

协变量带误差的随机删失数据线性模型 的一类半参数估计

刘网定^{1,2}, 王海康², 周秀轻²

(1 南京陆军指挥学院, 江苏 南京 210045)

(2 南京师范大学数学科学学院, 江苏 南京 210097)

[摘要] 考虑线性模型 $Y_i = X_i^T \beta + \varepsilon_i$, $i = 1, 2, \dots, n$, 其中 Y_i 为随机右删失因变量, X_i 难以观测, 或需要较高成本才能得到其精确观测值, 故转而观测与 X_i 相关的相对易得的随机变量 X_{δ} . 利用数据集 $\{(X_{\delta}, X_j)\}_{j=n+1}^{n+N}$ 估计 $E[X|X_{\delta}]$ 的同时, 给出了参数向量 β 的一类半参数估计, 并且证明了估计量的渐近正态性.

[关键词] 随机删失数据, 线性回归模型, 协变量带误差, 渐近正态性

[中图分类号] O212 [文献标识码] A [文章编号] 1001-4616(2009)02-0031-05

A Class of Semiparametric Estimators for Linear Error-in-Covariables Models Under Random Censorship

Liu Wangding^{1,2}, Wang Haikang², Zhou Xiuqing²

(1 Nanjing Army Command College, Nanjing 210045, China)

(2 School of Mathematical Science, Nanjing Normal University, Nanjing 210097, China)

Abstract Consider the linear models $Y_i = X_i^T \beta + \varepsilon_i$, $i = 1, 2, \dots, n$, with the response Y_i censored randomly on the right and X_i hard or costly to measure. A relative variable X_{δ} is to be measured instead of X . When estimating $E[X|X_{\delta}]$ with the help of validation data $\{(X_{\delta}, X_j)\}_{j=n+1}^{n+N}$, a class of semiparametric estimators for vector β are given and the asymptotic normality is also proved.

Key words random censoring, linear models, errors in covariables, asymptotic normality

回归模型是一个常用的重要模型. 考虑线性回归模型

$$Y_i = X_i^T \beta + \varepsilon_i, \quad i = 1, 2, \dots, n, \quad (1)$$

其中 Y_i 为数值型因变量, X_i 为 p 维随机协变量, X_i^T 是 X_i 的转置, $\beta = (\beta_1, \beta_2, \dots, \beta_p)^T$ 是 p 维待估参数, ε_i 是随机误差, 并且在给定 X_i 的条件下, 误差项 $\varepsilon_i = Y_i - X_i^T \beta$ 独立同分布.

当因变量发生右删失时, 某些 Y_i 无法观测到, 观测到的是 $Z_i = \min(Y_i, T_i)$ 和 $\delta_i = I(Y_i \leq T_i)$, 其中 $I(A)$ 是集合 A 的指示函数, T_i 为随机删失变量. 此时, 对模型 (1) 参数的 LSE 估计见文献 [1-5]. 在有些情况下, 删失是由某些自然原因或突发事件而产生的, 此时, 删失变量的分布是未知的. 例如, 在医学研究中, 由于病人的中途退出, 或在观测结束时仍然存活等等, 造成对病人生存时间的观测往往是不完全的. 但在其它一些情况下, 删失是由于人为的设定与控制而造成. 例如, 在工程技术方面, 对一些物件进行(毁坏性)测试, 但不希望无休止地等待下去直至所有的物件都毁坏, 因为那将耗费太大的人力财力, 所以可以设定试验的时间不能超过某个界限. 在这种情况下, 删失变量的分布是完全已知的. 有不少作者对删失分布已知情况下的统计模型作过研究, 例如文献 [6-7].

另外, 在许多研究背景中, 存在某种变量(如 X) 难以观测到, 或者对 X 的精确观测需要较高的成本, 从而转向观测一个与 X 相关的且相对容易观测到的变量(如 X_{δ}), 用 $E[X|X_{\delta}]$ 来代替 X , 这样的例子见文献 [8-12]. 此时称协变量 X 带误差. 一般情况下, 并不能指出 X 与 X_{δ} 之间的确切关系, 但是可以通过某种代

收稿日期: 2008-07-12

通讯联系人: 刘网定, 助教, 研究方向: 生存分析和回归分析. E-mail: memoryliu@163.com

2 假设条件和主要结论

首先假定:

(1) \mathcal{D} 为定义在 R^d 上的所有连续函数 f 的集合, 并且 f 的微商满足

$$\frac{i_1}{x_1^{i_1}} \frac{i_2}{x_2^{i_2}} \cdots \frac{i_d}{x_d^{i_d}} f(x_1, \dots, x_d)$$

对于 $0 \leq i_1 + i_2 + \dots + i_d \leq m$ 一致有界.

(2) $F(t|\mathbf{x}) = P(Y \leq t | \mathbf{X} = \mathbf{x}), H(t|\mathbf{x}) = P(Z \leq t | \mathbf{X} = \mathbf{x})$.

(3) 对于任意分布函数 $W(\cdot)$ 以及 $r > 0$ $W(\cdot) = 1 - W(\cdot)$, $W^{-r}(\cdot) = (W(\cdot))^{-r}$.

(4) $X_{i \setminus r}(\mathbf{x})$ 分别为 $X_i(\mathbf{x})$ 的第 r 个分量.

(5) 对于任意向量 \mathbf{a}, \mathbf{b} , $\|\mathbf{a} - \mathbf{b}\| = \sum_i |a_i - b_i|$, 其中 a_i, b_i 分别为 \mathbf{a}, \mathbf{b} 的第 i 个分量.

为了证明本文的定理, 并给出如下假设条件:

(C) $E[\epsilon | \mathbf{X} = \mathbf{x}] = 0$

(C) 的真实值 θ_0 为有界常向量, 在 θ_0 的有界区域内.

(C X) $\sup_{\mathbf{x} \in \mathcal{X}} E[X_{1r}^4 | \mathbf{X} = \mathbf{x}] < \infty$, $r = 1, 2, \dots, p$.

(C X) (i) X 的密度函数 $f_X(\mathbf{x})$ 存在, 并且存在 $\epsilon_n > 0$ 使得 $nP(f_X(\mathbf{x}) < \epsilon_n) \rightarrow 0$

(ii) 存在 $m > 2d$, 使得 $f_X(\mathbf{x}) \in \mathcal{D}^m$.

(C) $(\cdot) \in \mathcal{D}^m$.

(C Y) $\sup_{\mathbf{x} \in \mathcal{X}} E[(\epsilon_1(Z) + (1 - \epsilon_1(Z))^4 | \mathbf{X} = \mathbf{x})] < \infty$.

(C K) (i) $K(\cdot)$ 是一个具有有界支撑的有界核函数; (ii) $K(\cdot)$ 具有有界变差; (iii) $|K(\cdot)|$ 具有有界变差; (iv) $K(\cdot)$ 为 m 阶核函数.

(C h_N) (i) $(N h_N^{2d/n})^{-1/2} \sqrt{\log \log N} \rightarrow 0$ (ii) $N h_N^{4d/n} \rightarrow 0$. (iii) 对于 (C X) 中的 m 有 $N h_N^{2m/n} \rightarrow 0$ (iv)

对于 (C X) (i) 中的 ϵ_n , 有 $h_N / \epsilon_n \rightarrow 0$

(C N_n) $\frac{n}{N} \rightarrow 0$, 其中 γ 为非负常数.

在下面的定理中, 我们给出了估计量 $\hat{\theta}_{nN}$ 的渐近表达式, 进而给出了它的渐近正态性. 对于 $i, j = 1, 2, \dots, n, k = n+1, n+2, \dots, n+N$, 设

$$\mathbf{h}_0(\mathbf{X}_i, \mathbf{Z}_i; \mathbf{X}_j, \mathbf{Z}_j) = (\mathbf{X}_i)(\mathbf{Y}_i^* - \mathbf{T}(\mathbf{X}_i)) + (\mathbf{X}_j)(\mathbf{Y}_j^* - \mathbf{T}(\mathbf{X}_j)), \quad (10)$$

$$\mathbf{h}_0(\mathbf{X}_k, \mathbf{X}_k) = -(\mathbf{X}_k)(\mathbf{X}_k - \mathbf{T}(\mathbf{X}_k))^T,$$

$$= E(\mathbf{X})(\mathbf{X})^T,$$

$$\mathbf{h}(\mathbf{X}_i, \mathbf{Z}_i; \mathbf{X}_j, \mathbf{Z}_j) = \mathbf{h}_0(\mathbf{X}_i, \mathbf{Z}_i; \mathbf{X}_j, \mathbf{Z}_j),$$

$$(\mathbf{X}_k, \mathbf{X}_k) = \mathbf{h}_0(\mathbf{X}_k, \mathbf{X}_k). \quad (11)$$

定理 1 在条件 (C), (C X), (C K) (i-iv), (C X), (C Y), (C), (C h_N) 和 (C N_n) 下, 可以将 $\hat{\theta}_{nN} - \theta_0$ 分解为

$$\hat{\theta}_{nN} - \theta_0 = \mathbf{U}_n + \mathbf{S}_N + o_p(n^{-\frac{1}{2}}),$$

$$\text{其中 } \mathbf{U}_n = \frac{1}{2} \sum_{i < j \leq n} \mathbf{h}(\mathbf{X}_i, \mathbf{Z}_i; \mathbf{X}_j, \mathbf{Z}_j), \mathbf{S}_N = \frac{1}{N} \sum_{k=n+1}^{n+N} \mathbf{h}(\mathbf{X}_k, \mathbf{X}_k).$$

定理 1 将 $\hat{\theta}_{nN} - \theta_0$ 分解成 3 部分, 其中前两部分相互独立, 第三部分为余项. 如果我们能证明前两项的渐近正态性, 则 $\hat{\theta}_{nN} - \theta_0$ 的渐近正态性就可得证. 根据这种思路, 我们有如下定理.

定理 2 在条件 (C), (C X), (C K), (C X), (C Y), (C), (C h_N) 和 (C N_n) 下,

$$\sqrt{n}(\hat{\theta}_{nN} - \theta_0) \xrightarrow{d} N(0, \mathbf{V}),$$

其中 d 表示依分布收敛,

$$\mathbf{V} = \mathbf{V}_1 + \mathbf{V}_2 (\mathbf{V}_1^{-1})^T,$$

$$V_1 = E \{ (X_1)^T (X_1) (Y_1^* - \beta^T(X_1))^2 \},$$
$$V_2 = E \{ (X_1)^T (X_1) [(X_1^T - \beta^T(X_1))]^2 \}.$$

在利用定理 2对 进行区间估计和假设检验时, 由于 V 是未知的, 因此下面给出 V 的连续估计量:

$$\hat{V}_n = \hat{\Sigma}_{n,N}^{-1} (\hat{V}_{1n} + \hat{V}_{2n}) (\hat{\Sigma}_{n,N}^{-1})^T,$$

其中 $\hat{\Sigma}_{n,N}$ 如式 (8) 所定义,

$$\hat{V}_{1n} = \frac{1}{n} \sum_{i=1}^n \hat{\Sigma}_N(X_i) \hat{\Sigma}_N^T(X_i) (Y_i^* - \hat{\Sigma}_N^T(X_i) \hat{\Sigma}_{n,N})^2,$$
$$\hat{V}_{2n} = \frac{1}{n} \sum_{i=1}^n \hat{\Sigma}_N(X_i) \hat{\Sigma}_N^T(X_i) (X_i - \hat{\Sigma}_N^T(X_i) \hat{\Sigma}_{n,N})^2.$$

3 定理的证明

由 $\hat{\Sigma}_{n,N}$ 的定义, 可得

$$\hat{\Sigma}_{n,N} - \Sigma = \hat{\Sigma}_{n,N}^{-1} A_{n,N} (\quad), \tag{12}$$

其中 $A_{n,N}(\quad) = \frac{1}{n} \sum_{i=1}^n \hat{\Sigma}_N(X_i) (\hat{\Sigma}_{i-1}(Z_i) + (1 - \hat{\Sigma}_{i-1})^2(Z_i) - \hat{\Sigma}_N^T(X_i) \quad).$

首先, 为了证明定理 1 我们需要下面的 3 个引理: 引理 1、引理 2 和引理 3 这 3 个引理的详细证明过程类似于文献 [14] 中的引理 4.1、引理 4.2 和引理 4.3 在此我们略去了其证明过程.

引理 1 在条件 (C X), (C K) (i) ii) iv), (C X) (i) ii), (C h_N) (i) 和 (C) 下, 我们有

$$\hat{\Sigma}_{n,N} \xrightarrow{P} \quad,$$

其中 在第二部分式 (10) 已有定义.

引理 2 在条件 (C X), (C Y), (C X), (C), (C K) (i) iv), (C h_N) (i) iii) 和 (C N_n) 下, 可以将 $A_{n,N}(\quad)$ 化简为

$$A_{n,N}(\quad) = \frac{1}{n} \sum_{i=1}^n \sum_{j=n+1}^{n+N} h_0(X_i, Z_i; X_j, Z_j) + \frac{1}{nN} \sum_{i=1}^n \sum_{j=n+1}^{n+N} h_n(X_i, Z_i; X_j, X_j) + o_p(n^{-\frac{1}{2}}),$$

其中

$$h_n(X_i, Z_i; X_j, X_j) = \frac{(X_j - \beta(X_i)) (Y_i^* - \beta^T(X_i)) K\left(\frac{X_i - X_j}{h_N}\right)}{\frac{h_N^d f_X(X_i)}{(X_i) (X_j - \beta(X_i))^T K\left(\frac{X_i - X_j}{h_N}\right)}},$$

$h_0(\quad)$ 如式 (10) 所定义, Y_i^* 如式 (3) 所定义, $i = 1, 2, \dots, n, j = N + 1, N + 2, \dots, n + N$.

引理 3 在条件 (C), (C K) (i) iv), (C X), (C X), (C Y) 下, 我们有

$$\frac{1}{nN} \sum_{i=1}^n \sum_{j=n+1}^{n+N} h_n(X_i, Z_i; X_j, X_j) = - \frac{1}{N} \sum_{j=n+1}^{n+N} (X_j) (X_j - \beta(X_j))^T + o_p(n^{-\frac{1}{2}}).$$

定理 1 的证明 由式 (12) 以及引理 1 ~ 引理 3 定理 1 结论显然.

定理 2 的证明 由于 U_n 与 S_N 相互独立, 因此只需要证明

$$\sqrt{n} U_n \rightarrow N(0, \Sigma^{-1} V_1 (2^{-1})^T), \tag{13}$$

$$\sqrt{n} S_N \rightarrow N(0, K 2^{-1} V_2 (2^{-1})^T). \tag{14}$$

根据 U_n 的定义, 可见 $(n^2 \mathcal{K}_n^2) U_n$ 为以 $h(X_i, Z_i; X_j, Z_j; D)$ 为对称核的 U 统计量.

对于任何 p 维向量 $A \in \mathbb{R}^p$ 设

$$h_1(X_i, Z_i; X_j, Z_j; D) = A^T h(X_i, Z_i; X_j, Z_j; D),$$

则

$$E(h_1(X_i, Z_i; X_j, Z_j; D)) = 0 \quad i, j$$

由计算可得

$$E h_1^2 = E (A^{T_2^{-1}} [L(X_i) (Y_i^* - L^T(X_i)B) + L(X_j) (Y_j^* - L^T(X_j)B)] \\ [L^T(X_i) (Y_i^* - L^T(X_i)B) + L^T(X_j) (Y_j^* - L^T(X_j)B)] (2^{-1})^T_A) = \\ 2A^{T_2^{-1}} E (L(X_1) L^T(X_1) E[(Y_1^* - L^T(X_1)B)^2 | X_1]) (2^{-1})^T_A,$$

由条件 (C X), (C Y) 可知 $E h_1^2 < J$. 设

$$h_2(X_1, Z_1, D): = E[h_1(X_1, Z_1, D; X_2, Z_2, D) | X_1, Z_1, D] = A^{T_2^{-1}} L(X_1) (Y_1^* - L^T(X_1)B),$$

易证

$$\text{Var}[h_2(X_1, Z_1, D)] = A^{T_2^{-1}} E (L(X_1) L^T(X_1) E[(Y_1^* - L^T(X_1)B)^2 | X_1]) (2^{-1})^T_A = \\ A^{T_2^{-1}} V_1 (2^{-1})^T_A > 0$$

其中 V_1 如定理 2 中定义.

根据 U 统计量中的 Hoeffding 定理 (见文献 [16]), 有

$$\sqrt{n} A^T (\frac{n^2}{C_n^2}) U_n \xrightarrow{d} N(0, 4A^{T_2^{-1}} V_1 (2^{-1})^T_A),$$

则

$$\sqrt{n} A^T U_n \xrightarrow{d} N(0, A^{T_2^{-1}} V_1 (2^{-1})^T_A).$$

由于 S_N 是一系列独立同分布的随机向量之和, 则对于 $A^T S_N$, 由中心极限定理得:

$$\sqrt{n} A^T S_N \xrightarrow{d} N(0, A^{T_{K2^{-1}}} V_2 (2^{-1})^T_A),$$

其中 V_2 如定理 2 中定义.

式 (13)、(14) 得证.

由于 A 的任意性, 从而定理 2 成立.

[参考文献]

- [1] Buckley J James. Linear regression with censored data[J]. Biometrika, 1979, 66(3): 429-436
- [2] Chatterjee S, McLeish D L. Fitting linear regression models to censored data by least squares and maximum likelihood methods[J]. Comm Statist-Theor Meth, 1986, 15(11): 3 227-3 243
- [3] Koul H, Susarla V, Van Ryzin J. Regression analysis with randomly right-censored data[J]. Ann Stat, 1981, 9(6): 1 276-1 288
- [4] Leungans S. Linear models random censoring and synthetic data[J]. Biometrika, 1987, 74(2): 301-309
- [5] Miller R G. Least squares regression with censored data[J]. Biometrika, 1976, 63(6): 449-464
- [6] Zheng Z K. A class of estimator for the parameter in linear regression with censored data[J]. Acta Mathematica Applicatae Sinica, 1987, 3: 231-241
- [7] 秦更生. 随机删失场合部分线性模型中的核光滑方法 [J]. 数学年刊, 1995, A16(4): 441-453
- [8] Prentice R L. Surrogate endpoints in clinical trials: definition and operational[J]. Criteria Statist, 1989, 8: 431-440
- [9] Bound J, Krunt A B. The extend of measurement error in longitudinal learning data: Do two wrongs make a right? [J]. J Labor Economics, 1989, 9: 1-24
- [10] Pepe M S, Fleming T R. A general nonparametric method for dealing with errors in missing or surrogate covariate data[J]. J Amer Statist Assoc, 1991, 86: 108-113
- [11] Pepe M S. Inference using surrogate outcome data and a validation sample[J]. Biometrika, 1992, 79(2): 355-365
- [12] Sepanski J H, Lee L F. Semiparametric estimation of nonlinear error-in-variable models with validation study[J]. J Nonparametr Statist, 1995, 4(4): 365-394
- [13] Carroll R J, Wand M P. Semiparametric estimation in logistic measurement error models[J]. J Roy Statist Soc B, 1991, 53(3): 573-585
- [14] Wang Q ihua. Estimation of linear error-in-covariates models with validation data under random censorship[J]. J Multivariate Anal, 2000, 74(2): 245-266
- [15] Tze Leung K, Zheng Zukang. Survival Analysis[M]. Hangzhou: Zhejiang Publishing House of Science and Technology, 1993: 105-116
- [16] 陈希儒. 非参数统计 [M]. 上海: 上海科学技术出版社, 2000: 58-67

[责任编辑: 丁 蓉]