

自助法 和 经验似然方法

Bootstrap 和 Empirical Likelihood

Mai Zhou

Abstract

我们用不太严格 (但是易懂) 的语言从一个侧面讲述 Bootstrap 和 Empirical Likelihood 方法的一点相似和不同之处。重点是介绍并帮助大家理解 Empirical Likelihood 构造置信区间的方法, 以及关于 Empirical Likelihood 的 Wilks 定理。

1 问题设定

给定随机样本 x_1, x_2, \dots, x_n 我们假定它是从总体 F_0 抽样得来。我们对于总体 F_0 没有假定它是属于某个参数分布族, 所以这是一个非参数模型。另外又有一个我们感兴趣的 (有限维) 统计量 $T(x_1, x_2, \dots, x_n)$ 简单记为 $T(X)$ 。我们不妨先假定它是一维的。(可以想像 $T(X) = 1/n \sum x_i$)。

下面我们仔细分析, 比较 Bootstrap 和 Empirical Likelihood 如何做基于 $T(X)$ 的置信区间。这里的参数是 $\mathbf{E}T(X) = T(F_0)$ 。¹

2 Bootstrap 的理由

对于 Bootstrap 有所了解的读者, 可以略过这一节。

Bootstrap 做法的理由是:

如果我们可以得到更多从总体 F_0 抽样得来的 x_{n+1}, \dots, x_m 则不难用模拟得到 $T(X)$ 的分布。只要一遍又一遍的, 使用新的 x 观察值来计算新的 $T(X)$, 然后用大数定理就可以得出其分布。

但是我们只有 x_1, \dots, x_n , 没有更多。此路不通。

另一方面, 因为“样本是总体的一个忠实反映”, 既然不能从总体抽样, 那我们从它的“忠实反映”来抽!

这相当于从 \hat{F}_n 中抽样。这里 \hat{F}_n 是基于 x_1, \dots, x_n 的经验分布。

¹可能大家想到了用 t-test 和由它产生的置信区间。不过因为 1. 如果统计量 T 不是 $1/n \sum x_i$ 则没法用。2. 用 t-test 方法产生的区间必定是对称的。而 Bootstrap 和 Empirical likelihood 方法都有可能产生非对称的区间。

而众所周知, \hat{F}_n 是 F_0 的一个很好的估计。

$$\hat{F}_n(t) = 1/n \sum_{i=1}^n I[x_i \leq t]$$

把 \hat{F}_n 看成固定, 从这里面抽大小为 n 的随机样本 y_1, y_2, \dots, y_n 即所谓 Bootstrap 样本。由于 \hat{F}_n 和 F_0 很接近, 我们应该有

$$\sqrt{n} [T(y_1, y_2, \dots, y_n) - T(\hat{F}_n)] \sim \sqrt{n} [T(x_1, x_2, \dots, x_n) - T(F_0)] . \quad (1)$$

其中 “ \sim ” 理解为分布很接近。注意: 左边的分布, 是把 \hat{F}_n 看成固定的, 条件分布。在那里只有 y_j 是随机的。

如果我们有 $T(X)$ 的方差估计 $V(X)$, (例如, 当 $T(X) = 1/n \sum x_i$ 时, 有 $V(X) = 1/(n-1) \sum (x_i - \bar{x})^2$) 我们应该有

$$\sqrt{n} \frac{T(y_1, y_2, \dots, y_n) - T(\hat{F}_n)}{\sqrt{V(Y)}} \sim \sqrt{n} \frac{T(x_1, x_2, \dots, x_n) - T(F_0)}{\sqrt{V(X)}} \quad (2)$$

也有人简单的说

$$T(y_1, y_2, \dots, y_n) \sim T(x_1, x_2, \dots, x_n) \quad (3)$$

我们不在这儿深入讨论这些逼近说法的好坏/异同/差别。我们主要看产生 y_1, y_2, \dots, y_n 的方法。

最后, 右边的分布是我们需要的。左边的分布是可以模拟出来的。当然, 左右两边 “很接近” 即 (1), (2) 或 (3) 这个事实需要证明, 也已经被许多人证明了。

用左边的分布来逼近右边的分布就是 Bootstrap。

有了分布, 置信区间就可以得出。比如, 如果 (2) 成立, 并且假设我们通过模拟得到对于左边的分布有

$$P \left(a < \sqrt{n} \frac{T(y_1, \dots, y_n) - T(\hat{F}_n)}{\sqrt{V(Y)}} < b \right) = 0.90$$

那么, 我们就近似的有

$$P \left(a < \sqrt{n} \frac{T(x_1, \dots, x_n) - T(F_0)}{\sqrt{V(X)}} < b \right) \approx 0.90$$

这就可以导出 $T(F_0)$ 的一个 (Bootstrap t-) 置信区间。当然还有别的 (如 Bootstrap percentile) 方法等等。

3 Bootstrap 抽样的三种等价的视角

总结一下: Bootstrap 如何产生 y_1, y_2, \dots, y_n 的三个理解方法。

A. 使用分布函数 \hat{F}_n 来产生样本。即把 \hat{F}_n 当作总体。得到 Bootstrap 样本 y_1, \dots, y_n 。

B. 对于 x_1, x_2, \dots, x_n 做有放回的抽样。抽 n 次得到 Bootstrap 样本 y_1, y_2, \dots, y_n 。

如果我们重新排列, 归类一下 y_1, y_2, \dots, y_n , 按照这些 y 中有多少个等于 x_1 , 多少个等于 x_2 , 等等, 来记录:

$$w_1 = \sum_{j=1}^n I[y_j = x_1], w_2 = \sum_{j=1}^n I[y_j = x_2], \dots, w_n = \sum_{j=1}^n I[y_j = x_n]$$

那么, 在 x_1, x_2, \dots, x_n 已经给定的情况下, 不难看出 w_1, w_2, \dots, w_n 与 y_1, y_2, \dots, y_n 等价。唯一从 w 里得不到的信息是 y 的出现先后的次序。但是在我们的“随机样本”假定下, 观察值的出现次序是不带任何信息的。

不难看出, w_1, w_2, \dots, w_n 服从多项分布。这样, 我们就有了第三种产生 Bootstrap 样本的方法。

C. 产生一个服从多项分布 $M(n, p = (1/n, 1/n, \dots, 1/n))$ 的随机向量 $W = (w_1, w_2, \dots, w_n)$ 。将 x_1, x_2, \dots, x_n 用 W 加权就得到 $y_1^*, y_2^* \dots, y_n^*$ 。(唯一不同的是 y^* 的排列次序未必与原 y 一样)。

如果 $w_j = 2$ 就表示, y_1, y_2, \dots, y_n 中包含了两个 x_j , 等等。如果 $w_1 = 1, w_2 = 1, \dots, w_n = 1$ 就得到原来的样本。

注: 多项分布 $P(w_j = k) = \binom{n}{k} (1/n)^k (1 - 1/n)^{n-k}$ 其中 $k = 0, 1, \dots, n$ 。并且 $\sum w_j = n$ 。

4 贝叶斯 Bootstrap

贝叶斯 (Bayesian Bootstrap) 与上面第三种观点很像。只不过把 W 服从这个多项分布改为 W/n 服从 Dirichlet 分布, 参数为 $\alpha = (1, 1, \dots, 1)$ 。

改完之后 W 的均值, 方差, 协方差都很像。只不过多项分布是离散的, 可以取零值。而 Dirichlet 分布是连续的。Bayesian Bootstrap 把这个 Dirichlet 分布看作是 Posterior 分布。

从某种意义上讲, Dirichlet($\alpha = (1, 1, \dots, 1)$) 分布就是多项分布 $M(n, (1/n, \dots, 1/n))$ 的连续形式。

只不过要注意正则归一化: 多项分布的 W 有 $\sum w_i = n$ 。Dirichlet 分布的 W 有 $\sum w_i = 1$ 。注: 对于 Dirichlet, $\mathbf{E}w_j = 1/n$ 。对于多项分布 $\mathbf{E}w_j = 1$ 。以后我们总假定 W 已经正则归一化 $\sum w_i = 1$ 。

5 经验似然方法

经验似然方法和上面第三种 Bootstrap 抽样 w_1, w_2, \dots, w_n 的表述有一点联系/相近。

为确定起见，我们假定 w 是一个概率，即 $w_j \geq 0, \sum w_j = 1$ 。而且 w_j 不必是离散的，而可以取任何值，只要满足概率的要求。（这个有点像贝叶斯 Bootstrap，但是这里没有分布的假定。）

这样一个 w_1, w_2, \dots, w_n 可以看成/产生一个（离散的）分布函数：

$$F_w(t) = \sum_i w_i I[x_i \leq t].$$

如果 $w_1 = 1/n, \dots, w_n = 1/n$ 这就是 \hat{F}_n （经验分布或者样本分布）。

我们将 w 看作是对于 $1/n, 1/n, \dots, 1/n$ ，或者 \hat{F}_n 的一个扰动，或者叫扭曲。

但是 EL 方法没有假设 w 是随机的，具有一个分布（比如 Dirichlet）等等。而是：EL 引进了一个距离，专门用来测量 F_w 到 \hat{F}_n 的距离。或者是 w_1, w_2, \dots, w_n 到 $1/n, 1/n, \dots, 1/n$ 的距离。

$$D(F_w, \hat{F}_n) = -2 \sum_{i=1}^n \log \frac{w_i}{1/n} = -2 \sum_{i=1}^n \log n w_i$$

不难证明，当且仅当 $F_w = \hat{F}_n$ 时， $D = 0$ 。如若不然， $D > 0$ 。

注：常数 2 只是为了后面方便。这个距离有概率意义，即 $-2 \log$ 经验似然比。引进一个距离并不特别新奇，新奇的是我们有 Wilks 定理。

5.1 Wilks 定理的应用

如果定义了上面的距离 $D(F_w, \hat{F}_n)$ ，那么我们有一种构造置信区间的方法：

记

$$\mathcal{N} = \{F_w : s.t. D(F_w, \hat{F}_n) \leq 2.7\}$$

这是 \hat{F}_n 的一个邻域。

取 $T(\cdot)$ 在 \mathcal{N} 上的最小，最大值就得到置信区间：我们近似的有

$$P(\min_{\mathcal{N}} T(F_w) \leq T(F_0) \leq \max_{\mathcal{N}} T(F_w)) \approx 0.9 \quad (4)$$

上面的数字 2.7 和概率 0.9 的联系是来自卡方分布。因为

$$P(\chi_1^2 \leq 2.7) = 0.9$$

我们可以使用别的数字，比如把 2.7 换成 3.84，概率就变成 0.95。

我们将在下一节讲一点 Wilks 定理的证明。

严格的说，“Wilks 定理”一般指连续随机变量，参数模型的情况。由 Wilks 在 1930 年代提出。这里用的定理是对于非参数模型，由 Owen 在 1980 年代首先证明。

我们不妨还沿用这个名称。不过也有人把它叫 Empirical Likelihood 定理，或者非参数 Wilks 定理。

注：虽然置信区间的定义由 (4) 给出，但是具体计算时有更加直接的方法。

6 Wilks 定理的证明

此节在首次阅读时可以跳过。

这里的证明是 Owen (1988, 1990) 给出的。我们假定前面第一节给出的问题设定。并且进一步假定 $T(X) = \int g(t)d\hat{F}_n(t) = 1/n \sum g(x_i)$ 。其中 $g(\cdot)$ 是某个给定函数。我们记 $T(F_0) = \int g(t)dF_0(t) = \theta_0$ 。

首先我们叙述 Wilks 定理的最重要结论，当 $n \rightarrow \infty$

$$\min -2 \sum_{i=1}^n \log(nw_i) = -2 \max \sum \log(nw_i) \xrightarrow{D} \chi_1^2$$

这个极大 (或极小) 是对于概率 w_i 而言，并且有一个等式约束：

$$\max_w \left\{ \sum \log(nw_i) \text{ s.t. } \sum w_i = 1; w_j \geq 0; 1/n \sum w_i g(x_i) = \theta_0 \right\} \quad (5)$$

也就是

$$\max_{F_w} \left\{ \sum \log(nw_i) \text{ s.t. } \int g(t)dF_w(t) = \theta_0 \right\} . \quad (6)$$

我们先来看这个极限分布它有什么用。

有了这个结论，我们就可以用卡方分布计算假设检验 (列如) $H_0 : \theta_0 = 3$, vs $H_A : \theta_0 \neq 3$ 的 (近似) p - 值。只要将 θ_0 换成 3, 计算上述 \max , 乘 -2 。最后与卡方分布比较，如果这个值太大就不像是服从卡方的 (此时拒绝 H_0)：比如大于 2.7。因为卡方分布有 90% 的概率会小于 2.7。

精确的 p - 值就是 $P(\chi_1^2 > -2 \max \sum \log(nw_i))$ 。

有了对任何 H_0 的 p - 值，就可以得到置信区间：那些不能被拒绝的零假设参数值，收集在一起就构成置信区间。用数学公式写下来就是

$$\{\theta^* : \text{s.t. } -2 \max_{\theta^*} \sum \log(nw_i) < 2.7\} .$$

这里的 \max 就是上面定义的 (5) 或 (6)，只不过将 θ_0 换成 θ^* 。

请大家自行证明这个置信区间等价于上面用邻域定义的置信区间。

下面我们梳理一下证明的主要步骤。首先我们使用拉格朗日乘子法，对于 w_1, \dots, w_n ，计算带两个等式约束的极大 (5)。约束为 $\sum w_i = 1$ 和 $\sum w_i g(x_i) = \theta_0$ 。可以算出

$$w_i = w_i(\lambda^*) = \frac{1}{n - \lambda^*(g(x_i) - \theta_0)},$$

其中的 λ^* 选取要满足等式约束 $\sum w_i g(x_i) = \theta_0$ 。

从这个 $w_i(\lambda)$ 的表达式可以看到，如果 $\lambda = 0$ 那么 $w_i = 1/n$ 。这时 $\sum w_i g(x_i) = 1/n \sum g(x_i)$ 。但是这个一般来说不满足约束 $\sum w_i g(x_i) = \theta_0$ 。

所以 λ^* 要取另外一个非零值。不过，由于 $1/n \sum g(x_i)$ 趋向于真值 θ_0 （大数定律），所以 λ^* 离开零不远。

再多说两句：这个 $w(\lambda)$ 可以看成一个（以 λ 为参数的）单参数分布族。当然，需将 w 归一化，成为一个概率：使得对所有 λ 有 $\sum w_i = 1$ 。就是将 $w(\lambda)$ 除以这个和。

这个单参数分布族

$$F(t, \lambda) = \sum_{i=1}^n I[x_i \leq t] \frac{w_i(\lambda)}{\sum w_j(\lambda)}$$

叫做“最难参数分布族”。（最不友好的参数分布族）。这个参数分布在 $\lambda = 0$ 点的 Fisher 信息数，就是在估计 θ 时的**非参信息数**。此乃后话。

Owen 的计算证明了，如果在上面计算极大的时候，约束条件所用的 θ_0 的确是真值，那么

$$\begin{aligned} -2 \max \sum \log(nw_i) &= -2 \sum \log(nw_i(\lambda^*)) \\ &= \left[1/n \sum g(x_i) - \theta_0 \right] V \left[1/n \sum g(x_i) - \theta_0 \right] + o_p(1) \end{aligned} \quad (7)$$

其中

$$V = \sum (g(x_i) - \theta_0)^2$$

很显然，当 $n \rightarrow \infty$ 时，(7) 的分布趋向于卡方。计算所用到的条件就是可以 Taylor 展开以及大数定理。

7 注解，评论和推广

注 1. 参数 θ 的维数大于一时，证明类似。Owen (1990).

注 2. 注意到 EL 方法构造置信区间的一大特点：没有用到 $T(X)$ 的方差估计。只需要定义（关键的）距离 $D(F_w, \hat{F}_n)$ ，这个就是 $-2 \log$ 经验似然比。Wilks 定理也就是关于这个距离的渐近性质。

注 3. 当样本数据是删失数据时， $-2 \log$ 经验似然比，可以由它的抽样方法的概率，比较容易写出来。例如见 Thomas and Grunkemier (1975) 或者 Owen (2001) 的书中第六章，特别是第 6.6 节。不过证明相应的 Wilks 定理就麻烦一点。这时我们可以利用“最不友好参数分布族”的帮助来简化证明。具体证明细节，以及计算方法和各种例子请见拙著 Empirical Likelihood Method in Survival Analysis (2016) 或者中文的 2.0 版：经验似然方法：在生存分析中的理论和实践 (2023)。

注 4. 计算经验似然置信区间，相应的 R 计算函数包是 `emplik`，可以在 CRAN 上免费下载。具体例子在 `emplik` 包里有一些。在 [7] 里有更多。

References

- [1] Efron, B. and Tibshirani, R. (1993). An introduction to the bootstrap, New York: Chapman & Hall,
- [2] Rubin, D. The Bayesian Bootstrap. (1981). *Ann. Statist.* 130-134.
- [3] Thomas, D.R. and Grunkemeier, G.L. (1975). Confidence Interval Estimation of Survival Probabilities for Censored Data. *Journal of the American Statistical Association*, 70, 865-871.
- [4] Owen, A. B. (1988). Empirical likelihood ratio confidence intervals for a single functional. *Biometrika* 75, 2, 237–249.
- [5] Owen, A. (1990). Empirical Likelihood Ratio Confidence Regions *Ann. Statist.* 18(1): 90-120. DOI: 10.1214/aos/1176347494
- [6] Owen, A. *Empirical Likelihood*. Chapman & Hall (2001)
- [7] Zhou, M. *Empirical Likelihood Method in Survival Analysis*. Chapman & Hall (2016).
- [8] 经验似然方法：在生存分析中的理论和实践，周迈著，杨一帆周迈译