


Bartik工具变量与模拟的工具变量

慧航

2025年11月



Bartik工具

Bartik工具变量，也称为移动-份额工具（shift-share instruments）最初由Bartik (1991) 使用并讨论，在Blanchard和Katz (1992) 之后更加流行，目前已近被应用于很多领域：

- 移民: Altonji和Card (1991) 、 Card (2001)
 - 银行借贷: Amiti和Weinstein (2018) 、 Greenstone, Mas和Nguyen (2015)
 - 市场规模与创新: Acemoglu和Linn (2004)
 - 贸易: Autor, Dorn和Hanson (2013,2018) 、 Piveteau和Smagghue (2017) 、 de Roux等 (2017)
 - 国外援助: Nunn和Qian (2014)
 - 自动化: Acemoglu和Restrepo (2017)

基本设定

基本（简单）设定

- 结构方程：

$$y_i = \beta_0 + \beta w_i + u_i$$

其中 $i = 1, \dots, N$ 为个体（通常为地区），

- y_i 为地区的被解释变量，为了保证接下来的外生性，通常被解释变量为相对值（比如差分、增长率等）
- $\mathbb{C}(w_i, u_i) \neq 0$ 从而有内生性
- 假设 w_i 有如下的结构：

$$w_i = \sum_{m=1}^M z_{im} g_{im}$$

其中 z_{im} 为 i 地区第 m 个成分的份额， g_{im} 为增长率

基本设定

估计劳动供给弹性

- y : 工资增长率
 - w : 就业增长率
 - z_{im} : i 地区行业 m 的份额
 - g_{im} : i 地区行业 m 的工资增长率

估计移民的影响

- y : 本地和移民主工资差异
 - w : 移民增长率
 - z_{im} : i 地区来自国家 m 的移民份额
 - g_{im} : i 地区自国家 m 的人口增长率

Bartik工具的构建

- 现在假定：

$$g_{im} = g_m + \tilde{g}_{im}$$

其中 g_m 为第 m 个成分（行业、国家等）的平均增长率

- 构建Bartik工具变量：

$$B_i = \sum_{m=1}^M z_{im} g_m$$

- 问题：何时 B_i 是一个合格的工具变量？两个条件：

- $\mathbb{C}(B_i, w_i) \neq 0$
- $\mathbb{C}(B_i, u_i) = 0$

- 两只文献：

- Goldsmith-Pinkham, Sorkin和Swift (2020) 研究了份额 z_{im} 的外生性
- Borusyak、Hull和Jaravel (2022) 则研究了冲击 g_m 的外生性

一个特例: $M = 2$

- 如果 $M = 2$, 那么:

$$B_i = z_{i1}g_1 + z_{i2}g_2$$

由于 $z_{i1} + z_{i2} = 1$, 从而:

$$B_i = g_2 + (g_1 - g_2)z_{i1}$$

- 第一阶段:

$$\begin{aligned} w_i &= \gamma_0 + \gamma B_i + \epsilon_i \\ &= \underbrace{\gamma_0 + \gamma g_2}_{\text{常数项}} + \underbrace{\gamma (g_1 - g_2)z_{i1}}_{\text{系数}} + \epsilon_i \end{aligned}$$

- 相关性要求 $g_1 - g_2 \neq 0$: $g_1 - g_2$ 看做是某一个“政策”变动,

一个特例: $M = 2$

- 真正的工具: z_{i1} !
 - z_{i1} 可以看做是政策的暴露水平
 - 问题: z_{i1} 会不会直接影响 y_i ?
- 一般而言, 无法排除 z_{i1} 作为份额与 y_i 的直接关系
 - 在劳动供给弹性的例子中, z_{i1} 为某个行业的就业份额, y_i 为收入, 显然这是长期均衡共同决定的
 - 在移民的例子中, 不同国家的收入不一样, 显然当地收入也会影响不同国家的移民比例
 - 事情不一定这么悲观: y_i 并不是收入, 而是收入增长率 (变动, 而非水平), 外生性也许会满足

M 不受限、截面

- 现在考虑控制变量：

$$y_i = \beta_0 + \beta w_i + x_i' \eta + u_i$$

记 $Y^\perp = Y - \mathbb{L}(Y|X)$, $W^\perp = W - \mathbb{L}(W|X)$

- 如果有 M 个行业，那么 Bartik 工具的 2SLS 估计：

$$\hat{\beta}^{\text{Bartik}} = \frac{B' Y^\perp}{B' W^\perp}$$

- 同时，如果使用 $M - 1$ 个份额作为工具变量，那么：

$$\hat{\beta}^{\text{GMM}} = \frac{W^{\perp'} Z \Xi Z' Y^\perp}{W^{\perp'} Z \Xi Z' W^\perp}$$

其中 Ξ 为权重矩阵

M 不受限、截面

定理

定理：如果 $\Xi = GG'$, 那么 $\hat{\beta}^{Bartik} = \hat{\beta}^{GMM}$

启示

Bartik工具变量估计的结果等价于使用份额 z_{im} 作为工具变量，并没有使用 g_m 的外生性！

面板情形

- 对于面板设定（首先忽略控制变量）：

$$y_{it} = \beta_t + \beta w_{it} + u_{it}$$

其中 β_t 为时间固定效应

- Bartik工具：

$$B_{it} = \sum_{m=1}^M z_{im0} g_{mt}$$

其中 z_{im0} 为初始的份额，而增长率：

$$g_{imt} = g_{mt} + \tilde{g}_{imt}$$

特例: $M = 2, T = 2$

- 此时工具:

$$B_{it} = g_{1t}z_{i10} + g_{2t}z_{i20} = g_{2t} + (g_{1t} - g_{2t})z_{i10}$$

- 第一阶段:

$$\begin{aligned} w_{it} &= \gamma_t + \gamma B_{it} + \epsilon_{it} \\ &= \underbrace{\gamma_t + \gamma g_{2t}}_{\tilde{\gamma}_t} + \gamma (g_{1t} - g_{2t}) z_{i10} + \epsilon_{it} \end{aligned}$$

如果将其用两期的虚拟变量写出来:

$$w_{it} = \tilde{\gamma}_1 + \underbrace{\gamma (g_{11} - g_{21}) \mathbb{1}\{t=1\}}_{\tilde{\gamma}_1} z_{i10} + \underbrace{\gamma (g_{12} - g_{22}) \mathbb{1}\{t=2\}}_{\tilde{\gamma}_2} z_{i10} + \epsilon_{it}$$

其中 $\tilde{\gamma}_1, \tilde{\gamma}_2$ 为份额 z_{i10} 与时间固定效应的交互项的系数

- 等价关系: 特定权重矩阵下, Bartik工具的估计结果与使用“份额与时间固定效应的交互”作为工具变量是等价的。

Bartik与DID

- 如果将 $g_{1t} - g_{2t}$ 视为政策冲击，而 z_{i10} 视为政策暴露水平，以上设定与 DID 关系密切！
 - 具有高 ($m = 1$) 份额的地区与低 ($m = 1$) 份额的地区相比，对于 w 的增长率冲击 $g_{1t} - g_{2t}$ 的反应是不是不同的？
 - 如果高低地区的 w 反应不同、 y 反应也不同，那么推断 $w - y$ 有影响
 - 问题：平行趋势？分组变量 (z_{i10}) 外生吗？
 - 如果存在政策冲击，比如 $g_{11} - g_{21} = 0$ ，那么可以检验 z_{i10} 是否对事前的 y 有影响：平行趋势检验
 - 直觉：如果 $g_{11} - g_{21} = 0$ ，且 z_{i10} 不直接影响 y ，那么 z_{i10} 由于不影响事前 w ，从而也不影响事前的 y ；如果有影响： z_{i10} 不外生！

正式的识别假设

- 不失一般性用面板设定：

$$y_{it} = \beta w_{it} + x'_{it}\eta + u_{it}$$

其中 x_{it} 包含时间、个体固定效应等。

假设1

对于所有的 s, m , 回归：

$$w_{it} = x'_{it}\zeta + \sum_m \sum_s \delta_{ms} \times \mathbb{1}\{t = s\} \times z_{im0} + e_{it}$$

其中 δ_{ms} 有限且 $\sum_s \sum_m g_{ms} \delta_{ms} \neq 0$ 。

假设2

对于所有的 $g_m \neq 0$ 的 m , 有: $\mathbb{E}(u_{it} z_{im0} | x_{it}) = 0$ 。

打开Bartik工具的黑箱

- 根据以上介绍的等价关系，虽然 B_{it} 是一个工具变量，但是实际上等价于很多份额作为工具变量
 - 截面：份额作为工具变量
 - 面板：份额与时间固定效应的乘积作为工具变量
- 所以Bartik工具综合了很多很多工具变量的结果
 - 可以分解！
 - 可以直接使用这些多工具的结果进行估计，同时进行过度识别检验

Bartik工具变量估计的分解

Rotemberg权重（截面）

Bartik工具变量的结果可以分解为：

$$\hat{\beta}^{\text{Bartik}} = \sum_m \hat{\alpha}_m \hat{\beta}^m$$

其中 $\hat{\beta}^m$ 为使用份额 m 作为工具的 2SLS 估计结果， $\hat{\alpha}_m$ 为 Rotemberg 权重，且

$$\sum_m \hat{\alpha}_m = 1$$

Bartik工具变量估计的分解

注意！

权重 $\hat{\alpha}_m$ 有可能为负！从而：

- 如果同质性影响， $\hat{\beta}^m$ 都几乎相同，无影响
- 如果有异质性影响， $\hat{\beta}^{\text{Bartik}}$ 可能有问题
 - 使用bartik_weight (<https://github.com/paulgp/bartik-weight>) 计算 Rotemberg权重
 - 查看Rotemberg权重比较大的 m 的估计结果
 - 根据 $\hat{\alpha}_m$ 的正负分组，并观察两个组别权重的和

Rotemberg权重

- 可以计算 $\hat{\alpha}_m$ 与 g_m 的相关性: $\hat{\alpha}_m$ 多大程度上可以由 g_m 解释
- 可以计算 $\hat{\alpha}_m$ 与 z_{ik} 的方差的相关性, 其中的方差按照:

$$\frac{1}{N-1} \sum_i (z_{ik} - \bar{z}_k)^2$$

计算

- 同时可以计算 $\hat{\alpha}_m$ 与第一阶段 F 统计量 \hat{F}_k 的相关性: 第一阶段 F 大的工具不一定权重大
- 对于面板, 同理, 不过由于此时工具变量有 $(M-1) \times T$ 个, 所以需要加总:

$$\hat{\alpha}_m = \sum_t \hat{\alpha}_{m,t}$$

Bartik工具所需要做的一些检验

为了保证Bartik工具能够正确识别，一系列检验需要进行：

- 检验1：检查份额 z_{im0} 与初期的特征的相关性
 - 真正重要的是 z_{im0} 能否直接预测 y （的变化、增长率等）
 - 如果 z_{im0} 与一些能够预测 y 变化的因素相关，可能会有遗漏变量的偏误
- 检验2：如果有政策变化——平行趋势检验
- 检验3：
 - 其他的IV估计量（LIML、MB2SLS、HFUL等）结果是否大致相同
 - 过度识别检验（直接使用份额做IV）
 - 异质性影响：同样会使得以上两个检验不通过：直接查看 $\hat{\beta}^m$

Bartik工具：另一种视角

- 以上介绍Bartik工具聚焦份额的外生性，而Borusyak、Hull和Jaravel (2022) 考虑了 g_m 的外生性
- 考虑模型

$$y_i = \beta w_i + x_i' \eta + u_i$$

构建Bartik工具变量：

$$B_i = \sum_{m=1}^M z_{im} g_m$$

其中 $i = 1, \dots, N$ 为个体， $m = 1, \dots, M$ 为部门。

- 这里需要假设 $M(N) \rightarrow \infty$ ！
 - 需要大量的冲击 g_m

识别讨论

- 根据以上设定，识别条件为

$$\mathbb{E}(B_i u_i) = 0$$

- 然而，注意到 $\{B_i\}$ 不会是i.i.d的，类似的， $\{u_i\}$ 也有可能不是i.i.d的？
- 解决方法：转而使用矩条件

$$\mathbb{E} \left(\sum_{i=1}^N \omega_i B_i u_i \right) = 0$$

其中 ω_i 为回归权重，且 $\sum_i \omega_i = 1$ 。

- 根据以上的识别条件，矩估计为

$$\hat{\beta} = \frac{\sum_{i=1}^N \omega_i B_i y_i^\perp}{\sum_{i=1}^N \omega_i B_i w_i^\perp}$$

识别条件

- 核心问题：以上识别条件何时成立？
 - 将识别条件改写为

$$\begin{aligned}
\mathbb{E} \left(\sum_{i=1}^N \omega_i B_i u_i \right) &= \mathbb{E} \left(\sum_{i=1}^N \omega_i \sum_{m=1}^M z_{im} g_m u_i \right) \\
&= \mathbb{E} \left(\sum_{m=1}^M g_m \sum_{i=1}^N \omega_i u_i z_{im} \right) \\
&= \mathbb{E} \left(\sum_{m=1}^M g_m \sum_{i=1}^N \omega_i z_{im} \frac{\sum_{i=1}^N u_i \omega_i z_{im}}{\sum_{i=1}^N \omega_i z_{im}} \right) \\
&\stackrel{\Delta}{=} \mathbb{E} \left(\sum_{m=1}^M g_m s_m \bar{u}_m \right)
\end{aligned}$$

识别条件

- 识别条件成为

$$\mathbb{E} \left(\sum_{m=1}^M s_m g_m \bar{u}_m \right) = 0$$

- 其中:
 - 新的权重

$$s_m = \sum_{i=1}^N \omega_i z_{im}$$

- 且 $\sum_m s_m = \sum_m \sum_i \omega_i z_{im} = \sum_i \omega_i \sum_m z_{im} = \sum_i \omega_i = 1$ 。
- 新的误差项

$$\bar{u}_m = \frac{\sum_{i=1}^N u_i \omega_i z_{im}}{\sum_{i=1}^N \omega_i z_{im}}$$

将地区层面误差项进行加权平均得到部门层面的平均误差项

估计方法

- ① 使用 y, w 对 x 做回归得到残差 y^\perp, w^\perp ;
- ② 计算暴露加权 (exposure-weighted) 平均

$$\bar{v}_m = \frac{\sum_{i=1}^N v_i \omega_i z_{im}}{\sum_{i=1}^N \omega_i z_{im}}, v \in \{y^\perp, w^\perp\}$$

- ③ 在回归

$$\bar{y}_m^\perp = \alpha + \beta \bar{w}_m^\perp + \bar{u}_m$$

中, 使用 g_m 作为 \bar{w}_m^\perp 的工具变量

- 以上 (冲击层面的) 回归与使用 ω_i 加权的 Bartik IV 的估计完全等价 (证明)
- 但是标准误不等价!

识别条件

- 问题: 识别条件 $\mathbb{E} \left(\sum_{m=1}^M s_m g_m \bar{u}_m \right) = 0$ 何时成立?
 - 令 $\bar{u} = \{\bar{u}_m, m = 1, \dots, M\}$, $s = \{s_m, m = 1, \dots, M\}$

第一组假设

- ① (拟随机的冲击) $\mathbb{E}(g_n | \bar{u}, s) = \mu$
 - ② (不相关的冲击) 赫芬达指数 $\mathbb{E}(\sum_m s_m^2) \rightarrow 0$ 且 $\mathbb{C}(g_m, g_{m'} | \bar{u}, s) = 0, m \neq m'$

识别条件

- 如果假设 $\mathbb{E}(g_n | \bar{u}, s) = \mu$, 那么

$$\begin{aligned}
\mathbb{E} \left(\sum_{m=1}^M s_m g_m \bar{u}_m \right) &= \mathbb{E} \left[\mathbb{E} \left(\sum_{m=1}^M s_m g_m \bar{u}_m \mid \bar{u}, s \right) \right] \\
&= \mathbb{E} \left[\sum_{m=1}^M s_m \bar{u}_m \mathbb{E} (g_m \mid \bar{u}, s) \right] \\
&= \mu \mathbb{E} \left(\sum_{m=1}^M s_m \bar{u}_m \right) = \mu \mathbb{E} \left(\sum_{m=1}^M \sum_{i=1}^N u_i \omega_i z_{im} \right) \\
&= \mu \mathbb{E} \left(\sum_{i=1}^N u_i \omega_i \sum_{m=1}^M z_{im} \right) = \mu \mathbb{E} \left(\sum_{i=1}^N u_i \omega_i \right) \\
&= 0
\end{aligned}$$

识别条件

- 令 q_m 为部门的控制变量, 令 $q = \{q_m, m = 1, \dots, M\}$
 - 当然也可以是部门的分类 $c(m) \in \{1, \dots, C\}$

第二组假设

- (条件拟随机的冲击) $\mathbb{E}(g_n | \bar{u}, s, q) = q'_m \mu$
- (不相关的冲击残差) 赫芬达指
数 $\mathbb{E}(\sum_m s_m^2) \rightarrow 0$ 且 $\mathbb{C}(g_m, g_{m'} | \bar{u}, q, s) = 0, m \neq m'$

- 如果使用Bartik IV的估计方法, 需要额外控制 $q_i = \sum_m z_{im} q_m$
- 使用冲击层面的IV估计只需要加入 q_m 作为控制变量

识别条件

- 识别条件中冲击不相关的假定依然很强，两个放松的条件：

不相关假设的两种放松

- 存在部门的一个划分，使得 $\mathbb{E}(\sum_c s_c^2) \rightarrow 0$ ，其
中 $s_c = \sum_{m:c(m)=c} s_m$ 且 $\mathbb{C}(g_m, g_{m'} | \bar{u}, q, s) = 0, c(m) \neq c(m')$
- 存在一个序列 $B_M \geq 0$ 以及一个函数 $f(\cdot)$ 满足 $\sum_{r=1}^{\infty} f(r) < \infty$ ，使
得 $B_M \mathbb{E}(\sum_m s_m^2) \rightarrow 0$ 且 $|\mathbb{C}(g_m, g_{m'} | \bar{u}, q, s)| \leq B_M \cdot f(|m' - m|)$

估计问题

- 然而标准误可能有问题 (Adao, Kolesar和Morales, 2019)
 - 直接使用冲击层面的IV估计，并计算稳健标准误
 - Stata: ssaggregate

合成工具变量

- 工具变量（解释变量）需要满足外生性，比如一些自然实验的冲击
- 然而有时，有些冲击不得不与一些内生的变量合在一起才能被观察到：
 - Bartik工具：可能 g_m 是外生的，但是 z_{im} 的内生的
 - 交通设施：哪些地方开通高铁可能不是外生的，但是开通高铁的时间可能是外生的
 - 美国每个州的（给穷人的）健康保险政策是外生的，但是人口特征不是（比如可能跟健康状况有关）
- 问题：这些工具变量是否可以使用？如何使用？Borusyak和Hull (2021) 回答了这一问题。

一个示例：市场进入

- 考虑交通基础设施（市场进入， MA_i ）对土地价格 V_i 的影响：


$$\Delta \ln V_i = \beta_0 + \beta \Delta \ln MA_i + u_i$$

- 假设在一个棋盘上随机取点修建铁路
- 虽然哪个点修建铁路是外生的，但是地理位置是内生的！
 - 棋盘中间天然具有更高的市场进入
- 解决办法：
 - 如果棋盘上的点是随机被选取出来修建铁路的，计算一个期望的市场进入 $\mu_i = \mathbb{E}(\Delta \ln MA_i)$
 - 使用 $\Delta \ln MA_i - \mu_i$ 作为解释变量
 - μ_i ：可以通过模拟计算得到


市场进入示例

Figure 1: Market Access Growth in the Motivating Example


A. Line Construction and Market Access Growth



B. Expected Market Access Growth



C. Recentered Market Access Growth



设定

- 假设:

$$z_i = f_i(g, x)$$

其中：

- $f_i(\cdot), i = 1, \dots, N$ 为已知函数
 - g 为 $N \times 1$ 的外生冲击
 - x 为一些可观测变量

- 回归方程:

$$y_i = \beta_0 + \beta w_i + u_i$$

重要引理

假设1

假设冲击是外生的, 即 $g \perp\!\!\!\perp u|x$

在以上条件下, 由于:

$$\begin{aligned}
 \mathbb{E} \left(\frac{1}{N} \sum_i z_i u_i \right) &= \mathbb{E} \left(\frac{1}{N} \sum_i f_i(g, x) u_i \right) \\
 &= \mathbb{E} \left(\mathbb{E} \left[\frac{1}{N} \sum_i f_i(g, x) u_i | x \right] \right) \\
 &= \mathbb{E} \left(\frac{1}{N} \sum_i u_i \mathbb{E} [f_i(g, x) | x] \right) \\
 &= \mathbb{E} \left(\frac{1}{N} \sum_i u_i \mu_i \right)
 \end{aligned}$$

其中 $\mu_i = \mathbb{E} [f_i(g, x) | x]$ 为工具变量的期望。

新的工具

- 根据以上结论，有：

$$\mathbb{E} \left(\frac{1}{N} \sum_i (z_i - \mu_i) u_i \right) = 0$$

- 两种做法：

- 计算得到 μ_i 使用 $z_i - \mu_i$ 作为工具变量：重新中心化 (recentering)
 - 直接将 μ_i 作为控制变量、 z_i 作为工具变量
 - 启示：如果 μ_i 被其他控制变量、固定效应吸收了，不用做额外处理，使用 z_i 做工具就够了。

工具期望的计算

问题是：如何计算 μ_i ？

- 假设我们知道给定 x , g 的分布 $G(g|x)$, 那么可以直接计算：

$$\mu_i = \int f_i(g; x) dG(g|x)$$

- 然而 $G(\cdot|\cdot)$ 可能不好设定：直接将 g 向量进行重新排列组合，得到新的组合 $\pi(g)$, 然后计算 $f_i(\pi(g); x)$, 重复多次后计算均值即可。
 - 比如对于高铁开通，如果使用2016年的数据，假设开通时间是随机的，那么将2016已经开通的城市和有规划的城市进行一个排列组合，取MA的均值即可。
 - 对于保险资格，假设某个个体随机属于某一个州，按照这个州的标准判断其在这个州是不是有资格，然后求平均