

# NA 误差下部分线性模型的经验似然推断<sup>\*</sup>

于 卓 熙

(吉林大学数学学院, 长春 130012; 长春税务学院应用数学系, 长春 130117)

王 德 辉

(吉林大学数学学院, 长春 130012)

史 宁 中

(东北师范大学, 长春 130021)

**摘要** 对于部分线性模型  $y_i = \beta x_i + g(t_i) + e_i, 1 \leq i \leq n$ , 这里  $(x_i, t_i)$  是固定设计点,  $g$  是未知函数,  $e_i$  是负相协 (NA) 随机误差, 给出了回归系数的经验似然比统计量, 并讨论了似然比统计量的极限分布, 可构造参数的经验似然置信区间.

**关键词** 部分线性模型, 负相协随机误差, 经验对数似然, 置信区间.

**MR(2000) 主题分类号** 62G10, 62G20, 62M10

## 1 引 言

考虑下面的部分线性模型

$$y_i = \beta x_i + g(t_i) + e_i, \quad 1 \leq i \leq n, \quad (1.1)$$

这里  $(x_i, t_i)$  是非随机设计点,  $\beta$  是未知参数,  $g(\cdot)$  是定义在闭区间  $I$  上的未知函数.

模型 (1.1) 中误差项  $\{e_i\}$  是独立同分布 (i.i.d) 的情形已经被许多学者进行过深入的研究. 这个模型首先由 Engle 等<sup>[1]</sup> 提出, 又由 Heckman<sup>[2]</sup>, Chen<sup>[3]</sup>, Hamilton 和 Truong<sup>[4]</sup> 及 Mammen 和 Van de Geer<sup>[5]</sup> 等学者讨论过. Baek 和 Liang<sup>[6]</sup> 研究了上述模型在负相协 (NA) 误差下参数  $\beta$  的最小二乘估计的相合性和渐近正态性.

在本文中, 我们将运用经验似然方法, 讨论模型 (1.1) 中误差项  $\{e_i, 1 \leq i \leq n\}$  是平稳的 NA 序列的条件下参数的统计推断问题.

称随机变量序列  $\{X_i, 1 \leq i \leq n\}$  是 NA 的, 如果对  $\{1, 2, \dots, n\}$  的任何两个不相交的非空子集  $A$  和  $B$  都有

$$\text{Cov}(f_1(X_i, i \in A), f_2(X_j, j \in B)) \leq 0,$$

\* 国家自然科学基金 (10571073, J10630104), 高等学校博士学科点专项基金 (20070183023), 吉林大学“985”工程和长春税务学院科学研究 (2008016) 项目资助.

收稿日期: 2007-07-23, 收到修改稿日期: 2008-10-27.

其中  $f_1$  和  $f_2$  是任何两个使得协方差存在且对每个变元皆非降 (或同时对每个变元皆非增) 的函数. 称  $\{X_i, i \in N\}$  是 NA 的, 如果对任何自然数  $n \geq 2$ ,  $\{X_i, 1 \leq i \leq n\}$  是 NA 的.

NA 序列由于其在多元统计分析、渗透性理论、可靠性理论等中的广泛应用而越来越受到人们的关注. NA 序列的定义首先由 Alam 和 Saxena<sup>[7]</sup> 提出. Joag-Dev 和 Proschan<sup>[8]</sup>, Shao 和 Su<sup>[9]</sup> 及 Zhang<sup>[10]</sup> 等都相继进行了研究.

另一方面, 经验似然方法是一类非常重要的构造非参数置信区间和检验的方法, Owen<sup>[11]</sup> 对此方法的一般性质进行了系统的研究. 许多研究成果表明, 经验似然有类似于参数似然法的优良性, 特别是它的对数形式类似于 Wilk's 理论是趋于卡方分布的. NA 序列的经验似然推断由 Zhang<sup>[12]</sup> 提出. 目前这种方法还未被应用于 NA 误差下的模型 (1.1).

本文第 2 节构造了 NA 误差下模型 (1.1) 的回归系数的对数经验似然比统计量, 并讨论了统计量的渐近性质. 第 3 节给出数值模拟结果. 定理的证明将在第 4 节给出.

## 2 方法与主要结果

对模型 (1.1), 如果  $\beta$  是已知参数  $\beta_0$ , 则由  $Ee_i = 0$ , 有

$$g(t_i) = E(y_i - x_i\beta_0), \quad 1 \leq i \leq n.$$

所以在给定参数  $\beta$  下  $g(\cdot)$  的一个很自然的估计量是

$$\hat{g}_n(t, \beta) = \sum_{i=1}^n W_{ni}(t)(y_i - x_i\beta),$$

这里  $W_{ni}(\cdot)$  ( $1 \leq i \leq n$ ) 是一些定义在  $I$  上的权函数.

为估计  $\beta$ , 应使下式最小

$$SS(\beta) = \sum_{i=1}^n (y_i - x_i\beta - \hat{g}_n(t_i, \beta))^2. \quad (2.1)$$

(2.1) 式两边对  $\beta$  求导可得

$$\sum_{i=1}^n \left[ y_i - x_i\beta - \sum_{j=1}^n W_{nj}(t_i)(y_j - x_j\beta) \right] \left[ -x_i + \sum_{j=1}^n W_{nj}(t_i)x_j \right],$$

令  $\beta = \beta_0, m_i = [y_i - x_i\beta_0 - \sum_{j=1}^n W_{nj}(t_i)(y_j - x_j\beta_0)] [x_i - \sum_{j=1}^n W_{nj}(t_i)x_j]$ , 我们可以证明当  $n \rightarrow +\infty$  时,  $Em_i \rightarrow 0$ , 则有下面的表示式

$$-2\mathcal{LR}_n(\beta_0) = 2 \sum_{i=1}^n \log(1 + \lambda m_i), \quad (2.2)$$

其中  $\lambda$  满足

$$\frac{1}{n} \sum_{i=1}^n \frac{m_i}{1 + \lambda m_i} = 0. \quad (2.3)$$

为得到  $-2\mathcal{LR}_n(\beta_0)$  的渐近性质, 我们首先做一些假设.

假设  $\{y_i, x_i, t_i \in I, 1 \leq i \leq n\}$  满足模型 (1.1),  $\{e_i, i \geq 1\}$  是均值为零的平稳 NA 随机误差列,  $W_{ni}(\cdot) (1 \leq i \leq n)$  是定义在  $I$  上的一些权函数. 令  $\tilde{x}_i = x_i - \sum_{j=1}^n W_{nj}(t_i)x_j$ ,

$$\tilde{y}_i = y_i - \sum_{j=1}^n W_{nj}(t_i)y_j.$$

$$(C1) \quad i) \lim_{n \rightarrow +\infty} \frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 = \Gamma_0 (0 < \Gamma_0 < \infty), \quad \max_{1 \leq i \leq n} (\tilde{x}_i^2) = o(n^{\frac{1}{2}}).$$

$$ii) \limsup_{n \rightarrow \infty} \left( \frac{1}{\sqrt{n} \log n} \right) \max_{1 \leq k \leq n} \left| \sum_{i=1}^k \tilde{x}_{j_i} \right| < \infty, \text{ 这里 } (j_1, j_2, \dots, j_n) \text{ 是 } (1, 2, \dots, n) \text{ 的任意置换.}$$

(C2)  $g(\cdot)$  定义在  $I$  上并满足一阶 Lipschitz 条件.

$$(C3) \quad \max_{1 \leq i \leq n} \sum_{j=1}^n |W_{nj}(t_i)| = O(1), \quad \max_{1 \leq i, j \leq n} |W_{nj}(t_i)| = O(n^{-\frac{1}{2}} (\log n)^{-1}).$$

$$(C4) \quad i) \max_{1 \leq i \leq n} \left| \sum_{j=1}^n W_{nj}(t_i) - 1 \right| = O(n^{-\frac{1}{4}}).$$

$$ii) \text{ 对某些 } a > 0, \max_{1 \leq i \leq n} \sum_{j=1}^n |W_{nj}(t_i)| I_{(|t_i - t_j| > an^{-\frac{1}{4}})} = O(n^{-\frac{1}{4}}).$$

$$(C5) \quad \text{存在 } p > 4, E|e_i|^p < +\infty. \text{ 当 } u \rightarrow +\infty \text{ 时}, \sum_{j:|k-j| \geq u} |\text{cov}(e_k, e_j)| \rightarrow 0, \text{ 对 } k \geq 1 \text{ 一致成立. }$$

注 2.1 在一般的条件下, 下面的两个权函数就满足假设 (C3)–(C4).

$$W_{ni}^{(1)}(t) = \frac{1}{h_n} \int_{s_{i-1}}^{s_i} K\left(\frac{t-s}{h_n}\right) ds,$$

$$W_{ni}^{(2)}(t) = K\left(\frac{t-t_i}{h_n}\right) \left[ \sum_{j=1}^n K\left(\frac{t-t_j}{h_n}\right) \right]^{-1}.$$

这里  $s_i = \frac{t_i+t_{i-1}}{2}, i = 1, 2, \dots, n-1, s_0 = 0, s_n = 1, K(\cdot)$  是 Parzen-Rosenblatt 核函数,  $h_n$  是窗宽.

$-2\mathcal{LR}_n(\beta_0)$  的渐近性质由下面的定理 2.1 给出.

**定理 2.1** 假设 (C1)–(C5) 成立, 则有当  $n \rightarrow +\infty$  时

$$\frac{-2n\Gamma_0\sigma^2\mathcal{LR}_n(\beta_0)}{\sigma_n^2} \xrightarrow{\mathcal{D}} \chi_{(1)}^2,$$

其中 “ $\xrightarrow{\mathcal{D}}$ ” 是指依分布收敛,  $\sigma_n^2 = \text{Var}\left(\sum_{i=1}^n \tilde{x}_i e_i\right), Ee_i^2 = \sigma^2$ .

由定理 2.1 可知,  $\beta_0$  的一个水平为  $1 - \alpha$  的渐近置信区间为

$$I_\alpha = \left\{ \beta; \frac{-2n\Gamma_0\sigma^2\mathcal{LR}_n(\beta)}{\sigma_n^2} \leq u_\alpha \right\},$$

这里  $u_\alpha$  是  $\chi_{(1)}^2$  分布的  $1 - \alpha$  分位数, 即  $\Pr(\chi_{(1)}^2 \leq u_\alpha) = 1 - \alpha$ .

### 3 模拟计算

这一节我们给出一个数值模拟结果. 模拟中的设计点  $x_i, i = 1, 2, \dots, n$  取为  $x_i = \Phi^{-1}\left(\frac{i}{n+1}\right)$ , 这里  $\Phi(\cdot)$  是标准正态分布的分布函数. 设计点  $t_i, i = 1, 2, \dots, n$  从固定种子 10 的均匀分布  $U[0, 1]$  中产生, 以使它们在每次模拟中取值不变. 函数  $g(\cdot)$  取为  $g(t) = t^2$ . 核函数  $K(t)$  是 Gaussian 核且权函数  $W_{ni}(t)$  取为

$$W_{ni}(t) = K\left(\frac{t - t_i}{h_n}\right) \left[ \sum_{j=1}^n K\left(\frac{t - t_j}{h_n}\right) \right]^{-1}.$$

窗宽  $h_n$  取为  $n^{-\frac{1}{2}}(\log n)^{-1}$ . 误差分布取为标准正态分布, 协方差满足

$$Ee_i e_j (i \neq j) = \begin{cases} -0.25, & \text{如果 } |i - j| = 1, \\ -0.15, & \text{如果 } |i - j| = 2, \\ -0.1, & \text{如果 } |i - j| = 3, \\ 0, & \text{否则.} \end{cases}$$

则  $\{e_i\}$  是 NA 随机变量列. 样本容量分别取为 20, 50, 100, 200, 500 和 1000. 置信水平分别为  $1 - \alpha = 0.90$  和  $1 - \alpha = 0.95$ . 对每组数据重复实现 1000 次, 分别计算了经验似然方法的覆盖率, 表 1 给出了相关结果.

由表 1, 我们可以看出经验似然方法的优良性.  $\beta$  取不同值时, 覆盖率没有太大的变化. 更为有趣的是覆盖率随着样本容量  $n$  的增大而增大. 一般来讲, 不是所有情形下都是这样, 原因是设计点  $(x_i, t_i)$  对不同的样本容量  $n$  取值是不同的.

表 1  $\beta$  的覆盖率

		$\beta = -3.5$	$\beta = -1.5$	$\beta = -0.5$	$\beta = 0$	$\beta = 0.5$	$\beta = 1.5$	$\beta = 3.5$
$n = 20$	$\alpha = 0.10$	0.811	0.786	0.787	0.806	0.804	0.803	0.791
	$\alpha = 0.05$	0.877	0.875	0.876	0.886	0.879	0.868	0.872
$n = 50$	$\alpha = 0.10$	0.818	0.796	0.793	0.809	0.806	0.810	0.800
	$\alpha = 0.05$	0.879	0.882	0.879	0.888	0.880	0.880	0.879
$n = 100$	$\alpha = 0.10$	0.819	0.817	0.819	0.828	0.816	0.814	0.812
	$\alpha = 0.05$	0.885	0.889	0.892	0.892	0.882	0.892	0.886
$n = 200$	$\alpha = 0.10$	0.824	0.825	0.837	0.830	0.826	0.817	0.823
	$\alpha = 0.05$	0.893	0.891	0.896	0.898	0.898	0.893	0.892
$n = 500$	$\alpha = 0.10$	0.834	0.835	0.840	0.834	0.829	0.835	0.831
	$\alpha = 0.05$	0.903	0.896	0.907	0.901	0.907	0.905	0.897
$n = 1000$	$\alpha = 0.10$	0.845	0.844	0.846	0.847	0.849	0.849	0.834
	$\alpha = 0.05$	0.906	0.900	0.910	0.911	0.909	0.917	0.903

## 4 定理的证明

在本节,  $\{X_i, i \geq 1\}$  总表示 NA 随机变量序列且  $EX_i = 0$ . 为证明定理 2.1, 我们首先给出一系列引理.

**引理 4.1** 令  $X_1, X_2, \dots, X_N$  是平稳的 NA 序列且满足  $E|X_1|^{2+\delta} < \infty$ ,  $\delta > 0$ , 则

$$\max_{1 \leq k \leq N} |X_k| = o(N^{\frac{1}{2+\delta}}) \quad \text{a.s.} \quad (4.1)$$

证 见文献 [12].

**引理 4.2** 假设  $\{a_{ni}, 1 \leq i \leq n, n \geq 1\}$  是实三角阵满足  $\max_{1 \leq i \leq n} |a_{ni}| = O(n^{-\frac{1}{2}})$  及  $\sum_{i=1}^n a_{ni}^2 = o(n^{-\frac{1}{2}}(\log n)^{-1})$ . 如果存在  $p > 4$  使得  $\sup_i E|X_i|^p < +\infty$ , 则有

$$\sum_{i=1}^n a_{ni} X_i = o(n^{-\frac{1}{4}}) \quad \text{a.s.} \quad (4.2)$$

证 见文献 [6].

**引理 4.3** 假设  $\{a_{ni}(\cdot), 1 \leq i \leq n, n \geq 1\}$  是定义在闭区间  $I$  上的函数阵并且满足  $\max_{1 \leq i, j \leq n} |a_{ni}(u_j)| = O(n^{-\frac{1}{2}})$  及  $\max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ni}(u_j)| = O(1)$ . 如果存在  $p > 2$  使得  $\sup_i E|X_i|^p < +\infty$ , 则

$$\max_{1 \leq j \leq n} \left| \sum_{i=1}^n a_{ni}(u_j) X_i \right| = o(L(n)) \quad \text{a.s.,} \quad (4.3)$$

$$\max_{1 \leq j \leq n} \left( \sum_{i=1}^n |a_{ni}(u_j) X_i| \right) = O(1) \quad \text{a.s.,} \quad (4.4)$$

这里  $L(x) > 0$  是一个函数, 满足  $x \rightarrow \infty$  时,  $\sqrt{x}L(x)$  对于  $x \geq x_0 > 0$  是非降的.

证 见文献 [6].

**引理 4.4** 令  $\{a_{ni}, 1 \leq i \leq n, n \geq 1\}$  是一个实三角阵满足当  $n \rightarrow +\infty$  时,  $\sum_{i=1}^n a_{ni}^2 = O(1)$  及  $\max_{1 \leq i \leq n} |a_{ni}| \rightarrow 0$ . 假设当  $u \rightarrow +\infty$  时,  $\sum_{j:|k-j| \geq u} |\text{cov}(X_k, X_j)| \rightarrow 0$  对  $k \geq 1$  一致成立. 如果  $\text{Var}(\sum_{i=1}^n a_{ni} X_i) \rightarrow 1$  且  $X_i$  在  $L_2$  上一致可积, 则  $\sum_{i=1}^n a_{ni} X_i \xrightarrow{\mathcal{D}} N(0, 1)$ .

证 见文献 [13].

**引理 4.5** 假设定理 2.1 的条件成立, 则有

$$\max_{1 \leq i \leq n} |m_i| = o(n^{\frac{1}{2+\delta} + \frac{1}{4}}) \quad \text{a.s.} \quad (4.5)$$

证

$$\begin{aligned} \max_{1 \leq i \leq n} |m_i| &= \max_{1 \leq i \leq n} \left| \left( y_i - x_i \beta_0 - \sum_{j=1}^n W_{nj}(t_i)(y_j - x_j \beta_0) \right) \left( x_i - \sum_{j=1}^n W_{nj}(t_i)x_j \right) \right| \\ &= \max_{1 \leq i \leq n} \left| \tilde{g}(t_i) + e_i - \sum_{j=1}^n W_{nj}(t_i)e_j \right| |\tilde{x}_i| \end{aligned}$$

$$\leq \left( \max_{1 \leq i \leq n} |\tilde{g}(t_i)| + \max_{1 \leq i \leq n} |e_i| + \max_{1 \leq i \leq n} \left| \sum_{j=1}^n W_{nj}(t_i) e_j \right| \right) \max_{1 \leq i \leq n} |\tilde{x}_i|,$$

其中  $\tilde{g}(t_i) = g(t_i) - \sum_{j=1}^n W_{nj}(t_i)g(t_j)$ . 由引理 4.1 可知  $\max_{1 \leq i \leq n} |e_i| = o(n^{\frac{1}{2+\delta}})$  a.s., 这里  $p = 2 + \delta, \delta > 2$ .

(C1) i) 表明  $\max_{1 \leq i \leq n} |\tilde{x}_i| = o(n^{\frac{1}{4}})$ . 由 (C3) 及引理 4.3, 取  $L(n) = (\log n)^{-1}$ , 有

$$\max_{1 \leq i \leq n} \left( \left| \sum_{j=1}^n W_{nj}(t_i) e_j \right| \right) = o((\log n)^{-1}) \quad \text{a.s.}$$

由 (C2) 及 (C4) 可得

$$\begin{aligned} & \max_{1 \leq i \leq n} |\tilde{g}(t_i)| \\ &= \max_{1 \leq i \leq n} \left| g(t_i) - \sum_{j=1}^n W_{nj}(t_i)g(t_j) \right| \\ &\leq \max_{1 \leq i \leq n} |g(t_i)| \left| \sum_{j=1}^n W_{nj}(t_i) - 1 \right| + \max_{1 \leq i \leq n} \left| \sum_{j=1}^n W_{nj}(t_i) \right| |g(t_i) - g(t_j)| I_{(|t_i - t_j| > an^{-\frac{1}{4}})} \\ &\quad + \max_{1 \leq i \leq n} \left| \sum_{j=1}^n W_{nj}(t_i) \right| |g(t_i) - g(t_j)| I_{(|t_i - t_j| \leq an^{-\frac{1}{4}})} \\ &= O(n^{-\frac{1}{4}}). \end{aligned}$$

这表明  $\max_{1 \leq i \leq n} |m_i| = o(n^{\frac{1}{2+\delta} + \frac{1}{4}})$  a.s., 证毕

**引理 4.6** 假设定理 2.1 的条件成立, 则

$$|\lambda| = o(n^{-\frac{2}{2+\delta} - \frac{3}{4}}) \quad \text{a.s.} \quad (4.6)$$

证 记  $\lambda = \rho\psi$ , 其中  $\rho \geq 0, |\psi| = 1$ . 由

$$\frac{1}{n} \sum_{i=1}^n \frac{m_i}{1 + \lambda m_i} = 0,$$

可得

$$\begin{aligned} 0 &= \frac{1}{n} \psi \sum_{i=1}^n \frac{m_i}{1 + \rho\psi m_i} = \frac{1}{n} \psi \sum_{i=1}^n m_i - \frac{\rho}{n} \sum_{i=1}^n \frac{(\psi m_i)^2}{1 + \rho\psi m_i} \\ &\leq \frac{1}{n} \psi \sum_{i=1}^n m_i - \frac{\rho}{n} \frac{\sum_{i=1}^n (\psi m_i)^2}{1 + \rho \max_{1 \leq i \leq n} |m_i|} \\ &\leq \frac{1}{n} \psi \left( \sum_{i=1}^n m_i \right) \left( 1 + \rho \max_{1 \leq i \leq n} |m_i| \right) - \rho \left( \frac{1}{n} \sum_{i=1}^n m_i^2 \right), \end{aligned}$$

即

$$\rho\left(\frac{1}{n} \sum_{i=1}^n m_i^2 - \psi\left(\max_{1 \leq i \leq n} |m_i|\right) \left(\frac{1}{n} \sum_{i=1}^n m_i\right)\right) \leq \frac{1}{n} \psi \sum_{i=1}^n m_i.$$

而

$$\frac{1}{n} \sum_{i=1}^n m_i^2 \leq \frac{1}{n} \sum_{i=1}^n \left(\max_{1 \leq i \leq n} |m_i|\right)^2 = o(n^{\frac{2}{2+\delta} + \frac{1}{2}}) \quad \text{a.s.}$$

又

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n m_i &= \frac{1}{n} \sum_{i=1}^n \tilde{x}_i e_i - \frac{1}{n} \sum_{i=1}^n \left(\sum_{j=1}^n W_{nj}(t_i) e_j\right) \tilde{x}_i + \frac{1}{n} \sum_{i=1}^n \tilde{g}(t_i) \tilde{x}_i \\ &=: A_{1n} + A_{2n} + A_{3n}. \end{aligned}$$

由引理 4.2 及条件 (C1) i), 有

$$\max_{1 \leq i \leq n} \frac{|\tilde{x}_i|}{n} = o(n^{-\frac{3}{4}}), \quad \sum_{i=1}^n \frac{|\tilde{x}_i|^2}{n^2} = O(n^{-1}).$$

所以

$$A_{1n} = o(n^{-\frac{1}{4}}) \quad \text{a.s.}$$

显然,

$$A_{2n} = \sum_{j=1}^n \left(\frac{1}{n} \sum_{i=1}^n W_{nj}(t_i) \tilde{x}_i\right) e_j =: \sum_{j=1}^n V_{nj} e_j,$$

由 Abel's 不等式及条件 (C1) ii) 和 (C3), 有

$$\max_{1 \leq j \leq n} |V_{nj}| = \frac{1}{n} \max_{1 \leq j \leq n} \left| \sum_{i=1}^n W_{nj}(t_i) \tilde{x}_i \right| \leq \frac{C}{n} \max_{1 \leq i, j \leq n} |W_{nj}(t_i)| \cdot \max_{1 \leq k \leq n} \left| \sum_{i=1}^k \tilde{x}_{j_i} \right| = O(n^{-1}),$$

其中  $(j_1, j_2, \dots, j_n)$  是  $(1, 2, \dots, n)$  的任意置换.

$$\begin{aligned} \sum_{j=1}^n V_{nj}^2 &= \sum_{j=1}^n \frac{1}{n^2} \left( \sum_{i=1}^n W_{nj}(t_i) \tilde{x}_i \right)^2 \leq \frac{1}{n} \sum_{j=1}^n \sum_{i=1}^n W_{nj}^2(t_i) \left( \frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 \right) \\ &\leq \frac{C}{n} \sum_{i=1}^n \left( \max_{1 \leq j \leq n} |W_{nj}(t_i)| \right) \sum_{j=1}^n |W_{nj}(t_i)| = O(n^{-\frac{1}{2}} (\log n)^{-1}), \end{aligned}$$

这里  $C$  是一个不依赖于  $n$  的常数, 应用引理 4.2, 可得

$$A_{2n} = O(n^{-\frac{1}{4}}) \quad \text{a.s.}$$

由 Abel's 不等式及 (C1) ii) 有

$$|A_{3n}| = \frac{1}{n} \left| \sum_{i=1}^n \tilde{g}(t_i) \tilde{x}_i \right| \leq \frac{C}{n} \max_{1 \leq i \leq n} |\tilde{g}(t_i)| \cdot \max_{1 \leq k \leq n} \left| \sum_{i=1}^k \tilde{x}_{j_i} \right| = O(n^{-\frac{3}{4}} \log n).$$

所以

$$\frac{1}{n} \sum_{i=1}^n m_i = O(n^{-\frac{1}{4}}) \quad \text{a.s.}$$

由以上证明可知

$$\rho = o(n^{-\frac{2}{2+\delta}-\frac{3}{4}}) \quad \text{a.s.},$$

这表明

$$|\lambda| = o(n^{-\frac{2}{2+\delta}-\frac{3}{4}}) \quad \text{a.s.}$$

**引理 4.7** 假设定理 2.1 的条件成立, 则有

$$\frac{1}{\sigma_n} \sum_{i=1}^n m_i \xrightarrow{\mathcal{D}} N(0, 1), \quad (4.7)$$

其中  $\sigma_n^2 = \text{Var}\left(\sum_{i=1}^n \tilde{x}_i e_i\right)$ .

证 由 (C5) 及 [14], 可知

$$\begin{aligned} \sigma_n^2 &= \text{Var}\left(\sum_{i=1}^n \tilde{x}_i e_i\right) = \int_{-\pi}^{\pi} f(\omega) \left| \sum_{k=1}^n \tilde{x}_k e^{-ik\omega} \right|^2 d\omega \\ &\geq 2\pi\delta \sum_{k=1}^n \tilde{x}_k^2 = O(n). \end{aligned}$$

$$\frac{1}{\sigma_n} \sum_{i=1}^n m_i = \frac{1}{\sigma_n} \sum_{i=1}^n \tilde{g}(t_i) \tilde{x}_i - \frac{1}{\sigma_n} \sum_{i=1}^n \left( \sum_{j=1}^n W_{nj}(t_i) e_j \right) \tilde{x}_i + \frac{1}{\sigma_n} \sum_{i=1}^n \tilde{x}_i e_i.$$

由  $\max_{1 \leq i \leq n} |\tilde{g}(t_i)| = O(n^{-\frac{1}{4}})$  及 (C1) ii), 有

$$\frac{1}{\sigma_n} \sum_{i=1}^n |\tilde{g}(t_i) \tilde{x}_i| \leq \frac{C}{\sqrt{n}} \sum_{i=1}^n |\tilde{g}(t_i) \tilde{x}_i| \leq \frac{C}{\sqrt{n}} \max_{1 \leq i \leq n} |\tilde{g}(t_i)| \cdot \max_{1 \leq k \leq n} \left| \sum_{i=1}^k \tilde{x}_{j_i} \right| = O(n^{-\frac{1}{4}} \log n).$$

由 (C1) ii) 并且应用引理 4.3, 取  $L(n) = (\log n)^{-1}$ , 可得

$$\begin{aligned} \frac{1}{\sigma_n} \sum_{i=1}^n \left| \left( \sum_{j=1}^n W_{nj}(t_i) e_j \right) \tilde{x}_i \right| &\leq \frac{C}{\sqrt{n}} \sum_{i=1}^n \left| \tilde{x}_i \sum_{j=1}^n W_{nj}(t_i) e_j \right| \\ &\leq \frac{C}{\sqrt{n}} \left( \max_{1 \leq k \leq n} \left| \sum_{i=1}^k \tilde{x}_{j_i} \right| \right) \left( \max_{1 \leq i \leq n} \left| \sum_{j=1}^n W_{nj}(t_i) e_j \right| \right) \\ &= \frac{1}{\sqrt{n}} O(n^{\frac{1}{2}} \log n) o((\log n)^{-1}) \\ &= o(1) \quad \text{a.s.} \end{aligned}$$

应用引理 4.4, 由 (C1) 及 (C5) 知  $\max_{1 \leq i \leq n} \frac{|\tilde{x}_i|}{\sigma_n} \rightarrow 0$  且  $\sum_{i=1}^n \frac{\tilde{x}_i^2}{\sigma_n^2} = O(1)$ , 可以得到

$$\frac{1}{\sigma_n} \sum_{i=1}^n \tilde{x}_i e_i \xrightarrow{\mathcal{D}} N(0, 1),$$

从而引理 4.7 的结论成立.

**引理 4.8** 假设定理 2.1 的条件成立, 则有

$$\frac{1}{n} \sum_{i=1}^n m_i^2 \longrightarrow \Gamma_0 \sigma^2 \quad \text{a.s.} \quad (4.8)$$

证

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n m_i^2 &= \frac{1}{n} \left[ \sum_{i=1}^n \tilde{g}^2(t_i) \tilde{x}_i^2 + 2 \sum_{i=1}^n \tilde{g}(t_i) \tilde{x}_i^2 e_i - 2 \sum_{i=1}^n \left( \sum_{j=1}^n W_{nj}(t_i) e_j \right) \tilde{g}(t_i) \tilde{x}_i^2 \right. \\ &\quad \left. - 2 \sum_{i=1}^n \left( \sum_{j=1}^n W_{nj}(t_i) e_j \right) \tilde{x}_i^2 e_i + \sum_{i=1}^n \tilde{x}_i^2 e_i^2 + \sum_{i=1}^n \left( \sum_{j=1}^n W_{nj}(t_i) e_j \right)^2 \tilde{x}_i^2 \right], \end{aligned}$$

由前面证明及 (C1) ii), 可得

$$\frac{1}{n} \sum_{i=1}^n \tilde{g}^2(t_i) \tilde{x}_i^2 \leq \left( \max_{1 \leq i \leq n} |\tilde{g}(t_i)| \right)^2 \left( \frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 \right) = O(n^{-\frac{1}{2}}).$$

而

$$\begin{aligned} \frac{1}{n} \left| \sum_{i=1}^n \left( \sum_{j=1}^n W_{nj}(t_i) e_j \right) \tilde{g}(t_i) \tilde{x}_i^2 \right| &\leq \left( \max_{1 \leq i \leq n} \left| \sum_{j=1}^n W_{nj}(t_i) e_j \right| \right) \left( \max_{1 \leq i \leq n} |\tilde{g}(t_i)| \right) \left( \frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 \right) \\ &= o(n^{-\frac{1}{4}} (\log n)^{-1}) \quad \text{a.s.} \end{aligned}$$

又

$$\begin{aligned} \frac{1}{n} \left| \sum_{i=1}^n \left( \sum_{j=1}^n W_{nj}(t_i) e_j \right)^2 \tilde{x}_i^2 \right| &\leq \left( \max_{1 \leq i \leq n} \left| \sum_{j=1}^n W_{nj}(t_i) e_j \right| \right)^2 \left( \frac{C}{n} \sum_{i=1}^n \tilde{x}_i^2 \right) \\ &= o((\log n)^{-2}) \quad \text{a.s.} \end{aligned}$$

注意到

$$\frac{1}{n} \sum_{i=1}^n \tilde{g}(t_i) \tilde{x}_i^2 e_i = \sum_{i=1}^n \tilde{g}(t_i) \frac{\tilde{x}_i^2}{n} e_i,$$

且由 (C1) i), 有

$$\max_{1 \leq i \leq n} \left| \tilde{g}(t_i) \frac{\tilde{x}_i^2}{n} \right| \leq \left( \max_{1 \leq i \leq n} |\tilde{g}(t_i)| \right) \left( \max_{1 \leq i \leq n} \left| \frac{\tilde{x}_i^2}{n} \right| \right) = o(n^{-\frac{3}{4}}),$$

$$\sum_{i=1}^n \tilde{g}^2(t_i) \frac{\tilde{x}_i^4}{n^2} \leq \left( \max_{1 \leq i \leq n} |\tilde{g}(t_i)| \right)^2 \left( \max_{1 \leq i \leq n} \left| \frac{\tilde{x}_i^2}{n} \right| \right) \left( \frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 \right) = o(n^{-1}),$$

所以, 由引理 4.2 可得

$$\frac{1}{n} \sum_{i=1}^n \tilde{g}(t_i) \tilde{x}_i^2 e_i = o(n^{-\frac{1}{4}}) \quad \text{a.s.}$$

又知

$$\frac{1}{n} \left| \sum_{i=1}^n \left( \sum_{j=1}^n W_{nj}(t_i) e_j \right) \tilde{x}_i^2 e_i \right| \leq \max_{1 \leq i \leq n} \left| \sum_{j=1}^n W_{nj}(t_i) e_j \right| \cdot \left( \frac{1}{n} \sum_{i=1}^n |\tilde{x}_i^2 e_i| \right),$$

由 (C1) i) 且应用引理 4.3, 可得  $\frac{1}{n} \sum_{i=1}^n |\tilde{x}_i^2 e_i| = O(1)$  a.s., 所以可以得到

$$\max_{1 \leq i \leq n} \left| \sum_{j=1}^n W_{nj}(t_i) e_j \right| \cdot \left( \frac{1}{n} \sum_{i=1}^n |\tilde{x}_i^2 e_i| \right) = o((\log n)^{-1}) \quad \text{a.s.}$$

现在我们来证明

$$\frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 e_i^2 \longrightarrow \Gamma_0 \sigma^2 \quad \text{a.s.}$$

显然

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 e_i^2 &= \frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 [(e_i^+)^2 - E(e_i^+)^2 + (e_i^-)^2 - E(e_i^-)^2 + Ee_i^2] \\ &= \frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 \{[(e_i^+)^2 - E(e_i^+)^2] + [(e_i^-)^2 - E(e_i^-)^2]\} + \frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 Ee_i^2. \end{aligned}$$

这里  $a^+ = \max(0, a)$ ,  $a^- = \max(0, -a)$ . 定义  $[(e_i^+)^2 - E(e_i^+)^2] + [(e_i^-)^2 - E(e_i^-)^2] =: \xi_i$ , 则  $\{\xi_i, i \geq 1\}$  仍然是均值为 0 的 NA 随机变量序列并且满足  $\sup_i E|\xi_i|^{\frac{p}{2}} \leq C \sup_i E|e_i|^p < +\infty$ ,

由引理 4.3 及条件 C(1) i), 有

$$\frac{1}{n} \left| \sum_{i=1}^n \tilde{x}_i^2 \{[(e_i^+)^2 - E(e_i^+)^2] + [(e_i^-)^2 - E(e_i^-)^2]\} \right| = o((\log n)^{-1}) \quad \text{a.s.}$$

所以可以得到

$$\frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 Ee_i^2 = \sigma^2 \frac{1}{n} \sum_{i=1}^n \tilde{x}_i^2 \longrightarrow \Gamma_0 \sigma^2,$$

从而引理 4.8 证毕.

### 定理 2.1 的证明

$$|Em_i| = |\tilde{g}(t_i)| |\tilde{x}_i| \leq \left( \max_{1 \leq i \leq n} |\tilde{g}(t_i)| \right) \left( \max_{1 \leq i \leq n} |\tilde{x}_i| \right) = o(1).$$

所以有

$$Pr(m_{(1)} < 0 < m_{(n)}) \longrightarrow 1,$$

其中  $m_{(i)}$  代表  $m_i$  中由小到大的第  $i$  个次序值. 显然

$$-2\mathcal{LR}_n(\beta_0) = 2 \sum_{i=1}^n \log(1 + \lambda m_i) = 2 \sum_{i=1}^n \left( \lambda m_i - \frac{1}{2} \lambda^2 m_i^2 \right) + R_{n1},$$

这里  $R_{n1} \leq \sum_{i=1}^n |\lambda m_i|^3 \leq |\lambda|^3 n \left( \max_{1 \leq i \leq n} |m_i| \right)^3 = o(n^{-\frac{3}{2+\delta}-\frac{1}{2}})$  a.s.

令

$$R_{n2} = \frac{1}{n} \sum_{i=1}^n \lambda^2 m_i^2 \frac{m_i}{1 + \lambda m_i},$$

则有

$$|R_{n2}| \leq \frac{1}{n} \sum_{i=1}^n |\lambda| \left( \max_{1 \leq i \leq n} |m_i| \right)^2 = o(n^{-\frac{1}{4}}) \quad \text{a.s.}$$

由于

$$\frac{1}{n} \sum_{i=1}^n m_i - \frac{1}{n} \sum_{i=1}^n \lambda m_i^2 + R_{n2} = \frac{1}{n} \sum_{i=1}^n \frac{m_i}{1 + \lambda m_i} = 0,$$

可知

$$\lambda = \frac{\frac{1}{n} \sum_{i=1}^n m_i}{\frac{1}{n} \sum_{i=1}^n m_i^2} + o(1) \quad \text{a.s.}$$

从而

$$\begin{aligned} -2\mathcal{LR}_n(\beta_0) &= 2 \frac{\frac{1}{n} \sum_{i=1}^n m_i}{\frac{1}{n} \sum_{i=1}^n m_i^2} \sum_{i=1}^n m_i - \left( \frac{\frac{1}{n} \sum_{i=1}^n m_i}{\frac{1}{n} \sum_{i=1}^n m_i^2} \right)^2 \sum_{i=1}^n m_i^2 + o(1) \\ &= \frac{2 \frac{1}{n} \left( \sum_{i=1}^n m_i \right)^2}{\frac{1}{n} \sum_{i=1}^n m_i^2} - \frac{\frac{1}{n^2} \left( \sum_{i=1}^n m_i \right)^2}{\frac{1}{n^2} \sum_{i=1}^n m_i^2} + o(1) \\ &= \frac{\frac{\sigma_n^2}{n} \left( \frac{1}{\sigma_n} \sum_{i=1}^n m_i \right)^2}{\frac{1}{n} \sum_{i=1}^n m_i^2} + o(1) \quad \text{a.s.} \end{aligned}$$

所以, 结合引理 4.7 及引理 4.8, 我们得到  $\frac{-2n\Gamma_0\sigma^2\mathcal{LR}_n(\beta_0)}{\sigma_n^2} \xrightarrow{\mathcal{D}} \chi_{(1)}^2$ , 证明完成.

## 参 考 文 献

- [1] Engle R, Granger C, Rice J, Weiss A. Nonparametric estimates of the relation between weather and electricity sales. *J. Amer. Statist. Assoc.*, 1986, **81**: 310–320.
- [2] Heckman N. Spline smoothing in partly linear models. *J. Roy. Statist. Soc. B*, 1986, **48**: 244–248.
- [3] Chen H. Convergence rates for parametric components in a partly linear model. *Ann. Statist.*, 1988, **16**: 136–146.

- [4] Hamilton S A, Truong Y K. Local linear estimation in partly linear models. *J. Multivariate Anal.*, 1997, **60**: 1–19.
- [5] Mammen E, Van de Geer. Penalized quasi-likelihood estimation in partly linear models. *Ann. Statist.*, 1997, **25**: 1014–1035.
- [6] Beak J I, Liang H Y. Asymptotics of estimators in semi-parametric model under NA samples. *J. Statist. Plann. Infer.*, 2006, **136**: 3362–3382.
- [7] Alam K, Saxena K M L. Positive dependence in multivariate distributions. *Comm. Statist. Theory Methods*, 1981, **A10**: 1183–1196.
- [8] Joag-Dev K, Proschan F. Negative association of random variables with applications. *Ann. Statist.*, 1983, **11**: 286–295.
- [9] Shao Q M, Su C. The law of the iterated logarithm for negatively associated random variables. *Stochastic Process. Appl.*, 1999, **83**: 139–148.
- [10] Zhang L X. The weak convergence for functions of negatively associated random variables. *J. Multivariate Anal.*, 2001, **78**: 272–298.
- [11] Owen A B. Empirical likelihood confidence regions. *Ann. Statist.*, 1990, **18**: 90–120.
- [12] Zhang J J. Empirical likelihood for NA series. *Statist. Probab. Lett.*, 2006, **76**: 153–160.
- [13] Liang H Y, Beak J I. Convergence of weighted sums for dependent random variables. *J. Korean Math. Soc.*, 2004, **41**(5): 883–894.
- [14] Chen Z G. An extension of Lai and Wei's law of the iterated logarithm with application to time series analysis and regression. *Comm. Statist. Theory Methods*, 1990, **32**: 55–69.

## EMPIRICAL LIKELIHOOD IN PARTIAL LINEAR MODEL UNDER NA SAMPLES

YU Zhuoxi

*(School of Mathematics, Jilin University, Changchun 130012; Department of Mathematics,  
Changchun Taxation College, Changchun 130117)*

WANG Dehui

*(School of Mathematics, Jilin University, Changchun 130012)*

SHI Ningzhong

*(Northeast Normal University, Changchun 130021)*

**Abstract** This paper is concerned with the typical partial linear model  $y_i = \beta x_i + g(t_i) + e_i, 1 \leq i \leq n$ , where  $(x_i, t_i)$  are fixed design points,  $g$  is an unknown function, and  $e_i$ 's are negatively associated (NA) random errors. An empirical log-likelihood ratio for the regression coefficient is proposed, the results show that the statistic is asymptotically chi-squared distributed and that the confidence intervals can be constructed accordingly.

**Key words** Partial linear model, negatively associated random errors, empirical log-likelihood, confidence intervals.