

SIMEX estimation for single-index model with covariate measurement error

姓 名： 张宇靖

中国人民大学统计学院

2021 年 12 月 21 日

SIMEX estimation for single-index model with covariate measurement error

① 单指标测量误差模型

② SIMEX估计程序

③ 演近性质

④ 模拟研究

SIMEX estimation for single-index model with covariate measurement error

① 单指标测量误差模型

② SIMEX估计程序

③ 演近性质

④ 模拟研究

考虑单指标测量误差模型

$$\begin{cases} Y = g(\beta^T X) + \varepsilon \\ W = X + U \end{cases}$$

其中 $g(\cdot)$ 是一元的未知联系函数

$\beta = (\beta_1, \dots, \beta_p)^T$ 是 $p \times 1$ 的未知指标参数向量, 满足 $\|\beta\| = 1$

ε 是随机误差, 满足 $E(\varepsilon | X) = 0$

测量误差 $U \sim N(0, \Sigma_{uu})$, 且独立于 (X, Y) , 且假设 Σ_{uu} 已知

SIMEX estimation for single-index model with covariate measurement error

① 单指标测量误差模型

② SIMEX估计程序

③ 演近性质

④ 模拟研究

(1) 模拟步: 对于每一个 $i = 1, \dots, n$, 产生随机变量序列

$$W_{ib}(\lambda) = W_i + (\lambda \Sigma_{uu})^{1/2} U_{ib}, \quad b = 1, \dots, B,$$

其中 $U_{ib} \sim N(0, I_p)$, I_p 是 $p \times p$ 的单位阵.

(2) 估计步: 假设联系函数 $g(\cdot)$ 有连续的二阶导数, 对于 t_0 邻域内的点 t , $g(t)$ 能够用一个线性函数进行逼近, 即

$$g(t) \approx g(t_0) + g'(t_0)(t - t_0) \equiv a + b(t - t_0)$$

下面介绍基于数据集 $\{(Y_i, W_{ib}(\lambda)), i = 1, \dots, n, b = 1, \dots, B\}$,
关于未知指标参数 β 和联系函数 $g(\cdot)$ 的估计问题.

步骤1. 对于给定的 t_0 和 β . 定义下面的加权最小二乘目标函数

$$\sum_{i=1}^n \left\{ Y_i - a - b [\beta^T W_{ib}(\lambda) - t_0] \right\}^2 K_h (\beta^T W_{ib}(\lambda) - t_0),$$

其中 $K_h(\cdot) = h^{-1}K(\cdot/h)$, $K(\cdot)$ 是核函数, h 是窗宽. 简单计算, 可得

$$\hat{g}(\beta, \lambda; t_0) = \sum_{i=1}^n M_{ni}(\beta, \lambda; t_0) Y_i \hat{g}'(\beta, \lambda; t_0) = \sum_{i=1}^n \tilde{M}_{ni}(\beta, \lambda; t_0) Y_i$$

步骤2. 采用“去一分量”方法转换 \mathbb{R}^p 空间中单位超球面上的点到 \mathbb{R}^p 空间单位球的内点. 具体思路是: $\beta^{(r)} = (\beta_1, \dots, \beta_{r-1}, \beta_{r+1}, \dots, \beta_p)^T$ 表示去掉 β 的第 r 个分量 β_r 以后的 $p - 1$ 维参数向量. 为了简单, 不妨假定 β 的第 r 个分量 β_r 是一个正的分量. 这时真参数 $\beta^{(r)}$ 满足 $\|\beta^{(r)}\| < 1$. 则 β 在真参数 $\beta^{(r)}$ 的某个邻域内是有限可微的, 其Jacobian矩阵是

$$J_{\beta^{(r)}} = (\gamma_1, \dots, \gamma_p)^T,$$

其中 γ_s ($1 \leq s \leq p, s \neq r$) 是一个 $(p - 1)$ 维的单位向量, 当 $s < r$ 时, 其第 s 个元素为 1, 当 $s > r$ 时, 其第 $s - 1$ 个元素为 1, 而 $\gamma_r = -\left(1 - \|\beta^{(r)}\|^2\right)^{-1/2} \beta^{(r)}$.

定义关于 $\beta^{(r)}$ 的估计方程如下

$$\frac{1}{n} \sum_{i=1}^n \hat{\eta}_{ib}(\beta, \lambda) = 0,$$

上式等价于极小化 $Q(\beta) = E[Y - \hat{g}(\beta, \lambda; \beta^T W)]^2$

其中 $\hat{\eta}_{ib}(\beta, \lambda) = [Y_i - \hat{g}(\beta, \lambda; \beta^T W_{ib}(\lambda))] \hat{g}'_{h_1}(\beta, \lambda; \beta^T W_{ib}(\lambda)) J_{\beta^{(r)}}^T W_{ib}(\lambda)$.

使用Newton-Raphson迭代算法求解方程，得到 $\beta^{(r)}$ 的估计，记为 $\hat{\beta}_b^{(r)}(\lambda)$. 进而可得指标参数 β 的估计，记为 $\hat{\beta}_b(\lambda)$.

步骤3. 对 $\hat{\beta}_b(\lambda)$ 关于 $b = 1, \dots, B$ 进行平均，则 $\hat{\beta}(\lambda)$ 定义为

$$\hat{\beta}(\lambda) = \frac{1}{B} \sum_{b=1}^B \hat{\beta}_b(\lambda)$$

(3) 外推步: 定义外推函数 $G(\lambda, \Gamma)$. 基于外推函数 $G(\lambda, \Gamma)$, 对 $\{\hat{\beta}(\lambda), \lambda \in \Lambda\}$ 在 $\{\lambda \in \Lambda\}$ 上关于 Γ 作拟合回归模型, 可以获得 Γ 的估计, 记为 $\hat{\Gamma}$. 最后可得到 β 的 SIMEX 估计定义为

$$\hat{\beta}_{\text{SIMEX}} = G(-1, \hat{\Gamma}).$$

注意到: 如果 λ 退化到 0, $\hat{\beta}_{\text{Naive}} = G(0, \hat{\Gamma})$ 就表示忽略测量误差后得到的估计, 即直接用 W 代替 X 得到的估计量.

在估计步中的步骤1中, 用SIMEX估计 $\hat{\beta}_{\text{SIMEX}}$ 代替 β , 并且用窗宽 h_2 获得估计 $\hat{g}_b(\lambda; t_0)$, 然后关于 $b = 1, \dots, B$ 作平均, 则有

$$\hat{g}(\lambda; t_0) = \frac{1}{B} \sum_{b=1}^B \hat{g}_b(\lambda; t_0)$$

关于 \mathbb{A} , 极小化

$$\sum_{\lambda \in \Lambda} \{\hat{g}(\lambda; t_0) - G(\lambda; \mathbb{A})\}^2$$

则可获得估计 $\hat{\mathbb{A}}$. 进一步, 可获得联系函数 $g(\cdot)$ 的SIMEX估计为

$$\hat{g}_{\text{SIMEX}}(t_0) = G(-1, \hat{\mathbb{A}})$$

SIMEX estimation for single-index model with covariate measurement error

① 单指标测量误差模型

② SIMEX估计程序

③ 演近性质

④ 模拟研究

定理 1

假设正则条件(C1)一条件(C7)成立。当 $n \rightarrow \infty$ 时, 则有 $\sqrt{n} (\hat{\beta}_{\text{SIMEX}} - \beta)$ 是渐近正态的, 均值为 0, 渐近协方差阵为

$$G_{\Gamma}(-1, \Gamma) \Sigma(\Gamma) \{G_{\Gamma}(-1, \Gamma)\}^T$$

其中 $G_{\Gamma}(\lambda, \Gamma) = \{\partial/\partial(\Gamma)^T\} G(\lambda, \Gamma)$.

定理 2

假设正则条件(C1)一条件(C7)成立. 如果 $nh_2^5 = O(1)$, 当 $n \rightarrow \infty$ 和 $B \rightarrow \infty$ 时, 则联系函数的SIMEX估计 $\hat{g}_{\text{SIMEX}}(t_0)$ 的渐近偏差和渐近方差分别为

$$C(\Lambda, \mathbb{A}) \sum_{\lambda \in \Lambda} \frac{1}{2} h_2^2 \mu_2 g''(\lambda; t_0) \gamma(\lambda, \mathbb{A})$$

和

$$[nh_2 f_0(t_0)]^{-1} \nu_2 \operatorname{Var}\left(Y \mid \beta^T W = t_0\right) C(\Lambda, \mathbb{A}) D C^T(\Lambda, \mathbb{A}),$$

其中 $g(\lambda; t) = E(Y \mid \beta^T W_b(\lambda) = t)$.

SIMEX estimation for single-index model with covariate measurement error

① 单指标测量误差模型

② SIMEX估计程序

③ 演近性质

④ 模拟研究

考虑下面的单指标测量误差模型

$$\begin{cases} Y_i = -2(\beta^T X_i - 1)^2 + 1 + \varepsilon_i, \\ W_i = X_i + U_i, \quad i = 1, \dots, n, \end{cases}$$

其中

- $\beta = (\beta_1, \beta_2)^T = (\sqrt{3}/3, \sqrt{6}/3)^T$
- X_i 是一个二维的随机向量, 每个分量独立的来自于 $N(0, 1)$
- $\varepsilon_i \sim N(0, 0.2^2)$
- $U_i \sim N(0, \text{diag}(\sigma_u^2, 0))$, 取 $\sigma_u = 0.2, 0.4, 0.6$ 表示不同的测量误差水平

- $n = 50, 100$ 和 150
- 重复模拟次数为 $N = 500$
- 对于SIMEX算法, 取 $\lambda = 0, 0.2, \dots, 2$ 和 $B = 50$
- Epanechnikov核函数 $K(u) = 0.75(1 - u^2)_+$
- h, h_1 和 h_2 可分别取为 $cn^{-1/4}(\log n)^{-1/2}$, $cn^{-1/5}$ 和 $cn^{-1/5}$, 其中 c 为 $\beta_{\text{int}}^T X$ 的标准差

表1: β_1 和 β_2 的 SIMEX 估计和自然估计的偏差 (Bias) 和标准差 (SD)

n	σ_u	SIMEX		Naive	
		β_1	β_2	β_1	β_2
		Bias(SD)	Bias(SD)	Bias(SD)	Bias(SD)
50	0.2	-0.0084(0.0520)	-0.0078(0.0377)	-0.0177(0.0291)	0.0146(0.0203)
	0.4	-0.0405(0.0875)	0.0171(0.0638)	-0.0764(0.0537)	0.0546(0.0388)
	0.6	-0.0508(0.1253)	0.0342(0.0821)	-0.1207(0.0680)	0.0700(0.0330)
100	0.2	-0.0083(0.0384)	-0.0074(0.0321)	-0.0126(0.0203)	0.0084(0.0142)
	0.4	-0.0381(0.0581)	0.0158(0.0334)	-0.0761(0.0397)	0.0434(0.0224)
	0.6	0.0394(0.0719)	-0.0206(0.0567)	-0.1154(0.0383)	0.0632(0.0210)
150	0.2	-0.0059(0.0169)	0.0039(0.0118)	-0.0187(0.0136)	0.0127(0.0093)
	0.4	0.0160(0.0341)	-0.0126(0.0258)	-0.0497(0.0279)	0.0324(0.0177)
	0.6	-0.0279(0.0599)	0.0163(0.0394)	-0.1088(0.0315)	0.0563(0.0171)

联系函数 $g(t)$ 估计 $\hat{g}(t)$ 的完成情况, 用均方根误差(root mean squared error, RMSE)进行评价

$$\text{RMSE} = \left[n_{\text{grid}}^{-1} \sum_{k=1}^{n_{\text{grid}}} \{\hat{g}(t_k) - g(t_k)\}^2 \right]^{1/2}$$

其中 n_{grid} 是格子点数, 且 $\{t_k, k = 1, 2, \dots, n_{\text{grid}}\}$ 是等间距的格子点, 模拟计算中取 $n_{\text{grid}} = 15$.




图2: (a) 实线表示联系函数 $g(t)$ 的真实曲线, 断线表示自然估计的拟合曲线, 点断线表示SIMEX估计的拟合曲线, 其中 $n = 100$ 和 $\sigma_u = 0.4$; (b) 基于500次重复试验的联系函数 $g(t)$ 两种估计的RMSE的箱线图

谢谢！



2021.12.21