

高等医药院校教材

孙尚拱 编著

实用 多变量 统计方法 与计算程序



北京医科大学
中国协和医科大学

联合出版社

实用多变量统计方法 与 计算程序

孙尚拱 编著

北京医科大学
中国协和医科大学联合出版社

实用多变量统计方法与计算程序

编 著 孙尚拱

责任编辑 暴海燕

* * *

北 京 医 科 大 学 联合出版社出版
中国协和医科大学

(社址: 北京医科大学院内)

新华书店总店科技发行所发行 各地新华书店经销

北京密云华都印刷厂印刷

* * *

开本: 787×1092 1/16 印张: 21.125 字数: 498 千字
1990年12月第一版 1990年12月第一次印刷 印数: 1—4000册
ISBN 7-81034-037-9/R·38 定价: 4.20元

前 言

随着多变量统计在国际上的日益深入发展与普遍应用，国内的自然科学、社会科学及经济领域中的统计工作者也日益从多变量角度去收集和分析统计资料。本书是作者多年来从事多变量统计的应用、教学及科研的结果；它是为应用多变量统计方法的实际工作者，研究生及有关的高年级大学生中的非数理统计专业者而写。

本书的主要特点：

(1) 实用性。除第二章外，其它几乎所有公式都不给证明，强调模型、概念、方法及结果的解释。方法的选材，视其在实用上的重要性与普遍性；对有关方法及概念的介绍更多的是从实用角度而不是从数学出发。

(2) 把国内外很多的研究新成果，特别是国内（当然也包括作者本人）的成果反映在书内。作者希望能对来之不易的数据尽可能地分析得细致一些，信息提取得更多一些。因此很多旧有的标题，比如判别分析，典则相关分析等等，都充实进大量的新内容。

(3) 本书附有10个用`Fortran`语言编写的计算程序。这些程序中很多是作者所首创，其它则是在旧方法中或多或少充实进新内容的新编程序。

(4) 本书不是单纯的介绍统计方法，它也是多年解决实际问题及教学工作中的体会、看法与见解，也包含着其他同行们的很多经验在内。

学习本书应具备初步的统计学及简单的微积分知识，有关线性代数方面的基本知识见附录2。

魏宗舒先生曾对本书稿作过非常认真细致的审查并为本书的出版作了很多努力，特此致谢。

一些常用记号定义如下：

$E(y)$ 表示 y 的平均值（或称期望值），

$\text{var}(y)$ 表示 y 的方差，

$\text{Corr}(x, y)$ 表示 x 与 y 的相关系数，

$\exp(x) = e^x$

$\triangle$

$\triangleq$ 表示定义或“记为”

本书一定会有很多不妥之处，请批评指正。

孙尚拱

1988年12月于

北京

目 录

前言

第一章 回 归 分 析

§ 1.1	其本概念	(1)
§ 1.2	回归模型的统计检验与预报	(9)
§ 1.3	回归变量的相对重要性、统计检验与置信区间	(17)
§ 1.4	关于变量的选择及逐步回归	(22)
§ 1.5	回归系数符号反常与重要变量选不进的原因分析	(30)
§ 1.6	岭回归分析	(34)
§ 1.7	变量的变换	(38)
§ 1.8	其它一些多重回归分析	(43)

第二章 通 径 分 析

§ 2.1	通径分析的基本概念	(50)
§ 2.2	通径链上的基本公式	(52)
§ 2.3	通径分析在流行病遗传学研究中的应用	(61)

第三章 判 别 分 析

§ 3.1	两母体的 <i>Bayes</i> 线性判别法	(69)
§ 3.2	多母体 <i>Bayes</i> (贝叶斯) 线性判别	(77)
§ 3.3	<i>Fisher</i> (费歇) 线性判别法	(90)
§ 3.4	二次型判别法	(96)
§ 3.5	离散变量判别法	(100)

第四章 因子分析与主成分分析

§ 4.1	因子分析的模型及基本公式	(109)
§ 4.2	参数的估计	(111)
§ 4.3	负荷系数的正交旋转	(117)
§ 4.4	因子得分的估计	(120)
§ 4.5	变量间的主成分分析	(126)
§ 4.6	样品间的 <i>Q</i> 型分析法	(129)
§ 4.7	合成资料的主成分分析	(135)
§ 4.8	对应分析	(138)

第五章 聚 类 分 析

§ 5.1	基本概念	(144)
§ 5.2	系统聚类法	(147)
§ 5.3	系统聚类的分解法	(152)
§ 5.4	<i>k</i> -均值法 (动态聚类法)	(156)

§ 5.5	有序样品的最优分割法	(160)
第六章 其它一些重要的多变量统计分析法		
§ 6.1	匹配资料的条件 $Logistic$ 回归(判别)	(164)
§ 6.2	匹配资料的条件均数筛选变量法	(169)
§ 6.3	两组变量的相关分析—典则分析	(174)
§ 6.4	多变量生存分析	(183)
§ 6.5	生存分析中 Cox 回归模型	(188)
§ 6.6	不完全数据中估计参数的 EM 算法	(194)
附录1: 计算程序		
1.	前进法选变量的回归分析(有非正态性调整)	(202)
2.	岭回归分析	(211)
3.	$Fisher$ 线性判别分析	(225)
4.	刀切法估计 $Bayes$ 线性判别法的错分情况	(244)
5.	二次型判别的刀切法	(254)
6.	R 型因子分析	(266)
7.	对应分析	(278)
8.	有序样本的最优分割法	(286)
9.	匹配资料选变量的 $Logistic$ 回归分析	(292)
10.	匹配资料选变量的条件均数法	(303)
附录2: 线性代数基本知识		(315)
参考文献		(330)

第一章 回归分析 (Regression Analysis)

§1.1 基本概念

自然现象及社会活动中, 变量之间不一定都存在有确定性的函数关系。但往往存在有一定的统计相关性。回归分析就是运用数学手段, 在大量统计资料中找出这种相关性, 并作定量分析。

回归分析中总有两类变量; 一类是因变量, 也称准则变量或反应变量; 一类是自变量, 也称回归变量、预测变量、独立变量或设计变量 (当后者可以人为控制时)。当因变量只有一个 (记为 y), 而自变量有多个时 (记 $x_1, x_2, \dots, x_m$), 则 y 与 $(x_1, x_2, \dots, x_m)$ 之间的回归, 称之为多重回归。如因变量也有多个时, 记为 $y_1, y_2, \dots, y_q$, 则 $(y_1, y_2, \dots, y_q)$ 与

表 1.1.1

镇序	Z_1 外来人口 (人)	Z_2 常住人口 (人)	W 工农业总产值 (万元)
1.	28070	42208	4464.34
2.	7382	11479	929.89
3.	4320	23961	4338.00
4.	4161	15655	2687.25
5.	16435	17408	1860.21
6.	12381	7356	886.75
7.	12996	10052	1313.86
8.	11024	15806	2153.95
9.	19040	9739	3553.81
10.	33767	12175	6721.16
11.	20879	10217	3648.39
12.	29669	23718	3461.89
13.	10687	8148	2428.72
14.	8419	8373	1388.73
15.	4199	8148	300.42
16.	2903	6595	527.83
17.	908	6286	113.99
18.	4169	5580	245.73

$(x_1, x_2, \dots, x_m)$ 之间的回归关系, 称之为多元 (或多变量) 回归, 但这种多个因变量的回归问题也常化为多个多重回归法处理。一般习惯上也把多重回归称为多元回归。

例1.1.1, 近几年来由于开放政策, 深圳经济特区中, 外来人口大幅度增加, 为了考察特区中外来人口对本地经济发展的贡献, 深圳特区的统计局收集宝安在1987年末所属的18个镇的人口与工农业产值数据, 见表1.1.1。

一般说来, 人口的多少对经济的发展是有影响的。在此例中要考察人口对经济的影响, 则把表1.1.1中工农业总产值当作因变量(W), 外地及本地人口看作两个自变量(Z_1, Z_2)。

回归分析主要解决下面几个问题。

1. 确定因变量, (上例中工农业总产值) 与各个自变量, (本地人口与外地人口数量) 之间是否存在有相关关系。如有, 指出相关性有多大, 比如例1.1.1中工农业总产值(W)的变动信息中, 有多大的一部分是被外地人口(Z_1)及本地人口(Z_2)的变动所决定的? 进一步应找出它们之间相互关系的定量表示式。指出如何用自变量(Z_1, Z_2)去预测因变量(W)的变化及给出预报精度。

2. 找出每个自变量对因变量作用的大小及方向性。它与一般单变量统计分析不同点是: 考察 Z_1 (外地人口) 对因变量 W (工农业总产值) 的影响大小时是把其它所有自变量

(表1·1·1中仅 Z_2)都固定不变时,考察 Z_1 对 W 的作用大小,这种考察法是与单元统计分析中考察 Z_1 与 W 关系时,把 Z_2 当作似乎不存在一样(即 Z_2 可以自由变动)的考察法是根本不同的。因此,当一个多变量问题,如把它们简单地拆成多个“单变量统计”法去考察,其结果也常与多变量统计分析的结果不一致。一般说来,当多个自变量之间存在有相关性时,把本质上是多变量相关问题拆成多个单变量去处理是不合理的。

3. 对于前述问题的结论(比如 W 与 (Z_1, Z_2) 的相关性)可以给出概率值。即可以求出有多大的把握说 (Z_1, Z_2) 影响 W ,如用 (Z_1, Z_2) 预报 W ,有多大把握说 W 的理论值在给定的范围中?对于第3个问题的解答,往往对资料有一定的要求,比如正态分布,样本之间彼此独立同分布等等。

在实际问题中,实际工作者不一定对上述三个问题都有兴趣,比如在因素分析中,往往对问题1不感兴趣。还应指出,对于本质上是多变量相关的数据,用多变量统计分析,在理论上虽然比单变量统计法科学及合理,但这并不是说,该批数据经任一种多变量分析法后,其结果就都是“正确”或“合理”的。实际情形及大量实例表明,情况远非如此,多变量统计分析中结果的不合实际情形到处可见。产生错误结果的原因是多方面的。因此,实际工作者千万不要以为经过“多变量统计分析”后,其结果就一定是正确的。客观实际的检验及专业知识仍是最根本的标准。以后我们将详细讨论。

一、指标数量化

回归分析是寻找以数量表示的自变量与因变量间的统计规律。因此,一切变量(实际工作中常称为指标、因素等)都必须给以数量化。比如表1·1·1中每个变量本身就已经是数量了,不存在数量化问题。但其它实际问题中情况并未都如此。比如寻找人的血压与性别的关系,男性与女性就不是数量指标,因此必须给以数量。最简单也是最常用的数量化方法是0—1法。具体做法如下:

如 x_1 表示性别, x_2 表示“病人”与“非病人”,则可令

$$x_1 = \begin{cases} 1 & \text{男性} \\ 0 & \text{女性} \end{cases}, \quad x_2 = \begin{cases} 1 & \text{病人} \\ 0 & \text{非病人} \end{cases},$$

如果某个指标比如文化程度,本来分成四级:“文盲,小学,中学,大学及大学以上”,则可以把这个指标用4个自变量或3个自变量表示它。比如想用4个自变量表示上述的文化程度,则可令:

$$\begin{aligned} x_1 &= \begin{cases} 1 & \text{文盲} \\ 0 & \text{其它(指非文盲者)} \end{cases}, & x_2 &= \begin{cases} 1 & \text{小学} \\ 0 & \text{其它} \end{cases}, & x_3 &= \begin{cases} 1 & \text{中学} \\ 0 & \text{其它} \end{cases}, \\ x_4 &= \begin{cases} 1 & \text{大学及大学以上} \\ 0 & \text{其它} \end{cases} \end{aligned} \quad (1 \cdot 1 \cdot 1)$$

这样在数据登记时,原来的文化程度只占用一列(或一行),而用回归分析处理时,该指标就必须变成4列(或4行),即用4个自变量代表文化程度。这种数量化法的优点是:把文化程度考察得很细致。比如考察文化程度 $(x_1, \dots, x_4)$ 与血压 (y) 的关系时,上法可以把每个级别的文化程度与血压的关系找出来。但文化程度的上述数量化方法有两个缺点:

(1) 上述 $(1 \cdot 1 \cdot 1)$ 表示法不能用于做后面要叙述的后退法线性回归分析,因为该法要求自变量之间不能有完全的线性相关情形,而 $(1 \cdot 1 \cdot 1)$ 表示法中显然有 $x_1 + x_2 + x_3 + x_4 = 1$,即其中一个文化等级可以用另外3个文化等级推算出来,比如 $x_1 = 1 - (x_2 + x_3 + x_4)$ 。因此,

我们可以只用3个自变量（比如 x_2, x_3, x_4 ）就可以表示上述的文化程度。这时数据登记中，文化程度所在的列（或行）即变成3列（或3行）。被取消了的等级 x_1 的作用如何估计？可以用下述方法估计：比如记 z 为另外的非文化程度的自变量，如果我们计算所得的回归方程（记 $\hat{y}$ 为 y 的估计值）为：

$$\hat{y} = a + b_2x_2 + b_3x_3 + b_4x_4 + cz$$

这时 $a + b_2$ 就是 x_2 （小学）对于 y 的作用大小；而常数 a 就是 x_1 （文盲）对于 y 的作用大小。所以四个文化程度等级（ $x_1, \dots, x_4$ ）对于 y 的作用大小就是（ $a, a + b_2, a + b_3, a + b_4$ ），相互比较此四个数及符号，就可以得出4个文化程度级别对于 y 作用的大小及方向（方向性视符号而定）。

（2）在某些实际问题中，并不关心每一个文化程度等级对于 y 的作用大小。而只想用一个自变量 x （而不是用3个或4个自变量）去表示文化程度。这时如用（1·1·1）式就不合要求（计算量也大了些），对于这种要求我们就可以用有序四个数值（比如，0, 1, 2, 3）去表示上述四个级别的文化程度：“0”表示文盲“1”表示小学等等。这种表示法的最大优点是计算简单，缺点是解的不定性。因为我们没有理由不可以应用（10, 12, 18, 30,）的4个数去表示4个级别的文化程度，但该结果与用（0, 1, 2, 3）法结果就不大会相同。而在0—1法中，“0, 1”的两个数是可以随便的。比如性别例子中如令

$$x_1 = \begin{cases} 10 & \text{男性} \\ 5 & \text{女性} \end{cases}$$

与用（1, 0）表示男或女，可以证明是等价的。正因为如此，在数量化方法中，0—1法是使用得最多也是最方便的方法。

二、回归模型

记 $\mathbf{x} = (x_1, x_2, \dots, x_m)'$ ，为 m 个自变量组成的自变量向量， y 为因变量。如我们要找一个函数 $f(\mathbf{x}) = f(x_1, x_2, \dots, x_m)$ 以使 $f(\mathbf{x})$ 与 y 的误差的平方在平均意义下为最小，数学记号为：

$$E(f(\mathbf{x}) - y)^2 = \min \quad (1.1.2)$$

则可以证明这个 $f(\mathbf{x})$ 必是 y 的条件均值 $E(y/\mathbf{x})$ ，即如果我们求出 x 值下 y 的均值 $E(y/\mathbf{x})$ ，则这 $E(y/\mathbf{x})$ 就是（1·1·2）最小二乘方意义下的理想回归函数 $f(\mathbf{x})$ 。但实际上我们往往不知道 $E(y/\mathbf{x})$ ，比如在例1·1·1中，对给定的每一组数据（ Z_1, Z_2 ）值后，工农业生产总值 W 的均值是什么？不知道。一般只能利用专业知识或采用多项式逼近法求它。而在例1·1·1中我们可以利用经济学中有名的柯布—道格拉斯生产函数去取代条件均值，即我们采用下面的数学模型

$$\hat{W} = K \cdot Z_1^{b_1} \cdot Z_2^{b_2} \quad (1.1.3)$$

拟合表1·1·1的数据，其中 K 为比例常数，它包含未控制的因素。 W 表示用 W 中可用（ Z_1, Z_2 ）估计出来的部分。如令

$$y = \ln(W), \quad x_1 = \ln(Z_1), \quad x_2 = \ln(Z_2),$$

则（1·1·3）等价于

$$\hat{y} = b_0 + b_1x_1 + b_2x_2 \quad (1.1.4)$$

其中 b_0 是（1·1·3）中比例常数引出的结果， $\hat{y} = \ln(\hat{W})$ 是 $\ln(W)$ 的估计值， b 是要用样本估计的参数。可见（1·1·3）模型虽然不是一个线性函数，但它可以变成一个线性模型。由

于线性模型统计上处理起来方便,且已有一套相当成熟的理论,所以实际工作中遇到的一般性模型,总是想方设法把它变成线性模型。因此,一般计算机软件中的回归模型也几乎都是线性模型。

下面介绍一般性的线性回归模型。

假设有 m 个自变量 $(x_1, x_2, \dots, x_m)$,它与因变量 y 存在有如下的线性关系:

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_m x_m + \varepsilon \quad (1.1.5)$$

其中 $\beta_0 + \beta_1 x_1 + \dots + \beta_m x_m$ 称为 y 的线性回归部分。 ε 表示 y 与线性回归部分间的误差,一般称残差。 $(1.1.5)$ 是 y 与 $(x_1, x_2, \dots, x_m)'$ 间的数学模型,其中 $(\beta_1, \beta_2, \dots, \beta_m)' = \beta$ 为理论回归系数向量, β_0 为常数项,它们都称为模型中的参数,是需要用样本去估计的。

下面考察 $(1.1.5)$ 中参数的意义及所选模型正确性的简单分析法。

由 $(1.1.5)$ 可见,当固定其它变量时, x_1 增加一个单位 y 的增加值为 b_1 ; $b_2, \dots, b_m$ 的意义类似。因此称 b_i 为 x_i 的偏回归系数。 b_i 实际上就是 y 关于 x_i 的偏导数,也称 b_i 是 y 在 x_i 上的变化率。由 $(1.1.5)$ 可见,当仅允许 x_1 变化而其它 $(x_2, \dots, x_m)$ 变量都固定不变时,则 x_1 与 y 呈直线关系。因此,如果由专业知识及由样本中看出, x_1 与 y 不成直线关系,这时用 $(1.1.5)$ 模型去代表样本就不合适了。

另外从模型 $(1.1.5)$ 还可以分析出, y 在 x_1 上的变化率 b_1 是与自变量 x_2 (及其它自变量)无关的。即 x_2 及其它自变量无论取什么数值,都不会影响 y 在 x_1 上的变化率。比如在细菌繁殖问题中,如记 y 为一定容器中细菌总量。 x_1, x_2 分别表示容器中的温度及营养物数量。采用 $(1.1.5)$ 模型就意味着,营养物质 x_2 不管是多或少,容器的温度不论是多少度,则容器内温度每升高一度时,细菌的总数永远是增加 b_1 个。由于细菌繁殖总有一个适宜温度,在不适合很好繁殖的温度与在适宜温度时,每增加一度, y 的增加值一般不会相同的。因此,对这样的细菌繁殖问题,如简单的采用 $(1.1.5)$ 模型是不合理的。

当使用很不合理的数学模型时很难想象回归分析最后的结果能正确地反映客观实际。而在实际工作者中间,滥用回归分析的情形相当普遍:找来一个回归分析软件包,对自己的数据也不加任何分析就套用任一个软件,对计算出来的结果,盲目的加以相信,有时该结果是明显地反常,也牵强附会地去作解释,这都是不应该的。可是对一批数量不很大的数据,若没有相当的专业知识,要正确地确定模型也确非易事。常用的两个简单方法是:

(1)法,把样本中每个自变量单独抽出来与因变量 y 作图。从图上大体看看,如每个自变量与因变量基本成直线,则采用 $(1.1.5)$ 或许是好的。比如对例 $(1.1.1)$,把 $x_1 = \ln Z_1$ 与 $y = \ln W$ 作图, $x_2 = \ln Z_2$ 与 $\ln y$ 作图,可得图 $(1.1.1)$ 。从图 $1.1.1$ 的(a)及(b)可见,两图基本上还是直线形状,因此采用模型 $(1.1.3)$ 还是可以的。(2)法,是先不对 (x_1, x_2, y) 作任何变换,做一次线性回归,再对某些变量(特别是经统计检验不显著的变量)作人为地变换(见后面§1.7),再看看衡量线性回归的指标是否有改善,以决定该批数据应取什么样的模型。

三、参数的估计

$(1.1.5)$ 中的模型为理论模型,参数 $\beta_0, \beta_1, \dots, \beta_m$ 为理论值。要把理论值准确地找出来是不大可能的,一般都是抽取一批数据(样本)去估计 $\beta_0, \beta_1, \dots, \beta_m$ 。记参数的样本估计值为 $b_0, b_1, \dots, b_m$ 。一般记 $b = (b_1, b_2, \dots, b_m)'$ 为参数向量, b_0 为常数项,有的统计书中也把 b_0 作为 b 向量的一个分量。记




图1.1.1 表1.1.1的数据

$$\hat{y} = b_0 + b_1 x_1 + \cdots + b_m x_m \quad (1.1.6)$$

$\hat{y}$ 称为(1.1.5)中 y 的估计值,也称回归部分。

设对 $(x_1, x_2, \cdots, x_m, y)$ 抽取几组样本,记第 i 组样本值为 $(x_{i1}, x_{i2}, \cdots, x_{im}, y_i)$, $i = 1, 2, \cdots, n$.

记

$$X = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \cdots & \cdots & \cdots & \cdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{pmatrix}, \quad Y = \begin{pmatrix} y_1 \\ y_2 \\ \cdots \\ y_n \end{pmatrix}$$

则 X, Y 表示全部数据构成的数据矩阵(简称数据阵)。记 $\bar{x}_j, \bar{y}$ 为 x_j 及 y 的样本均数,其计算公式为:

$$\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{ij}, \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i, \quad \bar{x} = (\bar{x}_1, \bar{x}_2, \cdots, \bar{x}_m)'$$

$\bar{x}$ 为 $(x_1, x_2, \cdots, x_m)'$ 的均数向量。求(1.1.6)中参数值的准则一般是用最小二乘方准则:它求参数值以使下式为最小

$$Q = \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad \hat{y}_i = b_0 + b_1 x_{i1} + \cdots + b_m x_{im} \quad (1.1.7)$$

对于不同的 $b_0, b_1, \cdots, b_m$ 值,(1.1.7)中可求出不同的 Q 值,能使 Q 达到最小值的参数值,称之为参数 $\beta_0, \beta_1, \cdots, \beta_m$ 的最小二乘方估计值。

记:

$$l_{ij} = \sum_{t=1}^n (x_{ti} - \bar{x}_i)^2 = \sum_{t=1}^n x_{ti} x_{tj} - n \bar{x}_i \bar{x}_j, \quad i, j = 1, 2, \cdots, m$$

$$l_{iy} = \sum_{t=1}^n (x_{ti} - \bar{x}_i)(y_t - \bar{y}) = \sum_{t=1}^n (x_{ti} - \bar{x}_i) y_t = \sum_{t=1}^n x_{ti} y_t - n \bar{x}_i \bar{y}$$

$$l_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n y_i^2 - n\bar{y}^2, \quad s_y = \sqrt{\frac{l_{yy}}{n-1}}, \quad s_i = \sqrt{\frac{l_{ii}}{n-1}} \quad (1.1.8)$$

$$L_{xx} = \begin{pmatrix} l_{11} & l_{12} & \cdots & l_{1m} \\ l_{21} & l_{22} & \cdots & l_{2m} \\ \cdots & \cdots & \cdots & \cdots \\ l_{m1} & l_{m2} & \cdots & l_{mm} \end{pmatrix}, \quad l_{xy} = \begin{pmatrix} l_{1y} \\ l_{2y} \\ \vdots \\ l_{my} \end{pmatrix}, \quad b = \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_m \end{pmatrix} \quad (1.1.9)$$

L_{xx} 称为 $(x_1, x_2, \dots, x_m)$ 的离差阵, l_{xy} 为 x 向量与 y 的离差乘积阵。 s_y 称为 y 的标准差, s_i 为 x_i 的标准差。利用样本, 可以求出 $\{l_{ij}\}$, $\{l_{iy}\}$ 及 s_y , s_i 。用数学方法中的极值方法, 可以证明使(1.1.7)达最小值的 b_i 满足下面线性方程组:

$$\begin{cases} l_{11}b_1 + l_{12}b_2 + \cdots + l_{1m}b_m = l_{1y} \\ l_{21}b_1 + l_{22}b_2 + \cdots + l_{2m}b_m = l_{2y} \\ \cdots \quad \quad \quad \cdots \\ l_{m1}b_1 + l_{m2}b_2 + \cdots + l_{mm}b_m = l_{my} \end{cases} \quad (1.1.10)$$

求(1.1.10)线性方程组的解, 即可得 b 向量, 如用矩阵表示, 则为

$$b = L_{xx}^{-1} \cdot l_{xy}, \quad b_0 = \bar{y} - b_1\bar{x}_1 - \cdots - b_m\bar{x}_m \quad (1.1.11)$$

求出 b , b_0 后代回(1.1.7), 可得出使(1.1.7)中 Q 的最小值为

$$Q = l_{yy} - b' l_{xy} = l_{yy} - b' Lb \quad (1.1.12)$$

Q 称为回归方程(1.1.6)的残差平方和或失拟平方和。记

$$s = \sqrt{\frac{Q}{n-m-1}} \quad (1.1.13)$$

把 b 向量及 b_0 代回(1.1.6), 即得出每一个样本点上对 y_i 的估计值 $\hat{y}_i$, 而 s 就描述了用 $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n$ 估计 $y_1, y_2, \dots, y_n$ 的一个平均性精确度指标, s 称之为残差标准差, 有的书也称之为回归标准误。

对表1.1.1数据, 对每一个数据取对数后, 可算得($n=18, m=2$);

$$\bar{X} = \begin{pmatrix} 9.1149 \\ 9.3556 \end{pmatrix}, \quad L = \begin{pmatrix} 15.2955 & 4.3345 \\ 4.3345 & 4.9190 \end{pmatrix}, \quad l_{xy} = \begin{pmatrix} 14.2705 \\ 7.1380 \end{pmatrix}, \quad l_{yy} = 21.6610, \quad (1.1.14)$$

于是得

$$L^{-1} = \begin{pmatrix} 0.08714 & -0.07678 \\ -0.07678 & 0.27095 \end{pmatrix}, \quad b = \begin{pmatrix} 0.6954 \\ 0.8383 \end{pmatrix}, \quad b_0 = -6.8890$$

于是得 y 的回归方程为

$$\hat{y} = -6.8890 + 0.6954x_1 + 0.8383x_2 \quad (1.1.15)$$

其回归标准误 $s = 0.6193$

下面我们介绍回归系数公式的另外两种经常遇见的表示法:

(1) 数据中心化的表示法

记 $(\bar{x}_1, \bar{x}_2, \dots, \bar{x}_m, \bar{y})$ 为 $(x_1, x_2, \dots, x_m, y)$ 的样本均数, 用 $x_{ii} - \bar{x}_i$ 代替 x_{ii} , 用 $y_i - \bar{y}$ 代替 y_i , 这样改造后的数据称为中心化了的样本数据, 显然, 中心化的数据, 每个变量的样本均数为零。记 X 为中心化了的数据阵, Y 为因变量中心化了的数据向量。即:

$$X = \begin{pmatrix} x_{11} - \bar{x}_1, & x_{12} - \bar{x}_2, & \dots, & x_{1m} - \bar{x}_m \\ x_{21} - \bar{x}_1, & x_{22} - \bar{x}_2, & \dots, & x_{2m} - \bar{x}_m \\ \dots & & & \dots \\ x_{n1} - \bar{x}_1, & x_{n2} - \bar{x}_2, & \dots, & x_{nm} - \bar{x}_m \end{pmatrix}, \quad Y = \begin{pmatrix} y_1 - \bar{y} \\ y_2 - \bar{y} \\ \dots \\ y_n - \bar{y} \end{pmatrix}$$

这时 (1.1.9) 中 L_{xx} , L_{xy} , b 即为:

$$L_{xx} = X'X, \quad L_{xy} = X'Y, \quad b = (X'X)^{-1}X'Y \quad (1.1.16)$$

常数项 b_0 仍用 (1.1.11) 中 b_0 公式。这时 Y 的拟合值向量, 记为 $\hat{Y}$, 即为:

$$\hat{Y} = Xb = X(X'X)^{-1}X'Y = HY \quad (1.1.17)$$

其中,

$$H = X(X'X)^{-1}X' \quad (1.1.18)$$

(2) 同时计算常数项的表示法

把常数项当作永远取值为1的自变量, 于是数据阵 (不要求中心化) X 为:

$$X = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1m} \\ 1 & x_{21} & x_{22} & \dots & x_{2m} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nm} \end{pmatrix} \quad (1.1.19)$$

Y 是 $(y_1, y_2, \dots, y_n)'$ 。这时回归系数公式为

$b = (b_0, b_1, \dots, b_m)'$, 则

$$b = (X'X)^{-1}X'Y, \quad \hat{Y} = HY \quad (1.1.20)$$

H 仍如 (1.1.17), 定义, 但 X 用 (1.1.19) 式, Y 未中心化。

四、决定系数, 复相关系数

不管用何种方法表示回归系数, 回归系数及下面一切有关量的数值不会改变。

下面我们考虑描述回归方程好坏的两个基本指标, 我们称

$$U = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad (1.1.21)$$

为回归平方和。可以证明有等式

$$U = \sum_{i=1}^m l_{iy} b_i = L_{xy}' b \quad (1.1.22)$$

而且:

$$l_{yy} = U + Q \quad (1.1.23)$$

此式称之为离差平方和的分解公式。其中 Q 为残差平方和。显然, 一个拟合得好的模型应使 Q 最小, 也即 U 应最大 (l_{yy} 是被数据决定了的不变数), 但 U 及 Q 均受量纲的影响, 为了不受单位量纲的影响, 我们称

$$D = U/l_{yy} \quad (1.1.24)$$

为回归方程 (1.1.6) 的决定系数, 它表示在 y 的变动总信息 (用 l_{yy} 表示) 中, 可以被回归方程拟合的百分比。如例 1.1.1 中, 可算得:

$$U = 14.2705 \times 0.6954 + 7.1380 \times 0.8383 = 15.9075$$

$$\therefore D = U/l_{yy} = \frac{15.9075}{21.6610} = 0.7344 = 73.44\%$$

也就是说, 在 y 的离差平方和中73.44%的变异可由(1·1·6)表示。显然如决定系数的值愈近似于1愈说明模型对资料的拟合能力愈好。除非随机干扰很少, 一般说来决定系数73.44%是很高的了。反映模型对资料拟合程度的另一个指标为复相关系数 ρ 。 ρ 的严格定义是 y 与它的估计量 $\hat{y}$ 之间的相关系数, 此数可以证明永远是非负数。若用样本估计 ρ (记为 R), 则 R 用下式计算:

$$R = \left(\frac{U}{l_{yy}} \right)^{1/2} = D^{1/2} \quad (1.1.25)$$

例1·1·1中 $R = 0.8570$, 显然 R 愈接近于1则说明模型拟合程度愈好。永远有 $0 \leq R \leq 1$, 由统计理论可以证明用(1·1·25)计算的样本复相关系数并不是理论 ρ 值的无偏性估计, 而且总是过高地估计了 ρ 。因此一些近似的无偏性估计被发展起来, 一个常用公式, 称之为修正公式:

$$R_c^2 = R^2 - \frac{(m-1)(1-R^2)}{n-m} \quad (1.1.26)$$

在例1·1·1中, 有 $R_c^2 = 0.8570^2 - \frac{(1-0.8570^2)}{18-2} = 0.71785$ 所以近似无偏的复相关系数 ρ 的估计值为

$$R_c = 0.8473$$

附带说明一下, 使残差平方和 Q 为最小的参数解 b 及 b_0 。也就是使决定系数 D 为最大的参数解。

五、标准化回归系数

建立在(1·1·9)及由(1·1·11)确定的回归系数是有量纲的, 不同变量由于所使用的单位不同而使得它们的回归系数无法进行比较。为了克服这一缺点, 引进标准化回归系数的概念。称下面的数据为标准化数据:

$$\begin{aligned} \bar{x}_{ii} &= (x_{ii} - \bar{x}_i) / s_i, \quad \text{其中 } s_i = \sqrt{l_{ii} / (n-1)} \\ \bar{y}_i &= (y_i - \bar{y}) / s_y, \quad \text{其中 } s_y = \sqrt{l_{yy} / (n-1)} \end{aligned} \quad (1.1.27)$$

$i = 1, 2, \dots, n \quad i = 1, 2, m$

其中 s_i 为 x_i 的样本标准差, s_y 为 y 的样本标准差。经(1·1·27)处理后的数据, 可以发现, 每一个变量的样本均数为0, 样本标准差为1。称下面的量

$$r_{ij} = \frac{l_{ij}}{\sqrt{l_{ii}} \sqrt{l_{jj}}} \quad r_{iy} = \frac{l_{iy}}{\sqrt{l_{ii}} \sqrt{l_{yy}}} \quad i, j = 1, 2, \dots, m \quad (1.1.28)$$

为 x_i 与 x_j 的样本相关系数及 x_i 与 y 的样本相关系数。称

$$R_{xx} = \begin{pmatrix} r_{11} & r_{12} & \dots & r_{1m} \\ r_{21} & r_{22} & \dots & r_{2m} \\ \dots & & & \dots \\ r_{m1} & r_{m2} & \dots & r_{mm} \end{pmatrix}, \quad r_y = \begin{pmatrix} r_{1y} \\ r_{2y} \\ \vdots \\ r_{my} \end{pmatrix} \quad (1.1.29)$$

为 x 的样本相关阵及 x 与 y 的样本相关系数向量。在公式(1·1·9)中如用 $\bar{x}_{ii}$ 代替 x_{ii} , 且改

记 l_{ij} 为 $\bar{l}_{ij}$, l_{iy} 为 $\bar{l}_{iy}$, 则可以发现有

$$\bar{l}_{ij} = r_{ij}(n-1), \quad \bar{l}_{iy} = r_{iy}(n-1)$$

把 $\bar{l}_{ij}$ 及 $\bar{l}_{iy}$ 代入 (1.1.11) 中 b 公式 (改记为 $\tilde{b}$) 显然有

$$\tilde{b} = R_{xx}^{-1} \cdot r_y \quad (1.1.30)$$

这里的回归系数 $\tilde{b} = (\tilde{b}_1, \tilde{b}_2, \dots, \tilde{b}_m)'$ 显然是没有量纲的, 它称之为回归方程的标准化回归系数。可以找出标准化回归系数 $\tilde{b} = (\tilde{b}_1, \tilde{b}_2, \dots, \tilde{b}_m)$ 与一般回归系数 $b = (b_1, b_2, \dots, b_m)'$ 之间的关系式:

$$b_k = \frac{s_y}{s_k} \tilde{b}_k, \quad \tilde{b}_k = \frac{s_k}{s_y} b_k, \quad k = 1, 2, \dots, m \quad (1.1.31)$$

由于例1.1.1中已算得 $b_1 = 0.6954$, $b_2 = 0.8383$, 利用 $s_1 = (15.2955/(18-1))^{1/2} = 0.9485$, $s_2 = 0.5379$, $s_y = 1.1288$, 代入 (1.1.31) 得 $\tilde{b}_1 = 0.5844$, $\tilde{b}_2 = 0.3995$ 。比较可见, 似乎可以认为“外来人口” x_1 的变化比“本地人口” x_2 的变化对于宝安县的工农业总产值的变化有更大的影响。但在本例中对 $(\tilde{b}_1, \tilde{b}_2)$ 的解释似乎与对 (b_1, b_2) 的解释不一致。由于此例恰可以比较 b_1, b_2 的大小, 其结论是: 本地人口 x_2 每增加一个人时工农业总产值的增加比外地人口 x_1 每增加一个人时的产值为大。但在比较 $(\tilde{b}_1, \tilde{b}_2)$ 时结论似乎相反, 这个相反的结论来源于 x_1 与 x_2 有不同的标准差: $s_1 = 0.9485$ 比 $s_2 = 0.5379$ 大很多。由于 $\{\bar{x}_{it}\}$ 数据中每增加一个单位即是增加一个标准差, 所以比较 $\tilde{b}_1, \tilde{b}_2$, 严格地讲是: 当 x_1, x_2 都增加一个标准差时, 由 x_1 引起的工农业总产值的增加比由 x_2 引起的总产值的增加要大。所以, 这种比较法不同于“每增加一个人”时 b_1 与 b_2 的比较法。显然, 如果 x_1 与 x_2 有相同的量纲, 则比较标准化回归系数是不合适的; 而 x_1 与 x_2 在绝大多数情形下是有不同的量纲。因此在无法直接比较 b_1 与 b_2 时, 只好采用标准化数据法。

下面来看看例1.1.1中回归方程 (1.1.15) 的现实意义: 把 $y = \ln \hat{W}$, $x_i = \ln Z_i$ 代入 (1.1.15), 取微分, 得

$$\frac{d\hat{W}}{\hat{W}} = 0.6954 \frac{dZ_1}{Z_1} + 0.8383 \frac{dZ_2}{Z_2} \quad (1.1.32)$$

这里 dZ_1/Z_1 与 dZ_2/Z_2 都是没有量纲的。他们与 dW/W 一样都是增加量的相对数。比如, 外来人口 (Z_1) 及本地人口 (Z_2) 都增加一倍, 则工农业总产值将增加 $(0.6954 + 0.8383) = 1.5337$ 倍。而其中外地人口的贡献占 $0.6954/1.5337 = 45.3\%$ 本地人口的贡献占 54.7% 。所以 (1.1.32) 公式可用于去估计人口变动时工农业总产值增加的百分数。

§ 1.2 回归模型的统计检验与预报

前一节中所述的回归方程及有关公式都未涉及统计检验, 因此对因变量 y 的分布没有具体要求。在本节中, 我们假定 m 个自变量 $x_1, x_2, \dots, x_m$, 是非随机性的变量。如果它们是随机变量, 我们就规定它们是属于已给定具体值的量, 因此可以被当作非随机性变量处理。由于实际工作中往往用 $(x_1, x_2, \dots, x_m)$ 值去预报 y 值, 所以, 因变量总是随机变量, 即具有不确定性。假定模型的理论公式为

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_m x_m + \varepsilon \quad (1.2.1)$$

$\beta_0, \beta_1, \dots, \beta_m$ 为理论系数, 它们在最小二乘法准则下的样本估计为 § 1.1 的 $b_0, b_1, \dots, b_m$, 上

式中 e 为理论残差,我们在本节中假定

$$e \sim N(0, \sigma^2) \quad (1.2.2)$$

其中 $N(0, \sigma^2)$,表示正态分布,其理论均值为0,方差为 σ^2 。以后将指出,(1.2.2)的正态性条件是可以大大放松,甚至可以取消的。在回归分析理论中可以证明,在(1.2.2)条件下,几个基本的理论结果为:

(1) 残差平方和 Q 与回归系数向量 b 是独立的,且

$$E(Q) = (n - m - 1)\sigma^2 \quad (1.2.3)$$

(2) 回归系数向量 b 及 b_0 为正态分布:记 $b = (b_1, b_2, \dots, b_m)'$, 则

$$b \sim N_m(\beta, \sigma^2 L_{xx}^{-1}) \quad (1.2.4)$$

具体:

$$E(b_i) = \beta_i, \text{var}(b_i) = \sigma^2 l^{(i,i)}, \text{cov}(b_i, b_j) = \sigma^2 l^{(i,j)}$$

$$E(b_0) = \beta_0, \text{var}(b_0) = \sigma^2 \left(\frac{1}{n} + \bar{x}' L_{xx}^{-1} \bar{x} \right) \quad (1.2.5)$$

其中记 $L_{xx}^{-1} = (l^{(i,j)})$ 。

下面介绍基本的假设检验:

一、回归模型中对线性假定的检验

如果 y 与 $(x_1, x_2, \dots, x_m)$ 没有线性关系,此话用数学表示法为:

$$H_0: \beta_1 = \beta_2 = \dots = \beta_m = 0 \quad (1.2.6)$$

在 H_0 假定下,可以证明下面的统计量为 F 统计量

$$F(m, n - m - 1) = \frac{n - m - 1}{m} \cdot \frac{U}{Q} \quad (1.2.7)$$

其中 F 统计量的第一自由度为 m ,第二自由度为 $n - m - 1$, (1.2.7)也可写成

$$F(m, n - m - 1) = \frac{n - m - 1}{m} \cdot \frac{R^2}{1 - R^2} \quad (1.2.8)$$

如果上述 F 值大于显著性水平 α (一般为0.10, 0.05, 0.01)下的临界值 F_{α} ,则应否定 H_0 ,即认为 y 与 $(x_1, x_2, \dots, x_m)$ 间是存在有线性关系,也就是说(1.2.6)中的理论系数中至少有一个不应为零。对例1.1.1用(1.2.8),

$$F(2, 16 - 2 - 1) = \frac{0.8570^2}{1 - 0.8570^2} \times \frac{18 - 2 - 1}{2} = 20.7382$$

取 $\alpha = 0.01$, 则 $F_{0.01}(2, 15) = 6.36$, F 值远大于 $F_{0.01}$, 所以,否定假设 H_0 ; 也就是说,认为理论回归系数 $(\beta_1, \beta_2, \dots, \beta_p)$ 全为零(即 y 与 (x_1, x_2) 不存在线性关系)的说法是不对的,我们至少有99%以上的把握认为,例1.1.1的数据中 y 与 (x_1, x_2) 存在线性关系。

实际工作中一个容易犯的错误是:有的人误以为由(1.2.7)或(1.2.8)计算出来的 F 值愈大,愈说明 y 与 $(x_1, x_2, \dots, x_m)$ 的线性关系愈密切,因此也认为线性模型的假定也就愈合理,这种看法是错误的。原因是(1.2.8)的基本假定为 $(\beta_1, \beta_2, \dots, \beta_p)$ 全为零,否定了这个假定,并不等于 y 与 $(x_1, x_2, \dots, x_p)$ 的线性关系就密切。

如记 ρ 为 y 与 $(x_1, x_2, \dots, x_m)$ 的理论复相关系数,则上述基本假定 H_0 等价于 $\rho = 0$,所以否定 H_0 ,仅说明 ρ 不应为零。比如理论上如果 $\rho = 0.001$,显然,它不为零,但实际上这么小的复相关系数没有什么意义。而从(1.2.8)可见,当样本数 n 无限增加时, R^2 则

趋向于理论值 ρ^2 。明显可见(1.2.8)中 F 值正比于 n 。也就是说,如果理论复相关系数 $\rho \neq 0$ (不管多么小),只要 n 足够大,我们总可以使(1.2.8)中的 F 要多大就可以有多大。因此,把(1.2.8)中的 F 值(或由其计算出的概率值 p)的大小作为线性模型好坏的标准是不正确的。正确地说,(1.2.8)的检验仅说明 y 与 $(x_1, x_2, \dots, x_m)$ 是否存在有线性关系,绝不能说明这个关系的程度。当然,一般说来,具有较大理论值的 ρ ,公式(1.2.8)也容易出现较大的 F 值(样本数 n 不变时),这也是显然的。

我们根据文献[1]的结果,介绍如果 y 的正态分布不成立但等方差性($\text{var}(e) = \sigma^2$)仍然成立时如何检验(1.2.6)中 H_0 。记

$$\begin{aligned} Z_r &= \left(\frac{x_{r1} - \bar{x}_1}{\sqrt{l_{11}}}, \frac{x_{r2} - \bar{x}_2}{\sqrt{l_{22}}}, \dots, \frac{x_{rm} - \bar{x}_m}{\sqrt{l_{mm}}} \right)', \quad r = 1, 2, \dots, n \\ A &= \sum_{r=1}^n (Z_r' R_{xx}^{-1} Z_r)^2, \quad B = \frac{1}{l_{yy}^2} \sum_{r=1}^n (y_r - \bar{y})^4 \\ C_x &= \frac{n-1}{m(n-3)(n-m-1)} \{n(n+1)A - (n-1)m(m+2)\} \\ C_y &= \frac{n-1}{(n-3)(n-2)} \{n(n+1)B - 3(n-1)\} \\ C &= \frac{(n-3)C_x C_y}{2n(n-1)}, \quad \delta = 1 - \frac{C(n+1)}{(C+1)(n-1)} \end{aligned} \quad (1.2.9)$$

其中 R_{xx} 为 $(x_1, x_2, \dots, x_m)$ 的相关阵,则可以证明,即使(1.2.2)中正态分布条件不成立,则(1.2.7)或(1.2.8)的右边值仍然可用统计量 F 去近似,这时自由度要略作改变,即(1.2.7)或(1.2.8)改为

$$F(\delta m, \delta(n-m-1)) \doteq \frac{n-m-1}{m} \cdot \frac{R^2}{1-R^2} \quad (1.2.10)$$

可以称 δ 为非正态性的修正因子。可以证明,如果(1.2.6)成立,则 $E(C_y) = 0$,于是 δ 理论值为1。这时(1.2.10)自然即(1.2.8)。 C_x, C_y 是有上下限的,可以证明有下面不等式:

$$-2 \leq C_x \frac{(n-3)}{(n-1)} \leq n-1, \quad -2 \leq C_y \frac{(n-3)}{(n-1)} \leq n-1 \quad (1.2.11)$$

所以,当 C_x 与 C_y 并不是同时达到上限,又 n 足够大时从(1.2.9)可见, δ 很易近似于1。也就是说,即使正态分布条件不成立,但如果是大样本,则上述关于 H_0 的检验是可以成立的。这时也可以不必对自由度作修正。但如果是小样本,则还是应对自由度作修正。

本节中方法的计算程序见程序1。

例1.1.1中, $n=18$,可算得:

$A=2.9326, B=0.1509, C=0.0346, \delta=0.9627$,由于 $\delta \doteq 1$,所以,可不考虑修正 F 检验中的自由度。

二、回归模型拟合的优良性及实际误差

我们的目的是要考察用(1.2.1)的模型是否可以相当好地拟合已给的样本。首先考察拟合的残差。记(1.2.1)中 y 的估计值为 $\hat{y}$,记估计残差为 e ,即每点上残差为: