

回归分析在农业科学中的应用

丁 希 泉

吉林省农业科学院 情报资料室

一 九 七 八 年

目 录

前 言

第一章 农业科学中的相关分析

§ 1、相关分析原理	(1)
§ 2、直线相关分析	(3)
一、单相关系数的计算方法	(3)
二、等级相关时的相关系数计算方法	(9)
三、相关系数显著性测定方法	(10)
§ 3、非直线相关	(14)
一、相关比的计算方法	(14)
二、相关比的显著性测定	(21)
§ 4、偏相关分析	(22)
一、偏相关系数的计算	(23)
二、偏相关系数的显著性测定	(25)
§ 5、复相关分析	(27)
一、复相关系数的计算方法	(27)
二、复相关系数的显著性测定	(30)
三、筛选法	(31)

第二章 农业科学中的回归分析

§ 1、经验公式类型的选择	(33)
一、直线化法	(33)
二、差分法	(37)
三、差商法	(40)
§ 2、确定经验公式中的系数的方法	(42)
一、图解法	(42)
二、选点法	(42)
三、平均法	(43)
§ 3、最小二乘法原理	(44)
§ 4、直线方程式	(46)
§ 5、各种确定系数方法的准确程度比较	(48)

第三章 农业科学中的曲线回归分析

§ 1、幂函数曲线	(50)
一、一般的幂函数曲线	(50)
二、带常量的幂函数曲线	(52)
§ 2、二次抛物线	(54)
§ 3、变形双曲线	(57)
一、普通的变形双曲线	(57)
二、带常量的变形双曲线	(60)
§ 4、指数函数曲线	(63)
一、普通的指数函数曲线	(63)
二、带常量的指数函数曲线	(65)
§ 5、对数函数曲线	(68)
§ 6、指数函数的指数幂为指数函数的形式	(70)
§ 7、指数函数的指数幂为任一函数的形式	(75)
一、指数幂为多项式的形式	(75)
二、指数幂为对数函数的形式	(77)
三、指数幂为幂函数的形式	(78)
§ 8、复合函数曲线	(79)
一、直线式与指数函数之和的形式	(79)
二、若干个指数函数之和的形式	(85)
三、若干个指数函数相乘积的形式	(90)
四、幂函数与指数函数乘积的形式	(92)
§ 9、生长曲线	(95)

第四章 农业科学中的多元回归分析

§ 1、多元回归分析	(98)
一、多元一次回归分析	(98)
二、多元二次回归分析	(103)
三、求解多元回归方程式的综合法	(104)
四、偏回归系数的显著性测定	(106)
五、回归方程式的显著性测定	(110)
§ 2、正交多项式	(112)
一、最小二乘法	(112)
二、“正交多项式表”法	(113)

§ 3、正交多项式在气象要素时间分布状况对农作物产量影响的研究中的应用 (117)

§ 4、周期性经验公式 (124)

一、谐波分析 (125)

二、六个纵坐标的谐波分析 (130)

三、十二个纵坐标的谐波分析 (131)

第五章 观测值的修匀

§ 1、直线移动平均法 (137)

§ 2、多项式移动平均法 (144)

一、二次多项式移动平均 (145)

二、三次多项式移动平均 (148)

附表 1、 ρ 与 r 对照表 (161)

2、相关系数 r 显著性检验表 (161)

3、相关系数 r 变换为 Z 值表 (162)

4、 t 分布表 (163)

5、 F 分布表 (164)

6、正交多项式表 (ξ 值表) (169)

7、常用对数表 (182)

参考文献: 132篇 (略)

第一章 农业科学中的相关分析

在农业科学中，有很多事情彼此之间有密切关系。比如，作物生态受环境因素影响很大。有些环境因素的改变，能引起农作物生育产量的变化。大家都知道，土壤水分的多少与作物生育产量间的关系十分密切。土壤水分少（或降雨少），会使作物生育不良，造成严重减产。适宜的土壤水分，会使作物生育状况良好，产量提高。其它因素如温度、降水、日照等对作物生育产量都有极大的影响。因为这些因素是作物必不可少的生活条件。当然，不同作物品种、不同地区，各因素与作物生态间的关系也是不同的，有的与这个因素关系密切，有的与那个因素关系密切。怎样才能表示出它们之间的关系是否密切？它们之间的关系密切到什么样的程度呢？

为了便于讨论，我们将生态因子（如株高、干物重、产量等）、环境因素（如温度、水分、日照等）等等均用数学上常用的名称：“变量”来代表。相关系数就是表示两个连续变量之间关系密切程度的最常用的量数。它的好处是明了又便于计算。它的缺点是仅能表示相互关系的大小，不能表示是什么样的关系，这就要用另一个表示变量之间制约关系的方法——回归分析来解决（将在后面介绍）。相关分析与回归分析有着密切的联系。应用时，一般先用相关分析确定变量之间关系明显后，再用回归分析来说明它们是什么样的关系，即求出一个变量变化时制约着另一个变量变化的方程式。当然，根据需要或者试验数据不适于相关分析，也可以直接用回归分析。但应注意到，绝不能把实质上没有关系的两件事物硬放在一起分析，那样做会得出错误甚至荒谬的结论。

§ 1、相关分析原理

假设有两个连续变量 X 与 Y ，它们均为正态分布，并且 X 与 Y 之间有一定的关系，那么，二元正态分布密度函数为：

$$P(X \cdot Y) = \frac{1}{2\pi \sigma_x \sigma_y \sqrt{1-\rho^2}} e^{XP} \left\{ -\frac{1}{2(1-\rho^2)} \times \left(\frac{(x-\bar{U}_x)^2}{\sigma_x^2} - 2\rho \cdot \frac{(x-\bar{U}_x)(y-\bar{U}_y)}{\sigma_x \sigma_y} + \frac{(y-\bar{U}_y)^2}{\sigma_y^2} \right) \right\}$$

式中 $\bar{U}_x$ —— X 的总体平均值；

$\bar{U}_y$ —— Y 的总体平均值；

σ_x —— X 的总体标准差；


σ_y —— Y 的总体标准差；

ρ —— X 与 Y 的总体相关系数；

e^{XP} ——指数函数符号，即 $e^{XP} Z = e^Z$ 。当 Z 的表达式较繁时，用 $e^{XP} Z$ 的写法比较方便。

该函数的图形为一钟形曲面（如图 1）。

图 1
二元正态分布曲面




$$\begin{aligned}
 \therefore \sigma_{xy} &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \bar{U}_x)(y - \bar{U}_y) P(x, y) \cdot dx dy \\
 &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \bar{U}_x)(y - \bar{U}_y) \cdot \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{2(1-\rho^2)}\right. \\
 &\quad \left.\cdot \left(\frac{(x-\bar{U}_x)^2}{\sigma_x^2} - 2\rho \frac{(x-\bar{U}_x)(y-\bar{U}_y)}{\sigma_x\sigma_y} + \frac{(y-\bar{U}_y)^2}{\sigma_y^2}\right)\right\} \cdot dx dy \\
 &= \sigma_x\sigma_y\rho \\
 \therefore \rho &= \frac{\sigma_{xy}}{\sigma_x \cdot \sigma_y} \quad (2)
 \end{aligned}$$

公式(2)表示 x 与 y 两变量之间的总体相关系数或称理论相关系数。我们根据样本资料求的相关系数,以 r 表示,它是总体相关系数的估计值。实际上,我们只能计算出 r 值,并以此来判断 x 与 y 之间的相关性。

相关系数值的范围为 $-1 \leq \rho \leq 1$ 。当 $\rho = 0$ 时,说明变量 x 与 y 之间没有相关性,即 x 与 y 是相互独立的正态分布。当 $\rho = 1$ 或 $\rho = -1$ 时,表明两者有完全的正相关或负相关,它说明可以根据每一个 x 值求出与之相对应的 y 值,即回归式 $Y = a + bx$ 所表示的关系,称作 y 依 x 的回归式, b 则称为 y 依 x 的回归系数。反之,也可根据 y 的任何一个值求出与之相对应的 x 值,即回归式 $x = a' + b'y$ 所表示的关系, b' 则称为 x 依 y 的回归系数。当 $-1 < \rho < 1$ 时,表明两者有一定的关系,且 $|\rho|$ 值越大,两者的相关关系越大。上述情况如图 2。

图 2
相关系数几种情况



§ 2、直线相关分析

当两个变量 X_i 与 Y_i 之间呈简单的直线关系时，这是最简单的相关分析，其相关系数称为单相关系数。

一、单相关系数的计算方法

1、一般的计算公式：根据相关系数的定义，由公式（2）得出计算相关系数 r_{xy} 的公式为：

$$r_{xy} = \frac{S_{xy}}{S_x \cdot S_y} = \frac{\sum x y}{\sqrt{\sum x^2 \cdot \sum y^2}} = \frac{\sum (X_i - \bar{X}) \sum (Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \cdot \sum (Y_i - \bar{Y})^2}} \quad (3)$$

式中 $x_i = X_i - \bar{X}$, $y_i = Y_i - \bar{Y}$; X_i 、 Y_i 均为原始数据。 $\bar{X}$ 为 X_i 的平均值， $\bar{Y}$ 为 Y_i 的平均值。

2、直接计算法：

$$\begin{aligned} \because \sum x y &= \sum (X_i - \bar{X}) (Y_i - \bar{Y}) = \sum X_i Y_i - n \bar{X} \bar{Y} \\ \sum x^2 &= \sum (X_i - \bar{X})^2 = \sum X_i^2 - n \bar{X}^2 \\ \sum y^2 &= \sum (Y_i - \bar{Y})^2 = \sum Y_i^2 - n \bar{Y}^2 \end{aligned}$$

代入（3）式：

$$r = \frac{\sum X_i Y_i - n \bar{X} \bar{Y}}{\sqrt{(\sum X_i^2 - n \bar{X}^2)(\sum Y_i^2 - n \bar{Y}^2)}} \quad (4)$$

$$\text{又因为 } \bar{X} = \frac{\sum X_i}{n}, \quad \bar{Y} = \frac{\sum Y_i}{n}$$

所以（4）式又变为

$$\begin{aligned} r &= \frac{\sum X_i Y_i - n \left(\frac{\sum X_i}{n}\right) \cdot \left(\frac{\sum Y_i}{n}\right)}{\sqrt{[\sum X_i^2 - n \cdot \left(\frac{\sum X_i}{n}\right)^2] \cdot [\sum Y_i^2 - n \cdot \left(\frac{\sum Y_i}{n}\right)^2]}} \\ &= \frac{n \sum X_i Y_i - \sum X_i \cdot \sum Y_i}{\sqrt{[n \sum X_i^2 - (\sum X_i)^2] \cdot [n \sum Y_i^2 - (\sum Y_i)^2]}} \quad (5) \end{aligned}$$

一般地，当样本个数不太大时（ $n \leq 30$ ），大多采用此公式进行计算，并且计算误差较小。

例1 根据高粱产量与8月平均气温的资料（表1）计算相关系数。

先在表内完成各栏的计算。再根据表中第（3）（4）（5）栏内的数字，由公式（3）得：

$$r = \frac{1601.8}{\sqrt{7.77 \times 626049}} = \frac{1601.8}{2.787 \times 791.232} = \frac{1601.8}{2205.2} = 0.7264$$

根据表中第（6）（7）（8）栏内的数字，由式（4）得：

表1 $\times \times$ 县高粱产量与8月平均气温的相关系数计算

	y	x	(1) $\frac{y}{\bar{y}}$ (y - $\bar{y}$)	(2) $\frac{x}{\bar{x}}$ (x - $\bar{x}$)	(3) x^2	(4) y^2	(5) xy	(6) xy	(7) x^2	(8) y^2
	1253	22.8	56	0.6	0.36	3136	33.6	28568.4	519.84	1570009
	1583	23.5	386	1.3	1.69	148996	501.8	37200.5	552.25	2505889
	1005	22.4	-192	0.2	0.04	63864	-38.4	22512.0	501.76	1010025
	1268	21.9	71	-0.3	0.09	5041	-21.3	27769.2	479.61	1607824
	1230	21.2	33	-1.0	1.00	1089	-33.0	26076.0	449.44	1512900
	1095	22.4	-102	0.2	0.04	10404	-20.4	24528.0	501.76	1199025
	1523	23.1	326	0.9	0.81	106276	293.4	35181.3	533.61	2319529
	915	22.0	-282	-0.2	0.04	79524	56.4	20130.0	484.00	837225
	825	20.6	-272	-1.6	2.56	138384	595.2	16995.0	424.36	680625
	1058	21.3	-139	-0.9	0.81	19321	125.1	22535.4	453.69	1119364
	1275	22.7	78	0.5	0.25	6084	39.0	28942.5	515.29	1625625
	1088	22.0	-109	-0.2	0.04	11881	21.8	23936.0	484.00	1183744
	1440	22.4	243	0.2	0.04	59049	48.6	32256.0	501.76	2073600
合计	15558	288.3			7.77	626049	1601.8	346630.3	6401.37	19245384
平均	1197	22.2								

$$r = \frac{13 \times 346630.3 - 288.3 \times 15558.0}{\sqrt{[13 \times 6401.37 - (288.3)^2] [13 \times 19245384 - (15558)^2]}}$$

$$= \frac{20822.5}{\sqrt{100.92 \times 8138628.0}} = \frac{20822.5}{28659.2} = 0.7266$$

两个公式所得结果是相同的。但从表中的数值计算看出，当数值较大时，用公式(3)计算较方便，可以避免很大数值的计算。当数值较小时，用公式(4)计算则比较方便。

3、回归分析中计算相关系数

从回归分析(参见第二章 §4)可以知道，如果Y依X变量的回归式为 $y = a_1 + b_1 x$ ，那么，回归系数 b_1 为：

$$b_1 = \frac{\sum xy}{\sum x^2} = \frac{s_y}{s_x} \cdot r_{xy} \quad (6)$$

同样地，X依Y的回归式 $X = a_2 + b_2 y$ ，其回归系数 b_2 为：

$$b_2 = \frac{\sum xy}{\sum y^2} = \frac{s_x}{s_y} \cdot r_{xy} \quad (7)$$

因而 $b_1 \cdot b_2 = \left(\frac{s_y}{s_x} \cdot r_{xy} \right) \cdot \left(\frac{s_x}{s_y} \cdot r_{xy} \right) = r^2_{xy}$

$$\therefore r = \pm \sqrt{b_1 \cdot b_2} \quad (8)$$

另外，在回归分析中利用最小二乘法求出直线式 $\hat{y} = a + bX$ ，那么，距回归线的总误差 Q （见公式87）为：

$$Q = \sum d_i^2 = \sum (y_i - \hat{y}_i)^2 = \sum (y_i - a - bX)^2$$

$$\because \bar{y} = a + b\bar{x} \quad \therefore a = \bar{y} - b\bar{x}$$

代入 Q 的表达式，得：

$$\begin{aligned} Q &= \sum (y - \bar{y} + b\bar{x} - bX)^2 = \sum [(y - \bar{y}) - b(X - \bar{x})]^2 \\ &= \sum (y - \bar{y})^2 - b^2 \sum (X - \bar{x})^2 \end{aligned}$$

$$\therefore b^2 \sum (X - \bar{x})^2 = \sum (y - \bar{y})^2 - Q \quad (9)$$

于是，由公式（3）（6）（9）得：

$$\begin{aligned} r^2 &= \frac{[\sum (X - \bar{x})(y - \bar{y})]^2}{\sum (X - \bar{x})^2 \cdot \sum (y - \bar{y})^2} = \frac{b^2 \cdot \sum (X - \bar{x})^2}{\sum (y - \bar{y})^2} \\ &= \frac{\sum (y - \bar{y})^2 - Q}{\sum (y - \bar{y})^2} = 1 - \frac{\sum (y - \hat{y})^2}{\sum (y - \bar{y})^2} \end{aligned} \quad (10)$$

或者写成

$$r^2 = 1 - \frac{S_d^2}{S_y^2}, \quad \text{即} \quad r = \pm \sqrt{1 - \frac{S_d^2}{S_y^2}} \quad (11)$$

式中 S_d — y 距回归线的变异程度，即距回归的标准差； S_y — y 对于平均数 $\bar{y}$ 的变异程度，即为样本的标准差。

从上述的公式也可以清楚的看出：相关分析与回归分析是密切联系的。

4、利用相关表计算相关系数（相关表法）

当样本内试验数据的个数 n 很大时，用上面的公式计算相关系数很麻烦，工作量很大。在这种情况下，我们利用相关表计算相关系数就比较方便，可以减少很多工作量。

表2、 相关表（ X 为0—50cm层土壤湿度 Y 为0—100cm层土壤湿度）

X 的组距		18.1	21.1	24.1	27.1	30.1	33.1	36.1	39.1
		21.0	24.0	27.0	30.0	33.0	36.0	39.0	42.0
y 的组距		19.5	22.5	25.5	28.5	31.5	34.5	37.5	40.5
		-2	-1	0	1	2	3	4	5
18.1—21.0	19.5	-1	2	1					
21.1—24.0	22.5	0	41	15					
24.1—27.0	25.5	1		28	8	1			
27.1—30.0	28.5	2			11	2	1		
30.1—33.0	31.5	3					2	1	
33.1—36.0	34.5	4							1

相关表（见表2）的编制过程如下：将资料中X值由最小值到最大值，按一定的间距分为m组，表2中的组距为3.0， $m=8$ ；Y值也由最小值到最大值按一定的间距分为L组，表2中的组距为3.0， $L=6$ 。然后接着每对X、Y值找出所在组交叉处的格子登记上“—”，最后数出每格内“—”数，即成为表2的形式。例如，数据 $X=19$ ， $Y=20$ ，则应在X的18.1—21.0组与Y为18.1—21.0组相交处（即表内第一个格子内）记上“—”依此类推。

如果以 S_{xi} 表示横坐标各组的组中值， S_{yj} 表示纵坐标各组的组中值， f_{ij} 表示横坐标属于第i组，纵坐标属于第j组的数据个数，那么，

$$\begin{aligned}
 r &= \frac{\sigma_{xy}}{\sigma_x \cdot \sigma_y} \\
 &= \frac{\sum_{i=1}^m \sum_{j=1}^L f_{ij} (S_{xi} - \bar{X}) (S_{yj} - \bar{Y})}{\sqrt{\sum_{i=1}^m f_i (X_i - \bar{X})^2 \cdot \sum_{j=1}^L f_j (Y_j - \bar{Y})^2}} \\
 &= \frac{\sum_{i=1}^m \sum_{j=1}^L f_{ij} S_{xi} S_{yj} - n \bar{X} \bar{Y}}{\sqrt{(\sum_{i=1}^m f_i S_{xi}^2 - n \bar{X}^2) \cdot (\sum_{j=1}^L f_j S_{yj}^2 - n \bar{Y}^2)}} \quad (12)
 \end{aligned}$$

式中 $f_i = \sum_{j=1}^L f_{ij}$, $f_j = \sum_{i=1}^m f_{ij}$

$$\bar{X} = \frac{\sum_{i=1}^m f_i S_{xi}}{n}, \quad \bar{Y} = \frac{\sum_{j=1}^L f_j S_{yj}}{n}$$

上式也可以写成：

$$\begin{aligned}
 r &= \frac{\sum_{i=1}^m \sum_{j=1}^L f_{ij} S_{xi} S_{yj} - n \cdot \frac{\sum_{i=1}^m f_i S_{xi}}{n} \cdot \frac{\sum_{j=1}^L f_j S_{yj}}{n}}{\sqrt{\left(\sum_{i=1}^m f_i S_{xi}^2 - n \cdot \left(\frac{\sum_{i=1}^m f_i S_{xi}}{n} \right)^2 \right) \left(\sum_{j=1}^L f_j S_{yj}^2 - n \cdot \left(\frac{\sum_{j=1}^L f_j S_{yj}}{n} \right)^2 \right)}} \\
 &= \frac{n \sum_{i=1}^m \sum_{j=1}^L f_{ij} S_{xi} S_{yj} - \left(\sum_{i=1}^m f_i S_{xi} \right) \left(\sum_{j=1}^L f_j S_{yj} \right)}{\sqrt{\left[n \sum_{i=1}^m f_i S_{xi}^2 - \left(\sum_{i=1}^m f_i S_{xi} \right)^2 \right] \left[n \sum_{j=1}^L f_j S_{yj}^2 - \left(\sum_{j=1}^L f_j S_{yj} \right)^2 \right}}} \quad (13)
 \end{aligned}$$

为了计算方便,可以引入参变量后再进行计算。设参变数 $t_{xi} = \frac{S_{xi} - A}{C}$, 其中 C 表示 X 值的组距, A 表示任选的某一组的组中值, 一般选频数 f_i 最大的那一组。参变量 $t_{yj} = \frac{S_{yj} - B}{d}$, 其中 d 表示 y 值的组距, B 为任选的某一组的组中值。将 t_{xi} 与 t_{yj} 代入 (13) 式, 得:

$$r = \frac{n \sum_{i=1}^m \sum_{j=1}^L f_{ij} t_{xi} t_{yj} - \left(\sum_{i=1}^m f_{xi} t_{xi} \right) \left(\sum_{j=1}^L f_{yj} t_{yj} \right)}{\sqrt{\left[n \sum_{i=1}^m f_{xi} t_{xi}^2 - \left(\sum_{i=1}^m f_{xi} t_{xi} \right)^2 \right] \left[n \sum_{j=1}^L f_{yj} t_{yj}^2 - \left(\sum_{j=1}^L f_{yj} t_{yj} \right)^2 \right]}} \quad (14)$$

例2 根据表3的资料, 计算公主岭黑土地0—100cm层的土壤湿度与0—50cm层的土壤湿度的相关系数。

我们采用公式 (14) 形式来计算相关系数, 其计算过程如表3。表内各栏的计算说明如下:

纵行 第8栏: $-4 = -2 \times 2$; $-42 = (-1) \times 1 + (-1) \times 41$;。

第9栏: $8 = (-2)^2 \times 2$; $42 = (-1)^2 \times 1 + (-1)^2 \times 41$;。

第10栏: $-2 = (-1) \times 2$; $-1 = (-1) \times 1 + 0 \times 41$;。

第11栏: $4 = (-2) \times (-2)$; $1 = (-1) \times (-1)$;。

横行 第(10)栏: $-3 = (-1) \times 2 + (-1) \times 1$; $37 = 1 \times 28 + 1 \times 8 + 1 \times 1$。

第(11)栏: $3 = (-1)^2 \times 2 + (-1)^2 \times 1$; ... $37 = 1^2 \times 28 + 1^2 \times 8 + 1^2 \times 1$。

第(12)栏: $-5 = (-2) \times 2 + (-1) \times 1$; ...

$10 = 0 \times 28 + 1 \times 8 + 2 \times 1$;。

第(13)栏: $5 = (-1) \times (-5)$; ... $10 = 1 \times 10$。

将表内数值代入公式 (14), 得:

$$\begin{aligned} r &= \frac{124 \times 101 - (-3) \times 75}{\sqrt{[124 \times 149 - (-3)^2] [124 \times 139 - (75)^2]}} \\ &= \frac{12749}{\sqrt{18467 \times 11611}} = \frac{12749}{135.9 \times 107.75} \\ &= \frac{12749.0}{14642.15} = 0.8707 \end{aligned}$$

此外, 在观测资料数目较大时, 或者从许多因素中挑出有关因素时, 还有一种求相关系数的近似方法。首先, 根据数据点出两变量 X 与 Y 的相关图, 图3表示大豆产量与开花一成熟期降水量的关系。然后作一条水平线, 将点上下平分; 再作一条垂直线, 将点左右平分。这两条线将平面分成四块, 分别数每一块的点数 (在平分线上的点不算), 得出相关方向上两块 (即点数多的两块) $n_1 = n_2 = 14$ 其余两块 $n_3 = n_4 = 4$ 。

表 3 相关系数的计算

编号	号	(1)(2)(3)(4)(5)(6)(7)(8)(9)(10)(11)(12)(13)										
		t_{xi}	t_{yi}	f_{xi}^2	f_{yi}^2	$t_{xi}f_{xi}$	$t_{yi}f_{yi}$	$t_{xi}^2f_{yi}$	$\Sigma t_{xi}f_{yi}$	$t_{yi}\Sigma t_{xi}f_{yi}$	$t_{yi}\Sigma t_{xi}f_{yi}$	
1	-1	2	1						3	-3	3	5
2	0		41	15			0	0	56	0	-41	0
3	1			28	8	1	37	37	37	10	10	10
4	2				11	2	28	56	14	18	18	36
5	3					2	9	27	3	10	10	30
6	4						4	16	1	5	5	20
7	Σf_{xi}	2	42	43	19	3	75	139	124	—	—	101
8	$\Sigma t_{xi}f_{xi}$	-4	-42	0	19	6			-3			
9	$\Sigma t_{xi}^2f_{xi}$	8	42	0	19	12			149			
10	$\Sigma t_{yi}f_{xi}$	-2	-1	28	30	5			—			
11	$t_{xi}\Sigma t_{yi}f_{xi}$	4	1	0	30	10			101			

设 $n_+ = n_1 + n_2 = 28$, $n_- = n_3 + n_4 = 8$ 则由相关系数近似计算公式:

$$r = \sin \left(\frac{n_+}{n_+ + n_-} - \frac{1}{2} \right) \pi \quad (15)$$

得:

$$r = \sin \left(\frac{28}{28 + 8} - \frac{1}{2} \right) \pi = \sin \frac{5}{18} \pi = \sin 50^\circ = 0.7660$$

如果根据公式(5)计算,则得相关系数为0.8245。虽然两个结果的数值不一样,但差别不大。如果用相关系数的显著性测定方法来检验,两者之间差异不显著(见例7)。它们均达到0.1%的显著水准,说明大豆产量与开花一成熟期降水量之间的相关关系极为明显。




图3 相关系数 r 的近似计算

二、等级相关时的相关系数计算方法

在实际工作中,常常遇到调查数据或试验结果不是具体的数值,而只是表示它们等级的号码。例如,我们将作物生长状况分为好、较好、一般、较差、差五等;将产量分为高产、一般、低产;将降水量分为极多、多雨、一般、少雨、极少五等,或者分为旱,一般,涝三等。并将它们用数字1、2、3、4、5来表示。在这种情况下它们之间的相关称为等级相关,也可以计算出相关系数。但是,由于等级不可能分得很多,一般也就是3~5等,而等级少时所计算出的相关系数受到偶然性影响较大,所以结果并不十分可靠,只能反映出一般的情况,可作参考之用。

计算等级相关,相关系数的公式为史皮曼(Spearman)公式:

$$\rho = 1 - \frac{6 \sum D^2}{n(n^2 - 1)} \quad (16)$$

式中, n 为项数; $D = Y - X$, 即相关的两变量的等级差值。

求得 ρ 后，再由下式求得相关系数 r ：

$$r = 2 \sin \left(\frac{\pi \rho}{6} \right) \quad (17)$$

皮尔逊 (Pearson) 根据公式 (17)，制作出 ρ 与 r 的对照表 (附表 1)，求得 ρ 后，直接查表得出 r 。

例 3 $\times \times$ 县农民谚语说“秋后雨水多，来夏淹山坡”，为了检验这一谚语，我们将降雨量分为少，偏少，偏多，多四等，其界限分别为平均降雨量的 70% 以下，70—100%，101—130%，130% 以上，并记为 1，2、3、4 等，如表 4，X 表示秋雨 (10—11 月) 等级，Y 表示夏季 (6—9 月) 降雨等级。

表 4 秋雨与夏季降雨的等级相关

年 份	X	Y	D	D ²	年 份	X	Y	D	D ²
1955	3	3	0	0	1963	3	3	0	0
56	4	3	1	1	64	1	3	2	4
57	2	1	1	1	65	1	2	1	1
58	2	3	1	1	66	2	2	0	0
59	4	4	0	0	67	3	1	2	4
60	2	3	1	1	68	1	2	1	1
61	2	2	0	0	69	1	1	0	0
62	3	3	0	0	70	2	1	1	1

$$\therefore n = 16, \Sigma D^2 = 15$$

$$\therefore \rho = 1 - \frac{6 \times 15}{16 \times (16^2 - 1)} = 1 - 0.0221 = 0.9779$$

查附表 1，得 $r = 0.9818$ 。

如果用相关系数的显著性测定方法来检验 (见下节)，这是高度显著的，说明当年秋雨多少与来年夏季雨水的多少有极为密切的关系，即农民谚语：“秋后雨水多，来夏淹山坡”是正确的。

三、相关系数显著性测定方法

从前面的各种计算方法表明，我们所进行的相关系数计算都是以样本资料为基础的，它不是真正的总体相关系数，只是总体相关系数的一个近似值。它的近似程度随取样方法、样本单元数的多少及其样本资料的准确程度等的不同而异。那么，我们究竟怎样判断样本相关系数对总体相关系数的近似程度，即样本的相关系数能否代表总体的相关情况？还有计算出的样本相关系数与另一个标准相关系数比较；二个样本相关系数之间的比较等，诸如此类问题都是相关系数显著性测定要解决的问题。

1、或差法：

当样本单元数很大时，取自同一总体的各样本相关系数 r 就接近于正态分布，其平均

数即是总体相关系数 ρ 。

相关系数 r 的标准差为：

$$\sigma_r = \frac{1 - r^2}{\sqrt{n-1}} = \frac{1 - r^2}{\sqrt{n}} \quad (18)$$

于是，我们可以得到相应于相关系数 r 的正态分布曲线公式为：

$$P(r_0) = 1 - \int_0^{t_0} \frac{2}{\sqrt{\pi}} e^{-\frac{t^2}{2}} \cdot dt \quad (19)$$

$$\text{式中 } t = \frac{r_0}{\sigma_r}$$

从而可求出由于偶然机会而得到的相关系数 $r \geq r_0$ 的概率。在实际应用中，一般采用的概率标准（亦即显著水准）是0.05与0.01，此时的 t 值分别为 $t \geq 1.96$ ($P=0.05$ 时) 与 $t \geq 2.6$ ($P=0.01$ 时)。因而，只有 $r \geq 1.96 \sigma_r$ 与 $r \geq 2.6 \sigma_r$ 时才表示相关系数分别达到0.05与0.01的显著水准，即相关显著或很显著。

一般，并不采用上述那样具体的计算，只是用相关系数大于（或等于）或然差 ($P.E.r$) 的四倍就认为相关显著。这种相关程度仅达0.05的显著水准。其 $P.E.r$ 公式为

$$P.E.r = \pm 0.6745 \frac{1 - r^2}{\sqrt{n}} \quad (20)$$

并且习惯写成 $r \pm P.E.r$ 的形式。

若相关系数是由等级相关时计算出来的，其或然差公式则为：

$$P.E.r = \pm 0.7063 \frac{1 - r^2}{\sqrt{n}} \quad (21)$$

当然，这种方法只能在样本单元数很大时 ($n > 100$ ，严格要求应是 $n \geq 500$) 应用。对于 n 较小时， r 的分布就不是正态分布，因而再应用此法是不恰当的，需要采用另外的方法进行相关系数的显著性测定。

例4 由例2知： $n=124$ ， $r=0.8707$ ，试检验此相关是否显著。

根据公式 (20) 得：

$$P.E.r = \pm 0.6745 \frac{1 - (0.8707)^2}{\sqrt{124}} = \pm 0.0146$$

因 $r > 4 P.E.r = 0.0584$

所以，此相关显著。0—50厘米层土壤湿度与0—100厘米层土壤湿度之间关系很密切。

2、 t 测验法：

当样本单元数较小时，相关系数 r 的分布就不是正态分布，而是一个偏态分布（如图4）。因此，不能用或然差法来测定 r 的显著性。费雪氏 (Fisher) 指出，假设总体相关系数 $\rho = 0$ ，那么，新变量：

$$t = \frac{r\sqrt{n-2}}{\sqrt{1-r^2}} \quad (22)$$

是服从于自由度为 $n-2$ 的 t 分布, 亦称学生氏分布, 其公式为

$$P(t) = \frac{1}{\sqrt{m\pi}} \frac{\Gamma(\frac{m+1}{2})}{\Gamma(\frac{m}{2})} \left(\frac{t^2}{m} + 1 \right)^{-\frac{m+1}{2}} \quad (23)$$

式中 m 为自由度, $m = n - 2$ 。

从而可求出因偶然机会所得到的相关系数 $r \geq r_0$ 的机率。并且已有根据 t 分布制成的表, 即 t 分布表。因而容易查出自由度为 $n-2$ 时, t 值的机率值 $P(t)$ 。若 $P < P_0$ ($P_0 = 0.05$ 或 0.01), 即为相关显著。反之, $P > P_0$, 即为不显著。

但是, 这样计算、查表仍还很麻烦。于是, 费雪氏根据这个原理, 编制了直接根据相关系数 r 与自由度 $n-2$ 就可以查出相关显著程度的表, 即相关系数显著性检验表 (附表 2)。

例 5 从例 1 知高粱产量与 8 月气温的相关系数 $r = 0.7266$, $n = 13$, 试检验相关程度?

∵ 自由度 $d.f. = n - 2 = 13 - 2 = 11$

查附表 2, 得:

5% 显著水准时, $r_{0.05} = 0.5529$, 1% 显著水准时, $r_{0.01} = 0.6835$, 因为, $r > r_{0.01}$ 。所以, 相关很显著, 即高粱产量与 8 月气温之间的关系很密切。

3、Z 测定法

当样本单元数小, 并且要比较的总体相关系数 $\rho \neq 0$, 或者是由两个样本分别得到相关系数 r_1 与 r_2 , 要比较这两个相关系数是否有差异, 如果仍用上面的方法是不适合的。这时, 相关系数 r 的分布特别偏斜, 对于这样的偏态分布, 费雪又引进一个新变量 Z 进行变换, 使其 Z 值分布符合于正态分布 (图 5), 这个变换步骤很复杂, 其最后的变换式为:

$$Z = \frac{1}{2} \ln \frac{1+r}{1-r} = 1.1513 \log \frac{1+r}{1-r} \quad (24)$$




图 4 正态相关下, 样本相关系数 r 的分布曲线 ($n=10$)




图 5 正态相关下, $Z = \frac{1}{2} \ln \frac{1+r}{1-r}$ 的分布曲线 ($n=10$)

$$\text{及} \quad \xi = \frac{1}{2} \ln \frac{1+\rho}{1-\rho} = 1.1513 \log \frac{1+\rho}{1-\rho} \quad (25)$$

式中 r 与 ρ 分别为样本与总体的相关系数。于是 $Z - \xi$ 则近似于正态分布，其平均数为 0，标准差 (σ_z) 为 $1/\sqrt{n-3}$ ； Z 近似于正态分布，其平均数为 ξ ，标准差为 $1/\sqrt{n-3}$ 。它的概率公式为：

$$P(Z) = \frac{1}{\sqrt{\frac{2}{\pi}}} \int_0^Z e^{-\frac{Z^2}{2\sigma_z^2}} \cdot dZ \quad (26)$$

从而可以求出因偶然机会所得到的相关系数 $r \geq \rho$ 的机率 P 。若 $P < P_0$ ($P_0 = 0.05$ 或 0.01)，则为显著。也就是说明，在总体相关系数 ρ 与样本相关数 r 之间差异显著。

如果不是上面那样将一个样本的相关系数 r 与一个总体相关系数 ρ ($\rho \neq 0$) 进行比较，而是比较二个样本相关系数 r_1 与 r_2 ，或者是二个总体相关系数 ρ_1 与 ρ_2 进行比较，用 Z 测验法来测定如下：

根据公式 (24)、(25) 或者查附表 3 得：

$$\begin{cases} Z_1 = \frac{1}{2} \ln \frac{1+r}{1-r} \\ Z_2 = \frac{1}{2} \ln \frac{1+r}{1-r} \end{cases}$$

及

$$\begin{cases} \xi_1 = \frac{1}{2} \ln \frac{1+\rho}{1-\rho} \\ \xi_2 = \frac{1}{2} \ln \frac{1+\rho}{1-\rho} \end{cases}$$

于是 $Z_1 - Z_2$ 的分布近似于正态分布，其平均数为 $\xi_1 - \xi_2$ ，标准差 ($\sigma_{Z_1-Z_2}$) 为：

$$\sigma_{Z_1-Z_2} = \sqrt{\sigma_{Z_1}^2 + \sigma_{Z_2}^2} = \sqrt{\frac{1}{n_1-3} + \frac{1}{n_2-3}} \quad (27)$$

因而

$$t = \frac{Z_1 - Z_2}{\sigma_{Z_1-Z_2}} = \frac{Z_1 - Z_2}{\sqrt{\frac{1}{n_1-3} + \frac{1}{n_2-3}}} \quad (28)$$

查附表 4 得出 $t_{0.05}$ 与 $t_{0.01}$ 值。若 $t > t_{0.05}$ 或 $t_{0.01}$ ，则二个相关系数差异显著或很显著，亦即它们的差异可能是真正的差异。反之，若 $t < t_{0.05}$ ，则二个相关系数差异不显著，即它们的差异可能是由于误差所造成的。

例 6 今有大豆产量与开花期降水量的相关系数 $r_1 = 0.5805$, $n_1 = 17$; $r_2 = 0.5525$, $n_2 = 12$ ，它们分别是根据分期播种资料与历年产量资料求得的，试问两者结果是否一致？

解：查附表 3

当 $n_1 = 17$, $r_1 = 0.5805$ 时，得 $Z_1 = 0.66$

$n_2 = 12$, $r_2 = 0.5525$ 时，得 $Z_2 = 0.63$

于是由 (28) 式得：