

文章编号 :1000-6788 (2005) 09-0071-07

投影寻踪在机会约束规划中的应用研究

李寿德¹, 安凯²

(1. 上海交通大学管理学院, 上海 200052; 2. 山东航天电子技术研究所, 山东 烟台 264000)

摘要: 投影寻踪方法应用于机会约束规划中, 将随机变量约束下的集合 $X(\cdot)$ 、 $X_i(\cdot)$ 转化为确定函数约束下的集合, 从而将机会约束规划转变成一般的非线性规划问题, 并对 $(b(w), A(w))$ 和 $(b(W), A(W))$ 的某一行向量的几种分布给出了 $X(\cdot)$ 、 $X_i(\cdot)$ 凸性的结论.

关键词: 机会约束规划; 投影寻踪; 概率密度

中图分类号: O221

文献标识码: A

Applications Studies of Projection Pursuit in the Chance Constrained Programming

LI Shou-de¹, AN Kai²

(1. Management School, Shanghai Jiaotong University, Shanghai 200052, China; 2. Shandong Institute of Aerospace Electronic Technology, Yantai 264000, China)

Abstract The application of projection pursuit to the chance constrained programming, this paper convert the set of constrained stochastic variable $X(\cdot)$ 、 $X_i(\cdot)$ to the set of constrained determined function, so as to convert the chance constrained programming to common nonlinear programming, and give the $X(\cdot)$ 、 $X_i(\cdot)$ convex conclusion for some row vector geometry distribution of the $(b(w), A(w))$ and $(b(W), A(W))$.

Keywords chance constrained programming; projection pursuit; probability density

1 引言

机会约束规划问题主要有如下两种不同的形式, 即或者是

$$\begin{aligned} \min \quad & f(x) \\ \text{s. t.} \quad & p(\{w \mid A(W)x = b(W)\}) \\ & x \in X_i \end{aligned} \tag{1.1}$$

或者

$$\begin{aligned} \min \quad & f(x) \\ \text{s. t.} \quad & p_w(\{w \mid A_i(w)x = b_i(w)\}) \leq \alpha_i \quad i = 1, 2, \dots, m, \\ & x \in X_0 \end{aligned} \tag{1.2}$$

其中 $A_i(w)$ 表示 $A(w)$ 的第 i 行, $b_i(w)$ 为 $b(w)$ 的第 i 个分量. 给定 f 为一凸函数, X_0 为一凸集, 则主要问题是确定集合

$$X(\cdot) = \{x \mid p_w(\{w \mid A(w)x = b(w)\}) \leq \alpha\} \tag{1.3}$$

和

$$X_i(\cdot) = \{x \mid p_w(\{w \mid A_i(w)x = b_i(w)\}) \leq \alpha_i\} \tag{1.4}$$

是否为凸集. 文献[1]中已对几种特殊的情形给出了 $X(\cdot)$ 、 $X_i(\cdot)$ 凸性的结论, 但并没有解决机会约束规

收稿日期: 1999-11-16

资助项目: 国家自然科学基金 (70273021)

作者简介: 李寿德 (1964 -), 男, 青海人, 博士, 副教授, 研究方向: 环境管理; 安凯 (1957 -), 男, 山西人, 博士, 副研究员, 研究方向: 智能控制.

划向非线性规划的转化问题. 本文将使用投影寻踪的方法来解决这一问题, 并对随机系数矩阵 $A(w)$ 和它的某一行随机向量 $A_i(w)$ 的几种分布讨论 $X(\cdot)$ 、 $X_i(\cdot)$ 的凸性.

2 主要结论及证明

在给出主要结论之前我们需要以下的一个关于投影寻踪方法的定义.

定义 1 设 w 是 P 维随机向量, 其概率密度为 $f(x)$, a_1, \dots, a_k ($k \leq p$) 是 R^p 中的线性独立的 k 个单位向量, (a_1^T, \dots, a_k^T) 的联合概率密度称为 $f(x)$ 在 a_1, \dots, a_k 方向上的投影密度, 记作 $f^{a_1, \dots, a_k}(t_1, \dots, t_k)$.

若 A 是前 k 行分别为 a_1^T, \dots, a_k^T 是非奇异矩阵, 则容易求得:

$$f^{a_1, \dots, a_k}(t_1, \dots, t_k) = \frac{1}{k^{p-k} |\det A|} f(A^{-1} T) dt_{k+1} \dots dt_p. \tag{2.1}$$

有了这一定义, 我们就可以将 (1.3), (1.4) 中的集合 $X(\cdot)$ 、 $X_i(\cdot)$ 化为确定的函数约束下的集合.

定理 2.1 设 mp 维随机向量 $(w) = (b_1(w), A_1(w), \dots, b_m(w), A_m(w))^T = (b_1(w), a_{11}(w), \dots, a_{1,p-1}(w), \dots, b_m(w), a_{m1}(w), \dots, a_{m,p-1}(w))^T$ 的联合概率密度为 $f(x)$, 则

$$X(\cdot) = \left\{ x \mid p_w(\{w \mid A(w)x = b(w)\}) \right\} \\ = \left\{ x \mid \underbrace{\int \dots \int}_{m \text{重}} f^{a_1, \dots, a_m}(t_1, \dots, t_m) dt_1 \dots dt_m, \right. \\ \left. a_i = \left(\underbrace{0 \dots 0}_{(i-1) \text{重}} \sqrt{1 + \frac{x^2}{2}} (1, -x), \underbrace{0 \dots 0}_{(m-i) \text{重}} \right)^T, i = 1, 2, \dots, m \right\} \triangleq Y(\cdot), \tag{2.2}$$

其中

$$A(w) = \begin{pmatrix} A_1(w) \\ \dots \\ A_m(w) \end{pmatrix}, \quad b(w) = \begin{pmatrix} b_1(w) \\ \dots \\ b_m(w) \end{pmatrix}.$$

证明 任取 $x \in X(\cdot)$, 设 $x = \begin{pmatrix} x_1 \\ \dots \\ x_{p-1} \end{pmatrix}$, 则

$$\begin{aligned} & p_w(\{w \mid A(w)x = b(w)\}) \\ &= p_w(\{w \mid A_1(w)x = b_1(w), \dots, A_m(w)x = b_m(w)\}) \\ &= p_w(\{w \mid b_1 - x_1 a_{11}(w) - \dots - x_{p-1} a_{1,p-1}(w) = 0, \dots, \\ & \quad b_m(w) - x_1 a_{m1}(w) - \dots - x_{p-1} a_{m,p-1}(w) = 0\}) \\ &= p_w \left\{ \left\{ w \mid \frac{1}{\sqrt{1 + \frac{x^2}{2}}} b_1(w) + \left(\frac{-x_1}{\sqrt{1 + \frac{x^2}{2}}} \right) a_{11}(w) + \dots + \right. \right. \\ & \quad \left. \left. \left(\frac{-x_{p-1}}{\sqrt{1 + \frac{x^2}{2}}} \right) a_{1,p-1}(w) = 0, \dots, \frac{1}{\sqrt{1 + \frac{x^2}{2}}} b_m(w) + \right. \right. \\ & \quad \left. \left. \left(\frac{-x_1}{\sqrt{1 + \frac{x^2}{2}}} \right) a_{m1}(w) + \dots + \left(\frac{-x_{p-1}}{\sqrt{1 + \frac{x^2}{2}}} \right) a_{m,p-1}(w) = 0 \right\} \right\} \\ &= p_w(\{w \mid a_1^T(w) = 0, \dots, a_m^T(w) = 0\}) \\ &= \underbrace{\int \dots \int}_{m \text{重}} f^{a_1, \dots, a_m}(t_1, \dots, t_m) dt_1 \dots dt_m. \tag{2.3} \end{aligned}$$

这里 f^{a_1, \dots, a_m} 是 $f(x)$ 在 a_1, \dots, a_m 方向上的投影密度. 由 (2.3) 知 $x \in Y(\cdot)$, 再由 $x \in X(\cdot)$ 的任意性即知 $X(\cdot) \subset Y(\cdot)$. 又由于 (2.3) 的每一等式都是可逆的, 因此同法可证 $X(\cdot) \supset Y(\cdot)$. 结合起来便得出要证明的结论.

定理 2.2 设 a_1, \dots, a_m 如(2.2)所示,若 $f^{a_1, \dots, a_m}(t_1, \dots, t_m)$ 是 x 的凹函数,则 $X(\cdot)$ 是凸集.

证明 由定理 2.1 只需证 $Y(\cdot)$ 是凸集即可.

任取 $x, y \in Y(\cdot)$, 设

$$a_i = \left\{ \begin{array}{l} \int_{(i-1)p}^0 \frac{1}{\sqrt{1+x^2}}(1, -x), \int_{(m-i)p}^0 \\ \int_{(i-1)p}^0 \frac{1}{\sqrt{1+x^2}}(1, -y), \int_{(m-i)p}^0 \end{array} \right\},$$

$$i = 1, 2, \dots, m.$$

则对于 $0 < \lambda < 1$, 令 $a_i'' = \left\{ \int_{(i-1)p}^0 \frac{1}{\sqrt{1+(x+(1-\lambda)y)^2}}(1, -x - (1-\lambda)y), \int_{(m-i)p}^0 \right\}$

由于 f^{a_1, \dots, a_m} 是 x 的凹函数,故

$$\begin{aligned} & \int_{(i-1)p}^0 \dots \int_{(m-i)p}^0 f^{a_1, \dots, a_m}(t_1, \dots, t_m) dt_1 \dots dt_m \\ &= \int_{(i-1)p}^0 \dots \int_{(m-i)p}^0 [f^{a_1, \dots, a_m}(t_1, \dots, t_m) + (1-\lambda) f^{a_1'', \dots, a_m''}(t_1, \dots, t_m)] dt_1 \dots dt_m \\ &= \int_{(i-1)p}^0 \dots \int_{(m-i)p}^0 f^{a_1, \dots, a_m}(t_1, \dots, t_m) dt_1 \dots dt_m \\ &+ (1-\lambda) \int_{(i-1)p}^0 \dots \int_{(m-i)p}^0 f^{a_1'', \dots, a_m''}(t_1, \dots, t_m) dt_1 \dots dt_m \\ &+ (1-\lambda) = \dots \end{aligned}$$

故 $x + (1-\lambda)y \in Y(\cdot)$, 再由 $x, y \in Y(\cdot)$ 的任意性即知 $Y(\cdot)$ 是凸集,从而利用定理 2.1 知 $X(\cdot)$ 是凸集.

推论 2.1 设 a_1, \dots, a_m 如(2.2)所示,若积分 $\int_{(i-1)p}^0 \dots \int_{(m-i)p}^0 f^{a_1, \dots, a_m}(t_1, \dots, t_m) dt_1 \dots dt_m =$ 是一与 x 无关的常数,则当 $\lambda < 1$ 时 $X(\cdot) = R^{p-1}$ 是凸集;当 $\lambda > 1$ 时 $X(\cdot) = \dots$

这是定理 2.1 的直接推论,证明从略.

在以上的结论中若取 $m = 1$ 则可得到 $X_i(\cdot)$ 的相应的结论. 下面我们给出这些结论,它们均为本节前面几个结论的直接推论.

定理 2.3 设 p 维随机向量 $(w) = (b_i(w), A_i(w))^T = (b_i(w), a_{i1}(w), \dots, a_{i,p-1}(w))^T$ 的联合概率密为 $f(x)$, 则

$$X_i(\cdot) = \left\{ x \mid \int_{(i-1)p}^0 \dots \int_{(m-i)p}^0 f^{a_1, \dots, a_m}(t_1, \dots, t_m) dt_1 \dots dt_m \leq \frac{1}{\sqrt{1+x^2}} \begin{pmatrix} 1 \\ -x \end{pmatrix} \right\}, \quad (2.4)$$

定理 2.4 若 $f^a(t) \left[a = \frac{1}{\sqrt{1+x^2}} \begin{pmatrix} 1 \\ -x \end{pmatrix} \right]$ 是 x 的凹函数,则 $X_i(\cdot)$ 是凸集.

推论 2.2 若 $\int_{(i-1)p}^0 \dots \int_{(m-i)p}^0 f^a(t) \left[a = \frac{1}{\sqrt{1+x^2}} \begin{pmatrix} 1 \\ -x \end{pmatrix} \right] dt =$ 是一与 x 无关的常数,则当 $\lambda < 1$ 时 $X_i(\cdot) = R^{p-1}$ 是凸集;当 $\lambda > 1$ 时, $X_i(\cdot) = \dots$

3 定理的具体应用

在本节我们将使用上节的结论,对 $(b(w), A(w))$ 和它的某一行随机向量 $(b_i(w), A_i(w))$ 的几种分布探讨 $X(\cdot)$ 和 $X_i(\cdot)$ 的凸集.

3.1 独立柯西分布的情况.

结论 3.1.1 设 p 维随机向量 $(w) = (b_i(w), A_i(w))^T = (b_i(w), a_{i1}(w), \dots, a_{i,p-1}(w))^T$ 的联合概率密度为 $f(y) = \prod_{j=1}^p \frac{1}{j + (y_j - \mu_j)^2}, -\infty < \mu_j < \infty, j > 0$, 则当 $\lambda < 1$ 时 $X_i(\cdot)$ 为凸集;当 $\lambda = 1$

0 时 $X_i(\cdot) = R^{p-1}$. 若 $p > 2$, 则当 $0 < \cdot < \frac{1}{2}$ 时 $X_i(\cdot) = R^{p-1}$, 或者 $X_i(\cdot)$ 为非空非凸集.

证明 对任一 p 维单位向量 $a = (a_1, \dots, a_p)^T$ 可求得 $a^T(\mu)$ 的特征函数为

$$\begin{aligned} \exp\left\{i \sum_{j=1}^p a_j \mu_j t - \sum_{j=1}^p |a_j| |t|\right\}, \text{ 因此 } f^a(t) &= \frac{\sum_{j=1}^p |a_j|}{\left[\left(\sum_{j=1}^p |a_j|\right)^2 + \left(t - \sum_{j=1}^p a_j \mu_j\right)^2\right]^{-1}} \\ \int_{-\infty}^{\infty} f^a(t) dt &= \int_{-\infty}^{\infty} \frac{\sum_{j=1}^p |a_j|}{\left[\left(\sum_{j=1}^p |a_j|\right)^2 + \left(t - \sum_{j=1}^p a_j \mu_j\right)^2\right]^{-1}} dt \\ &= \int_{-\infty}^{\infty} \frac{\sum_{j=1}^p |a_j|}{\left[\left(\sum_{j=1}^p |a_j|\right)^2 + t^2\right]^{-1}} dt \\ &= \int_{-\infty}^{\infty} \frac{\sum_{j=1}^p |a_j| / \sum_{j=1}^p |a_j|}{1 + t^2} dt \\ &\triangleq C_i \left(\frac{\sum_{j=1}^p a_j \mu_j}{\sum_{j=1}^p |a_j|} \right). \end{aligned} \tag{3.1}$$

故 $\int_{-\infty}^{\infty} f^a(t) dt \geq 0$ 等价于 $C_i^{-1}(\cdot) \sum_{j=1}^p |a_j| + \sum_{j=1}^p a_j \mu_j \geq 0$, 将 $a = \frac{1}{\sqrt{1+x^2}} \begin{pmatrix} 1 \\ -x \end{pmatrix}$ 代入不等式并在两端同乘 $\sqrt{1+x^2}$ 得:

$$C_i^{-1}(\cdot) \left(|a_1| + \sum_{j=2}^p |a_j x_{j-1}| \right) + \mu_1 - (\mu_2, \dots, \mu_p) x \geq 0. \tag{3.2}$$

由于 $|a_1| + \sum_{j=2}^p |a_j x_{j-1}|$ 为 x 的凸函数, 而 $(\mu_1, \dots, \mu_p) x$ 也是 x 的凸函数, 故当 $C_i^{-1}(\cdot) \geq 0$ 时 (3.2) 的左端为 x 的凸函数, 而 $\int_{-\infty}^{\infty} \frac{1}{1+t^2} dt = \frac{1}{2}$, 故 $C_i^{-1}(\cdot) \geq 0$ 等价于 $\cdot \geq \frac{1}{2}$, 于是当 $\cdot \geq \frac{1}{2}$ 时 (3.2) 的左端是 x 的凸函数, 即 $X_i(\cdot)$ 是凸集. $X_i(0) = R^{p-1}$ 是显然的.

若 $p > 2$, 当 $0 < \cdot < \frac{1}{2}$ 时 $C_i^{-1}(\cdot) < 0$. 由于 $x \in X_i(\cdot)$ 当且仅当 (3.2) 成立, 假设 $X_i(\cdot) = R^{p-1}$, 则有

$$x = \begin{pmatrix} x_1 \\ \dots \\ x_{p-1} \end{pmatrix} \in X_i(\cdot). \text{ 因为 } p > 2, \text{ 故必有 } y = \begin{pmatrix} y_1 \\ \dots \\ y_{p-1} \end{pmatrix} = 0, \text{ 使 } (\mu_2, \dots, \mu_p) y = 0, \text{ 取 } \theta \text{ 充分大使}$$

$$\begin{aligned} |C_i^{-1}(\cdot)| \left(|a_1| + \sum_{j=2}^p |a_j (x_{j-1} \pm \theta y_{j-1})| \right) &> |(\mu_1 - (\mu_2, \dots, \mu_p) x)| \\ &= |(\mu_1 - (\mu_2, \dots, \mu_p) (x \pm \theta y))|. \end{aligned}$$

由此知 $x + \theta y, x - \theta y$ 均满足 (3.2) 式. 故

$$x + \theta y \in X_i(\cdot), \quad x - \theta y \in X_i(\cdot).$$

而 $x = \frac{1}{2}(x + \theta y) + \frac{1}{2}(x - \theta y) \in X_i(\cdot)$.

因此 $X_i(\cdot)$ 是非空非凸集.

结论 3.1.2 设 mp 维随机向量 $(w) = (b_1(w), A_1(w), \dots, b_m(w), A_m(w))^T = (b_1(w), a_{11}(w), \dots,$

$a_{1,p-1}(w), \dots, b_m(w), a_{m1}(w), \dots, a_{m,p-1}(w))^T$ 的联合概率密度为 $f(y) = \prod_{j=1}^{mp} \frac{1}{1+y_j^2}$. 则当 $\frac{1}{2^m}$ 时

$X(\cdot) = R^{p-1}$ 是凸集; 当 $\alpha > \frac{1}{2^m}$ 时 $X(\cdot) = \phi$.

证明 由结论 3.1 的证明过程可知

$$f^{a_1, \dots, a_m}(t_1, \dots, t_m) = \prod_{j=1}^m \left(\sum_{i=1}^p |a_{ji}| \right)^{-1} \left(1 + \left(\sum_{j=1}^m \left(\sum_{i=1}^p |a_{ji}| \right)^2 t_j^2 \right)^{-1} \right)^{-1}$$

这里的 a_1, \dots, a_m 如 (2.2) 所示, $\begin{pmatrix} 1 \\ \dots \\ p \end{pmatrix} = \frac{1}{\sqrt{1+x^2}} \begin{pmatrix} 1 \\ \dots \\ -x \end{pmatrix}$, 故

$$\begin{aligned} & \int_0^1 \dots \int_0^1 f^{a_1, \dots, a_m}(t_1, \dots, t_m) dt_1 \dots dt_m \\ &= \prod_{j=1}^m \int_0^1 \left(\sum_{i=1}^p |a_{ji}| \right)^{-1} \left(1 + \left(\sum_{j=1}^m \left(\sum_{i=1}^p |a_{ji}| \right)^2 t_j^2 \right)^{-1} \right)^{-1} dt \\ &= \prod_{j=1}^m \int_0^1 \frac{1}{(1+t^2)} dt \\ &= \frac{1}{2^m}. \end{aligned}$$

由推论 2.1 知, 当 $\alpha = \frac{1}{2^m}$ 时 $X(\cdot) = R^{p-1}$ 是凸; 当 $\alpha > \frac{1}{2^m}$ 时 $X(\cdot) = \emptyset$.

3.2 椭球等高分布的情况

结论 3.2 设 p 维随机向量 $(w) = (b_i(w), A_i(w))^T = (b_i(w), a_{i1}(w), \dots, a_{i,p-1}(w))^T$ 的联合概率密度为 $f(y) = (\det A)^{-\frac{1}{2}} g[(y - \mu)^T A^{-1} (y - \mu)]$, 其中 $A > 0, g(\cdot) \geq 0$, 令 $G_1(t) = \int_{R^{p-1}} \left[\int_{R^{p-1}} g(w^2) dw_2 \dots dw_p \right] dw_1$, 则当 $G_1^{-1}(\alpha) > 0$ 时 $X_i(\alpha)$ 是凸集. 当 $\alpha = 0$ 时, $X_i(\alpha) = R^{p-1}$; 若 $p > 2$, 则当 $-\infty < G_1^{-1}(\alpha) < 0$ 时 $X_i(\alpha) = R^{p-1}$ 或为非空非凸集.

证明 由于 $A > 0$, 不妨设 $A^{-1} = H H^T$, 作代换 $Z = H(y - \mu)$, 由 Z 的密度为 $g(z^2)$. 对任何单位向量 $a \in R^p$, 以 a^T 为第一行构造正交阵 B , 则 $W = BZ$ 的概率密度为 $g(w^2)$. 因此 $a^T Z$ 的概率密度为

$$\int_{R^{p-1}} g(w^2) dw_2 \dots dw_p \triangleq g_1(w_1^2),$$

而 $a^T Y = a^T H^{-1} Z + a^T \mu = a^T H^{-1} \frac{a^T H^{-1}}{a^T H^{-1}} Z + a^T \mu$, 由前面的推导 $\frac{a^T H^{-1}}{a^T H^{-1}} Z$ 的概率密度为

$g_1(t^2)$, 故 $a^T H^{-1} \frac{a^T H^{-1}}{a^T H^{-1}} Z$ 的概率密度为 $a^T H^{-1} g_1 \left[\left(\frac{a^T H^{-1}}{a^T H^{-1}} \right)^2 \right]$. 从而 $a^T Y$ 的概率密度为

$a^T H^{-1} g_1 \left[\left(\frac{t - a^T \mu}{a^T H^{-1}} \right)^2 \right]$, 而 $a^T H^{-1}{}^2 = (a^T H^{-1})(a^T H^{-1}) = a^T A a$. 故

$$\begin{aligned} f^a(t) &= a^T H^{-1} g_1 \left[\left(\frac{t - a^T \mu}{a^T H^{-1}} \right)^2 \right] \\ &= \frac{1}{\sqrt{a^T A a}} g_1 \left[\left(\frac{t - a^T \mu}{\sqrt{a^T A a}} \right)^2 \right], \\ \int_0^1 f^a(t) &= \frac{1}{\sqrt{a^T A a}} \int_0^1 g_1 \left[\left(\frac{t - a^T \mu}{\sqrt{a^T A a}} \right)^2 \right] dt \\ &= \frac{1}{\sqrt{a^T A a}} g_1(t^2) dt \\ &\triangleq G_1 \left[- \frac{a^T \mu}{\sqrt{a^T A \mu}} \right], \end{aligned}$$

故 $\int_0^1 f^a(t) dt$ 等价于 $G_1\left(-\frac{a^T \mu}{\sqrt{a^T A \mu}}\right)$ 或 $-\frac{a^T \mu}{\sqrt{a^T A \mu}} G_1^{-1}(i)$, 即 $G_1^{-1}(i) \sqrt{a^T A a} + a^T \mu = 0$.

将 $a = \frac{1}{\sqrt{1+x^2}} \begin{pmatrix} 1 \\ -x \end{pmatrix}$ 代入并在不等式的两端同乘 $\sqrt{1+x^2}$ 得:

$$G_1^{-1}(i) \sqrt{(1, -x) A \begin{pmatrix} 1 \\ -x \end{pmatrix}} + (1, -x) \mu = 0. \tag{3.3}$$

容易求得 $(1, -x) A \begin{pmatrix} 1 \\ -x \end{pmatrix}$ 的海赛矩阵为 A 除去第一行后的矩阵, 而 A 正定. 故此海赛矩阵的行列式大于零, 从而 $(1, -x) A \begin{pmatrix} 1 \\ -x \end{pmatrix}$ 为凸函数. 因此 $\sqrt{(1, -x) A \begin{pmatrix} 1 \\ -x \end{pmatrix}}$ 为 x 的凸函数, 而 $(1, x) \mu$ 也是 x 的凸函数 (也是 x 的凹函数). 故当 $G_1^{-1}(i) = 0$ 时满足 (3.3) 的 x 构成一凸集, 即 $X_i(i)$ 为凸集, 而 $i = 0$ 时 $X_i(0) = R^{p-1}$ 显然成立.

若 $p > 2$, 且 $-\infty < G_1^{-1}(i) < 0$, 由于 $x \in X_i(i)$, 当且仅当 (3.3) 成立. 假设 $X_i(i) = R^{p-1}$, 则有 $x = \begin{pmatrix} 1 \\ \dots \\ x_{p-1} \end{pmatrix} \in X_i(i)$, 因为 $p > 2$, 故必有 $y = \begin{pmatrix} 1 \\ \dots \\ x_{p-1} \end{pmatrix} = 0$. 使 $(\mu_2, \dots, \mu_p) y = 0$, 取 ϵ_0 充分大使

$$-G_1^{-1}(i) \sqrt{(1, -(x \pm \epsilon_0 y)) A \begin{pmatrix} 1 \\ -(x \pm \epsilon_0 y) \end{pmatrix}} > |(1, -x) \mu| = |(1, -(x \pm \epsilon_0 y)) \mu|.$$

由此知 $x + \epsilon_0 y, x - \epsilon_0 y$ 均满足 (3.3) 式. 故

$$x + \epsilon_0 y \in X_i(i), \quad x - \epsilon_0 y \in X_i(i),$$

而

$$x = \frac{1}{2}(x + \epsilon_0 y) + \frac{1}{2}(x - \epsilon_0 y) \notin X_i(i).$$

因此 $X_i(i)$ 是非空非凸集.

若在结论 3.2 中取 $g(x) = (2)^{-\frac{x}{2}} e^{-\frac{x}{2}}$ 则得到文献 [1] 中的一个定理:

推论 3.2.1 设 p 维随机向量 $(w) = (b_i(w), A_i(w))^T = (b_i(w), a_{i1}(w), \dots, a_{i,p-1}(w))^T$ 的联合概率密度为 $f(y) = (\det A)^{-\frac{1}{2}} (2)^{-\frac{p}{2}} e^{-\frac{(y-\mu)^T A^{-1} (y-\mu)}{2}}$, 则对于 $i = \frac{1}{2}$, $X_i(i)$ 为凸集; $i = 0$ 时 $X_i(0) = R^{p-1}$;

若 $p > 2$, 则当 $0 < i < \frac{1}{2}$ 时或者 $X_i(i) = R^{p-1}$, 或者 $X_i(i)$ 为非凸集.

证明 在结论 3.2 中取 $g(x) = (2)^{-\frac{x}{2}} e^{-\frac{x}{2}}$, 则

$$\begin{aligned} G_1(t) &= \int_{R^{p-1}} \left[(2)^{-\frac{t}{2}} e^{-\frac{t^2 + \dots + t_p^2}{2}} dt_2 \dots dt_p \right] dt_1 \\ &= \frac{1}{\sqrt{2}} \int_{-\infty}^{\infty} e^{-\frac{t^2}{2}} dt_1 \end{aligned}$$

故 $G_1^{-1}(i) = 0$ 等价于 $i = \frac{1}{2}$, $0 < G_1^{-1}(i) < 0$ 等价于 $0 < i < \frac{1}{2}$, 利用结论 3.2 即得所要证的结论.

若在结论 3.2 中取 $\mu = 0, A$ 为单位阵, $g(t) = C_p (1+t)^{-k}$, $k > \frac{p}{2}$, C_p 是使 $C_p (1+y^2)^{-k}$ 构成 p 维概率密度的常数, 则可得如下结论:

推论 3.2.2 设 p 维随机向量 $(w) = (b_i(w), A_i(w))^T = (b_i(w), a_{i1}(w), \dots, a_{i,p-1}(w))^T$ 的联合概率密度为 $f(y) = C_p(1 + \|y\|^2)^{-k}$, $k > \frac{p}{2}$, 则当 $\mu_i < \frac{1}{2}$ 时 $X_i(\mu_i)$ 是凸集; $\mu_i = 0$ 时 $X_i(0) = R^{p-1}$; 若 $p > 2$, 则当 $0 < \mu_i < \frac{1}{2}$ 时, 或者 $X_i(\mu_i) = R^{p-1}$, 或者 $X_i(\mu_i)$ 为非空非凸集.

证明 在结论 3.2 中取 $\mu = 0, A$ 为单位阵, $g(t) = C_p(1+t)^{-k}$, $\left(k > \frac{p}{2}\right)$, C_p 是使 $C_p(1 + \|y\|^2)^{-k}$ 构成 p 维概率密度的常数. 则

$$\begin{aligned} G_1(t) &= \int_{R^{p-1}} \left[\int_{R^{p-1}} g(\|y\|^2) dy_2, \dots, dy_p \right] dy_1 = \int_{R^{p-1}} \left[\int_{R^{p-1}} C_p(1 + y_1^2 + \dots + y_p^2)^{-k} dy_2 \dots dy_p \right] dy_1 \\ &= C_p \int_{R^{p-1}} (1 + y_1^2 + r^2)^{-k} r^{p-2} dr \cdot C_0 \\ &= C_p C_0^* \int_0^t (1 + y_1^2 + Z)^{-k} Z^{\frac{p-2}{2}-\frac{1}{2}} dZ \\ &= C_p C_0^* \int_0^t (1 + y_1^2)^{-k+\frac{p-1}{2}} dy_1 \int_0^{\frac{p-1}{2}-1} (1+Z)^{-k} dZ \\ &= C_p \int_0^t (1 + y_1^2)^{-\frac{2k+1-p}{2}} dy_1, \end{aligned} \quad (3.4)$$

其中 $C_p = \left(\int_{R^{p-1}} (1 + y_1^2)^{-\frac{2k+1-p}{2}} dy_1 \right)^{-1}$.

由(3.4)式右端被积函数关于 0 的对称性可知 $G_1(0) = \frac{1}{2}$, 即 $G_1^{-1}\left(\frac{1}{2}\right) = 0$. 故 $G_1^{-1}(\mu_i) = 0$ 等价于 $\mu_i < \frac{1}{2}$, $0 < G_1^{-1}(\mu_i) < 0$ 等价于 $0 < \mu_i < \frac{1}{2}$, 利用结论 3.2 即得所要证的结论.

参考文献:

- [1] P·卡尔. 随机线性规划[M]. 王金德译. 上海:上海科学技术出版社, 1988.
P·Karar. Stochastic Linear Programming[M]. Wang Jir-de, translator. Shanghai :Shanghai Science and Technology Press, 1988.
- [2] Cheng Ping. Optimum initial condition of projection pursuit approximation[J]. Acta Mathematicae Applicatae Sinica, Beijing, 1985, 2(3) :269 - 280.
- [3] 成平. 投影寻踪经验分布的极限分布[J]. 应用概率统计, 1987, 3(1) :8 - 20.
Cheng Ping. The limiting distribution of projection pursuit empirical distribution[J]. Applied Probability Statistics, 1987, 3(1) :8 - 20.