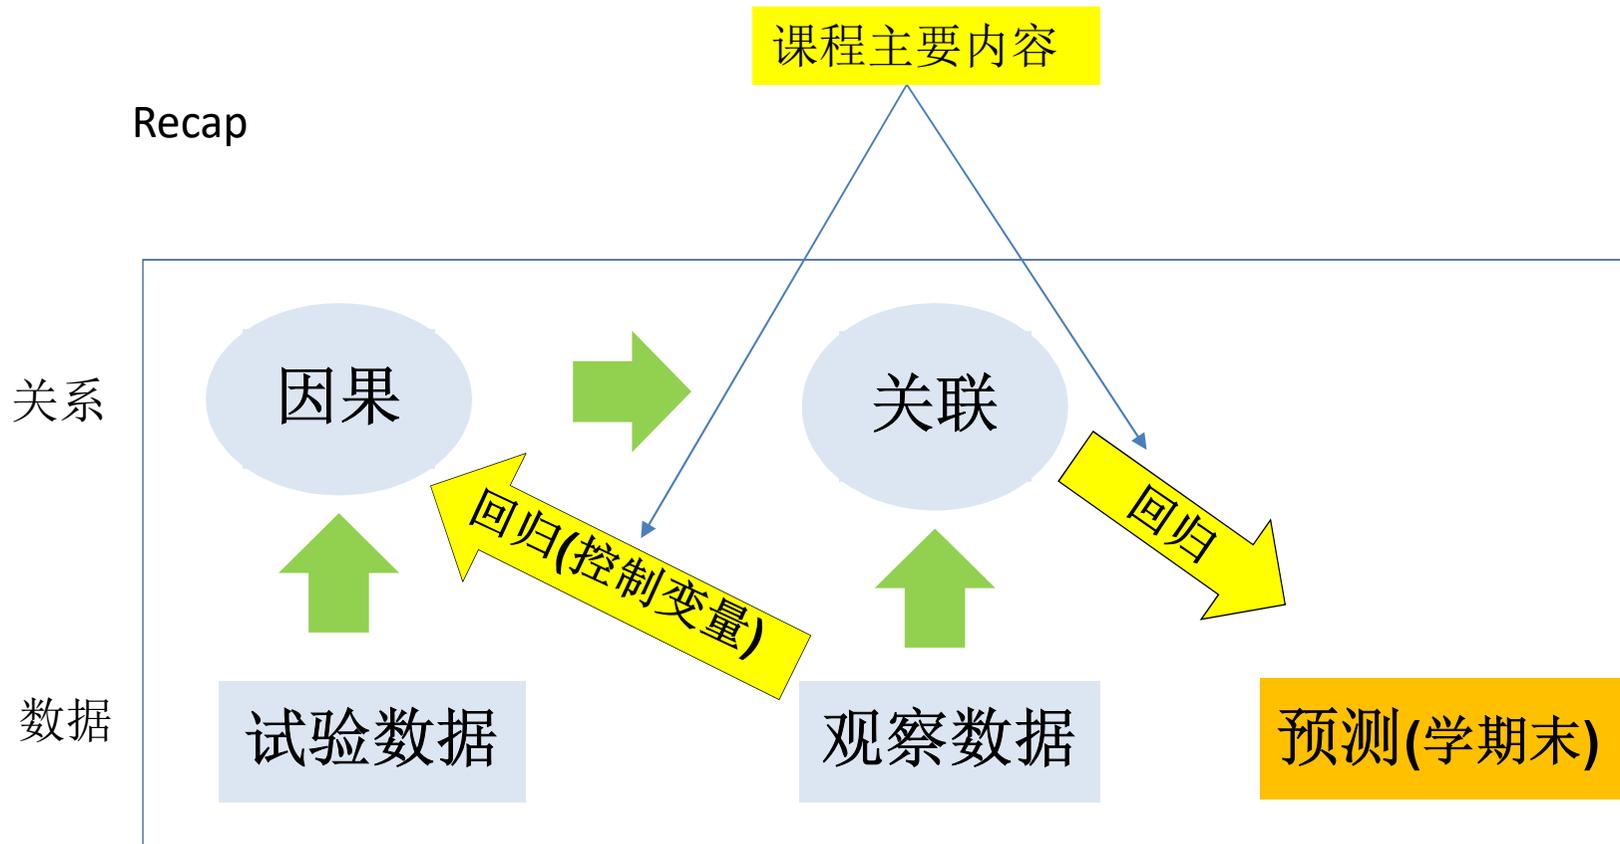


第二讲 相关系数与偏相关系数

2022.9.9

问题: 样本相关系数 $r_{xy} = 0.3$ 是否足够大, 是否表明 x 和 y 相关? 考察 $|\sqrt{nr}|$ 是否大于 1.96



研究两个随机变量 x, y 的关系，有两种常见策略

- 相关系数度量：无模型，两个变量地位相同、对称。最常用的是Pearson相关系数，还有非参数的Kendall's tau, Spearman's rho.
- 简单线性回归模型： $y = a + bx + \varepsilon$, b 与相关系数成正比， x, y 地位不对称。

其中第一种方式给出一个数字度量，简单明了，但缺少细节；第二种方式给出变量关系的显式表达。

研究给定/控制其它变量 \mathbf{z} 的条件下，两个随机变量 x, y 的关系：

- 偏相关系数度量：无模型， x, y 地位不对称。类似于Pearson相关系数（未见过Kendall's tau, Spearman's rho对应版本）。
- 多重线性回归模型： $y = a + bx + \mathbf{c}^T \mathbf{z} + \varepsilon$, b 与偏相关系数成正比。 y 为主（响应）， x, \mathbf{z} 是解释变量/自变量/预测变量。

今天回顾相关系数，并介绍三元情形下的偏相关系数

Pearson相关系数

Pearson相关系数，它度量的是两个随机变量之间的线性相关程度。相关系数的概念和初始定义由Galton提出，但深入的研究和推广属于 Pearson。

相关系数

随机变量 x, y 的(总体)Pearson相关系数: $\rho_{xy} = \frac{\text{cov}(x, y)}{\sqrt{\text{var}(x)}\sqrt{\text{var}(y)}}$

样本相关系数

样本 $(x_1, y_1), \dots, (x_n, y_n)$ 的 Pearson 样本相关系数:

$$r_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}} \hat{=} \frac{s_{xy}}{\sqrt{s_{xx}s_{yy}}},$$

其中 $s_{xy} = \sum (x_i - \bar{x})(y_i - \bar{y})$, $s_{xx} = \sum (x_i - \bar{x})^2$.

性质: $|\rho_{xy}| \leq 1, |r_{xy}| \leq 1$ (Cacuhy - Schwartz不等式).

约定:

小写字母: 随机变量

小写黑体: 向量

大写字母: 矩阵

记 $\mathbf{x} = (x_1, \dots, x_n)^\top$, $\mathbf{y} = (y_1, \dots, y_n)^\top$, 它们的中心化记为:

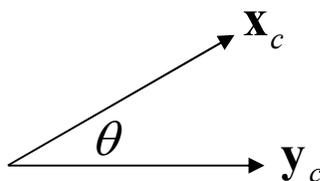
$$\mathbf{x}_c = (x_1 - \bar{x}, \dots, x_n - \bar{x})^\top = \mathbf{x} - \mathbf{1}\bar{x},$$

$$\mathbf{y}_c = (y_1 - \bar{y}, \dots, y_n - \bar{y})^\top = \mathbf{y} - \mathbf{1}\bar{y}.$$

样本相关系数
度量相似性

Pearson 相关系数度量了中心化向量之间的相似性/角度:

$$r_{xy} = \frac{\mathbf{x}_c^\top \mathbf{y}_c}{\|\mathbf{x}_c\| \cdot \|\mathbf{y}_c\|} = \left(\frac{\mathbf{x}_c}{\|\mathbf{x}_c\|} \right)^\top \left(\frac{\mathbf{y}_c}{\|\mathbf{y}_c\|} \right) = \cos(\theta_{\mathbf{x}_c \mathbf{y}_c}).$$



高尔顿定义的相关系数: $g = \frac{\sum x_i y_i}{\sqrt{\sum x_i^2} \sqrt{\sum y_i^2}}$.

卡尔.皮尔逊 (Karl Pearson, 1857-1936)



卡尔.皮尔逊，英国数学家，现代统计的创始人(以1900年的皮尔逊卡方检验为标志)。他是高尔顿的门徒和传记作者。现代统计学的奠基人。

- 1901年他和Galton, Weldon 一起创办了第一份统计杂志Biometrika;
- 1925年创办了优生学/遗传学杂志*Annals of Eugenics* (后改名为*Annals of Human Genetics*)。
- 1911年在伦敦大学学院 (UCL) 建立了世界上第一个(生物)统计系。

生物统计: biostatistics, 与人有关的统计, 可能翻译为医学统计更恰当

主要贡献: 相关系数, 矩方法, p 值, Pearson卡方检验, 主成分分析, Pearson分布族.

虚线框内
容不要求
掌握

样本均值的期望、方差、分布相对容易获得，但样本方差、相关系数等二阶统计量的期望、方差、分布通常较难计算，即使假设正态总体也是如此。

样本均值、 样本方差的 期望和方差

总体均值 μ ，方差 σ^2 ，样本均值 \bar{x} ，样本方差 s^2 ，样本量 n ，则

$$E(\bar{x}) = \mu, \text{var}(\bar{x}) = \sigma^2 / n;$$

$$E(s^2) = \sigma^2, \text{var}(s^2) = \frac{1}{n} \left(E(x - \mu)^4 - \frac{n-3}{n-1} \sigma^4 \right)$$

如果总体是正态分布 $N(\mu, \sigma^2)$ ，则 $\text{var}(s^2) = 2\sigma^4 / (n-1)$ 。

样本相关系 数的期望和 方差

如果总体是二元正态，则基于简单随机样本(样本量 n)的样本相关系数的均值和方差为

$$E(r) = \rho \left[1 - \frac{(1-\rho^2)}{2n} + O\left(\frac{1}{n^2}\right) \right], \quad \text{var}(r) = \frac{(1-\rho^2)^2}{n-2} + O\left(\frac{1}{n^2}\right),$$

由此得到 ρ 的偏差更小的估计 $r^* = r + \frac{r(1-r^2)}{2n}$; r 的方差的估计 $\widehat{\text{var}}(r) = \frac{(1-r^2)^2}{n-2}$ 。

(参见Lehmann《点估计理论》)

相关性的精确检验

为了求 r 的分布，我们需如下引理

引理1. 假设随机向量 \mathbf{x} 的分量 x_1, \dots, x_n $iid \sim N(0,1)$, 记作 $\mathbf{x} \sim N_n(\mathbf{0}, I_n)$, 则
(1) 对任何常数向量 $\mathbf{a} \in R^n, \|\mathbf{a}\|=1$, 则 $\mathbf{a}^T \mathbf{x} \sim N(0,1)$, $\|\mathbf{x}\|^2 - (\mathbf{a}^T \mathbf{x})^2 \sim \chi_{n-1}^2$,
两者独立, 且

$$\sqrt{n-1} \frac{\mathbf{a}^T \mathbf{x}}{\sqrt{\|\mathbf{x}\|^2 - (\mathbf{a}^T \mathbf{x})^2}} \sim t_{n-1}$$

(2) $\|\mathbf{a}\|=\|\mathbf{b}\|=1, \mathbf{a}^T \mathbf{b}=0$, 则 $\sqrt{n-2} \frac{\mathbf{a}^T \mathbf{x}}{\sqrt{\|\mathbf{x}\|^2 - (\mathbf{a}^T \mathbf{x})^2 - (\mathbf{b}^T \mathbf{x})^2}} \sim t_{n-2}$

证明（经典方法）：(1)构造 $n \times n$ 正交矩阵 A ，第一行为 \mathbf{a}^\top （其它行随意），

令 $\mathbf{y} = A\mathbf{x} = \begin{pmatrix} \mathbf{a}^\top \mathbf{x} \\ * \\ y_n \end{pmatrix}$ 记作 $\begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}$ ，可以证明 $y_1, y_2, \dots, y_n \text{ iid} \sim N(0,1)$ ，即 $\mathbf{y} \sim N_n(\mathbf{0}, I_n)$ 。

注意

(a) $y_1 = \mathbf{a}^\top \mathbf{x} \sim N(0,1)$,

(b) 由 $\|\mathbf{x}\|^2 = \|\mathbf{y}\|^2 \Rightarrow \|\mathbf{x}\|^2 - (\mathbf{a}^\top \mathbf{x})^2 = \|\mathbf{y}\|^2 - y_1^2 = y_2^2 + \dots + y_n^2 \sim \chi_{n-1}^2$,

且 $\|\mathbf{x}\|^2 - (\mathbf{a}^\top \mathbf{x})^2$ 只与 y_2, \dots, y_n 独立，因而与 $\mathbf{a}^\top \mathbf{x} = y_1$ 独立

(c) 由t分布的定义知

$$\sqrt{n-1} \frac{\mathbf{a}^\top \mathbf{x}}{\sqrt{\|\mathbf{x}\|^2 - (\mathbf{a}^\top \mathbf{x})^2}} = \frac{y_1}{\sqrt{(y_2^2 + \dots + y_n^2)/(n-1)}} \sim t_{n-1}.$$

(2)的证明类似。

正态假设 下相关系 数的分布

命题1(正态总体). 假设 $(x_1, y_1), \dots, (x_n, y_n)$ iid 服从二元正态分布, 则当 $\rho_{xy} = 0$ 时, 有

$$t = \sqrt{n-2} \frac{r}{\sqrt{1-r^2}} \sim t_{n-2}$$

注: 我们用引理1进行(经典的)证明。

以后将在线性模型框架下更简单地证明命题1

命题1的证明: 当 $\rho_{xy} = 0$ 时, y_i 与 x_i 独立, 且 $y_i \sim$ 一元正态, 因为 r 平移刻度变换下不变, 我们不妨设 $y_i \sim N(0,1)$, 即 $\mathbf{y} = (y_1, \dots, y_n)^\top \sim N(0, I_n)$ 。

因为 $r = \frac{s_{xy}}{\sqrt{s_{xx}s_{yy}}}$, 所以

$$\frac{r}{\sqrt{1-r^2}} = \frac{s_{xy} / \sqrt{s_{xx}}}{\sqrt{s_{yy} - s_{xy}^2 / s_{xx}}} = \frac{s_{xy} / \sqrt{s_{xx}}}{\sqrt{\sum y_i^2 - n\bar{y}^2 - (s_{xy} / \sqrt{s_{xx}})^2}},$$

下面我们在给定 x_1, \dots, x_n 的条件下计算 t 的分布。

其中，分子项

$$s_{xy} / \sqrt{s_{xx}} = \sum (x_i - \bar{x})(y_i - \bar{y}) / \sqrt{s_{xx}} = \sum (x_i - \bar{x})y_i / \sqrt{s_{xx}} = \mathbf{a}^\top \mathbf{y},$$

其中 $\mathbf{a} = (x_1 - \bar{x}, \dots, x_n - \bar{x})^\top / \sqrt{s_{xx}}$, $\|\mathbf{a}\| = 1$ 。

另外, $\sqrt{n}\bar{y} = \mathbf{b}^\top \mathbf{y}$, 其中 $\mathbf{b} = (1, \dots, 1)^\top / \sqrt{n}$, $\|\mathbf{b}\| = 1$, 且 $\mathbf{a} \perp \mathbf{b}$ 。

给定 x_1, \dots, x_n 条件下 \mathbf{a} , \mathbf{b} 皆为常数向量, 由引理 1,

$$\sqrt{n-2} \frac{r}{\sqrt{1-r^2}} \Big|_{x_1, \dots, x_n} = \sqrt{n-2} \frac{\mathbf{a}^\top \mathbf{y}}{\sqrt{\sum y_i^2 - (\mathbf{b}^\top \mathbf{y})^2 - (\mathbf{a}^\top \mathbf{y})^2}} \Big|_{x_1, \dots, x_n} \sim t_{n-2}$$

该分布与条件无关, 所以 $\sqrt{n-2} \frac{r}{\sqrt{1-r^2}} \sim t_{n-2}^\circ$ 。

下面考虑相关系数的检验。一般假设检验或显著性检验的大致步骤：

- 选一个待检验参数的估计量，
- 适当变换 / 标准化构建检验统计量，使得它在原假设下服从一个标准的分布（与数据无关、与参数无关）
- 若实际计算得到的检验统计量在该标准分布的尾端（小概率），拒绝原假设。

相关性检验原假设 $H_0: \rho_{xy} = 0$ 。当 $|r|$ 较大 ($\Leftrightarrow |t|$ 较大) 时，拒绝原假设。我们以 t 作为检验统计量。是否可用 r 作为检验统计量？

可以，但其原假设下的分布不常见，而 $t \sim t_{n-2}$ 分布，是一个常见的标准分布（历史原因，Fisher和Student没有定义 r 的分布）。

假设实际的 $|t|$ 值较大，而从 t_{n-2} 分布得到一个处于尾端的值的概率较小（比如 < 0.05 ）。因为小概率事件难以发生，所以“ H_0 下 $t \sim t_{n-2}$ 分布”这一结论很可能是错的，从而原假设很可能不成立。

相关性的 精确检验

若 $(x_1, y_1), \dots, (x_n, y_n)$ iid, 假设 $y_i | x_i \sim N(a + bx_i, \sigma^2)$ 。

原假设为 $H_0 : \rho_{xy} = 0$, 检验统计量 $t = \sqrt{n-2} \frac{r}{\sqrt{1-r^2}}$,

- 当 $|t| \geq t_{n-2}(\alpha/2)$ 时, 在 α 水平下否定原假设.
- 对于给定的检验统计量 t 的数值, p 值 = $P(|T| \geq |t|)$, $T \sim t_{n-2}$

注: t 检验的表达式说明, 在评价 r 的大小的时候, 也要考虑样本量 n .

例1. 样本相关系数 $r_{xy} = 0.3$, $H_0 : \rho_{xy} = 0$, 样本相关系数是否足够大到拒绝原假设? $n = 20, 50$ 两种情形下分别检验。

假设数据来自于二元正态分布, 应用精确检验,

若 $n = 20, t = 1.334$, $p = P(|t_{18}| \geq 1.33) = 0.199$, 不显著;

若 $n = 50, t = 2.179$, $p = P(|t_{48}| \geq 2.179) = 0.034$, 显著。

相关性的大样本检验

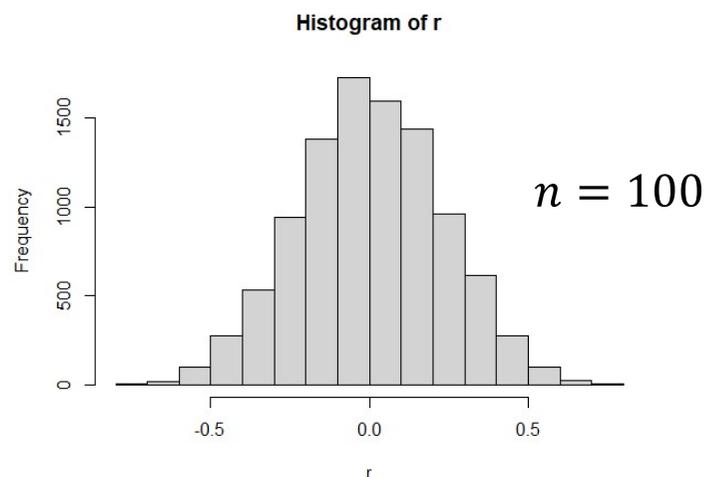
相关系数的渐近分布

命题2. 若 $(x_1, y_1), \dots, (x_n, y_n)$ 服从二元正态, 总体相关系数为 $\rho = \rho_{xy}$, 样本相关系数为 r , 则有渐近分布

$$\sqrt{n} (r - \rho) \xrightarrow{d} N(0, (1 - \rho^2)^2), \text{当 } n \rightarrow \infty.$$

证明: 略 (不要求)。

注: 当 n 足够大时, 近似地 $r \sim N(\rho, (1 - \rho^2)^2 / n)$,
 $\rho = 0$ 时, 近似地 $r \sim N(0, 1/n)$.



相关性的 大样本检验

二元正态总体假设下，零假设 $H_0: \rho_{xy} = 0$ 的检验统计量取为

$$z = \sqrt{n} \times r,$$

- 检验准则为：当 $|z| \geq z_{\alpha/2}$ 时在 α 水平下拒绝原假设。
- 给定 z ， p 值 $\approx P(|X| > |z|) = 2(1 - \Phi(|z|))$, $X \sim N(0,1)$ 。

注1: 以 r 与样本量 n 的综合，即 \sqrt{nr} ，判定相关与否。

注2: 等价地，可用卡方检验： $z^2 = nr^2$ ，原假设下近似服从 χ_1^2

例1(续). 大样本检验

若 $n = 20, z = \sqrt{nr} = 1.34, p = P(|N(0,1)| \geq 1.34) = 0.179$ ，不显著

若 $n = 50, z = 2.12, p = P(|N(0,1)| \geq 2.12) = 0.034$ ，显著。

结果与精确检验类似，事实上，除非样本量 n 很小，通常大样本检验和精确检验的结果相差不大。

相关性的置换检验(精确检验)

在总体分布不是正态的情况下，难以求得零假设下t或z的精确分布或大样本渐近分布。相关性的置换检验是一种替代方法，它对数据模型不做任何假设，应用广泛。缺点是需要大量置换，计算耗时，且功效有时候偏低。

置换检验

原始数据： $(x_1, y_1), \dots, (x_n, y_n) \Rightarrow$ 相关系数 r

随机置换： $(x_{i_1}, y_1), \dots, (x_{i_n}, y_n) \Rightarrow$ 相关系数 $r^{(per)}$ ，

其中 (i_1, i_2, \dots, i_n) 是 $(1, 2, \dots, n)$ 的一个随机置换

反复置换 N 次，得到置换数据的相关系数 $r_k^{(per)}$, $k = 1, \dots, N$

p 值 = $\#\{k : |r_k^{(per)}| \geq |r|\} / N$.

置换方法中相关性度量不限于Pearson相关系数，其它可选的相关性统计量包括Pearson卡方，非参数的Kenadall's tau 和 Spearman's rho等。

相关系数的置信区间

虚线框内的内容可忽略

命题2说明，当 n 较大时， r 近似地服从正态分布： $r \sim N(\rho, (1-\rho^2)^2/n)$ ，其方差与均值 ρ 有关，我们称这种现象为“方差不稳定”。基于该分布，我们可以构建 ρ 的置信水平为 $1-\alpha$ 置信区间：

$$\left\{ \rho: \left| \frac{r - \rho}{(1 - \rho^2) / \sqrt{n}} \right| \leq z_{\alpha/2} \right\} \quad (1)$$

该区间可能是两个区间的并集，其覆盖率不够精确。

Fisher's z-变换是 r 的变换，其渐近分布是方差稳定的正态分布，且比 r 的分布更接近正态（更快地收敛到正态）

Fisher变换

样本相关系数 r 的 Fisher's z - 变换 (方差稳定化变换) :

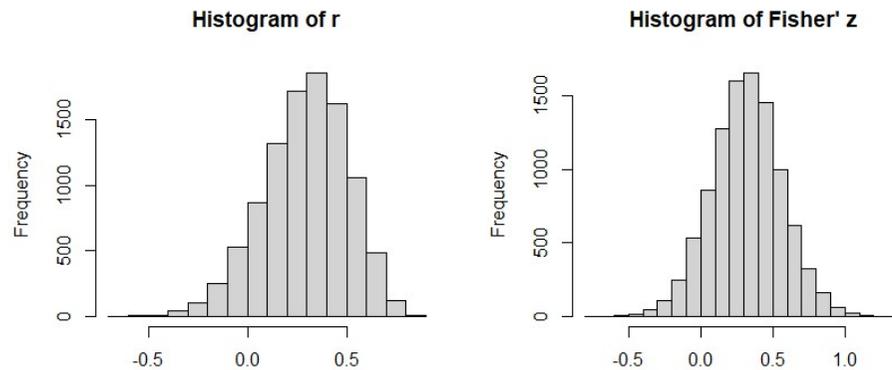
$$z = \operatorname{atanh}(r) = \frac{1}{2} \log \left(\frac{1+r}{1-r} \right), \text{ 反双曲正切函数}$$

双曲正切函数：
$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

命题3. 假设 $(x_1, y_1), \dots, (x_n, y_n)$ iid \sim 二元正态,
设 $\rho = \rho_{xy}$ 为总体相关系数, r 为样本相关系数, 则

$$\sqrt{n} [\operatorname{atanh}(r) - \operatorname{atanh}(\rho)] \xrightarrow{d} N(0,1), \text{ 当 } n \rightarrow \infty$$

证明: 基于命题2的结果, 应用 *delta* 方法。



Fisher's z 的分布比 r 更快地收敛到正态分布.

模拟实验：
对比 r , z 的
分布

$n = 20$ 。从二元正态分布($\rho = 0.3$)反复抽样 $N=10000$ 次, 每次都计算 r 和Fisher变换 z 。 N 个 r , z 的直方图如上页所示。
代码如下：

```
n=20
rho=0.3
N=10000
r=NULL
for (i in 1:N){
  x=rnorm(n)
  y=rho*x+sqrt(1-rho^2)*rnorm(n)
  corr=cor(x,y)
  r=c(r,corr)
}
z=(log(1+r)-log(1-r))/2
par(mfrow=c(1,2))
hist(r, main="Histogram of r",sub="")
hist(z, main="Histogram of Fisher' z",sub="")
```

基于Fisher's z 的置信区间

基于Fisher变换的 ρ 的置信水平为 $1-\alpha$ 的置信区间：

$$\left\{ \rho : \sqrt{n} \left| \operatorname{atanh}(r) - \operatorname{atanh}(\rho) \right| \leq z_{\alpha/2} \right\}, \quad (2)$$

其中 $z_{\alpha/2} = \Phi^{-1}(1-\alpha/2), 0 < \alpha < 1$.

注1：基于Fisher变换构造的置信区间(2)比基于r的区间(2)表现更好（更精确的覆盖率或更短的长度）。

注2：你可通过模拟实验，对比基于r和基于z的渐近分布构造的置信区间。

注3：基于Fisher变换的检验也比基于r的z检验表现更好。

两样本t检验和Pearson卡方检验都与相关系数有关

两样本t检验

假设第一组 $y_1, \dots, y_{n_0} \text{ iid } \sim N(\mu_0, \sigma^2)$, 第二组 $y_{n_0+1}, \dots, y_{n_0+n_1} \text{ iid } \sim N(\mu_1, \sigma^2)$,

$$\text{记 } s^2 = \frac{1}{n-2} \left(\sum_{i=1}^{n_0} (y_i - \bar{y}_0)^2 + \sum_{i=n_0+1}^{n_0+n_1} (y_i - \bar{y}_1)^2 \right), \quad n = n_0 + n_1,$$

$$H_0: \mu_1 = \mu_0, \quad \text{两样本 } t \text{ 检验: } t_{\text{twosample}} = \frac{\bar{y}_1 - \bar{y}_0}{\sqrt{(1/n_1 + 1/n_0)s^2}} \stackrel{H_0}{\sim} t_{n_0+n_1-2}.$$

事实(作业): 以 x_i 表示第 i 个样本的组号, 比如第一组的 $x_i = 0$, 第二组 $x_i = 1$, 记 r 为 $(x_i, y_i), i = 1, 2, \dots, n$ 的样本相关系数, 则两样本t检验统计量 $t_{\text{twosample}} = \sqrt{n-2}r/\sqrt{1-r^2}$

2x2列联表的卡方检验

2x2列联表:

		y		总计
		1	0	
x	1	a	b	n_1
	0	c	d	n_0
总计		m_1	m_0	n

$$\text{Pearson卡方: } X^2 = \frac{n(ad - bc)^2}{n_1 n_0 m_1 m_0},$$

原假设下(x, y 独立), 近似地 $X^2 \sim \chi_1^2$.

事实（作业）：假设二元随机样本 $(x_i, y_i), i = 1, 2, \dots, n$ 中 x_i, y_i 都是0-1伯努利变量， r 为样本相关系数，则Pearson卡方 $X^2 = nr^2$.

置换检验、上页作业以及hw1第6题表明：对于二元正态相独立性检验，两正态均值齐一性检验，以及二元伯努利独立性检验，两正态概率齐一性检验等问题，**精确检验都可统一为置换检验，大样本检验都可统一为卡方检验** $z^2 = nr^2 \sim_{H_0} \chi_1^2$

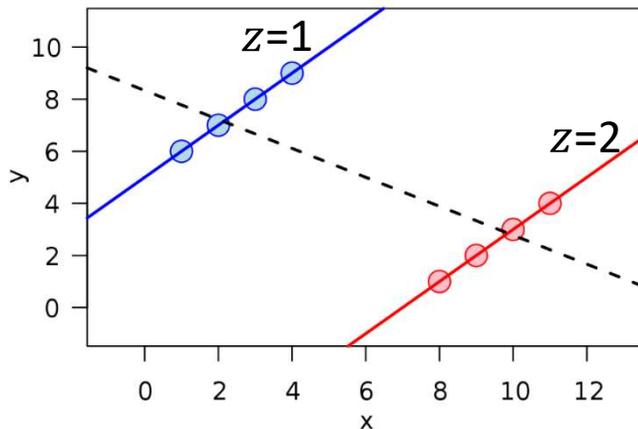
	二元正态	两正态	两二项 (齐一性检验)	二元伯努利 (独立性检验)
数据,模型	$(x_i, y_i), i = 1, \dots, n \sim$ 二元正态, 相关系数 ρ	$y_1, \dots, y_{n_1} \sim N(\mu_1, \sigma^2)$ $y_{n_1+1}, \dots, y_n \sim N(\mu_2, \sigma^2)$ $n = n_1 + n_2$ 两组的标号 $x_i = 1$ 或 0	$y_1, \dots, y_{n_1} \sim B(1, p_1)$ $y_{n_1+1}, \dots, y_n \sim B(1, p_2)$ $n = n_1 + n_2$ 两组的标号 $x_i = 1$ 或 0	$(x_i, y_i), i = 1, \dots, n$ 服从二元伯努利, 相关系数 ρ
原假设	$H_0: \rho=0$ (x, y 独立)	$H_0: \mu_1=\mu_2$	$H_0: p_1=p_2$	$H_0: \rho=0$ (x, y 独立)
下述精确检验（基本上）等价于置换检验				
精确检验 /置换检验	$t = \frac{\sqrt{n-2} r}{\sqrt{1-r^2}} \sim t_{n-2}$	$t = \frac{(\bar{y}_1 - \bar{y}_2)}{\sqrt{\left(\frac{1}{n_1} + \frac{1}{n_2}\right) s^2}}$ $= \frac{\sqrt{n-2} r}{\sqrt{1-r^2}} \sim t_{n-2}$	Fisher's exact test	Fisher's exact test
原假设下近似地, $z^2 = nr^2 \sim \chi_1^2$				
大样本检验 /卡方检验	$t \approx z$ $= \sqrt{nr} \sim N(0,1)$	$t \approx z = \sqrt{nr} \sim N(0,1)$	$z = \frac{(\bar{p}_1 - \bar{p}_2)}{\sqrt{\left(\frac{1}{n_1} + \frac{1}{n_2}\right) p(1-p)}}$ $= \sqrt{nr} \sim N(0,1)$	Pearson卡方 $X^2 = nr^2 \sim \chi_1^2$

本课程将上述检验拓广到控制干扰因素的情形。

Pearson卡方检验

辛普森悖论(Simpson's paradox)

辛普森悖论是一种组内趋势与各组合并后趋势不同或相反的现象。这里组别是干扰因素，分组意味着控制干扰因素。如下图，组内负相关（实线），所有数据呈负相关（虚线）：分组变量 z 既与 x 有关，也与 y 有关，是个干扰因素。 https://en.wikipedia.org/wiki/Simpson%27s_paradox



不控制 z (虚线): $y = a + bx + \varepsilon$

控制 z (实线): $y = a + bx + cz + \varepsilon$

回归分析中辛普森悖论描述的是这样的现象：在研究 y, x 的关系时，控制干扰因素 z 与不控制 z 时结果不一致。

例2. 加州大学Berkeley分校1973年研究生招生的女生录取率显著低于男生的录取率 44%。校方担心被控告存在女性歧视。但分别考察各个系的录取率，反而大部分是女生录取率高。这里我们构造一个简单例子演示这种现象（分母为申请人数，分子为录取人数）：

1系录取率： $4/10$ （男） $< 1/2$ （女）

2系录取率： $2/10$ （男） $< 5/20$ （女）

合并两个系： $(4 + 2)/(10 + 10)$ （男） $> (1 + 5)/(2 + 20)$ （女）

各个系录取过程中有均衡男女人数的趋势：如果女生申请人数较少，则倾向于多录取女生，录取率就会偏高。

参考：

1. Bickel, Hammel and O'Connell (1975) Sex Bias in Graduate Admissions: Data From Berkeley". *Science*. 187 (4175): 398–404.
2. Freedman, Pisani, Purves (2007) *Statistics*, Norton P17. 第一章下载英文、中文版:
x=2.5, 2.6

Berkeley实际数据如下：女生录取率 35%，男生录取率 44%（p值=0）。

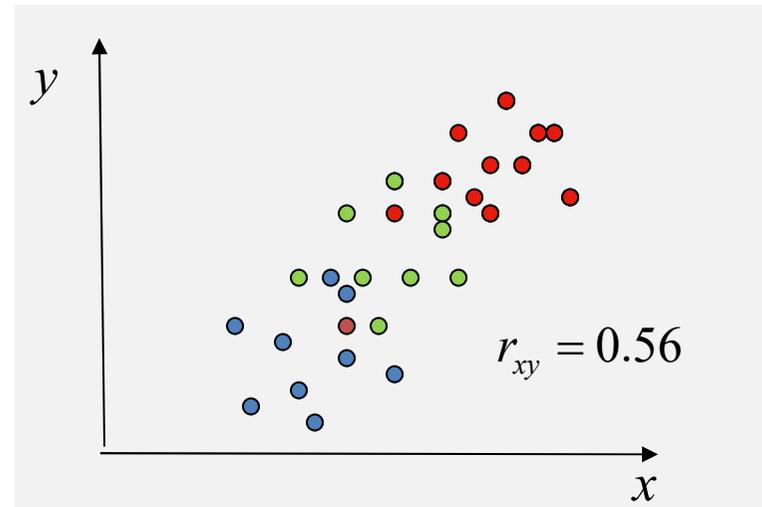
	所有人		男生		女生	
	申请人数	录取率	申请人数	录取率	申请人数	录取率
总计	12,763	41%	8442	44%	4321	35%

但从各个系的数据来看，并没有发现明显的歧视证据，例如6个最大的系的录取情况如下，多数系女生的录取率高于男生（红色）。

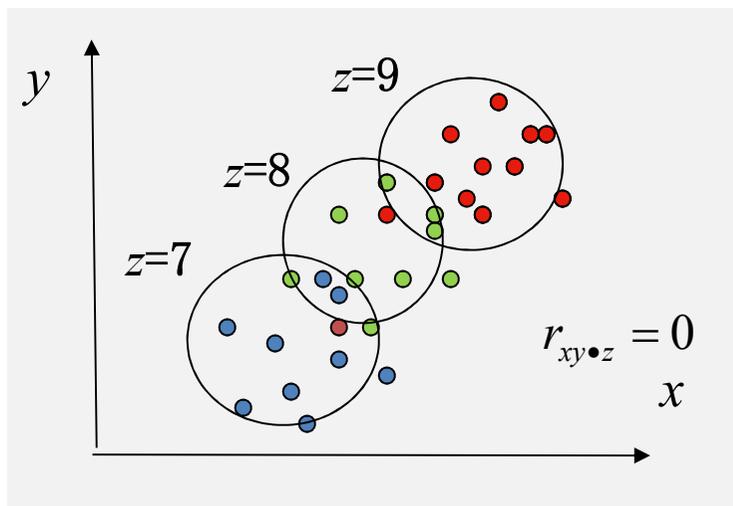
系	所有人		男生		女生	
	申请人数	录取率	申请人数	录取率	申请人数	录取率
A	933	64%	825	62%	108	82%
B	585	63%	560	63%	25	68%
C	918	35%	325	37%	593	34%
D	792	34%	417	33%	375	35%
E	584	25%	191	28%	393	24%
F	714	6%	373	6%	341	7%

Bickel et al. (1975)认为多数女生申请了竞争比较激烈的专业（C,D,E,F），拉低了女生的总录取率。女生录取率很高的两个系（A,B,工程、计算机）女生申请人数偏少，对女生总体录取率影响不大。

例3. 调查100名 7-9岁儿童 ($z=7, 8, 9$), 发现阅读能力 y 与身高 x 正相关, 相关系数 $r_{xy} = 0.56$ (右图).



但如果考虑年龄组, $z = 7, 8, 9$, 则发现各个组内 x, y 不相关 (下图)



x, y 都随年龄增加而增加, 使得 x, y 呈现出正相关现象。年龄 z 是干扰因素。

控制年龄, 即给定年龄 z 时, x 与 y 条件独立: $P(x, y|z) = P(x|z)P(y|z)$

如何控制 z ?

- (1) 我们在线性回归模型中添加 z 项
- (2) 计算控制 z 条件下 x, y 的偏相关系数。两者等价。

偏相关系数(partial correlation coefficient)

三元情形下的偏相关系数

当 x, y, z 都是一维随机变量时, 相关系数矩阵 $R = \begin{pmatrix} 1 & \rho_{xy} & \rho_{xz} \\ \rho_{xy} & 1 & \rho_{yz} \\ \rho_{xz} & \rho_{yz} & 1 \end{pmatrix}$,

其中 ρ_{ab} 代表随机变量 a, b 的Pearson相关系数, 则偏相关系数 $\rho_{xy \cdot z}$ 定义为

$$\rho_{xy \cdot z} = \frac{\rho_{xy} - \rho_{xz}\rho_{yz}}{\sqrt{1 - \rho_{xz}^2} \sqrt{1 - \rho_{yz}^2}}$$

注1: $|\rho_{xy \cdot z}| \leq 1$

这是因为 $\det(R) \geq 0 \Rightarrow 1 - \rho_{xy}^2 - \rho_{yz}^2 - \rho_{zx}^2 + 2\rho_{xy}\rho_{xz}\rho_{yz} \geq 0 \Leftrightarrow |\rho_{xy \cdot z}| \leq 1$

注2: 后面我们将会定义一般情况下(\mathbf{z} 为向量)的偏相关系数。

例3（续）. 阅读能力(y)、身高(x)和年龄(z)的相关系数矩阵如下，求偏相关系数 $r_{xy \cdot z}$ ，检验阅读与身高是否相关 ($n=100$)。

$$\begin{array}{c} \text{x身高} \quad \text{y阅读} \quad \text{z年龄} \\ \text{x} \\ \text{y} \\ \text{z} \end{array} \begin{pmatrix} 1 & 0.56 & 0.8 \\ 0.56 & 1 & 0.7 \\ 0.8 & 0.7 & 1 \end{pmatrix}$$

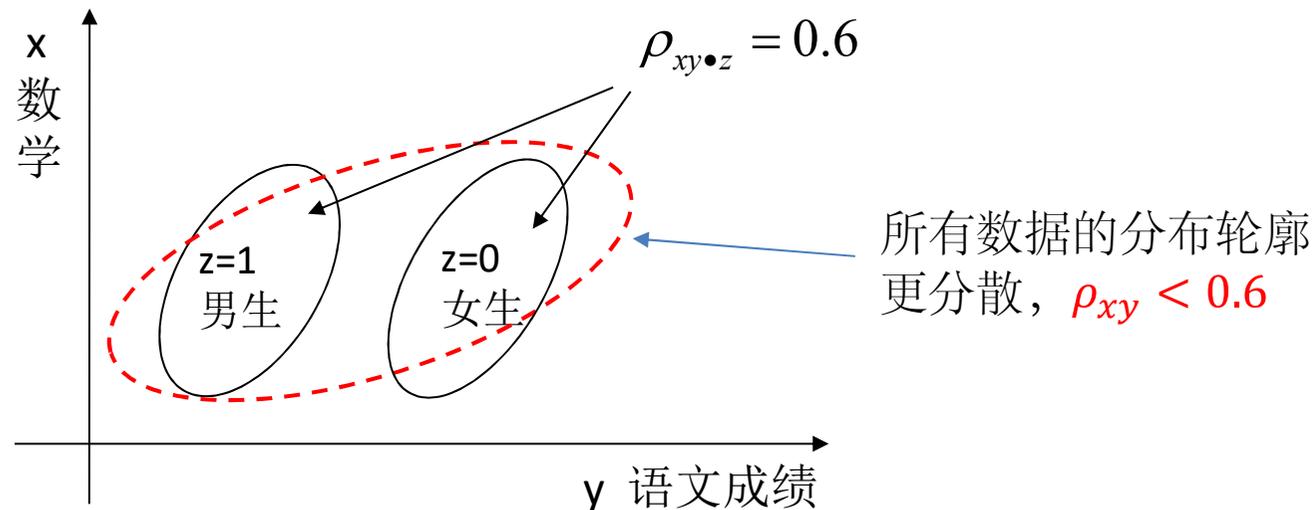
$$r_{xy \cdot z} = \frac{r_{xy} - r_{xz}r_{yz}}{\sqrt{1-r_{xz}^2} \sqrt{1-r_{yz}^2}} = \frac{0.56 - 0.8 \times 0.7}{\sqrt{1-0.8^2} \sqrt{1-0.7^2}} = 0$$

即，控制年龄之后，阅读能力和身高相关系数为0。

例4. 高中男、女生的数学成绩 x 与语文成绩 y 的相关系数都为0.6, 假设男女生数学成绩没有差异, 但女生的语文成绩要好于男生。如果男女生混合在一起, 得到的相关系数是大于、等于还是小于0.6?

以 $z = 1, 0$ 分别代表男、女。已知 $\rho_{xy \cdot z} = 0.6$, $\rho_{xz} = 0$ (数学与性别不相关)

$$\text{故 } 0.6 = \rho_{xy \cdot z} = \frac{\rho_{xy}}{\sqrt{1 - \rho_{yz}^2}} \geq \rho_{xy}$$



总结:

- 考察样本相关系数大小的时候也要考虑样本量。具体地，
 - $|t| = \left| \frac{\sqrt{n-2}r}{\sqrt{1-r^2}} \right| > t_{n-2}(\alpha/2)?$
 - $|z| = |\sqrt{nr}| > z(\alpha/2)?$

- 偏相关系数是控制干扰因素条件下的相关系数。

- 相关系数 \approx 简单回归（仅一个自变量）；
偏相关系数 \approx 多重回归（多个自变量）。