

文章编号:1671-6833(2003)02-0084-03

污染数据回归分析的参数估计

胡玉萍¹, 王霞², 李学相³

(1. 郑州大学系统科学与数学系, 河南 郑州 450052; 2. 郑州轻工业学院信息与计算科学系, 河南 郑州 450002; 3. 郑州大学工程力学系, 河南 郑州 450002)

摘要: 截断数据是生存分析的重要研究内容, 而关于污染数据的分析在近几年也越来越受到人们的重视. 研究简单回归模型: $X_i^{(0)} = \gamma + \beta\mu_i + \xi$, $i = 1, 2, \dots, n$, 其中 $E\xi = 0$, $E\xi^2 = \sigma_1^2$; 但 $X_1^{(0)}, X_2^{(0)}, \dots, X_n^{(0)}$, 受到另一独立同分布随机变量序列 W_1, W_2, \dots, W_n 的污染, W_i 与 X_i 独立, 即有 $X_i = (1 - \alpha)X_i^{(0)} + \alpha W_i$, $i = 1, 2, \dots, n$. 给出污染系数 α 的区间估计, 并由此给出 γ, β 的点估计.

关键词: 截断数据; 污染数据; 区间估计

中图分类号: O 212.7

文献标识码: A

0 引言

近年来, 截断数据(Censored Data)的研究获得了很大的发展. 在实际问题中, 除了截断数据之外, 还经常会遇到一些关于所谓污染数据(Contaminated Data)的统计分析问题. 其中一类污染数据具有形式

$$X_i = (1 - \alpha)X_i^{(0)} + \alpha W_i, (i = 1, 2, \dots, n) \quad (1)$$

即我们在观察随机变量 $X_i^{(0)}$ 时, 受到随机变量 W_i 的干扰. 一般我们假定 $X_i^{(0)}$ 是独立同分布的, 且序列 W_i 与序列 $X_i^{(0)}$ 独立, 使观察数据受到污染, 我们希望由观察数据 X_i 来对 $X_i^{(0)}$ 的分布及其特征作出统计推断.

考虑简单线性模型

$$X_i^{(0)} = \gamma + \beta\mu_i + \xi, (i = 1, 2, \dots, n) \quad (2)$$

式中: μ_i 为固定的回归设计(常数序列); γ, β 是待估参数. 设

$$\{\xi, 1 \leq i \leq n\} \text{ i. i. d. }, \xi \sim N(0, \sigma_1^2), (0 < \sigma_1^2 < \infty) \quad (3)$$

在式(1)决定的污染状态下, 我们只能观察到

$$X_i = (1 - \alpha)X_i^{(0)} + \alpha W_i, (0 \leq \alpha \leq 1),$$

设随机变量 W_i 相互独立, 服从分布 $N(0, \sigma_2^2)$, 且与序列 $\{\xi\}, \{X_i^{(0)}\}$ 独立, 即

$$\{W_i, 1 \leq i \leq n\} \text{ i. i. d. }, W_i \sim N(0, \sigma_2^2), (0 < \sigma_2^2 < \infty) \quad (4)$$

我们的目的是要用观察数据 X_i 来估计参数 γ, β , 假定 σ_1^2, σ_2^2 已知, 且要求

$$\sigma_1^2 / \sigma_2^2 > \alpha / (1 - \alpha) \quad (5)$$

直观上要求因污染而引起的方差(按一定比例)小于系统部分引起的方差. 注意到

$$\begin{aligned} X_i &= (1 - \alpha)X_i^{(0)} + \alpha W_i \\ &= (1 - \alpha)(\gamma + \beta\mu_i + \xi) + \alpha W_i \\ &= (1 - \alpha)(\gamma + \beta\mu_i) + [(1 - \alpha)\xi + \alpha W_i] \end{aligned} \quad (6)$$

令 $\eta = (1 - \alpha)\xi + \alpha W_i$, 则 η 相互独立服从 $N(0, (1 - \alpha)^2\sigma_1^2 + \alpha^2\sigma_2^2)$.

令 $\gamma_1 = (1 - \alpha)\gamma, \beta_1 = (1 - \alpha)\beta$, 把 γ_1, β_1 视为新的参数, 文献[1]用最小二乘法可求出 γ_1, β_1 的最小二乘估计

$$\gamma_1 = \frac{\sum_{i=1}^n \mu_i \sum_{i=1}^n \mu_i x_i - \sum_{i=1}^n \mu_i^2 \sum_{i=1}^n x_i}{\left(\sum_{i=1}^n \mu_i\right)^2 - n \sum_{i=1}^n \mu_i^2} \quad (7)$$

$$\beta_1 = \frac{\sum_{i=1}^n \mu_i \sum_{i=1}^n x_i - n \sum_{i=1}^n \mu_i x_i}{\left(\sum_{i=1}^n \mu_i\right)^2 - n \sum_{i=1}^n \mu_i^2} \quad (8)$$

又考虑 X_i 的方差估计

$$R_n = \frac{1}{n-2} \sum_{i=1}^n [X_i - \gamma_1 - \beta_1 \mu_i]^2,$$

当 $n \rightarrow \infty$ 时, 由文献[2]知 $R_n \rightarrow (1 - \alpha)^2\sigma_1^2 + \alpha^2\sigma_2^2 \triangleq \sigma^2(a.s.)$.

收稿日期: 2003-01-10; 修订日期: 2003-03-02

基金项目: 河南省自然科学基金资助项目(0311010500)

作者简介: 胡玉萍(1971-), 女, 河南省尉氏县人, 郑州大学讲师, 硕士, 主要从事非参数统计方面的研究.

(C)1994-2023 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

令 $R_n = (1 - \alpha)^2 \sigma_1^2 + \alpha^2 \sigma_2^2$, 可解出 α 的估计值

$$\hat{\alpha} = \frac{\sigma_1^2 - \sqrt{(\sigma_1^2 + \sigma_2^2) R_n - \sigma_1^2 \sigma_2^2}}{\sigma_1^2 + \sigma_2^2} \quad (9)$$

又 $\gamma_1 = (1 - \alpha) \gamma$, $\beta_1 = (1 - \alpha) \beta$, 由 γ_1 , β_1 , α 的估计值 γ_1 , β_1 , $\hat{\alpha}$ 可解出 γ , β 的估计值:

$$\gamma = \gamma_1 \frac{1}{1 - \hat{\alpha}} \quad (10)$$

$$\beta = \beta_1 \frac{1}{1 - \hat{\alpha}} \quad (11)$$

1 污染数据回归分析的参数估计

引理1 设 X_1, X_2, \dots, X_n 为观察到的一系列相互独立数据, 且 $X_i = (1 - \alpha) X_i^{(0)} + \alpha W_i$, $X_i^{(0)} = \gamma + \beta \mu_i + \xi$, $i = 1, 2, \dots, n$. 若式 (3), (4) 成立, 则

$$\frac{1}{\sigma^2} \sum_{i=1}^n (X_i - (\gamma_1 + \beta_1 \mu_i))^2 \sim \chi^2(n-2).$$

证明 由已知条件知 X_1, X_2, \dots, X_n 相互独立, 又由式 (6) 可知

$$E(X_i) = (1 - \alpha)(\gamma + \beta \mu_i);$$

$$D(X_i) = (1 - \alpha)^2 \sigma_1^2 + \alpha^2 \sigma_2^2 = \sigma^2,$$

且 ξ 与 W_i 相互独立, $\xi \sim N(0, \sigma_1^2)$, $W_i \sim N(0, \sigma_2^2)$. 故

$$X_i \sim N((1 - \alpha)(\gamma + \beta \mu_i), \sigma^2).$$

又 γ_1, β_1 分别是 $\gamma_1 = (1 - \alpha) \gamma$, $\beta_1 = (1 - \alpha) \beta$ 的最小二乘估计, 由文献 [3] 中第33页命题3的证明可得

$$\frac{1}{\sigma^2} \sum_{i=1}^n (X_i - (\gamma_1 + \beta_1 \mu_i))^2 \sim \chi^2(n-2),$$

证毕.

定理1 设 X_1, X_2, \dots, X_n 为观察到的一系列相互独立数据, 且

$$X_i = (1 - \alpha) X_i^{(0)} + \alpha W_i, i = 1, 2, \dots, n;$$

$$X_i^{(0)} = \gamma + \beta \mu_i + \xi, i = 1, 2, \dots, n,$$

其中: $\{\mu_i\}$ 为已知的常数序列; 序列 $\{X_i^{(0)}\}$, $\{\xi\}$, $\{W_i\}$ 相互独立, 且 ξ 与 W_i 相互独立. 如果式 (3)、(4) 成立, 则参数 α 的给定置信度为 $1 - \alpha_1$ 的置信区间为 (b, c) .

$$b = \frac{\sigma_1^2 - \sqrt{\sigma_1^2 + \sigma_2^2 \sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{1-\alpha_1/2}^2(n-2) - \sigma_1^2 \sigma_2^2}}{\sigma_1^2 + \sigma_2^2} \quad (12)$$

$$c = \frac{\sigma_1^2 - \sqrt{\sigma_1^2 + \sigma_2^2 \sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{\alpha_1/2}^2(n-2) - \sigma_1^2 \sigma_2^2}}{\sigma_1^2 + \sigma_2^2} \quad (13)$$

定理2 在定理1的条件下, α 在区间 (b, c) 内任取一值 $\hat{\alpha}$, 则可得 γ, β 的估计值为

$$\gamma = \frac{\sum_{i=1}^n \mu_i \sum_{i=1}^n \mu_i x_i - \sum_{i=1}^n \mu_i^2 \sum_{i=1}^n x_i}{\left(\sum_{i=1}^n \mu_i\right)^2 - n \sum_{i=1}^n \mu_i^2} \cdot \frac{1}{1 - \hat{\alpha}} \quad (14)$$

$$\beta = \frac{\sum_{i=1}^n \mu_i \sum_{i=1}^n x_i - n \sum_{i=1}^n \mu_i x_i}{\left(\sum_{i=1}^n \mu_i\right)^2 - n \sum_{i=1}^n \mu_i^2} \cdot \frac{1}{1 - \hat{\alpha}} \quad (15)$$

证明 先证明定理1. 根据引理1知

$$\frac{1}{\sigma^2} \sum_{i=1}^n (X_i - (\gamma_1 + \beta_1 \mu_i))^2 \sim \chi^2(n-2),$$

给定置信度为 $1 - \alpha_1$, 则

$$P\{\chi_{1-\alpha_1/2}^2(n-2) < \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - (\gamma_1 + \beta_1 \mu_i))^2 < \chi_{\alpha_1/2}^2(n-2)\} = 1 - \alpha_1,$$

解得

$$P\{\sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{\alpha_1/2}^2(n-2) < \sigma^2 <$$

$$\sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{1-\alpha_1/2}^2(n-2)\} = 1 - \alpha_1,$$

所以, σ^2 的置信度为 $1 - \alpha_1$ 的置信区间为

$$[\sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{\alpha_1/2}^2(n-2), \sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{1-\alpha_1/2}^2(n-2)],$$

由

$$\sigma^2 = (1 - \alpha)^2 \sigma_1^2 + \alpha^2 \sigma_2^2, \text{ 令 } (1 - \alpha)^2 \sigma_1^2 + \alpha^2 \sigma_2^2$$

$$= \sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{1-\alpha_1/2}^2(n-2),$$

解得

$$\alpha = \frac{\sigma_1^2 - \sqrt{\sigma_1^2 + \sigma_2^2 \sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{1-\alpha_1/2}^2(n-2) - \sigma_1^2 \sigma_2^2}}{\sigma_1^2 + \sigma_2^2},$$

令

$$(1 - \alpha)^2 \sigma_1^2 + \alpha^2 \sigma_2^2 = \sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{\alpha_1/2}^2(n-2),$$

解得

$$\alpha = \frac{\sigma_1^2 - \sqrt{\sigma_1^2 + \sigma_2^2 \sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{\alpha_1/2}^2(n-2) - \sigma_1^2 \sigma_2^2}}{\sigma_1^2 + \sigma_2^2},$$

所以 α 的置信度为 $1 - \alpha_1$ 的置信区间为 (b, c) ,

其中,

$$b = \frac{\sigma_1^2 - \sqrt{\sigma_1^2 + \sigma_2^2 \sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{1-\alpha_1}^2 / (n-2) - \sigma_1^2 \sigma_2^2}}{\sigma_1^2 + \sigma_2^2};$$
$$c = \frac{\sigma_1^2 - \sqrt{\sigma_1^2 + \sigma_2^2 \sum_{i=1}^n (X_i - \gamma_1 - \beta_1 \mu_i)^2 / \chi_{\alpha_1}^2 / (n-2) - \sigma_1^2 \sigma_2^2}}{\sigma_1^2 + \sigma_2^2}.$$

对于定理 2,由式(7)、(8)、(10)、(11)及 α 的估计值即可得式(14)、(15),即得定理 2.
证毕.

2 结束语

通过 $\frac{1}{\sigma^2} \sum_{i=1}^n (X_i - (\gamma_1 + \beta_1 \mu_i))^2 \sim \chi^2(n-2)$

求得 σ^2 的置信度为 $1 - \alpha_1$ 的置信区间,从而得到污染系数 α 的置信度为 $1 - \alpha_1$ 的区间估计及回归参数 γ, β 的点估计.

参考文献:

[1] 郑祖康,吴雪明,饶刚.污染数据处理[J].应用概率统计,1998,14(3):307~312.
[2] 陈希孺,陈桂景,吴启光,等.线性模型参数的估计理论[M].北京:科学出版社,1985.
[3] 周纪芾.实用回归分析方法[M].上海:上海科学技术出版社,1990.

Parameter Estimation in Regression Analysis for Contamination Data

HU Yu -ping¹, WANG Xia², LI Xue -xiang³

(1. Department of System Science & Mathematics, Zhengzhou University, Zhengzhou 450052, China; 2. Department of Information and Computing Sciences, Zhengzhou Institute of Light Industry, Zhengzhou 450002, China; 3. Department of Engineering Mechanics, Zhengzhou University, Zhengzhou 450002, China)

Abstract : Survival analysis attaches much importance to censored data and the analysis of contaminated data is attracting more and more attention in recent years. This paper studies the simple regression model

$$X_i^{(0)} = \gamma + \beta \mu_i + \xi, i = 1, 2, \dots, n$$

where $E\xi = 0, E\xi^2 = \sigma_1^2$. But $X_1^{(0)}, X_2^{(0)}, \dots, X_n^{(0)}$ are contaminated by another i.i.d. random variable sequence W_1, W_2, \dots, W_n . $\{W_i\}$ is independent of $\{X_i^{(0)}\}$. $X_i = (1 - \alpha) X_i^{(0)} + \alpha W_i, i = 1, 2, \dots, n$ gives the interval estimation of α and the point estimation of γ and β respectively.

Key words : censored data ; contamination data ; interval estimation