

应用概率统计

下册

马逢时 荷良材
余明书 范金城 合编

一九八四年五月

第二篇 多元统计分析

多元统计分析（简称多元分析）是运用数理统计的方法来研究多指标问题的理论和方法。它是一元统计学的推广，它对所研究的每个观测对象（又叫个体）要同时观测 p ($p \geq 2$) 个变量值。例如，我们要挑选一部分人，担任一部门的某一工作，必须对被挑选的对象进行多指标的观测。如：要了解他的学术能力、精明程度、理解能力、交际能力、适应性、外貌等。现有了 n 个人的以上这些指标所测得的数据表，怎样分析这些数据，从而找到最好的挑选方法呢？这就是多元分析所要研究的内容之一。多元分析以 p 个变量的多组数据建立的资料表为依据，寻求多种方法，或对所考查的观测对象进行分组、分类，或分析这 p 个变量之间的相互关联程度，或找出内在规律等等。随着电子计算机的广泛应用以及科研、生产发展方面的迫切需要，多元分析已广泛地应用于工业、农业、经济、医学、文教、气象、地质、考古、社会科学等各个方面。下面我们分三章介绍有关基本概念和常用的一些统计方法。

第七章 多元正态分布及参数的估计和检验

在多元统计学中，多元正态分布占有相当重要的位置。这是因为，一方面，许多随机向量确实服从正态分布，或近似服从正态分布。另一方面，对于多元正态分布，已有一整套统计推断方法，并且得到了许多完整的结果。本章要从多元正态分布的样本观测值——样本资料阵开始，介绍一些直观背景和简单分析，再正式给出多元正态分布的定义及一些重要性质，最后讨论多元正态分布的参数估计、均值检验。

§1 随机向量

我们所讨论的是多个变量的总体，所研究的数据是同时观测 p 个变量（即指标），又进行 n 次观测得到的，我们把这 p 个指标表示为 x_1, \dots, x_p ，常用随机向量

$$X = (x_1, \dots, x_p)'$$

表示对同一个体观测的 p 个变量。如果观测了 n 个个体，则称每一个个体的 p 个变量为一个样品，而全体 n 个样品形成一个样本。

一、样本资料阵：

本节中我们先介绍样本观测值形成的样本资料阵。然后介绍一般的多元随机变量——随

编号	变量	x_1	$x_2 \dots \dots x_p$
1		x_{11}	$x_{12} \dots \dots x_{1p}$
2		x_{21}	$x_{22} \dots \dots x_{2p}$
⋮		⋮	⋮
n		x_{n1}	$x_{n2} \dots \dots x_{np}$

机向量的数字特征及其计算公式。

对上表中横看，记

$$\mathbf{X}_{(a)} = (x_{a1}, x_{a2}, \dots, x_{ap})' \quad a = 1, 2, \dots, n$$

它表示第 a 个样品观测值。

竖看上表，第 i 列的元素

$$X_i = (x_{1i}, x_{2i}, \dots, x_{ni})'$$

表示对第 i 个变量 x_i 的 n 次不同的取值数。

故样本资料表可用矩阵语言表为

$$\mathbf{X} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \cdots & \cdots & \cdots & \cdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} = (X_1, X_2, \dots, X_p) = \begin{pmatrix} X_{(1)}' \\ X_{(2)}' \\ \vdots \\ X_{(n)}' \end{pmatrix}$$

有时，也简单的表示为

$$\mathbf{X}_{(a)} = (x_{a1}, x_{a2}, \dots, x_{ap})' \quad a = 1, \dots, n$$

为了避免使用过多的符号，在不致混淆的情况下，我们一般对随机变量及其取值使用相同符号。大写字母表示向量，如 $\mathbf{X}_{(a)}$ （第 a 个样品）， X_i （第 i 个分量的 n 个值）。用大写黑体字母表示矩阵，如 \mathbf{X} （表示资料阵）等。变量用小写字母，如 x_i （表示第 i 个变量）。

二、随机向量的数字特征

设 $\mathbf{X} = (x_1, \dots, x_p)'$, $\mathbf{Y} = (y_1, \dots, y_q)'$ 是两个随机向量，其中 x_i, y_j 是随机变量 $i = 1, \dots, p, j = 1, \dots, q$

1. 随机向量 \mathbf{X} 的均值

随机向量 \mathbf{X} 有 p 个分量。若 $E(X_i) = \mu_i$ 存在， $i = 1, 2, \dots, p$ ，我们定义随机向量 \mathbf{X} 的均值为

$$E \mathbf{X} = \begin{pmatrix} E x_1 \\ E x_2 \\ \vdots \\ E x_p \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_p \end{pmatrix} = \boldsymbol{\mu} \quad (1.1)$$

$\boldsymbol{\mu}$ 是一个 p 维向量，称为均值向量。类似地可以定义 \mathbf{X} 为矩阵时的均值。

2. 向量的 \mathbf{X} 的协差阵

$$V \approx D(\mathbf{X}) = E(\mathbf{X} - E\mathbf{X})(\mathbf{X} - E\mathbf{X})'$$

$$= \begin{pmatrix} D x_1 & C_{ov}(x_1, x_2) \cdots C_{ov}(x_1, x_p) \\ C_{ov}(x_2, x_1) & D x_2 & \cdots C_{ov}(x_2, x_p) \\ \cdots & \cdots & \cdots & \cdots \\ C_{ov}(x_p, x_1) & C_{ov}(x_p, x_2) \cdots & D x_p \end{pmatrix} \triangleq (\sigma_{ij}) \quad (1.2)$$

3. 向量 \mathbf{X} 和向量 \mathbf{Y} 的协差阵

$$C_{ov}(\mathbf{X}, \mathbf{Y}) = E(\mathbf{X} - E\mathbf{X})(\mathbf{Y} - E\mathbf{Y})'$$

$$= \begin{pmatrix} Cov(x_1, y_1) & Cov(x_1, y_2), & \cdots & Cov(x_p, y_q) \\ \vdots & \vdots & & \vdots \\ Cov(x_p, y_1) & Cov(x_p, y_2) & \cdots & Cov(x_p, y_q) \end{pmatrix} \quad (1.3)$$

4. 向量 X 的相关矩阵

$$R = (r_{ij})$$

其中

$$r_{ij} = \frac{Cov(x_i, x_j)}{\sqrt{Dx_i} \sqrt{Dx_j}} = \frac{\sigma_{ij}}{\sqrt{\sigma_{ii}} \sqrt{\sigma_{jj}}} \quad i, j = 1, \dots, p \quad (1.4)$$

三、常用的公式及其性质

1. 常用公式：设 X, Y 为随机向量， A, B 为常数矩阵

则

$$E(AX) = AE(X) \quad (1.5)$$

$$E(AXB) = AE(X)B \quad (1.6)$$

$$D(AX) = AD(X)A' = AVA' \quad (1.7)$$

$$Cov(AX, BY) = ACov(X, Y)B' \quad (1.8)$$

上述式中 (1.5) (1.6) 当向量 X 为矩阵 X 时，等式仍然成立。

2. 关于协差阵

任何随机向量 $X = (x_1, \dots, x_p)$ 的协差阵 V ，都是对称阵，同时总是非负定（也称半正定）的。大多数情形下是正定的。

以后将“ V 是正定阵”表示为 $V > 0$ ；“ V 是半正定阵”表示为 $V \geq 0$ 。

从矩阵代数知识可知，若协差阵 $V > 0$ ，则 V 的特征根均为正数， $|V| > 0$ ， $V' = V$ ；同时有 $V = AA'$ （即正定阵可分解为非奇异矩阵 A 与其转置阵的乘积）。我们还可以要求 A 是对称阵，记这样的 A 为 $V^{\frac{1}{2}}$ ，则 V 可表示为 $V^{\frac{1}{2}}V^{\frac{1}{2}}$ 。若将 V 剖分为

$$V = \begin{pmatrix} V_{11} & V_{12} \\ V_{21} & V_{22} \end{pmatrix}$$

其中 V_{11}, V_{22} 为方阵，则 V_{11}, V_{22} 亦为正定阵。

四、多元变量的独立性

设 $X = (x_1, \dots, x_p)$, $Y = (y_1, \dots, y_q)'$ 分别是 p 维, q 维随机向量， X 与 Y 的独立性定义可以有下列三种方式：

1. 称多元变量 X, Y 为相互独立，若它们的分布函数满足关系

$$F(X, Y) = F_1(X)F_2(Y) \quad (1.9)$$

其中 $F(X, Y)$ 是 (X, Y) 的联合分布函数， $F_1(X)$, $F_2(Y)$ 分别是 X , Y 的边缘分布函数。

2. 若多元变量 X, Y 的联合分布密度函数存在，分别记为

$$f(X, Y), f_1(X), f_2(Y) \quad (1.10)$$

则称 X 与 Y 相互独立，若 $f(X, Y) = f_1(X)f_2(Y)$ 成立。

3. 记 $X = (x_1, \dots, x_p)'$ 的特征函数为

$$\varphi(t) = Ee^{it' X}$$

其中 $t = (t_1, \dots, t_p)'$, $X = (x_1, x_2, \dots, x_p)'$, $i = \sqrt{-1}$

$$\text{即 } \varphi(t) = E e^{it' X} = E e^{i(t_1 x_1 + \dots + t_p x_p)}$$

称 X , Y 相互独立, 如果

$$\varphi(t) = \varphi_1(t_1) \cdot \varphi_2(t_2) \quad (1.11)$$

成立, 其中 $t' = (t'_1, t'_2)$, $\varphi(t)$, $\varphi_1(t_1)$, $\varphi_2(t_2)$ 分别是 (X, Y) , X 及 Y 的特征函数。

可以证明, 当密度存在时, 三者是等价的。在多元分析的理论中, 特征函数是不可缺少的工具, 对这部分内容不熟悉的读者, 有关证明可以暂时略去不读。

§2 多元正态分布

一、多元正态分布的定义

在概率论中, 已讲过一元正态分布的概率密度函数为

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad \sigma > 0.$$

上式可以改写成

$$f(x) = \frac{1}{(2\pi)^{\frac{1}{2}}(\sigma^2)^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2}(x-\mu)' (\sigma^2)^{-1} (x-\mu) \right\}$$

这里 $(x-\mu)'$ 代表 $(x-\mu)$ 的“转置”, 但由于 x , μ 均为一维的数字, 转置与否都相同, 因此可以这样写。

当服从一元正态分布的随机变量 X 的概率密度函数改写为上式时, 我们就可以将其推广, 定义出多元正态分布。

定义2.1 若 p 元随机向量 $X = (x_1, \dots, x_p)'$ 的概率密度函数为

$$f(x_1, \dots, x_p) = \frac{1}{(2\pi)^{\frac{p}{2}} |V|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2}(X-\mu)' V^{-1} (X-\mu) \right\} \quad (V > 0) \quad (2.1)$$

则称 $X = (x_1, \dots, x_p)'$ 服从 p 元正态分布, 也称 X 为 p 元正态变量。记为 $X \sim N_p(\mu, V)$, 在不强调维数时可以简记为 $X \sim N(\mu, V)$ 。

可以证明, 这里的 μ 即为 X 的均值向量 (或称数学期望向量), V 即为 X 的协差阵, 它是 $p \times p$ 阶正定阵。具体写出来就是

$$\mu = EX = \begin{pmatrix} Ex_1 \\ \vdots \\ Ex_p \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \vdots \\ \mu_p \end{pmatrix} \quad V_{p \times p} = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1p} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2p} \\ \cdots & \cdots & \cdots & \cdots \\ \sigma_{p1} & \sigma_{p2} & \cdots & \sigma_{pp} \end{pmatrix}$$

$|V|$ 为协差阵 V 的行列式。

当 $p = 2$ 时，我们可以得到二元正态分布的密度式：

设 $X = (x_1, x_2)'$ 服从二维正态分布，其概率密度函数为

$$f(x_1, x_2) = \frac{1}{(2\pi)^{\frac{p}{2}} |V|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2}(X - \mu)' V^{-1} (X - \mu) \right\}, V > 0$$

其中

$$V = \begin{pmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{21} & \sigma_{22} \end{pmatrix} = \begin{pmatrix} \sigma_1^2 & \sigma_1 \sigma_2 r \\ \sigma_1 \sigma_2 r & \sigma_2^2 \end{pmatrix}, r \neq \pm 1$$

这里 σ_1^2, σ_2^2 分别是 x_1 与 x_2 的方差， r 是 x_1, x_2 的相关系数。由于 $|V| = \sigma_1^2 \sigma_2^2 (1 - r^2)$,

$$V^{-1} = \frac{1}{\sigma_1^2 \sigma_2^2 (1 - r^2)} \begin{pmatrix} \sigma_2^2 & -\sigma_1 \sigma_2 r \\ -\sigma_1 \sigma_2 r & \sigma_1^2 \end{pmatrix}$$

故

$$\begin{aligned} f(x_1, x_2) &= \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-r^2}} e^{-\frac{1}{2(1-r^2)} \left[\frac{(x_1-\mu_1)^2}{\sigma_1^2} - 2r\frac{(x_1-\mu_1)(x_2-\mu_2)}{\sigma_1\sigma_2} \right.} \\ &\quad \left. + \frac{(x_2-\mu_2)^2}{\sigma_2^2} \right]} \end{aligned}$$

这与我们在概率论中所学的结果是一致的。

对于 p 维正态分布，也可以用特征函数来定义。

定义2.2 若随机向量 X 的特征函数为 $\varphi_X(t) = e^{it'\mu - \frac{1}{2}t'Vt}$ ，则称 X 服从 p 维正态分布（这里 μ 为 p 维列向量， V 为 p 阶非负定阵）。记为 $X \sim N(\mu, V)$ 。

下面讲述一下它的来源。并且由密度求出特征函数来。

对于一元正态分布 $X \sim N(\mu, \sigma^2)$ ，它的特征函数为（ t 是单个变量）

$$\begin{aligned} \varphi(t) &= Ee^{itx} = \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{+\infty} e^{itx} e^{-\frac{1}{2}\frac{(x-\mu)^2}{\sigma^2}} dx \\ &= \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{+\infty} e^{itx - \frac{(x-\mu)^2}{2\sigma^2}} dx \end{aligned}$$

注意到： $\frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{+\infty} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx = 1$

由于 $itx - \frac{(x-\mu)^2}{2\sigma^2} = \frac{-(x-\mu-it\sigma^2)^2}{2\sigma^2} + it\mu - \frac{t^2\sigma^2}{2}$

故

$$\begin{aligned} \varphi(t) &= \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{+\infty} e^{itx - \frac{(x-\mu)^2}{2\sigma^2}} dx \\ &= \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{+\infty} e^{-\frac{(x-\mu-it\sigma^2)^2}{2\sigma^2} + it\mu - \frac{t^2\sigma^2}{2}} dx \end{aligned}$$

$$= e^{it'\mu - \frac{t^2\sigma^2}{2}}$$

为了推广它得到多维正态分布的特征函数，注意 t' 与 t 是一回事，故这时特征函数亦可写为

$$\varphi(t) = e^{it'\mu - \frac{1}{2}t'\sigma^2 t} \quad (2.2)$$

因为特征函数唯一地决定分布函数，故由正态分布的特征函数 $\varphi(t)$ 的表达式中也能直接看到其中的参数 μ 和 σ^2 正好是正态随机变量 X 的数学期望与方差。

如果随机向量 $X = (x_1, \dots, x_p)' \sim N_p(\mu, V)$, ($V > 0$), 则 X 的特征函数可以仿上述方法推出。

首先，当 $X = (x_1, \dots, x_p)'$ 的各分量为 p 个独立标准正态变量时，有 $X \sim N_p(0, I_p)$ ，这时可求出 X 的特征函数

$$\begin{aligned}\varphi_X(t) &= Ee^{it'X} \\ &= Ee^{it\sum_{i=1}^p t_i X_i} \\ &= E \prod_{j=1}^p e^{it_j X_j} \\ &= \prod_{j=1}^p Ee^{it_j X_j} \\ &= \prod_{j=1}^p (e^{it'_j 0 - \frac{1}{2}t_j'^2}) \\ &= e^{it'0 - \frac{1}{2}t' I_p t}\end{aligned}$$

即 $Ee^{it'X} = \int \cdots \int \frac{1}{(2\pi)^{p/2}} e^{-t'X - \frac{1}{2}X'X} dX = e^{-\frac{1}{2}t't} \quad (2.3)$

其次，当 $X = (x_1, \dots, x_p)' \sim N_p(\mu, V)$ ($V > 0$)，则 X 的特征函数可以证明为：

$$\varphi_X(t) = e^{it'\mu - \frac{1}{2}t'Vt}$$

由于 $V > 0$ ，故 $V^{-1} > 0$ ，因而 $V^{-1} = B'B$ ，其中 B 为 p 阶非退化方阵，且 $|B| = |V|^{\frac{1}{2}}$ ，这时

$$\begin{aligned}\varphi_X(t) &= E(e^{it'X}) = \int \cdots \int e^{it'X} \frac{1}{(2\pi)^{p/2} |V|^{\frac{1}{2}}} e^{-\frac{1}{2}(X-\mu)'V^{-1}(X-\mu)} dX \\ &= \frac{1}{(2\pi)^{p/2} |V|^{\frac{1}{2}}} \int \cdots \int e^{it'X} -\frac{1}{2}(X-\mu)'B'B(X-\mu) dX\end{aligned}$$

令 $Y = B(X - \mu)$ ，则由 $dX = dx_1 \cdots dx_p$ 到 $dY = dy_1 \cdots dy_p$ 的积分变量变换的 Jacobi 行列式

$$|J| = \left| \frac{\partial Y}{\partial X} \right| = |B|, \text{ 又 } X = B^{-1}Y + \mu.$$

故

$$\begin{aligned}\varphi_X(t) &= \frac{1}{(2\pi)^{p/2} |V|^{\frac{1}{2}}} \int \cdots \int e^{i t' (B^{-1}Y + \mu) - \frac{1}{2} Y' Y} \frac{1}{|B|} dY \\ &= e^{it'\mu} \cdot \frac{1}{(2\pi)^{p/2}} \int \cdots \int e^{i(t' B^{-1})Y - \frac{1}{2} Y' Y} dydY\end{aligned}$$

由于此式后一个因子即是 (2.3) 式中形式, 只不过这里要用 $t' B^{-1}$ 代替 (2.3) 式中的 t' 而已。故

$$\begin{aligned}\varphi_X(t) &= e^{it'\mu} \cdot e^{-\frac{1}{2}(t' B^{-1})(t' B^{-1})'} \\ &= e^{it'\mu - \frac{1}{2} t' B^{-1} B^{-1} t} \\ &= e^{it'\mu - \frac{1}{2} t' V t}\end{aligned}$$

多元正态分布还可以用另一种方式来定义。

若

$$\frac{X}{p \times 1} = \frac{A}{p \times m} \frac{Y}{m \times 1} + \frac{\mu}{p \times 1} \quad (2.4)$$

其中 $Y \sim N_m(0, I_m)$, A 为任意矩阵, (p 可以比 m 小, 也可以比 m 大), 则称 $X \sim N_p(\mu, AA')$ 。

我们下面推出这时 X 的特征函数为 $\varphi_X(t) = e^{it'\mu - \frac{1}{2} t' A' At}$

由于

$$\begin{aligned}\varphi_X(t) &= Ee^{it'X} = Ee^{it'(AY + \mu)} \\ &= Ee^{it'\mu} \cdot Ee^{it'AY} \\ &= e^{it'\mu} \cdot Ee^{i(A't)'Y} \\ &= e^{it'\mu - \frac{1}{2}(A't)'(A't)} = e^{it'\mu - \frac{1}{2} t' AA' t}\end{aligned}$$

令

$$V = AA', \text{ 则 } V \geq 0, \text{ 故}$$

$$\varphi_X(t) = e^{it'\mu - \frac{1}{2} t' V t}$$

以上我们实际上给出了正态分布的三种定义:

1. 密度定义

$$f(X) = \frac{1}{(2\pi)^{p/2} |V|^{\frac{1}{2}}} e^{-\frac{1}{2}(X-\mu)' V^{-1}(X-\mu)} \quad (V > 0)$$

则称 $X \sim N_p(\mu, V)$ 。

2. 特征函数定义

若

$$\varphi(t) = Ee^{it'X} = e^{it'\mu - \frac{1}{2} t' V t} \quad (V \geq 0)$$

则称 $X \sim N_p(\mu, V)$

3.

$$\frac{X}{p \times 1} = \frac{A}{p \times m} \frac{Y}{m \times 1} + \frac{\mu}{p \times 1} \quad y \sim N(0, I_m)$$

则

$$X \sim N_p(\mu, AA') \quad (V = AA' \geq 0)$$

可以证明: 在 $V > 0$ 时, 三者是等价的, 而后二定义包含了 $V \geq 0$ 的情形, 因而严格说来, 后二者更广泛些。

为了简便，以下各章均假定 $V > 0$ 。

二、多元正态分布的性质

多元正态分布有许多重要性质，这些性质对于建立多元统计分析的理论是极为重要的基础。下面我们根据需要，讨论最重要的几条：

性质1 如果正态随机向量 $X = (x_1, \dots, x_p)'$ 的协差阵 V 是对角阵，则 X 的每一分量是相互独立的随机变量。

证：设随机向量 $X = (x_1, \dots, x_p)'$ ~ $N_p(\mu, V)$ ，其中

$$\mu = \begin{pmatrix} \mu_1 \\ \vdots \\ \mu_p \end{pmatrix}, \quad V = \begin{pmatrix} \sigma_1^2 & 0 & & \\ 0 & \sigma_2^2 & & \\ & & \ddots & \\ 0 & & & \sigma_p^2 \end{pmatrix}$$

则随机向量 X 的特征函数为

$$\begin{aligned}\varphi_X(t) &= e^{it'\mu - \frac{1}{2}t'Vt} \\ &= e^{i(t_1\mu_1 + \dots + t_p\mu_p) - \frac{1}{2}(t_1^2\sigma_1^2 + \dots + t_p^2\sigma_p^2)} \\ &= \prod_{j=1}^p e^{it_j\mu_j - \frac{1}{2}t_j^2\sigma_j^2} \\ &= \prod_{j=1}^p e^{it_j\mu_j - \frac{1}{2}t_j^2\sigma_j^2 t_j} \\ &= \varphi_{x_1}(t_1) \cdot \varphi_{x_2}(t_2) \cdots \varphi_{x_p}(t_p)\end{aligned}\tag{2.5}$$

由(1.11)及(2.2)知， x_1, \dots, x_p 相互独立，且分别具有均值 $\mu_1, \mu_2, \dots, \mu_p$ 和方差 $\sigma_1^2, \sigma_2^2, \dots, \sigma_p^2$ 。

性质2 多元正态变量 $X = (x_1, \dots, x_p)'$ 的任意线性变换仍然服从多元正态分布。即设 $X \sim N_p(\mu, V)$ 而 m 维随机向量 $Y_{m \times 1} = AX + b$ ，其中 $A = (a_{ij})$ 是 $m \times p$ 阶的常数矩阵， b 是 m 维的常向量。则 m 维随机向量 Y 也是正态的，且 $Y \sim N_m(A\mu + b, AVA')$ 。即 Y 服从从 m 元正态分布，其均值向量为 $A\mu + b$ ，协差阵为 AVA' 。

证：我们直接求随机向量 Y 的特征函数：

$$\begin{aligned}\varphi_Y(t) &= Ee^{it'Y} \\ &= Ee^{it'(AX+b)} \\ &= Ee^{it'AX + it'b} \\ &= e^{it'b} \cdot Ee^{i(A't)'X} \\ &= e^{it'b} \cdot e^{i(A't)' \mu - \frac{1}{2}(A't)'V(A't)} \\ &= e^{it'b} \cdot e^{it'A\mu - \frac{1}{2}t'AVA't} \\ &= e^{it'(A\mu + b) - \frac{1}{2}t'AVA't}\end{aligned}\tag{2.6}$$

由上所证，就知 m 维随机向量 Y 服从 m 维正态分布，其均值向量为 $A\mu + b$ ，协差阵为 AVA' 即 $Y \sim N_m(A\mu + b, AVA')$

性质3 多元正态分布的任何边际分布都是正态分布。（多元正态随机向量 X 的某些分量的联合分布称为 X 的边际分布）。

即设 $X = (x_1, \dots, x_p)' \sim N_p(\mu, V)$ ，如果将 X 、 μ 、 V 作相应的剖分

$$X = \begin{pmatrix} X^{(1)} \\ X^{(2)} \end{pmatrix}, \quad \mu = \begin{pmatrix} \mu^{(1)} \\ \mu^{(2)} \end{pmatrix}, \quad V = \begin{pmatrix} V_{11} & V_{12} \\ V_{21} & V_{22} \end{pmatrix}$$

则 $X^{(1)}$ ， $X^{(2)}$ 都服从多元正态分布。

证：现在求 $X^{(2)}$ 的分布。

我们取 $t = \begin{pmatrix} 0 \\ t_2 \end{pmatrix}$ ， t_2 与 $X^{(2)}$ 同维数， t 与 X 同维数，则 $X^{(2)}$ 的特征函数为

$$\begin{aligned} \varphi_{X^{(2)}}(t) &= \varphi\left(\begin{pmatrix} 0 \\ t_2 \end{pmatrix}\right) = e^{it'\mu - \frac{1}{2}t'Vt} \\ &= e^{i(0-t_2')\begin{pmatrix} \mu^{(1)} \\ \mu^{(2)} \end{pmatrix} - \frac{1}{2}(0-t_2')\begin{pmatrix} V_{11} & V_{12} \\ V_{21} & V_{22} \end{pmatrix}\begin{pmatrix} 0 \\ t_2 \end{pmatrix}} \\ &= e^{it'\mu^{(2)} - \frac{1}{2}t_2'V_{22}t_2} \end{aligned}$$

由此可知， $X^{(2)}$ 服从正态分布，且其均值为 $\mu^{(2)}$ ，协差阵为 V_{22} ，即 $X^{(2)} \sim N(\mu^{(2)}, V_{22})$ 。

同样可以证明 $X^{(1)} \sim N(\mu^{(1)}, V_{11})$ ，这就证明了性质3。

性质4 若 p 元随机向量 $X = (x_1, \dots, x_p)'$ 服从 p 元正态分布 $N_p(\mu, V)$ ，($V > 0$)。我们对 X ， μ ， V 作相应的剖分。

$$X = \begin{pmatrix} X^{(1)} \\ X^{(2)} \end{pmatrix}, \quad \mu = \begin{pmatrix} \mu^{(1)} \\ \mu^{(2)} \end{pmatrix}, \quad V = \begin{pmatrix} V_{11} & V_{12} \\ V_{21} & V_{22} \end{pmatrix}$$

$$p_1 + p_2 = p$$

则 $X^{(1)}$ 与 $X^{(2)}$ 独立的充要条件是 $X^{(1)}$ 的每一分量与 $X^{(2)}$ 中的每一分量的协方差为0，即 $V_{12} = V_{21} = 0$

证：

$X = \begin{pmatrix} X^{(1)} \\ X^{(2)} \end{pmatrix}$ 的特征函数为：

$$\begin{aligned} \varphi_{(X^{(1)}, X^{(2)})}(t) &= e^{i(t_1'\mu^{(1)} + t_2'\mu^{(2)}) - \frac{1}{2}(t_1', t_2')\begin{pmatrix} V_{11} & V_{12} \\ V_{21} & V_{22} \end{pmatrix}\begin{pmatrix} t_1 \\ t_2 \end{pmatrix}} \\ &= e^{(it_1'\mu^{(1)} - \frac{1}{2}t_1'V_{11}t_1)} \cdot e^{(it_2'\mu^{(2)} - \frac{1}{2}t_2'V_{22}t_2)} \cdot e^{-t_1't_2} \\ &= \varphi_{X^{(1)}}(t_1) \cdot \varphi_{X^{(2)}}(t_2) \cdot e^{-t_1't_2} \end{aligned}$$

故 $X^{(1)}$ 与 $X^{(2)}$ 相互独立的充要条件是 $t_1't_2 = 0$ ，对于任何的 t_1 ， t_2 成立。故要式为零，其充要条件为 $V_{12} = 0$ 。

§3 均值向量和协差阵的估计和检验

上节讨论了多元正态分布的性质，在实际问题中，多元正态分布的参数 μ 和 V 都是未知的，我们只能观测到样本资料阵。如何通过样本资料阵，对参量 μ 和 V 作出估计呢？又怎样检验总体之间是否存在差异？这就是本节所要讨论的问题。

一、多元正态分布的参数估计

我们首先通过一个实例，了解求 μ 和 V 的估计量的方法，再讲到一般的公式。

例3.1 表中的数据，是从某地一个村庄里关于黄麻的一项试验中收集的。对于20个随机选取的个体植株，记录其青黄麻植株的重量(x_1)与它们的干黄麻纤维的重量(x_2)，假定 $X = (x_1, x_2)'$ 是正态分布的，它具有均值 $\mu = (\mu_1, \mu_2)'$ ，且协差阵是 V ，求 μ 和 V 的估计 $\hat{\mu}$ 和 \hat{V} 。

植株号	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
x_1 (克)	68	63	70	6	65	9	10	12	20	30	33	27	21	5	14	27	17	53	62	65
x_2 (克)	971	892	1125	82	931	112	162	321	315	375	462	352	305	84	229	332	185	703	872	740

解：均值 μ 的估计量记作 \bar{X} ，称为样本均值。

$$\hat{\mu} = \bar{X} = \frac{1}{20} \begin{pmatrix} (68+63+\cdots+65) \\ (971+892+\cdots+740) \end{pmatrix} = \begin{pmatrix} 33.85 \\ 477.50 \end{pmatrix} = \begin{pmatrix} \bar{x}_1 \\ \bar{x}_2 \end{pmatrix}$$

协差阵 V 的估计量记作 \hat{V} ，对它有多种估计法。这里用样本协差阵，它是 \hat{V} 的无偏估计。为计算 \hat{V} ，先计算离差阵 S ，而

$$\hat{V} = \frac{1}{20-1} S$$

令 $X_{(\alpha)} = (x_{\alpha 1}, x_{\alpha 2})'$ $\alpha = 1, \dots, 20$

$$S = \sum_{\alpha=1}^{20} (X_{(\alpha)} - \bar{X})(X_{(\alpha)} - \bar{X})'$$

$$= \sum_{\alpha=1}^{20} \left[\begin{pmatrix} x_{\alpha 1} \\ x_{\alpha 2} \end{pmatrix} - \begin{pmatrix} \bar{x}_1 \\ \bar{x}_2 \end{pmatrix} \right] \left[\begin{pmatrix} x_{\alpha 1} \\ x_{\alpha 2} \end{pmatrix} - \begin{pmatrix} \bar{x}_1 \\ \bar{x}_2 \end{pmatrix} \right]'$$

$$= \begin{pmatrix} \sum_{\alpha=1}^{20} (x_{\alpha 1} - \bar{x}_1)^2 & \sum_{\alpha=1}^{20} (x_{\alpha 1} - \bar{x}_1)(x_{\alpha 2} - \bar{x}_2) \\ \sum_{\alpha=1}^{20} (x_{\alpha 2} - \bar{x}_2)(x_{\alpha 1} - \bar{x}_1) & \sum_{\alpha=1}^{20} (x_{\alpha 2} - \bar{x}_2)^2 \end{pmatrix}$$

$$= \begin{pmatrix} 10838.6 & 149056.6 \\ & 2135681 \end{pmatrix}$$

由于 \hat{V} 为对称阵，这里只需写出上三角部分，下同。所以协差阵 V 的估计量为

$$\hat{V} = \frac{1}{20-1} \begin{pmatrix} 10838.6 & 149056.6 \\ & 2135681 \end{pmatrix} = \begin{pmatrix} 570.45 & 7845.08 \\ & 112404.26 \end{pmatrix}$$

在一般情况下，如果样本资料阵为

$$\mathbf{X} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \cdots & \cdots & \cdots & \cdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} = (X_1, X_2, \dots, X_p) = \begin{pmatrix} X_{(1)}' \\ X_{(2)}' \\ \vdots \\ X_{(n)}' \end{pmatrix}$$

设样品 $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ 相互独立，同服从于 p 元正态分布 $N_p(\mu, V)$ ，而且 $n > p$ ，
 $V > 0$ ，则总体参数 μ 和 V 的估计量分别是

$$\hat{\mu} = \bar{X} = \frac{1}{n} \sum_{a=1}^n X_{(a)} = \frac{1}{n} \begin{pmatrix} \sum_{a=1}^n x_{a1} \\ \sum_{a=1}^n x_{a2} \\ \vdots \\ \sum_{a=1}^n x_{ap} \end{pmatrix} = \begin{pmatrix} \bar{x}_1 \\ \bar{x}_2 \\ \vdots \\ \bar{x}_p \end{pmatrix} \quad (3.1)$$

即，均值向量 μ 的估计量，就是样本均值。这是由极大似然法推导出来的。容易看出，当我们的样本资料阵选取的是 p 个变量的数据时，则 $\hat{\mu} = \bar{X}$ 当然也是 p 维向量。协差阵 V 的极大似然估计量 \hat{V} 为

$$\hat{V}_M = \frac{1}{n} S = \frac{1}{n} \sum_{a=1}^n (X_{(a)} - \bar{X})(X_{(a)} - \bar{X})' \quad (3.2)$$

其中 S 是离差阵，它是每一个样品（向量）与样本均值（向量）的离差积形成的 n 个 $p \times p$ 阶对称阵的和。求出 S ，再除以样本容量 n 就是总体协差阵 V 的极大似然估计。同一维相似，用 \hat{V}_M 估计 V 并不是无偏的，为了得到无偏估计我们常用样本协差阵 $\hat{V} = \frac{1}{n-1} S$ 作为总体协差阵的估计。以下我们都是这样做的。

可以证明， μ 的估计量 \bar{X} 是最小方差无偏估计，是有效估计，是强相合估计。 V 的估计量 $\hat{V} = \frac{1}{n-1} S$ 是最小方差无偏估计，是渐近有效估计，是强相合估计。

二、总体均值向量的检验

在一元统计中，有检验总体均值的问题，如：当总体是正态分布 $N(a, \sigma^2)$ 时，要由样本资料检验假设 $H_0: a = a_0$ ， a_0 是某指定的数。在方差未知时，我们用统计量 t 来作检

验统计量。

$$T = \sqrt{n} \frac{\bar{X} - \mu_0}{S}$$

其中 n 是样本容量, \bar{X} 是样本均值, S^2 是样本方差。

由于在 H_0 下, 统计量 T 服从 $n - 1$ 个自由度的 t 分布, 给出检验水平 α , 可以求出相应的拒绝域, 从而得出对假设 $H_0: \mu = \mu_0$ 作出判断的一般方法。

现在, 假设总体是多元正态分布的, 但 μ 和 V 未知, 我们的任务是要寻找一个最有代表性而且易求出分布规律的统计量, 然后根据检验水平 α , 求出拒绝域, 从而对假设 $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$ 作出肯定或否定判断。

在多元正态分布下, 均值检验能否化为 p 个一维正态分布检验来作呢? 这是不能的。因为通常这 p 个分量之间有互相依赖的关系, 分开作, 往往得不出正确结论。

在多元分析中, 常用的是 T^2 统计量和 χ^2 统计量, 现分别叙述如下:

1. 协差阵 V 已知时, 均值向量的检验

(i) 均值向量为指定值的检验

设 $X_{(a)} = (X_{a1}, \dots, X_{ap})'$, $a = 1, \dots, n$, 是容量为 n 的随机样本, 它们来自均值向量为 μ , 协差阵为已知正定阵 V 的 p 元正态总体, 对于指定向量 μ_0 , 要检验假设 $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$, 这时检验统计量为

$$D = n(\bar{X} - \mu_0)' V^{-1} (\bar{X} - \mu_0) \quad (3.3)$$

可以证明: 在 H_0 成立条件下, 它服从自由度为 p 的 χ^2 分布。其中 \bar{X} 是样本均值, n 是样本容量。而在备择假设成立时, D 有变大的趋势, 因而拒绝域可以取为 D 值较大的右侧部分。因此, 当给定检验水平 α 后, 由样本值可以算出 \bar{X} 的值, 当

$$D = n(\bar{X} - \mu_0)' V^{-1} (\bar{X} - \mu_0) \geq \chi^2_{1-\alpha}(p)$$

时, 便拒绝 H_0 , 其中 $\chi^2_{1-\alpha}(p)$ 是自由度为 p 的 χ^2 分布的 $1 - \alpha$ 分位数。

即 $P\{\chi^2(p) \leq \chi^2_{1-\alpha}(p)\} = 1 - \alpha$

(ii) 两个正态总体均值向量相等的检验

设 $X_{(a)} = (x_{a1}, \dots, x_{ap})'$, $a = 1, \dots, n_1$, 是来自 p 元正态总体 $N_p(\mu_1, V)$ 的容量为 n_1 的样本; $Y_{(a)} = (y_{a1}, \dots, y_{ap})'$, $a = 1, \dots, n_2$, 是来自 p 元正态分布 $N_p(\mu_2, V)$ 的容量为 n_2 的样本, 并且两个样本间相互独立。又设 $V > 0$ 是两个正态总体共同的协差阵。

当 V 已知时, 我们要检验假设

$H_0: \mu_1 = \mu_2$, 备择假设 $H_1: \mu_1 \neq \mu_2$ 。

这时检验统计量为

$$D^* = \frac{n_1 n_2}{n_1 + n_2} (\bar{X} - \bar{Y})' V^{-1} (\bar{X} - \bar{Y}) \quad (3.4)$$

可以证明, 当 H_0 成立时, D^* 服从自由度为 p 的 χ^2 分布, 其中 \bar{X}, \bar{Y} 分别是两个总体的样本均值, n_1, n_2 是样本容量。当 H_1 成立时, D^* 有变大的趋势, 因而拒绝域可取为 D^* 值较大的右侧部分。具体做法是, 当给定检验水平 α 后, 由样本值计算出统计量 D^* 的值, 当

$$D^* = \frac{n_1 n_2}{n_1 + n_2} (\bar{X} - \bar{Y})' V^{-1} (\bar{X} - \bar{Y}) \geq \chi^2_{1-\alpha}(p)$$

时，便拒绝 H_0 ，即认为两个总体的均值向量不等，其中 $\chi^2_{1-\alpha}(p)$ 是自由度为 p 的 χ^2 分布的 $1 - \alpha$ 分位数。

2. 协差阵未知时，均值向量的检验

(i) 均值向量为指定值的检验。

设 $X_{(a)} = (X_{a1}, \dots, X_{ap})'$, $a = 1, \dots, n$, 是容量为 n 的样本 ($n > p$)，它们来自均值向量为 μ ，协差阵为未知正定阵 V 的 p 元正态总体，要对假设

$$H_0: \mu = \mu_0, \text{ 备择假设 } H_1: \mu \neq \mu_0$$

进行检验，其中 μ_0 是指定的已知向量。这时，所用统计量为

$$F = \frac{(n-p)}{(n-1)p} T^2 = \frac{n}{p} (n-p)(\bar{X} - \mu_0)' S^{-1} (\bar{X} - \mu_0) \quad (3.5)$$

其中

$$T^2 = n(n-1)(\bar{X} - \mu_0)' S^{-1} (\bar{X} - \mu_0)$$

称为霍太林 T^2 统计量，有些书中有它的分布表，但一般均用 F 检验来代替它。式中

$$S = \sum_{a=1}^n (X_{(a)} - \bar{X})(X_{(a)} - \bar{X})'$$

是样本的离差阵， \bar{X} 是样本均值， n 为样本容量， p 是随机向量的维数。

当假设 $H_0: \mu = \mu_0$ 成立时

$$F = \frac{(n-p)}{(n-1)p} T^2 = \frac{n}{p} (n-p)(\bar{X} - \mu_0)' S^{-1} (\bar{X} - \mu_0) \sim F(p, n-p)$$

且当 H_1 成立时，统计量 F 有变大的趋势。故在检验水平 α 下，如果

$$F = \frac{(n-p)}{(n-1)p} T^2 \geq F_{1-\alpha}(p, n-p)$$

则拒绝 H_0 ，否则接受 H_0 。

(ii) 两个正态总体均值向量相等的检验。

设 $X_{(a)} = (X_{a1}, \dots, X_{ap})'$, $a = 1, \dots, n_1$, 为来自 p 元正态总体 $N_p(\mu_1, V)$ 的容量为 n_1 的样本， $Y_{(a)} = (Y_{a1}, \dots, Y_{ap})'$, $a = 1, \dots, n_2$, 为来自 p 元正态总体 $N_p(\mu_2, V)$ 容量为 n_2 的样本，且两样本间相互独立。假定两总体协差阵相等，但未知，我们考虑对假设

$$H_0: \mu_1 = \mu_2, \text{ 备择假设 } H_1: \mu_1 \neq \mu_2$$

的检验问题。这时，选用的统计量是

$$\tilde{F} = \frac{n_1 n_2 (n_1 + n_2 - p - 1)}{p(n_1 + n_2)(n_1 + n_2 - 2)} (\bar{X} - \bar{Y})' \hat{V}^{-1} (\bar{X} - \bar{Y}) \quad (3.6)$$

其中 \bar{X} , \bar{Y} 分别是两个总体的样本均值， n_1 , n_2 是样本容量， p 为样品变量的维数，而

$$\hat{V} = \frac{1}{n_1 + n_2 - 2} (S_1 + S_2)$$

是协差阵 V 的估计量，其中 S_1 , S_2 是两个总体的样本离差阵，即

$$S_1 = \sum_{a=1}^{n_1} (X_{(a)} - \bar{X})(X_{(a)} - \bar{X})'$$

$$S_2 = \sum_{a=1}^{n_2} (Y_{(a)} - \bar{Y})(Y_{(a)} - \bar{Y})'$$

当 $H_0: \mu_1 = \mu_2$ 成立时， $F \sim F(p, n_1 + n_2 - p - 1)$ 。

当 $H_1: \mu_1 \neq \mu_2$ 成立时， F 有变大的趋势。因而拒绝域可以取为 F 值较大的右侧区域，即当给定检验水平 α ，若

$$\tilde{F} \geq F_{1-\alpha}(p, n_1 + n_2 - p - 1)$$

时，则拒绝 H_0 ，否则接受 H_0 。

例3.2 设 $X = (x_1, \dots, x_p)' \sim N_p(\mu_1, V)$, $Y = (y_1, \dots, y_p)' \sim N_p(\mu_2, V)$, $V > 0$ 未知。现分别测得来自两个总体的数据如表，试检验假设： $H_0: \mu_1 = \mu_2$ ($\alpha = 0.01$)

变量 编号	x_1	x_2	x_3	x_4	变量 编号	y_1	y_2	y_3	y_4
1	13.85	4.79	7.8	49.6	1	2.18	1.06	1.22	20.6
2	22.31	4.67	12.31	47.8	2	3.85	0.8	4.06	47.1
3	28.82	4.63	16.18	62.15	3	11.4	0	3.50	0
4	15.29	3.57	7.58	43.2	4	3.66	2.42	2.14	15.1
5	28.29	4.90	16.12	58.7	5	12.10	0	5.68	0

注：作这种检验时，必须用较多的样品。本例中样本量太少，仅用来解释计算步骤，实际中是不允许的。

解：此题属于对两个未知协差阵的总体，检验均值是否相等的问题，故首先要计算统计量 \tilde{F} 的值。

$$\tilde{F} = \frac{n_1 n_2}{(n_1 + n_2)(n_1 + n_2 - 2)} \cdot \frac{n_1 + n_2 - 1 - p}{p} (\bar{X} - \bar{Y})' \hat{V}^{-1} (\bar{X} - \bar{Y})$$

$$\Delta = \frac{n_1 n_2}{(n_1 + n_2)(n_1 + n_2 - 2)} \cdot \frac{n_1 + n_2 - 1 - p}{p} D^2$$

其中 D^2 是两个样本的马氏距离。马氏距离概念见 214 页。

$$D^2 = (\bar{X} - \bar{Y})' \hat{V}^{-1} (\bar{X} - \bar{Y}) = (n_1 + n_2 - 2) (\bar{X} - \bar{Y})' (S_1 + S_2)^{-1} (\bar{X} - \bar{Y})$$

(因为 $\hat{V} = \frac{1}{n_1 + n_2 - 2} (S_1 + S_2)$)。 S_1, S_2 是两总体的样本离差积和阵。

为计算 D^2

第一步：求 \bar{X} , \bar{Y}

$$\bar{X} = \frac{1}{n_1} \begin{pmatrix} n_1 \\ \sum_{j=1}^{n_1} x_{j1} \\ \vdots \\ n_1 \\ \sum_{j=1}^{n_1} x_{jP} \end{pmatrix} = \frac{1}{5} \begin{pmatrix} 13.85 + \dots + 28.29 \\ \vdots \\ 49.6 + \dots + 58.7 \end{pmatrix} = \begin{pmatrix} 21.712 \\ 4.105 \\ 11.998 \\ 52.290 \end{pmatrix} = \begin{pmatrix} \bar{x}_1 \\ \bar{x}_2 \\ \bar{x}_3 \\ \bar{x}_4 \end{pmatrix}$$

同理

$$\vec{Y} = \begin{pmatrix} 6.638 \\ 0.856 \\ 3.320 \\ 16.560 \end{pmatrix} = \begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \end{pmatrix}$$

第二步，计算 $\bar{x}_i - \bar{y}_i$ $i = 1, 2, 3, 4$ 。

$$a_1 = \bar{x}_1 - \bar{y}_1 = 21.712 - 6.638 = 15.074$$

$$a_2 = \bar{x}_2 - \bar{y}_2 = 4.105 - 0.856 = 3.249$$

$$a_3 = \overline{x_3} - \overline{y_3} = 11.998 - 3.820 = 8.673$$

$$a_4 = \overline{x_4} - \overline{y_4} = 52,290 - 16,560 = 35,730$$

第三步，计算 $S_1 + S_2$

$$S_1 + S_2 = \left(\begin{array}{c} \Sigma (x_{11} - \bar{x}_1)^2 + \Sigma (y_{11} - \bar{y}_1)^2 \dots \Sigma (x_{11} - \bar{x}_1)(y_{14} - \bar{y}_4) + \Sigma (y_{11} - \bar{y}_1) \\ \cdot (y_{14} - \bar{y}_4) \\ \dots \\ \dots \\ \Sigma (x_{14} - \bar{x}_4)^2 + \Sigma (y_{14} - \bar{y}_4)^2 \end{array} \right)$$

第四步：为计算 $D^2 = (n_1 + n_2 - 2)(\bar{x} - \bar{y})'(S_1 + S_2)^{-1}(\bar{x} - \bar{y})$ ，令

$$(S_1 + S_2)^{-1} (\bar{x} - \bar{y}) = \begin{pmatrix} b_1 \\ b_2 \\ b_3 \\ b_4 \end{pmatrix}$$

即

$$(S_1 + S_2) \begin{pmatrix} b_1 \\ b_2 \\ b_3 \\ b_4 \end{pmatrix} = \begin{pmatrix} a_1 \\ a_2 \\ a_3 \\ a_4 \end{pmatrix}$$

由

$$\begin{pmatrix} 286.230 & 9.1034 & 142.964 & -79.0278 \\ 7.232 & 9.1758 & 41.590 & \\ 83.671 & 91.483 & & \\ 1747.944 & & & \end{pmatrix} \begin{pmatrix} b_1 \\ b_2 \\ b_3 \\ b_4 \end{pmatrix} = \begin{pmatrix} 15.074 \\ 3.249 \\ 8.678 \\ 35.730 \end{pmatrix}$$

得方程组

$$\begin{cases} 286.230b_1 + 9.1034b_2 + 142.964b_3 - 79.0278b_4 = 15.074 \\ 9.1034b_1 + 7.232b_2 + 9.1758b_3 + 41.590b_4 = 3.249 \\ 142.964b_1 + 9.1758b_2 + 83.6713b_3 + 71.4839b_4 = 8.678 \\ -79.0278b_1 + 41.590b_2 + 91.483b_3 + 1747.944b_4 = 35.730 \end{cases}$$

解上述方程组得

$$b_1 = 0.6136 \quad b_2 = 0.5452 \quad b_3 = -1.1063 \quad b_4 = 0.0931$$

第四步：计算 \tilde{D}^2, \tilde{F}

$$\begin{aligned} D^2 &= (n_1 + n_2 - 2) (a_1 a_2 a_3 a_4) (b_1 b_2 b_3 b_4)' \\ &= (5 + 5 - 2) (15.074 \ 3.249 \ 8.678 \ 35.730) \cdot \\ &\quad \cdot (0.6136 \ 0.5452 \ -1.1061 \ 0.0931)' \\ &= 37.9744 \end{aligned}$$

于是

$$\begin{aligned} \tilde{F} &= \frac{n_1 n_2}{(n_1 + n_2)(n_1 + n_2 - 2)} \cdot \frac{n_1 + n_2 - p - 1}{p} D^2 \\ &= \frac{5 \times 5}{(5+5)(5+5-2)} \times \frac{5 + 5 - 4 - 1}{4} \times 37.9744 = 14.822 \end{aligned}$$

第五步：查 F 分布的 $1-\alpha = 0.99$ 的分位点表

$$F_{1-\alpha}(p, n_1 + n_2 - p - 1) = F_{0.99}(4, 5) = 11.4$$

第六步：比较作结论

因为 $14.822 > 11.4$, 故否定 H_0 , 即认为两总体均值有高度显著差异。