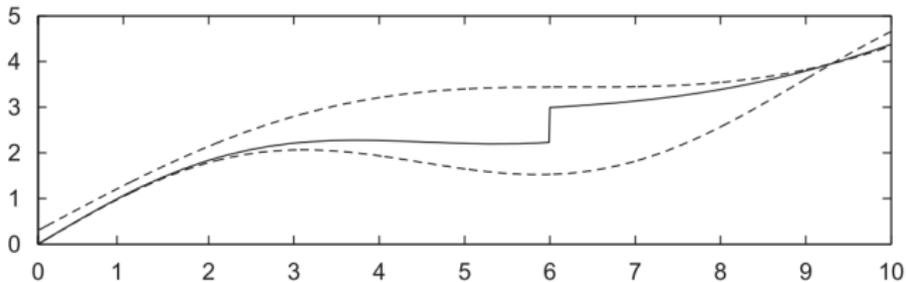


Fig. 4. Potential and observed outcome regression (FRD).

Fuzzy RD

对于Fuzzy RD, $S_i \neq W_i$ 。思想: S_i 作为 W_i 的工具变量:

- Intention-to-treat (ITT):

$$Y_i = \alpha_1 + \tau_{ITT} \cdot S_i + S_i \cdot f_r(X_i - c) + [1 - S_i] f_l(X_i - c) + u_i$$

- 政策概率:

$$W_i = \alpha_2 + \delta \cdot S_i + S_i \cdot g_r(X_i - c) + [1 - S_i] g_l(X_i - c) + v_i$$

- 结构方程:

$$Y_i = \alpha + \tau \cdot W_i + S_i \cdot h_r(X_i - c) + [1 - S_i] h_l(X_i - c) + \epsilon_i$$

Fuzzy RD

估计:

- ① 根据以上可知:

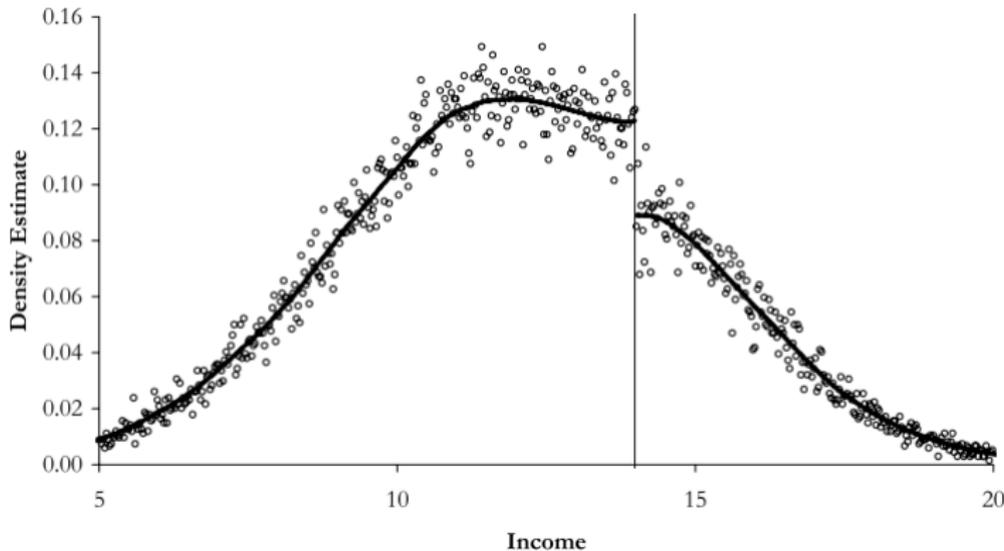
$$\tau = \frac{\tau_{ITT}}{\delta}$$

其中 τ_{ITT} 和 δ 都可以通过Local polynomial估计得到

- ② 2SLS: 直接进行工具变量回归
 - 本质上RD的识别是一个LATE
 - 而LATE使用2SLS估计

断点回归

检验manipulation: McCrary(2008)



Stata: rddensity

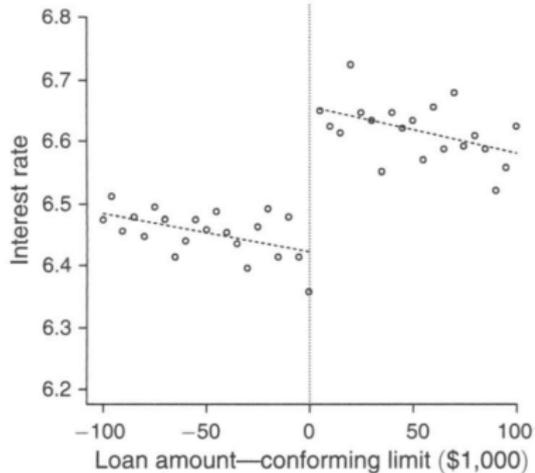
实例：意大利R&D

Bronzini and Iachini(2012) 研究了研发补贴对于企业的影响。背景：

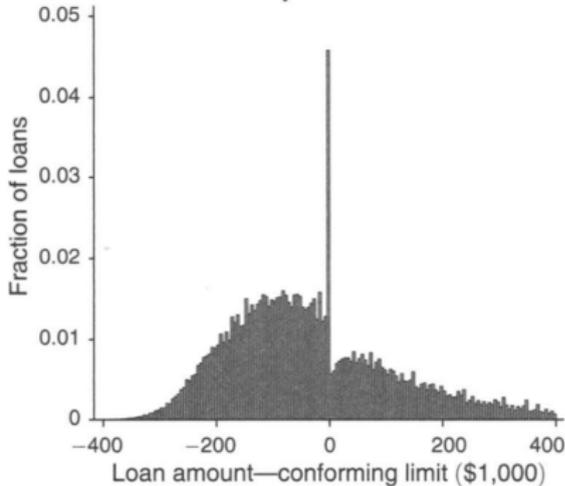
- 2003年，意大利Emilia-Romagna政府为了激励研发，实施了针对研发的补贴计划
- 能够被补贴的资质：通过打分确定，大于75分则可以接受补贴
- 断点：分数

数据中的聚类

Panel A. Mean interest rate by loan size (2006)



Panel B. Loan size density



Kinks

Kink最常见的例子：累进税制

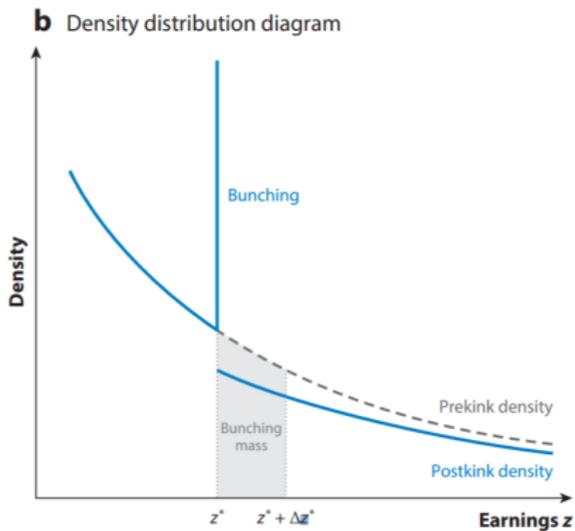
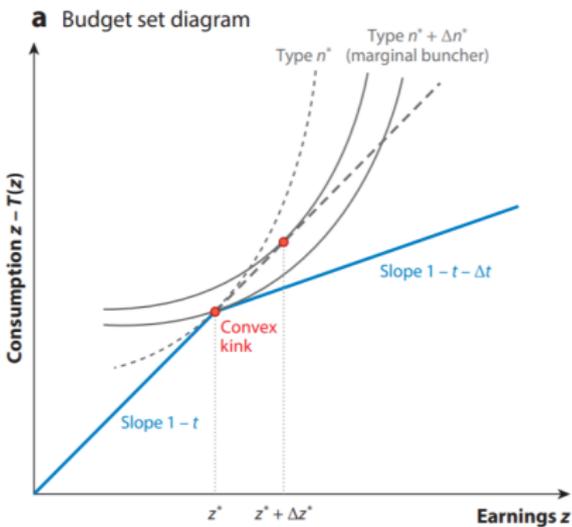
- 比如对于个人所得税，如果税前收入 z 在 z^* 的左右两边税率不同：

$$T(z) = \begin{cases} tz & z < z^* \\ tz + \Delta t(z - z^*) & z \geq z^* \end{cases}$$

即当收入在 z^* 以下时，边际税率为 t ，当收入超过 z^* 时，边际税率为 $t + \Delta t$

- 收入稍微超过 z^* 时，边际税率增加，激励不同，会导致一部分人（比如本来收入应该在 $(z^*, z^* + \Delta z^*)$ 的人）选择赚取 z^* 即可
- 效用最大化选择如下图
 - 会导致 z^* 左侧出现bunching现象
 - 右侧密度仍然不等于0，是由于右侧激励低，本来部分应该在更右侧的向左移动了

Kinks



弹性

- Saez(2010)指出，对于税前收入为 $z^* + \Delta z^*$ 的“边际人”（marginal buncher），其效用函数曲线应该相切于 z^* 后的折线
- 收入的补偿弹性：

$$e = \frac{\frac{\Delta z^*}{z^*}}{\frac{\Delta t}{1-t}}$$

其中： $\Delta t/(1-t)$ 是额外的税收百分比； $\Delta z^*/z^*$ 是收入增加百分比，“边际人”对于这两者无差异

Bunching的大小

- 如果假设税前收入有一个分布： $h(z)$
- 那么，选择 z^* 的人数：

$$B = \int_{z^*}^{z^* + \Delta z^*} h(z) dz \approx h(z^*) \Delta z^*$$

- 如果考虑 e 存在异质性，那么考虑 z, e 的联合分布函数： $h(z, e)$ ，那么：

$$B = \int_e \int_{z^*}^{z^* + \Delta z_e^*} h(z, e) dz de \approx \int_e h(z^*, e) \Delta z_e^* de = h(z^*) \mathbb{E}(\Delta z_e^*)$$

其中 $h(z^*) = \int_e h(z, e) de$ 。

- 只要计算出 B 和 $h(z^*)$ ，就可以计算出 Δz^* ($\mathbb{E}(\Delta z_e^*)$)

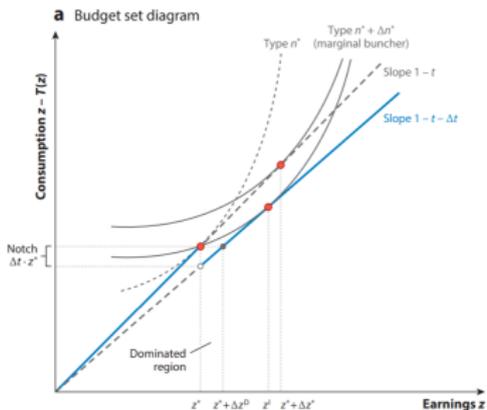
Norches

- norch与kink类似，区别在于：
 - kink在拐点处是连续的，norch在拐点处是离散的
 - norch造成了平均税率的不连续变化
 - norch可能会造成一部分被严格占优的区域
- 比如，以下这种非累进的、突然变化的税率：

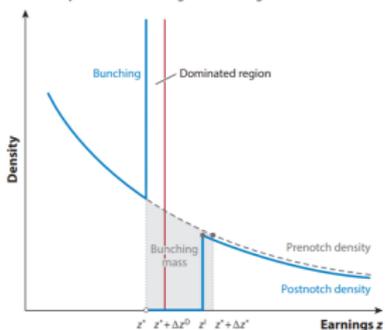
$$T(z) = \begin{cases} tz & z < z^* \\ tz + \Delta tz & z \geq z^* \end{cases}$$

- 例子：Kleven和Waseem(2013)

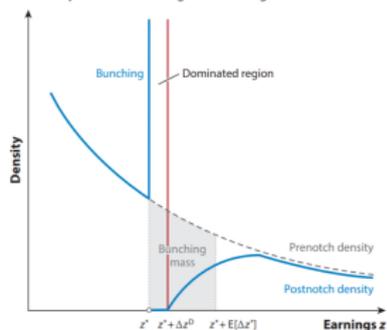
Norches



b Density distribution diagram: homogenous elasticities



c Density distribution diagram: heterogenous elasticities



Norches

- 以上区域中， $(z^*, z^* + \Delta z^D)$ 理论上应该是没有样本的——被占优的区域
- 然而，由于优化摩擦（optimization frictions）等的存在，实际数据中仍然可能会有少量样本
- 优化摩擦：经济个体没能达到最优的选择（未能达到kink或者norch的地方）
 - 调整成本（Chetty等人，2011）
 - 注意力成本
- 此外，行为经济学中的参照点（reference point）也可能会混淆bunching的估计
 - 比如退休年龄（Seibold, 2020）

Bunching的估计

- 在公式

$$B = \int_{z^*}^{z^* + \Delta z^*} h(z) dz \approx h(z^*) \Delta z^*$$

中，需要估计两个部分：

- Bunching B
- 反事实的密度函数 $h(z^*)$
- 实际上，只要估计出 $h(z)$ ，以上两个问题就都解决了
 - Bunching B 无非就是实际数据频率高出密度函数的部分

估计方法

不失一般性，我们假设Bunching的点 $z^* = 0$

- ① 类似于直方图，将数据按照 z 的取值进行分组，假设组中值为 $m_j, j = -J, \dots, L, \dots, 0, \dots, U, \dots J$
 - 比如，按照1的组距进行分组： $\dots (-4, -3], (-3, -2], (-2, -1], (-1, 0], (0, 1], (1, 2], \dots$ 对应的组中值为 $-3.5, -2.5, -1.5, -0.5, 0.5, 1.5$
- ② 确定排除区域 (excluded region) : $m_L < 0 < m_U$ ，即收到bunching影响的区域
- ③ 计算落入到每个组别的样本个数 n_j
- ④ 使用如下多项式回归拟合密度函数：

$$n_j = \sum_{k=0}^p \beta_k m_j^k + \sum_{t=L}^U \gamma_t 1 \{m_t = m_j\} + \epsilon_j$$

其中 p 为多项式阶数

估计方法

- 根据以上方法， γ_t 就度量了反事实的密度函数，从而：

$$\hat{n}_j = \sum_{k=0}^p \hat{\beta}_k m_j^k$$

- 从而bunching：

$$\hat{B} = \sum_{t=L}^0 \hat{\gamma}_t$$

- 而0右侧损失的密度为：

$$\hat{M} = \sum_{t=0}^U \hat{\gamma}_t$$

- 0处的密度函数：

$$\hat{h}(z^*) = \hat{h}(0) = \frac{\sum_{j=L}^0 \hat{n}_j}{\frac{m_0 - m_L}{L}}$$

- 从而：

超参数和标准误

需要决定的超参数：

- 多项式阶数 p
- 组距
- 排除区域： L 和 U

- 固定一个 L ，通过迭代的方法确定 U ，使得 $|\hat{B} - \hat{M}|$ 最小

标准误：使用bootstrap

例子：The interest rate elasticity of mortgage demand: evidence from bunching at the conforming loan limit