

多元统计方法

方开泰 编

中国科学院应用数学研究所
概率统计咨询服务中心 印

1984.7

编 者 的 话

近年来，许多部门经常要求我们举办多元分析方法的学习讨
班。为了给这一类活动提供适当的教材，特地选编了部分常用的方法。
其中包括：多变量样本的图分析法，聚类分析，回归分析、
判别分析，主分量分析和因子分析。由于这些材料来源不同，符
号体例均无法统一，希读者谅解。

方开泰

1984·6·18

目 录

1、多变量样本的图分析法(一)	方开泰	1
2、多变量样本的图分析法(二)	方开泰	19
3、聚类分析(I)	方开泰	36
4、聚类分析(II)	方开泰	68
5、回归分析简介	方开泰	88
6、判别分析	方开泰	161
7、主分量	M·肯德尔	255
8、因子分析	M·肯德尔	281

多变量样本的图分析法(一)

中国科学院应用数学研究所 方开泰

图形是帮助人们思维和判断的重要工具。当样本只有两个特性(变量或指标)时,可以用通常的直角坐标在平面上点图。当样本有三个变量时,虽然可以在三维的笛卡儿坐标里点图,但也是很不方便的。当变量数大于三时,用通常的方法已不能点图了。在多元分析中,样本的变量数一般均大于三,探讨多变量的点图法是长期来一直为人们所关注的研究课题,这里介绍一些有关的方法,特别是近十年来发展的一些方法。

作者非常感谢刘璋温副教授,因为他提供了许多有用的文献,并仔细校阅和修改了此文。

一、雷达图(radar chart)

设有 n 个样本 X_1, X_2, \dots, X_n , 各有 p 个变量 x_1, x_2, \dots, x_p , 用 x_{ij} ($i=1, 2, \dots, n; j=1, 2, \dots, p$) 表示第 i 个样本的第 j 个变量的值, 通常数据 $\{x_{ij}\}$ 列成表 1·1 的形式。

表 1·1 数据矩阵

变 量 样本	x_1	x_2	...	x_j	...	x_p
X_1	x_{11}	x_{12}	...	x_{1j}	...	x_{1p}
X_2	x_{21}	x_{22}	...	x_{2j}	...	x_{2p}
⋮	⋮	⋮	...	⋮	...	⋮
X_i	x_{i1}	x_{i2}	...	i_j	...	x_{ip}
⋮	⋮	⋮	...	⋮	...	⋮
X_n	x_{n1}	x_{n2}	...	x_{nj}	...	x_{np}

雷达图也称蜘蛛网图，其作图步骤如下：划一个圆，由 p 个点把圆周分成相等的 p 个部分，由圆心连接这 p 个点，得 p 个辐射状的半径，这 p 个半径就作为 p 个变量的坐标轴。根据各变量波动的大小，将相应的坐标轴标上刻度。将每个变量的值点在各自的坐标轴上，依次连接起来得一 P 边形。对每个样本都这样做，可得 n 个 P 边形，形成一个雷达图。

例 1、表 1·2 列出了邓阜仙岩体的部分化学成分，试用雷达图来表示它们。

运用上述作雷达图的步骤得图 1·1，从图上看到： X_1 与 X_2 ； X_3 ， X_4 与 X_5 ； X_6 与 X_7 图形分别相似，可以分成三类，这正好是三种类型的花岗岩。

表 1·2 邓阜仙岩体化学成分(部分)

岩 体	SiO ₂	TiO ₂	FeO	CaO	K ₂ O
X ₁ : 中粗粒班状黑云母花岗岩	75·20	0·14	1·86	0·91	5·21
X ₂ : 中粗粒班状黑云母花岗岩	75·15	0·16	2·11	0·74	4·93
X ₃ : 中粒二云母花岗岩	72·19	0·13	1·52	0·69	4·65
X ₄ : 中粒二云母花岗岩	72·35	0·13	1·37	0·83	4·87
X ₅ : 中粒二云母花岗岩	72·74	0·10	1·41	0·72	4·99
X ₆ : 细粒白云母花岗岩	73·29	0·033	1·07	0·17	3·15
X ₇ : 细粒白云母花岗岩	73·72	0·033	0·77	0·28	2·78




图 1·1 雷达图

在雷达图上，每个样本对应一个 P 边形。当 P 较大或样本较多时，图上线段太多，看起来很不方便，这时可以每个样本画一张图，如图 1·2。如果样本的分类已很清楚，这时可以将同类的计算均值，用每类的均值来作雷达图。这时图像既清晰，每类特征又很明显。例如对例 1，我们求得三类的均值列表 1·3，用三组均值作成雷达图 1·3，我们看到图像清晰，三类特点一目了然。




图 1·2

表 1·3 类均值

类	SiO_2	TiO_2	FeO	CaO	K_2O
I: $\{X_1, X_2\}$	75·18	0·15	1·99	0·83	5·07
II: $\{X_3, X_4, X_5\}$	72·43	0·12	1·43	0·75	4·84
III: $\{X_6, X_7\}$	73·51	0·033	0·92	0·23	2·97




图 1·3 均值的雷达图

二、星座图 (constellation graph)

上节我们看到，当 n 很大时，用雷达图来表达每一个样本是不方便的，这时可以用星座图来描述。所谓星座图，就是将样本

点在一个半圆内，一个样本用一颗星来表示。同类的样本组成一个星座。不同类样本组成不同的星座。很象天文学上表示星座的图象。

星座图的作图步骤如下：

(i) 先将数据 $\{x_{ij}\}$ 作一线性变换。使变换后的数据 $\{\xi_{ij}\}$ 落到 $[0, \pi]$ 内，常取

$$\xi_{ij} = \frac{x_{ij} - x_{\min j}}{R_j} \pi, \quad (1)$$

其中

$$x_{\min j} = \min_{1 \leq i \leq n} x_{ij}, \quad x_{\max j} = \max_{1 \leq i \leq n} x_{ij},$$

$$R_j = x_{\max j} - x_{\min j},$$

这就是极差标准化的办法。

(ii) 取一组权 $\{\omega_j\}$ ，使得

$$\omega_j \geq 0, \quad j=1, 2, \dots, p, \quad \sum_{j=1}^p \omega_j = 1.$$

重要的变量相应的权可取得大一点，或者也可以取等权，即

$$\omega_1 = \omega_2 = \dots = \omega_p = 1/p.$$

(iii) 画一个半径为 1 的上半圆及半圆底边的直径，使每个样本对应一个星，这些星就落在这个半圆内。比如求 x_1 对应的星，先以圆心 O 为圆心， ω_1 为半径划一上半圆，在这半圆周上对应弧度为 ξ_{11} 的点记作 O_1 ，接着以 O_1 为心， ω_2 为半

径作一上半圆。在这半圆周上对应弧度为 ξ_{12} 的点记作 O_2 ；再以 O_2 为心， ω_3 为半径作一上半圆。取弧度为 ξ_{13} 的点，记为 O_3 ；…依次一直求到 O_p ，这最后的 O_p 就是 X_1 所对应的星的位置，记作 z_1 。由于 $\sum \omega_j = 1, \omega_j \geq 0$ ，星必然落在半圆内。由 O 点通过上述作图步骤，到达星的路线（即 $OO_1O_2\cdots O_p$ ）称做该星的路径，通过星的位置和路径就全面的刻划了该样本的特征。对其余样本作图是类似的，详见图 2·1。




图 2·1 星座图

通过作图来求路径和星的位置是不方便的，最好借助于计算来实现。不难看出 X_a 对应的 $O_1, O_2, \dots, O_{p-1}, O_p$ 的坐标为

$$\left(\sum_{j=1}^l \omega_j \cos \xi_{aj}, \sum_{j=1}^l \omega_j \sin \xi_{aj} \right), \quad l=1, 2, \dots, p,$$

决定了 O_1, O_2, \dots, O_p 的位置后，不难用计算机来打图。

现在我们仍用例 1 来说明星座图的应用。由表 1·2 算得 $\{\xi_{ij}\}$ 列于表 2·1，并取

$$\omega_1 = \omega_2 = \omega_3 = \omega_4 = \omega_5 = 1/5,$$

由此作成图 2 · 2，我们看到组成了三个星座。对应于三类岩体，似乎比雷达图表达得更为直观和醒目。

表 2 · 1 ξ_{ij} 值

	SiO_2	TiO_2	FeO	CaO	K_2O
X ₁	3 · 14	2 · 65	2 · 56	3 · 14	3 · 14
X ₂	3 · 09	3 · 14	3 · 14	2 · 42	2 · 78
X ₃	0 · 00	2 · 40	1 · 76	2 · 21	2 · 42
X ₄	0 · 17	2 · 40	1 · 41	2 · 80	2 · 70
X ₅	0 · 57	1 · 66	1 · 50	2 · 33	2 · 86
X ₆	1 · 15	0 · 00	0 · 70	0 · 00	0 · 48
X ₇	1 · 60	0 · 00	0 · 00	0 · 47	0 · 00




图 2 · 2

当各类分得很清楚（如图2·2）时，只需画星的位置不一定画相应的路径，使图更加清晰明了。但有时也会出现异途同归的情况。星的路径很不一样，而星的位置很接近，这时如在图中去掉路径，就会发生误解。为了能够去掉路径，最好适当调整 $\{\omega_i\}$ ，使得异途不能同归。

星座图最初是由 Wakimoto 和 Taguri^[3] 提出来的，并在医学、行为科学、保险公司、学校教育等方面取得不少应用。笔者在国内介绍后，已在地质、气象、考古等方面得到了应用。如下例是关于考古学的。

例2、为了研究人类的进化，测了现代男人和古代雄猿的下颌和牙齿的十七个部位，有关数据来自^[4]。作成星座图2·3（图中·表示一颗星），其中编号1—20的为人，21—38的为猿，人全落在半圆的右边，猿在左边，两类泾渭分明。




图2·3

三、脸谱图(face graph)

脸谱是一个非常形象的东西。脸谱的胖瘦、喜怒哀乐给人留下深刻的印象，京剧就在脸谱的设计上下了很大功夫。用脸谱来表达样本首先是由统计学家 Chernoff[1] 提出来的，他将样本的特性用人脸的某一部位的形状或大小来表达，一个样本用一个脸谱来表达。相似的样本，它们构成的脸谱也很相象。Chernoff 首先把脸谱图用于聚类分析之中。日本很快的引进了脸谱图，并用于多元分析的各种应用之中。

脸谱图各部分用 18 个变量 (x_1, x_2, \dots, x_{18}) 来构成。当变量数 $P < 18$ 时，可将脸中某几个部位固定。当 $P > 18$ 时，可以设法在脸中再添加一些部位。脸谱由六部分来构成：脸的轮廓、鼻、嘴、眼、眼珠和眉。现在分别来介绍每一部分的画法。

1、脸的轮廓：它由上下两个椭圆来构成。它们的短轴均在 Y 轴上，长轴平行于 X 轴。两椭圆交于 P 和 P' ，自然 P 和 P' 关于 Y 轴对称。 P 到原点 O 的位置由距离 $h^* = \overline{OP}$ 和 $O P$ 与 X 轴夹角 θ^* 来决定（图 3·1），其中

$$h^* = \frac{1}{2} (1+x_1) H, \quad \theta^* = (2x_2 - 1) \frac{\pi}{4},$$

H 为一常数。由作图者决定。 H 大，脸也大。脸的两个椭圆与 Y 轴分别交于 U 和 L ，且

$$h \triangleq \overline{OU} = \overline{OL}, \quad h = \frac{1}{2} (1+x_3) H$$

由上述条件还不能唯一确定脸的两个椭圆，进一步规定，脸

的上半部椭圆的离心率为 x_4 ，下半部椭圆的离心率为 x_5 。

我们知道，椭圆的标准方程为

$$\frac{x^2}{a^2} + \frac{y^2}{b^2} = 1,$$

a , b 分别为它的长轴和短轴。离心率 e 的定义是

$$e = \sqrt{a^2 - b^2} / a,$$

a , b , e 中只要知道了其中任两个就可决定另一个。利用离心率，椭圆的标准方程可以表示为

$$(1-e^2)x^2 + y^2 = b^2. \quad (2)$$

给了上述条件后如何来作脸的两个椭圆呢？现以下半椭圆来说明之。记下半椭圆的长轴，短轴分别为 a 和 b ，记 $d \cong h - b$ ， P 点的坐标为 (X^*, Y^*) ，显见

$$X^* = h^* \cos \theta^* \quad Y^* = h^* \sin \theta^*.$$

椭圆中心的坐标为 $(0, -d)$ ，故椭圆方程为

$$x^2(1-e^2) + (y+d)^2 = b^2 = (h-d)^2$$

它过 P 点，应有

$$X^{*2}(1-e^2) + (Y^* + d)^2 = (h-d)^2,$$

解得

$$d = \frac{(h^2 - Y^{*2}) - (1-e^2)X^{*2}}{2(Y^* + h)}$$

e 为离心率 ($= x_5$)，上式 h , Y^* , X^* , e 均为已知，故可求出

d. 从而便可得到脸下半部的椭圆方程。上半部的椭圆方程求法是类似的。




图3-1 脸谱图

2、鼻：以O为中心在Y轴上，上下各取长度 hx_6 画一条粗线。

3、嘴：在O点下方。 $h[x_9 + (1-x_9)x_6]$ 的位置，用半径为 $h/|x_8|$ 的圆弧来描述。规定： x_8 为正，圆弧向上； x_8 为负，圆弧向下。嘴的大小由 a_m 来决定。 $a_m = x_9(h/|x_8|)$ ，嘴的圆弧关于Y轴对称。如果嘴太大，越过脸的轮廓，这时用 x_9w_m 来代替，其中 w_m 为点 P_m 到脸轮廓的水平距离。

4、眼：用两个椭圆来表达。椭圆的中心为： (x_e, y_e) ， $(-x_e, y_e)$ ，其中规定

$$y_e = h[x_{10} + (1-x_{10})x_6], \quad x_e = w_e(1+2x_{11})/4,$$

其中 w_e 为点 $(0, y_e)$ 至脸轮廓的水平距离。两眼椭圆的长轴

与 X 轴的夹角分别为 θ 和 $\pi - \theta$ ，其中 $\theta = (2x_{12} - 1)\pi/5$ ，其长轴为 L_e ， $L_e = x_{14} \min(x_e, w_e - x_e)$ 。椭圆的离心率为 x_{13} 。

5、眼珠：从眼的椭圆中心，沿着椭圆的长轴至 $\pm r_e(2x_{15} - 1)$ 的位置，其中

$$r_e = (\cos^2 \theta + \sin^2 \theta / x_{13}^2)^{-1/2} L_e,$$

r_e 为眼的长轴在 X 轴上投影的长度。在作图时要注意务使眼珠为左右对称。

6、眉：从眼的椭圆中心向上至 y_b 的高度决定了眉的中心，其长度为 $2L_b$ ，它与水平的夹角为 θ^{**} ，其中

$$\theta^{**} = \theta + 2(x_{17} - 1)\pi/5, \quad y_b = 2(x_{16} + 0.3)L_e x_{13},$$

$$L_b = r_e(2x_{18} + 1)/2.$$

表3·1 脸谱图各变量的意义

变 量	描述脸的变量	交 换 公 式	数 值 范 围	备 注
x_1	h^*	$h^* = \frac{1}{2} (1+x_1) H$	0~1	O P之长度，且为脸的大小比例数
x_2	θ^*	$\theta^* = (2x_2 - 1)\pi/4$	0~1	X轴与O P的角度
x_3	h	$h = \frac{1}{2} (1+x_3) H$	0~1	O U = O L之长度
x_4			0~2~0~8	脸的上半椭圆离心率
x_5			0~2~0~8	脸的下半椭圆离心率
x_6			0~1~0~7	鼻的长度
x_7			0~1	嘴的位置
x_8			-5~5	嘴的曲率(半径= $h / x_8 $)
x_9	a_m	$a_m = x_9 (h / x_8)$ 或 $x_9 w_m$	0~1	嘴的大小
x_{10}	y_e	$y_e = h [x_{10} + (1 - x_{10}) x_6]$	0~1	眼的位置(纵坐标)
x_{11}	x_e	$x_e = w_e (1 + 2x_{11}) / 4$	0~1	眼的位置(横坐标)
x_{12}	θ	$\theta = (2x_{12} - 1) \pi / 5$	0~1	眼的倾斜角
x_{13}	x_{13}	$0~4~0~8$	0~4~0~8	眼的椭圆离心率
x_{14}	L_e	$0~1$	0~1	眼的长轴之长度
x_{15}			0~1	眼珠的位置
x_{16}	y_b	$y_b = 2 (x_{16} + \theta * 3) L_e x_{13}$	0~1	眼到眉的高度
x_{17}	θ^{**}	$\theta^{**} = \theta + 2 (1 - x_{17}) \pi / 5$	0~1	眉的倾斜角
x_{18}	L_b	$L_b = r_e (2x_{18} + 1) / 2$	0~1	眉的长度($z L_b$)