

PP 型拟合优度检验*

张 航

(中国科学院系统科学研究所)

I. 引 言

摄影寻踪 (Projection Pursuit, 简称 PP) 是一种新兴的用来处理高维数据的统计方法, 其主要思想是通过极大化某个投影指标(通常是分布函数的泛函)来寻找低维投影, 通过对其低维投影数据的研究来发现高维数据的性质. PP 方法自首次提出, 已用于处理一些非正态多维数据分析问题, 如回归、判别、聚类、密度估计等^[2,4].

PP 的一个特点就是能把许多一维方法用于多维问题. 本文就是用 PP 方法, 以经典的 χ^2 检验统计量作为投影指标, 得到一种高维分布的拟合优度检验, 并对其极限分布进行研究.

II. 主要结果

(R^k, \mathcal{B}^k) 是 k 维 Lebesgue 可测空间, S_1, \dots, S_m 是 R^1 上的 m 个不相交的区间, 且 $\bigcup_{i=1}^m S_i = R^1$. 本文中的 a, b 均代表 k 维方向, 令 $S_i^a = \{x: a^T x \in S_i, x \in R^k\}$; $I_i^a = 1_{S_i^a}$, $1_{S_i^a}$ 是 S_i^a 的示性函数.

P, G 为 (R^k, \mathcal{B}^k) 上的概率分布, P 连续, 已知或仅含有未知参数. 我们要检验 $H_0: G = P \leftrightarrow k: G \neq P$.

有样本 X_1, \dots, X_n i. i. d $\sim G$, 对任意方向 a , $a^T X_1, \dots, a^T X_n$ i. i. d $\sim G_a$, 其中 G_a 是 G 在方向 a 上的边际分布.

传统的 χ^2 统计量 $z_n^a = \sum_{i=1}^m n(P_{ni}^a - \pi_i^a)^2 / \pi_i^a$ 可以用来检验 G_a 是否等于 P_a , 这里 $\pi_i^a = P(S_i^a)$, $P_{ni}^a = \frac{1}{n} \sum_{j=1}^n I_i^a(X_j)$.

G_a 与 P_a 差别越大, 则对于较大的样本, z_n^a 的值也较大, 用 z_n^a 作检验应该越显著; 反之, 若 $\sup_a z_n^a$ 的值较小, 则任何方向上, G_a 与 P_a 都相差不大, G 与 P 就没有明显差别. 所以可以考虑用 $z_n = \sup_a z_n^a$ 来作检验统计量.

下面我们分别对 F 已知和 F 含有未知参数两种情形给出 z_n 的极限分布. 为方便起

* 国家自然科学基金资助课题.

1986年11月17日收到, 1987年9月20日收到修改稿.

见,本文中实数的绝对值和向量的欧氏模都用 $|\cdot|$ 表示,而把 $\|\cdot\|$ 留作它用.

定理 1. 设 π_i^a 满足 $\inf_a \pi_i^a > 0, 1 \leq i \leq m$. 则当 H_1 成立时,

$$\{z_n^a: |a|=1\} \xrightarrow{\mathcal{L}} \{Y^a: |a|=1\},$$

$$z_n \xrightarrow{\mathcal{L}} z = \sup_a (Y^a)^t Y^a,$$

其中 “ $\xrightarrow{\mathcal{L}}$ ” 表示依分布收敛, $\{Y^a: |a|=1\}$ 是一 m 维 Gauss 过程:

$$\forall a, Y^a \sim N(0, \Sigma^a), \Sigma^a = (\sigma_{ij}^a)_{m \times m},$$

$$\sigma_{ij}^a = \begin{cases} 1 - \pi_i^a, & i = j, \\ -\sqrt{\pi_i^a \pi_j^a}, & i \neq j; \end{cases}$$

$$\forall a, b, \begin{pmatrix} Y^a \\ Y^b \end{pmatrix} \sim N(0, A^{ab}),$$

$$A^{ab} = \begin{pmatrix} \Sigma^a & \Sigma^{ba} \\ \Sigma^{ab} & \Sigma^b \end{pmatrix}, \Sigma^{ab} = \Sigma^{ba} = (\sigma_{ij}^{ab})_{m \times m},$$

$$\sigma_{ij}^{ab} = [P(S_i^a \cap S_j^b) - \pi_i^a \pi_j^b] / \sqrt{\pi_i^a \pi_j^b}.$$

定理 2. 设随机变量 X 的分布族为 $\{P_\theta: P_\theta \ll P, \theta \in \Theta\}$, 其中 P 是 Lebesgue 可测空间 (R^k, \mathcal{B}^k) 中的连续概率测度, Θ 为 R^k 中一开集. 又 X_1, \dots, X_n, \dots i.i.d $\sim P_\theta$,

$\theta \in \Theta$ 为未知参数, 记 $P_{ni}^a = \frac{1}{n} \sum_{j=1}^n I_i^a(X_j)$; $\pi_i^a(\varphi) = P_\varphi(S_i^a)$, $\varphi \in \Theta$. 设 $\pi_i^a(\varphi)$ 满足

1) $\pi_i^a(\varphi)$ 对 (a, φ) 连续;

2) $\forall \varphi \in \Theta, \inf \pi_i^a(\varphi) > 0, i = 1, \dots, m$;

3) 若 $\theta_1 \neq \theta_2$, 则 $\sum_{i=1}^m |\pi_i^a(\theta_1) - \pi_i^a(\theta_2)| > 0, \forall a$;

4) $\forall i = 1, \dots, m, \partial \pi_i^a(\varphi) / \partial \varphi$ 在 Θ 内存在, 对 (a, φ) 连续, 且作为 φ 的函数, 对 a 等度连续;

5) 方阵 $I^a(\varphi) = (I_{rs}^a(\varphi))$ 非异, 其中

$$I_{rs}^a(\varphi) = \sum_{i=1}^m \frac{1}{\pi_i^a(\varphi)} \frac{\partial \pi_i^a(\varphi)}{\partial \varphi_r} \frac{\partial \pi_i^a(\varphi)}{\partial \varphi_s}, r, s = 1, \dots, K, \forall \varphi \in \Theta.$$

则存在 $\hat{\theta}_n^a$ 为似然方程

$$\sum_{i=1}^m \frac{P_{ni}^a}{\pi_i^a(\varphi)} \frac{\partial \pi_i^a(\varphi)}{\partial \varphi_j} = 0, 1 \leq j \leq K$$

的一致相合解, 即 $P(\sup_a |\hat{\theta}_n^a - \theta| \xrightarrow{n \rightarrow \infty} 0) = 1$.

若记 $\hat{K}_n^a = \sum_{i=1}^m n(P_{ni}^a - \pi_i^a(\hat{\theta}_n^a))^2 / \pi_i^a(\hat{\theta}_n^a)$, $K_n = \sup_a \hat{K}_n^a$, 则有

$$K_n \xrightarrow{\mathcal{L}} K = \sup_a (Y^a)^t C^a Y^a,$$

其中 $\{Y^a: |a|=1\}$ 与定理 1 中相似 ($P = P_\theta$), $C^a = I_m - (B^a)(I^a(\theta))^{-1}(B^a)^t$, $B^a =$

$$(B_{ij}^a)^t, B_{ij}^a = \frac{1}{\sqrt{\pi_i^a(\varphi)}} \left. \frac{\partial \pi_i^a(\varphi)}{\partial \varphi_j} \right|_{\varphi = \theta^a}.$$

III. 预备知识

$(S, \sigma(S), P)$ 为一概率空间, \mathcal{F} 是 S 的子集类, 称 \mathcal{F} 是一多项式集类, 如果存在一个多项式 $F(x)$, 使 $\forall A \subset S, \#A = n$ ($\#A$ 表示 A 中元素个数) 有

$$\#\{A \cap D : D \in \mathcal{F}\} \leq F(n), n \text{ 为任何自然数.}$$

对于多项式集类有

引理 3.1 ([5], p.20). 设 \mathcal{D} 为 S 上的实函数构成的一个有限维集合, 则 $\{D : D = [s : d(s) \geq 0], d \in \mathcal{D}\}$ 是一多项式集类.

设 X_1, X_2, \dots, X_n 为 $(S, \sigma(S))$ 上的一组 i.i.d 样本, $X_1 \sim P$, 记 P_n 为经验概率测度.

设 \mathcal{F} 是 $(S, \sigma(S))$ 上的可测实函数集, \mathcal{F} 有指标集 T , $\mathcal{F} = \{f(\cdot, t) : t \in T\}$. 设 T 为一可分度量空间, $\mathcal{B}(T)$ 是 T 上的 Borel 域. 我们称 \mathcal{F} 是一可容许集, 如果 \mathcal{F} 的指标集 T 满足:

i) 函数 $f(\cdot, \cdot)$ 是 $\sigma(S) \times \mathcal{B}(T)$ 可测;

ii) T 是紧致度量空间的一个解析子集.

称 \mathcal{D} 是可容许集, 如果 $\{I_D : D \in \mathcal{D}\}$ 是一可容许函数集.

引理 3.2 ([5], p. 22). 若 \mathcal{D} 为一可容许多项式集类, 则

$$\sup_{D \in \mathcal{D}} |P_n(D) - P(D)| \xrightarrow{n \rightarrow \infty} 0; \text{ a. s.}$$

若 f 为 S 上的实函数, f 的图集定义为 $G_f = \{(s, t) : 0 \leq t \leq f(s) \text{ 或 } 0 \geq t \geq f(s), s \in S\}$

\mathcal{C} 为 S 上的实函数构成的空间, 在上面定义了某种距离 d , $\mathcal{F} \subset \mathcal{C}, \forall \varepsilon > 0, \mathcal{F}$ 的 ε -覆盖数 $N(\varepsilon, d, \mathcal{F})$ 定义为 $\min\{i : \exists i \text{ 个 } f_1, \dots, f_i \in \mathcal{C} \text{ 使得 } \min_{1 \leq j \leq i} d(f_j, f) < \varepsilon, \forall f \in \mathcal{F}\}$.

记 $L^1(P) = \{f : \int |f| dP < \infty\}$, $L^2(P) = \{f : \int f^2 dP < \infty\}$, 当 \mathcal{C} 为 $L^1(P), L^2(P)$ 距离 d 为 L^1, L^2 即 $\int |f - g| dP, \left(\int |f - g|^2 dP\right)^{\frac{1}{2}}$ 时, 相应的覆盖数分别记作 $N_1(\varepsilon, P, \mathcal{F}), N_2(\varepsilon, P, \mathcal{F})$.

若 $F \in \mathcal{C}$, 且满足: $\forall f \in \mathcal{F}, |f(s)| \leq F(s), \forall s \in S$, 称 F 是 \mathcal{F} 的封套.

引理 3.3 ([5], p. 27). 设 \mathcal{F} 是 S 上的一个可测函数集, 有封套 F, Q 为 S 上概率测度, $0 < \int F dQ < \infty$, 如果 \mathcal{F} 的图象集构成一个多项式集类, 则 $N_1(\varepsilon Q F, Q, \mathcal{F}) \leq A \varepsilon^{-w}$. 这里非零常数 A, w 只与 \mathcal{F} 的图集有关, 同 Q 无关, $QF = \int F dQ$.

记 $E_n f = \frac{1}{\sqrt{n}} \sum_{i=1}^n (f(X_i) - E f(X_i)), f$ 为一可积函数. $\forall \delta > 0$, 定义随机覆盖积分

$$J_1(\delta, P_n, \mathcal{F}) = \int_0^\delta [2 \log(N_1(u, P_n, \mathcal{F})^2 / u)]^{\frac{1}{2}} du. \quad (1)$$

引理 3.4 ([5], p. 150). 设 \mathcal{F} 是 $L^2(P)$ 的可容许函数集, 有封套 $F \in L^2(P)$, 假设 $\forall \eta > 0, \varepsilon > 0, \exists \nu > 0$, 使得 $\limsup_{n \rightarrow \infty} P\{J_2(\nu, P_n, \mathcal{F}) > \eta\} < \varepsilon$, 则 $\exists \delta > 0$, 使 $\limsup_{n \rightarrow \infty} P\{\sup_{\{\delta\}} |E_n(f-g)| > \eta\} < \varepsilon$. 这里 $\{\delta\} = \{(f, g) : f, g \in \mathcal{F}, \rho_p(f-g) \leq \delta\}$, ρ_p 为 L^2 距离.

设 \mathcal{F} 为一逐点有界的可容许函数集, 且 $\sup_{\mathcal{F}} \int |fdP| < \infty$. 记 \mathcal{A} 为 \mathcal{F} 上所有有界函数组成的空间, 随机过程 $E_n = \{E_n f : f \in \mathcal{F}\}$ 可看成是 \mathcal{F} 上的随机有界函数, 其样本轨道 (Sample path) 属于 \mathcal{A} , 在 \mathcal{A} 上定义一致距离: $x, y \in \mathcal{A}, d(x, y) = \|x - y\| = \sup_{\mathcal{F}} |x(f) - y(f)|$. 又令 $C(\mathcal{F}, P) = \{x : x \in \mathcal{A}, x \text{ 对 } \mathcal{F} \text{ 中的距离 } \rho_p \text{ 而言一致连续}\}$.

引理 3.5 ([5], p. 157). 设 \mathcal{F} 是一个逐点有界、全有界、可容许的 $L^2(P)$ 子集, 如果 $\forall \eta > 0, \varepsilon > 0, \exists \delta > 0$, 使得

$$\limsup_{n \rightarrow \infty} P\{\sup_{\{\delta\}} |E_n(f-g)| > \eta\} < \varepsilon,$$

则作为 \mathcal{A} 中的随机元序列, $\{E_n\}$ 依律收敛到 \mathcal{A} 中的随机元 $E_p, E_p = \{E_p f : f \in \mathcal{F}\}$ 是一个紧 (tight) 的高斯过程, 其样本轨道在 $C(\mathcal{F}, P)$ 中, $E_p f$ 期望为零, $E_p f$ 和 $E_p g$ 的协方差为 $\int fgdP - \left(\int fdP\right)\left(\int gdP\right), \forall f, g \in \mathcal{F}$.

由引理 3.4 和引理 3.5 立即得到

推论 3.1. 设 \mathcal{F} 是 $L^2(P)$ 中逐点有界, 全有界且可容许的子集, 有封套 $F \in L^2(P)$ 若对 $\forall \eta > 0, \varepsilon > 0, \exists \nu > 0$, 使 $\limsup_{n \rightarrow \infty} P\{J_2(\nu, P_n, \mathcal{F}) > \eta\} < \varepsilon$, 则 E_n 依律收敛到引理 3.5 中的高斯过程 E_p .

IV. 定理证明

现在回到第 II 节的问题, 沿用前面的记号, 令 $\mathcal{F}_i = \{I_i^* : |a| = 1\}, i = 1, 2, \dots, m$. 由于 $\{a^T x - t : |a| = 1, t \in R^1\}$ 是 R^k 中的有限维实函数集, 应用引理 3.1 易得 $\mathcal{D}_i = \{S_i^* : |a| = 1\}, i = 1, \dots, m$ 是多项式集类, 再由 $I_i^* = I_{S_i^*}$ 只取 0, 1 两个值的性质, 可以证明 \mathcal{F}_i 的图集也是多项式集类.

故由引理 3.3 知, $\exists A, \omega$, 使对任何概率测度 Q 有 $N_i(\varepsilon, Q, \mathcal{F}_i) \leq A\varepsilon^{-\omega} (\forall \varepsilon > 0)$, 由此即知, \mathcal{F}_i 是全有界的.

因为在 \mathcal{F}_i 中 L_1^2 距离等于 L_2^2 距离的平方, 故对 $\forall 0 < \delta < \frac{1}{c}$, 随机覆盖积分的定义 (1) 给出

$$\begin{aligned} J_2(\delta, P_n, \mathcal{F}_i) &= \int_0^\delta [2 \log(N_i(u, P_n, \mathcal{F}_i)^2/u)]^{\frac{1}{2}} du \\ &= \int_0^\delta [2 \log(N_i(u^2, P_n, \mathcal{F}_i)^2/u)]^{\frac{1}{2}} du \\ &\leq \int_0^\delta [2 \log(A^2 u^{-\omega})]^{\frac{1}{2}} du \end{aligned}$$

$$\leq C \int_0^\delta -\log u du = C(\delta - \delta \log \delta) \xrightarrow{\delta \rightarrow 0} 0,$$

其中 C 为只与 A, w 有关的正常数.

由于 $\{a : |a| = 1\}$ 是紧致度量空间, 容易验证 $\mathcal{F}_i (1 \leq i \leq m)$ 是可容许集; \mathcal{F}_i 逐点有界, 有封套 $F = 1$ 都是显然的, 从而推论 3.1 的一切条件满足. 记 \mathcal{A}_i 是定义在 \mathcal{F}_i 上的有界实函数全体, 由推论 3.1 可知

$$\{E_n f : f \in \mathcal{F}_i\} \xrightarrow{\mathcal{L}} \{E_P f : f \in \mathcal{F}_i\}, i = 1, 2, \dots, m.$$

回到第 II 节的记号, 并注意 E_n 的定义 (见第 III 节), 上式即是

$$\{\sqrt{n}(P_{n_i}^a - \pi_i^a) : |a| = 1\} \rightarrow \{E_P(I_i^a) : |a| = 1\}. \quad (2)$$

为完成定理, 还需要下面的引理.

引理 4.1. 设 \mathcal{A} 是 \mathcal{F} 上有界实值泛函全体, $X_n (n = 1, 2, \dots)$ 和 X 都是 \mathcal{A} 中的随机元, $X_n \xrightarrow{\mathcal{L}} X$ 且 X 的样本轨道在 $C(\mathcal{F}, P)$ 中, 又 $\alpha = \{\alpha(f) : f \in \mathcal{F}\}$ 满足 $\|\alpha\| = \sup_f |\alpha(f)| < \infty$, 则

$$\{X_n(f)\alpha(f) : f \in \mathcal{F}\} \xrightarrow{\mathcal{L}} \{X(f)\alpha(f) : f \in \mathcal{F}\}.$$

证. 定义 H 为从 \mathcal{A} 到 \mathcal{A} 的映象: $\forall x \in \mathcal{A}, (Hx)(f) = x(f)\alpha(f) (f \in \mathcal{F})$. 由于 $\|Hx - Hy\| = \sup_f |x(f)\alpha(f) - y(f)\alpha(f)| \leq \sup_f |\alpha(f)| \sup_f |x(f) - y(f)| = \|\alpha\| \cdot \|x - y\|$, 故 H 是连续映象; 又 X 的样本轨道都在 $C(\mathcal{F}, P)$ 中, 由连续映象定理 ([5], p. 70) 知 $HX_n \xrightarrow{\mathcal{L}} HX$. 这就是本引理的结论.

定理 1 的证明

先固定 \mathcal{F}_i 和 $\mathcal{A}_i (i = 1 \dots m)$. 对每个 $I_i^a \in \mathcal{F}_i$, 令 $\alpha(I_i^a) = (P(S_i^a))^{-\frac{1}{2}} = (\pi_i^a)^{-\frac{1}{2}}$. 由于 $\inf_a \pi_i^a > 0$, 依引理 4.1 和 (2) 可知

$$\{\sqrt{n}(P_{n_i}^a - \pi_i^a)/\sqrt{\pi_i^a} : |a| = 1\} \xrightarrow{\mathcal{L}} \{B_P(I_i^a)/\sqrt{\pi_i^a} : |a| = 1\}. \quad (3)$$

记 $\mathcal{A} = \mathcal{A}_1 \times \dots \times \mathcal{A}_m$. 注意到 \mathcal{A}_i 的元素 $x_i = \{x_i(f) : f \in \mathcal{F}_i\}$ 的指标集实际上是 $\{a : |a| = 1\}$. 为方便起见, 可以把 $x \in \mathcal{A}$ 表示成 $x = \{(x_1(a), \dots, x_m(a))^r : |a| = 1\}$. 定义 \mathcal{A} 上距离为

$$\|x - y\| = \sup\{|x_i(a) - y_i(a)| : |a| = 1, i = 1, 2, \dots, m\}.$$

令

$$Y_n^a = (Y_{n_1}^a, \dots, Y_{n_m}^a)^r = (\sqrt{n}(P_{n_1}^a - \pi_1^a)/\sqrt{\pi_1^a}, \dots, \sqrt{n}(P_{n_m}^a - \pi_m^a)/\sqrt{\pi_m^a})^r,$$

$$Y^a = (Y_{(1)}^a, \dots, Y_{(m)}^a)^r = (B_P(I_1^a)/\sqrt{\pi_1^a}, \dots, B_P(I_m^a)/\sqrt{\pi_m^a})^r,$$

$$Y_n = \{Y_n^a : |a| = 1\}, Y = \{Y^a : |a| = 1\}.$$

显然 $Y_n (n = 1, 2, \dots)$ 和 Y 都是 \mathcal{A} 上的随机元, 由 (3) 不难证明

$$\{Y_n^a : |a| = 1\} \xrightarrow{\mathcal{L}} \{Y^a : |a| = 1\}.$$

由高斯过程 B_P 的性质 (参见引理 3.5) 即知 $Y_{(i)}^a$ 的期望为 0 ($i = 1, \dots, m; |a| = 1$).

$$\text{cov}(Y_{(i)}^a, Y_{(j)}^b) = \int (I_i^a/\sqrt{\pi_i^a})(I_j^b/\sqrt{\pi_j^b})dP - \int I_i^a/\sqrt{\pi_i^a}dP \int I_j^b/\sqrt{\pi_j^b}dP$$

$$= [P(S_i^a \cap S_j^b) - \pi_i^a \pi_j^b] / \sqrt{\pi_i^a \pi_j^b}.$$

最后,注意到 $Mx \triangleq \sup_a \sum_{i=1}^m x_i^a(a)$ 是 \mathcal{E} 上连续映象,由连续映象定理 ([5], p. 70) 即得

$$z_n = MY_n \xrightarrow{\mathcal{L}} MY = z.$$

定理 2 的证明

首先,由于 $(P_{n1}^a, \dots, P_{nm}^a)$ 服从多项分布 $M(n; \pi_1^a(\theta), \dots, \pi_m^a(\theta))$, 不难看出似然方程为

$$\sum_{i=1}^m \frac{P_{ni}^a}{\pi_i^a(\varphi)} \frac{\partial \pi_i^a(\varphi)}{\partial \varphi_j} = 0, \quad j = 1, 2, \dots, K. \quad (4)$$

记球面 $C(\delta) = \{\varphi: |\varphi - \theta| = \delta, \varphi \in \Theta\}$, 由题设知: 向量 $(\pi_i^a(\theta), i = 1 \dots m)$ 及 $(\pi_i^a(\varphi), i = 1 \dots m)$ 是不同的, 从而它们的 Kullback-Leibler 信息数

$$A^a(\varphi) \triangleq \sum_{i=1}^m \pi_i^a(\theta) \log \frac{\pi_i^a(\theta)}{\pi_i^a(\varphi)}$$

在球面 $C(\delta)$ 上为正 (参见 [3]) 又 $\pi_i^a(\varphi)$ 关于 (a, φ) 连续, 故 $\inf\{A^a(\varphi): |a| = 1, \varphi \in C(\delta)\} > 0$. 由于 $\{S_i^a: |a| = 1\}$ 是多项式集类, 依引理 3.2, 有

$$P_\theta\{\sup_a |P_{ni}^a - \pi_i^a(\theta)| \rightarrow 0, (n \rightarrow \infty)\} = 1, \quad i = 1, \dots, m.$$

于是概率为 1 地有

$$\inf\left\{\sum_{i=1}^m P_{ni}^a \log \frac{\pi_i^a(\theta)}{\pi_i^a(\varphi)}: |a| = 1, \varphi \in C(\delta)\right\} > 0, \quad n \text{ 足够大时.}$$

即对 $|a| = 1$ 和 $\varphi \in C(\delta)$ 一致地有

$$\sum_{i=1}^m P_{ni}^a \log \pi_i^a(\theta) > \sum_{i=1}^m P_{ni}^a \log \pi_i^a(\varphi), \quad n \text{ 足够大时.}$$

这说明除了一个零测集外, 对数似然函数 $l_n^a(\varphi) \triangleq \sum_{i=1}^m P_{ni}^a \log \pi_i^a(\varphi)$ 在闭球 $|\theta - \varphi| \leq \delta$

中心 θ 处的值, 大于在球面 $C(\delta)$ 上任一点的值. 由 $\pi_i^a(\varphi)$ ($1 \leq i \leq m$) 的连续性知 $l_n^a(\varphi)$ 在 $|\theta - \varphi| \leq \delta$ 内至少有一个局部极大点, 该极大点显然是似然方程 (4) 的一个根. 取 $\delta_n \downarrow 0$. 记 $\hat{\theta}_n^a = \hat{\theta}_n^a(X_1, \dots, X_n)$ 为 $l_n^a(\varphi)$ 在 $C(\delta_n)$ 中的一个局部极大点, 则 $\hat{\theta}_n^a$ 满足方程 (4), 且显然有

$$P_\theta\{\sup_{|a|=1} |\hat{\theta}_n^a(X_1, \dots, X_n) - \theta| \rightarrow 0 (n \rightarrow \infty)\} = 1. \quad (5)$$

这就是本定理的第一个结论.

对于偏导列向量 $\frac{\partial \pi_i^a(\varphi)}{\partial \varphi}$, 记

$$\left. \frac{\partial \pi_i^a(\varphi)}{\partial \varphi} \right|_{\varphi=\mu} \triangleq \frac{\partial \pi_i^a}{\partial \mu},$$

则由 (5) 和 $\pi_i^a(\varphi)$ 及 $\frac{\partial \pi_i^a(\varphi)}{\partial \varphi}$ 的连续性知

$$P_{\theta} \left\{ \sup_{|a|=1} |\pi_i^a(\hat{\theta}_n^a) - \pi_i^a(\theta)| \rightarrow 0 \ (n \rightarrow \infty) \right\} = 1, \quad (6)$$

$$P_{\theta} \left\{ \sup_{|a|=1} \left| \frac{\partial \pi_i^a}{\partial \hat{\theta}_n^a} - \frac{\partial \pi_i^a}{\partial \theta} \right| \rightarrow 0 \ (n \rightarrow \infty) \right\} = 1. \quad (7)$$

记

$$\eta_{ni}^a = \sqrt{n} (P_{ni}^a - \pi_i^a(\hat{\theta}_n^a)) / \sqrt{\pi_i^a(\hat{\theta}_n^a)}, \quad \eta_n^a = (\eta_{n1}^a, \dots, \eta_{nm}^a);$$

$$Y_{ni}^a = \sqrt{n} (P_{ni}^a - \pi_i^a(\theta)) / \sqrt{\pi_i^a(\theta)}, \quad Y_n^a = (Y_{n1}^a, \dots, Y_{nm}^a);$$

$$u_{ni}^a = \sqrt{n} (\pi_i^a(\hat{\theta}_n^a) - \pi_i^a(\theta)) / \sqrt{\pi_i^a(\theta)}, \quad u_n^a = (u_{n1}^a, \dots, u_{nm}^a).$$

显然 $K_n^a = (\eta_n^a)^T (\eta_n^a)$, 而且由 (6) 知

$$P_{\theta} \left\{ \sup_{|a|=1} |\eta_n^a - (Y_n^a - u_n^a)| \rightarrow 0 \ (n \rightarrow \infty) \right\} = 1. \quad (8)$$

因此只须求出 $\{Y_n^a - u_n^a : |a| = 1\}$ 的极限分布就容易得到 $\{K_n^a : |a| = 1\}$ 和 K_n 的极限分布.

依定理 1, 并以 P_{θ} 代替定理 1 中的 P , 得

$$Y_n \triangleq \{Y_n^a : |a| = 1\} \xrightarrow{\mathcal{L}} \{Y^a : |a| = 1\} \triangleq Y, \quad (9)$$

其中 Y 是一个为定理 1 所述的高斯过程, 不过 $P = P_{\theta}$.

下面看 u_n^a . 利用中值公式有

$$u_{ni}^a = \sqrt{n} \cdot \frac{1}{\sqrt{\pi_i^a(\theta)}} \left(\frac{\partial \pi_i^a}{\partial \theta} \right)^T (\hat{\theta}_n^a - \theta),$$

其中 θ 的各分量 θ_j 在 $\hat{\theta}_{nj}^a$ 和 θ 的相应分量 $\hat{\theta}_{nj}^a$ 和 θ_j 之间. 记

$$B^a = \left(\frac{\partial \pi_1^a}{\partial \theta} / \sqrt{\pi_1^a(\theta)}, \dots, \frac{\partial \pi_m^a}{\partial \theta} / \sqrt{\pi_m^a(\theta)} \right)$$

为 $K \times m$ 矩阵, 利用 (7) 有

$$P_{\theta} \left\{ \sup_{|a|=1} |u_n^a - B^a [\sqrt{n} (\hat{\theta}_n^a - \theta)]| \rightarrow 0 \ (n \rightarrow \infty) \right\} = 1. \quad (10)$$

由于 $\hat{\theta}_n^a$ 满足 (4) 又 $\sum_{i=1}^m \pi_i^a(\varphi) = 1 \ (\varphi \in \Theta)$ 给出了 $\sum_{i=1}^m \frac{\partial \pi_i^a}{\partial \hat{\theta}_n^a} = 0$. 再利用中值公式可得

$$\begin{aligned} z_{nr}^a &\triangleq \sum_{i=1}^m \frac{\sqrt{n} (P_{ni}^a - \pi_i^a(\hat{\theta}_n^a))}{\pi_i^a(\hat{\theta}_n^a)} \frac{\partial \pi_i^a}{\partial \hat{\theta}_{nr}^a} \\ &= \sum_{i=1}^m \frac{\sqrt{n} (\pi_i^a(\hat{\theta}_n^a) - \pi_i^a(\theta))}{\pi_i^a(\hat{\theta}_n^a)} \frac{\partial \pi_i^a}{\partial \hat{\theta}_{nr}^a} \\ &= \sum_{i=1}^m \frac{\sqrt{n}}{\pi_i^a(\hat{\theta}_n^a)} \sum_{j=1}^K (\hat{\theta}_{nj}^a - \theta_j) \frac{\partial \pi_i^a}{\partial \theta_j} \frac{\partial \pi_i^a}{\partial \hat{\theta}_{nr}^a} \\ &= \sum_{i=1}^K \sqrt{n} (\hat{\theta}_{nr}^a - \theta_r) \sum_{i=1}^m \frac{1}{\pi_i^a(\hat{\theta}_n^a)} \frac{\partial \pi_i^a}{\partial \theta_r} \frac{\partial \pi_i^a}{\partial \hat{\theta}_{nr}^a}. \end{aligned}$$

其中 $\bar{\theta}_j$ 在 $\hat{\theta}_{nj}^a$ 和 θ_j 之间. 利用 (6) 和 (7) 可知

$$P_{\theta} \left\{ \sup_{|a|=1} \left| \sum_{i=1}^m \frac{1}{\pi_i^a(\hat{\theta}_n^a)} \frac{\partial \pi_i^a}{\partial \bar{\theta}_r} \frac{\partial \pi_i^a}{\partial \hat{\theta}_{nr}^a} - I_{rr}^a(\theta) \right| \rightarrow 0 \ (n \rightarrow \infty) \right\} = 1.$$

记 $z_n^a = (z_{n1}^a, \dots, z_{nK}^a)$ 即得

$$P_{\theta}\left\{\sup_{|a|=1} |z_n^a - I^a(\theta) \sqrt{n}(\hat{\theta}_n^a - \theta)| \rightarrow 0 \ (n \rightarrow \infty)\right\} = 1, \quad (11)$$

另一方面由 z_n^a 的定义和 (6), (7) 两式, 我们有

$$P_{\theta}\left\{\sup_{|a|=1} |z_n^a - (B^a)^T Y_n^a| \rightarrow 0 \ (n \rightarrow \infty)\right\} = 1.$$

再利用 (10) 可知

$$P_{\theta}\left\{\sup_{|a|=1} |u_n^a - B^a(I^a(\theta))^{-1}(B^a)^T Y_n^a| \rightarrow 0 \ (n \rightarrow \infty)\right\} = 1.$$

注意到 $C^a = I_m - B^a(I^a(\theta))^{-1}(B^a)^T$, 我们有

$$P_{\theta}\left\{\sup_{|a|=1} |(Y_n^a - u_n^a) - C^a Y_n^a| \rightarrow 0 \ (n \rightarrow \infty)\right\} = 1.$$

由 (9), (8) 和 (7), 利用连续映象定理和类似定理 1 的推理便得

$$K_n = \sup_{|a|=1} K_n^a \xrightarrow{\mathcal{L}} K = \sup_{|a|=1} (Y^a)^T C^a Y^a$$

这就完成了定理证明.

V. Bootstrap 逼近

由于定理 1, 定理 2 中最后的极限分布不能精确算出来, 所以检验的渐近否定域就不好构造出来. 利用 Bootstrap 方法, 可以解决这一困难.

设 P 如定理 1 中所述, X_1, \dots, X_n i.i.d $\sim P$. P_n 为 X_1, \dots, X_n 的经验分布, 取样本 $\bar{X}_1, \dots, \bar{X}_n$ i.i.d $\sim P_n$. 设 a_1, a_2, \dots, a_{K_n} i.i.d $\sim \mu$, 这里 μ 是 K 维单位球面上的均匀分布, 令

$$\begin{aligned} \bar{P}_{ni}^a &= \frac{1}{n} \sum_{j=1}^n I_i^a(\bar{X}_j), \\ \bar{z}_n^a &= \sum_{i=1}^m \frac{n(\bar{P}_{ni}^a - P_{ni}^a)^2}{P_{ni}^a}, \\ \bar{z}_n &= \max_{1 \leq k \leq K_n} \bar{z}_n^k, \quad \bar{z}_n = \sup_a \bar{z}_n^a. \end{aligned}$$

则我们可以得到

定理 1'. 设定理 1 的条件满足. 设 $t_n(\alpha, P_n)$ 为 \bar{z}_n 的 $1 - \alpha$ 分位点, $0 < \alpha < 1$. $\bar{t}_n(\alpha, P_n)$ 是 \bar{z}_n 的 $1 - \alpha$ 分位点, r 为 $\sup_a (Y^a)^T Y^a$ (Y^a 如定理 1) 的 $1 - \alpha$ 分位点, 则以概率为 1 地有

$$\begin{aligned} t_n(\alpha, P_n) &\rightarrow r \quad \text{以概率 } \mu^{K_n} \times P_n^a, \\ \bar{t}_n(\alpha, P_n) &\rightarrow r \quad \text{以概率 } P_n^a, \end{aligned}$$

该结论的证明, 作者将在另一文中讨论.

本文在成平、李国英教授的指导下完成的, 在此表示感谢.

参 考 文 献

- [1] Billingsley, P., *Convergence of Probability Measures*, Wiley, New York, 1968.
[2] 成平, 李国英等, 投影导论讲义, 中国科学院系统所统计室, 1985.

- [3] 陈希孺, 数理统计引论, 科学出版社, 北京 1981 年.
[4] Huber, P.J., Projection pursuit, *Ann. Statist.*, **13**(1985), 435—475.
[5] Pollard, D., Convergence of stochastic Processes, New York, Springer-Verlag, 1984.

A PP GOODNESS-OF-FIT TEST AND ITS ASYMPTOTIC PROPERTIES

ZHANG HANG

(*Institute of Systems Science, Academia Sinica*)

ABSTRACT

By the use of the Projection Pursuit method, we get a multivariate goodness-of-fit test with the classical χ^2 -test statistic as an index. The asymptotic properties of the test are discussed, and the asymptotic rejection region is obtained by bootstrapping the test statistic.