

## 前 言

1982 年美国大学生数学建模竞赛开始，1992 年我国全国大学生数学建模竞赛也开赛，之后数学模型、数学建模、数学实验课程应运而生，且越来越普及；国家统计局于 2008 年开展面向全国政府统计系统的职业技能竞赛活动——统计建模大赛。2009 年全国大学生统计建模竞赛也开赛了，2011 年国务院学位办将统计学提升为一级学科。这不仅仅是统计学的重要性和必要性所致，更是学科划分的科学性使然。理所当然统计模型、统计建模、统计实验课程也应该设置起来。

目前国内在统计专业开设统计模型课程和统计实验课程的很少，其中统计模型的部分内容在数学模型课程中有所涉及，统计实验的部分内容在数学实验课程中有所涉及，主要是数学软件应用。随着计算机的普及和统计软件的大力发展，SAS、SPSS、MINITAB、JMP、R、DPS、马克威等统计软件被广泛应用。2009 年，中国统计教育学会、中国现场统计研究会、中国数学会概率统计学会联合举办首届全国大学生统计建模大赛，共有来自全国 57 所大学的 334 支队伍参赛，其中包括北京大学、中国人民大学、南开大学等全国知名高校，之后的 5 年，我们在各类统计课程、课外科技活动中融入统计建模的思想和方法，2013 年第三届全国大学生统计建模大赛共有来自全国 103 所大学的 508 支队伍参赛；以多年从事统计专业教学实践来看，为使学生具备良好的应用统计的能力，我们仍感到有开设一门相关课程的必要，为此南京财经大学在新的《统计学专业培养方案（2010 级）》中，设立了《统计模型与统计实验》课程，并将它列为新的专业主干课之一（在每届二年级下学期开设），同时它也是一门创新课程。我校以前从未开过，国内极少学校有所涉及，可供参考模式少，因此这是一项具有挑战性的统计课程体系的教学改革，也必将促进其他许多相关课程的改革，特别是统计学专业课程的内容与体系结构改革和调整。由此看来，建设面向 21 世纪的新型课程《统计模型与统计实验》势在必行。

主讲、主编人王庚 1994—2007 年从事数学模型教学与应用，做大学生数学

包含很多 R 的入门资料、实用函数列表和更广泛的应用案例等。编程能力的高低取决于两个方面,一是对程序本身的认识;另一个是算法设计的技巧。对于前者,如果读者想更方便地了解 R 语言全貌,建议遵循如下步骤:(1)了解这个软件长什么样子;(2)找几个简单案例,知道这些程序大概长什么样子,大概是怎么运行的;(3)了解 R 语言的各种数据类型及其注意事项;(4)把一些常用的、实用的函数整理成列表,打印出来放在手边,作为参考手册之一;(5)有机会的话多处理一些实际问题。



Ross Ihaka



Robert Gentleman

图 1.1.14 R 开发者

## R 的下载和安装

### 1. R 的下载

- (1) 进入网站:<http://www.r-project.org>,点击其中的“download R”;
- (2) 如果是第一次进入 R 官网,并按上述点击,则网站会提示您选择一个下载镜像(Mirrors)。如果在国内的话,选择“China”下面的某个镜像就可以了;
- (3) 点击 Download R for windows,并按照提示进行后续操作,即可下载得到在 windows 操作系统上运行的 R 语言软件。如果需要其他操作系统的 R 软件,如 MacOS X 或 Linux 等,读者可以选择相应的链接。

### 2. R 的安装

这里以 R-2.14.0-win.exe 为例讲解 R 安装的过程。下载得到 R-2.14.0-win.exe 以后,双击它。在下图 1.1.15 中选择需要的语言,这里使用“中文(简体)”,点击“确定”,根据提示完成安装。

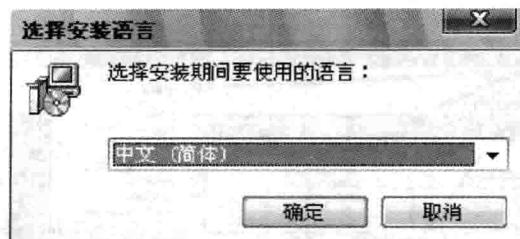


图 1.1.15 R 的安装

## R 的进入与界面认识

1. 双击桌面上的 R 图标(图 1.1.16), 进入 R 软件界面。



图 1.1.16 R 开始图标

2. 认识 R 界面

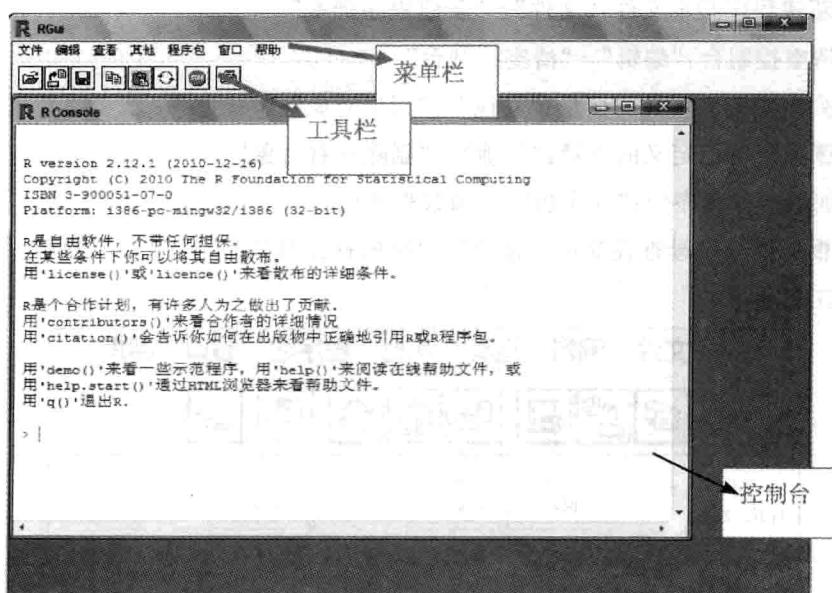


图 1.1.17 R 界面认识

特色,不过目前大家用得比较多的应算 Rstudio 软件<sup>①</sup>,这也是本书推荐的辅助工具。

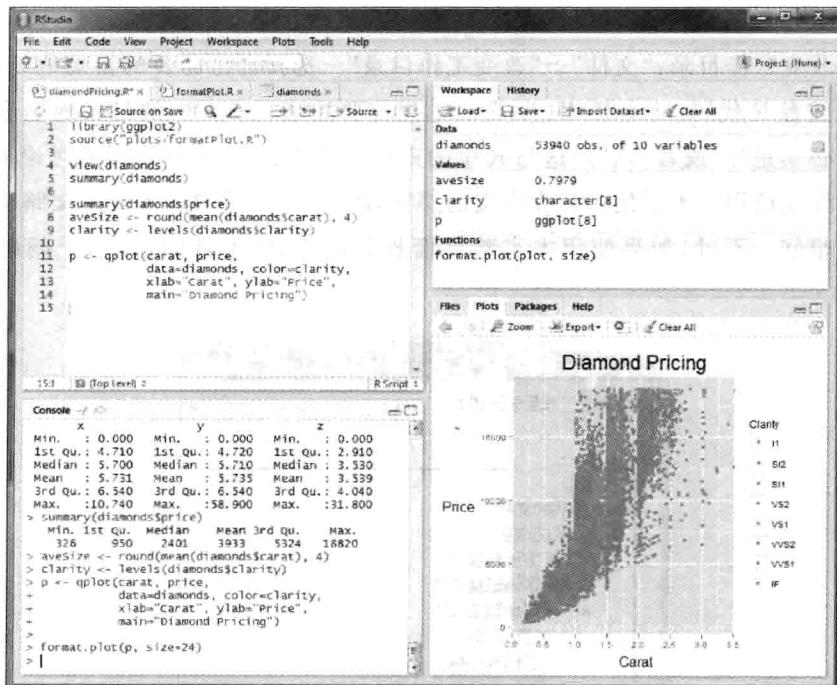


图 1.1.21 Rstudio 软件界面

按照其官网的介绍,Rstudio 是辅助用户进行 R 语言编程的一个集成开发环境(IDE, Integrated Development Environment)。与 R 软件类似,它是开源的、免费的,针对 Windows、Mac 或 Linux 不同操作系统有不同的版本。它可以直接在其官网上(<http://www.rstudio.com/>)下载。下载完毕并安装以后,它会自动识别计算机中已经装好的 R 软件,并自动与最新版本的 R 软件进行连接。当读者在 Rstudio 中输入命令,并点击 RUN 按钮,或者按 Ctrl+R 或按 Ctrl+Enter 以后,读者的命令就可以运行得到结果了。图 1.1.21 是 Rstudio 的一个界面。

在使用 Rstudio 过程中需要注意几个问题:(1)windows 系统的账户名称最好不要包含中文,否则软件自带的图形(Plot)显示区域可能不能正常工作。(2)windows 系统下可以手动将“.R”文件关联到 Studio。操作方法是,右击任意“.R”文

<sup>①</sup> 请读者注意,不是 R-studio,而是 Rstudio。这两个软件的用途是截然不同的。

件,选择“打开方式”,选择“默认程序”,找到 Rstudio,确定即可。使用 Rstudio 直接打开 R 程序文件以后,工作路径会自动指向该文件所在文件夹,无须再设置工作路径了。

## 1.3 统计科学基础

### R 语言案例

下面借用几个例子简单熟悉一下统计软件的编程过程;这些例子都是采用最基本的命令。由于读者可能对编程不是很熟悉,因此这里仔细讲解了每个程序的设计思路。

#### 【例 1.2】计算常用统计量

##### 1. 计算平均身高

(1)计算平均身高主要运用了 R 语言中求平均数的函数 mean(x)。其中的 x 是包含一系列数值的向量,在 R 中可根据 c() 函数生成向量。关于 R 语言的数据结构和其他常用统计函数的介绍,读者可以阅读本书的附录部分,或者访问本书对应的网站。

(2)新建一个脚本程序窗口(“问卷”—“新建脚本程序”),在打开的窗口中输入以下源程序,就可以计算得到他们的平均身高。

```
x=c(1.65,1.69,1.70,1.71,1.75)
mean(x)
```

(3)全选以上程序,按快捷键 Ctrl+R 运行以上程序,得到如下结果,均值为 1.7。

The screenshot shows the R Console window with the following content:

```
R Console
文件 编辑 其他 程序包 窗口 帮助
> setwd("E:/r/20110106-tongjixue") #改变工作目录
> x=c(1.65,1.69,1.70,1.71,1.75)
> mean(x)
[1] 1.7
>
```

##### 2. 计算调和平均数

假如某种蔬菜在早、中、晚市的每市斤的单价分别为 0.5 元、0.4 元、0.2 元,若

`rep()` 函数的标准结构为：

```
rep(x, times/each)
```

其中 `x` 表示一个数据向量, `each` 和 `times` 参数只能有一个。`each` 的值只能是一个非负数值, 表示对 `x` 中每个元素重复 `each` 次以后, 再把重复以后的片段连接起来。`times` 参数稍复杂点, 如果 `times` 的值和 `x` 包含的元素个数相同, 则表示对 `x` 的每个元素重复相应次数以后, 再把片段连接起来; 如果 `times` 的值只包含一个数值, 则表示把 `x` 这个向量整体重复 `times` 次以后, 再把每个片段连接起来。通常默认是 `times` 参数。

具体可以看下面的一个例子。

```
x1=c(17,18,19,20,21)    # 年龄
x2=c(5,8,26,9,2)          # 学生人数
y1=rep(x1,x2)
y1
median(y1)                # 直接用函数 median

# 关于 rep() 的一个例子
x=c(1,2,3)
rep(x,times=c(3,2))       # times 长度和 x 不同, 会出错哦
rep(x, each=3)
rep(x,each=c(3,2,1))      # 只识别第一个元素 3
rep(x,times=3)             # 把整体重复 3 遍
rep(x,times=c(3,2,1))     # 对 x 的每个元素重复不同次数
```

(3) 全选以上程序, 按快捷键 `Ctrl+R` 运行以上程序, 得到如下结果。

```
R Console
文件 编辑 其他 程序包 窗口 帮助
> x1=c(17,18,19,20,21)    # 年龄
> x2=c(5,8,26,9,2)
> y1=rep(x1,x2)
> y1
[1] 17 17 17 17 17 18 18 18 18 18 18 18 19 19 19 19 19 19 19 19 19 19 19 19 19 19 19 19 19 19
[25] 19 19 19 19 19 19 19 19 19 19 19 19 19 19 19 19 20 20 20 20 20 20 20 20 20 20 20 20
[49] 21 21
> median(y1)
[1] 19
> |
```

b. 次数统计。对于一个数据向量,首先对其进行分组,再对每个组的个数进行统计。`cut(x,breaks)`表示按照 `breaks` 的划分标准,对 `x` 向量进行分组,并标记 `x` 中每个元素的组别。`table(x)`统计向量 `x` 中相同元素出现的次数。

c. 绘制直方图。采用 `hist()` 函数可以直接对一个数据向量进行分组统计,并绘图。所以这一步可以不依赖于 b 步骤。如果想要直方图画的漂亮点,可以对其中的多个参数进行设定。`hist()` 的常用参数包括 `hist(x, breaks, freq, right, density, col, angle, xaxt, yaxt, xlab, ylab, main, ...)`

其中:`x` 表示数据向量。

`breaks` 表示分割点的位置向量。

`freq` 是逻辑参数,如果为真(`T`),表示直方图的纵坐标是概率密度;如果为假(`F`)或空(`NULL`),表示直方图的纵坐标为个数统计。

`right` 是一个逻辑参数,真(`right = T`)表示每个分组区间是左开右闭的;假(`right = F`)表示每个分组区间是左闭右开的。这里采用后者的设定方法。

`density` 默认情况下为空(`NULL`),表示对直方图每个条柱的填充是纯色的。当 `density` 参数为非负数值时,直方图的每个条柱由直线纹理构成。`density` 数值的大小表示一英寸宽度内的直线条数,可控制纹理的密度。

`angle` 表示以上纹理的倾斜度数,默认是 45 度。

`col` 是颜色参数,表示每个直方条柱的填充颜色。注意的是,如果 `density` 不是 `NULL` 的时候,表示其中纹理线条的颜色。读者可以把下述程序中的 `density = 50` 去掉以后看看是什么效果。

`xaxt` 表示是否绘制横坐标的刻度,`xaxt = "n"` 表示不绘制横坐标刻度;`yaxt` 表示是否绘制纵坐标的刻度,与 `xaxt` 类似。

`xlab` 表示横坐标的标签;`ylab` 表示纵坐标的标签。

`main` 表示图形的主标题。

其他参数的介绍可以查看 `hist` 的帮助,即在命令窗口中输入? `hist` 即可。由于默认情况下的直方图横坐标刻度比较松散,在这里的绘图中首先不绘制横坐标的刻度,然后采用 `axis(side,at,label)` 添加刻度。

`axis(side,at,labels)`

其中,`side` 的取值为 1 到 4 的数值之一,分别表示在下、左、上、右添加相应的刻度。

`at` 是一个数据向量,表示在哪几个位置上添加刻度。

`labels` 是与 `at` 相同长度的向量,表示在以上位置分别添加什么刻度,可以是字

```

# 本程序用于实现“排列图”
# 输入数据
x=c(104,42,20,10,6,4,14)
names(x)=c("变形","刮花","针眼","裂缝","斑点","有沟","其他")
x                                     # 看看 x 是什么样子的
x3=sort(x,decreasing=T)           # 排序
# 绘制条件图
barplot(x3,col=rgb(0/255,1,77/255),las=2,angle=c(45,135),density=50,
        main="排列图(帕累托图)")      # 条形图命令
# 运算过程
累计比例刻度位置=c(0, max(x3)/10 * (1:10))          # 累计比例曲线纵坐标刻度的位置
累计比例刻度值=0:10/10          # 累积比例曲线纵坐标刻度
累计比例=cumsum(x3/sum(x3))
累计比例纵坐标=累计比例 * max(累计比例刻度位置)
累计比例横坐标=1:length(累计比例纵坐标)+0.2 * 0:(length(累计比例纵坐标)-1)-0.25
## 添加图线
# 辅助线
for(i in 1:11){lines(c(-100,100), c(累计比例刻度位置[i],累计比例刻度位置[i]),
                      lty=3,col=3,lwd=1)}
# 累积比例为 80% 的线
lines(c(-100,100),c(累计比例刻度位置[9],累计比例刻度位置[9]),
      lty=3,lwd=3,col=3)
# 累计比例曲线
lines(x4a,x4,type="o",lwd=2,col=4,pch=15)
# 添加累积比例曲线
# 右侧刻度
axis(4,at=累计比例刻度位置,labels=累计比例刻度值,las=1)

```

(因子类型),在无特别要求情况下建议读者尽量避免使用它。不过,R 默认是将字符转成因子类型的,所以在每次程序的开头加上 options(stringsAsFactors=F)就可以避免字符类型向因子类型的转换。

```

setwd("E:/r/20120203-book/programs_in_book")
dat=read.csv("02.1.csv",header=T)
head(dat)          # 查看前六行
tail(dat)          # 查看后六行
# 考核结果是分类数据,这里按照指定顺利重新编码
x1=factor(dat$X2002 考核, levels=c("不合格","合格","中","良","优"),
           labels=c("不合格","合格","中","良","优"))
x2=factor(dat$X2003 考核, levels=c("不合格","合格","中","良","优"),
           labels=c("不合格","合格","中","良","优"))
x3=factor(dat$X2004 考核, levels=c("不合格","合格","中","良","优"),
           labels=c("不合格","合格","中","良","优"))
# 进行统计,并显示结果
(y1=table(x1))
(y2=table(x2))
(y3=table(x3))
# 将三个图画在一个图形中
ol=par(mfrow=c(1,3))    # 将图形区域切成 1 行 3 列,可以包含三个图
barplot(y1,col=rgb(178/255,204/255,51/255),las=2,angle=c(45,135),density
        =50,
main="2002 年职工考核情况")
barplot(y2,col=rgb(178/255,204/255,51/255),las=2,angle=c(45,135),density
        =50,
main="2003 年职工考核情况")
barplot(y3,col=rgb(178/255,204/255,51/255),las=2,angle=c(45,135),density
        =50,
main="2004 年职工考核情况")
par(ol) # 恢复默认设置,以免干扰后续程序

```

**实验练习**

1. 安装 Minitab15.0 中文版,进入系统,学会利用帮助运行基本模式。
2. 安装 R3.0.1 版,进入系统,熟悉命令交互式和输入程序运行基本模式。  
学会利用帮助。逐句运行例 1.3~例 1.6,并改写其中 1~2 个程序。

**参考文献**

- [1] 汤银才:《R 语言与统计分析》,北京,高等教育出版社,2008 年。
- [2] 洪楠等:《Minitab 统计分析教程》,北京,电子工业出版社,2007 年。
- [3] [美]R. I. Kabacoff,高涛等译:《R 语言实践》,北京,人民邮电出版社,2012 年。
- [4] 薛毅、陈立萍:《统计建模与 R 软件》,北京,清华大学出版社,2007 年。

续表

分布名称	R 中的表达	参数 1	参数 2	参数 3
t 分布	t	df	ncp	
均匀分布	unif	min	max	
Weibull 分布	weibull	shape	scale	
Wilcoxon 分布	wilcox	m	n	

每种分布有四种表示形式:d-、q-、p-和 r-,分别表示概率密度,累计概率密度的反函数,累计概率密度,生成随机数等。以正态分布为例,它的四种形式为:

```
dnorm(x, mean = 0, sd = 1, log = FALSE) # 计算 x 值对应的概率密度
pnorm(q, mean = 0, sd = 1, lower.tail = TRUE, log.p = FALSE)
# 计算 q 对应的累计概率密度值
qnorm(p, mean = 0, sd = 1, lower.tail = TRUE, log.p = FALSE)
# 计算累计概率密度为 p 的位置
rnorm(n, mean = 0, sd = 1) # 生成 n 个正态分布随机数
```

## 2. 部分统计函数

+,-,\*,/,?,%%,%%/%

<> <= >= == .. ! ==..

sin,cos,tan,asin,acos,atan,atan2,log,log10,exp

max(x) 最大值

min(x) 最小值

range(x) 返回 x 中的最大值和最小值组成的向量

sum(x) 求和

diff(x) 进行差分运算,后面减前面

prod(x) x 中元素全部相乘

mean(x) 均值

abs(x) 绝对值

sqrt(x) 开根号

median(x) 中位数

quantile(x,probs=) 分位数,默认返回最小值、第一分位数、第三分位数、最

choose(n,k) 组合数= $n! / [(n-k)! k!]$

sign 大于 0 则返回 1, 小于 0 返回 -1, 等于 0 返回 0

duplicated(x) 返回向量中重复元素的逻辑值

### 4. 部分高级数据处理函数

apply(X, INDEX, FUN) X 为矩阵或者数据框。index = 1 时, 按行调用 FUN 函数; index = 2 时, 按列调用 FUN 函数。

lapply、vapply、sapply、tapply 等均类似, 可以提高运算速度。

### 5. 几个高级绘图函数

plot(x) 或 plot(x,y) 最基本的绘图函数

hist(x) 直方图

barplot(x) 条形图

boxplot(x) 箱线图

### 6. 几个低水平绘图函数

points(x,y) 加点

lines(x,y) 加线

segments() 线段

arrows() 箭头

rect() 矩形

polygon() 多边形

legend() 添加标签

text(x,y,labels,...) 添加文字

### 7. 补充说明

(1) 具体函数的使用, 可以参照 R 的帮助。运行“? 函数名称”可以打开帮助文档。

(2) 写出函数的前面几个字母, 按 tab 键会自动匹配能够匹配的函数。这在 Rstudio 中尤其实用。

## 实验举例

### 频率与概率

**【例 3.1】(高尔顿钉板试验)** 自高尔顿钉板上端放一个小球, 任其自由下落。在其下落过程中, 当小球碰到钉子时从左边落下的概率为  $p$ , 从右边落下的概率为  $1-p$ , 碰到下一排钉子又是如此, 最后落到底板中的某一格子。因此任意放入

输出：

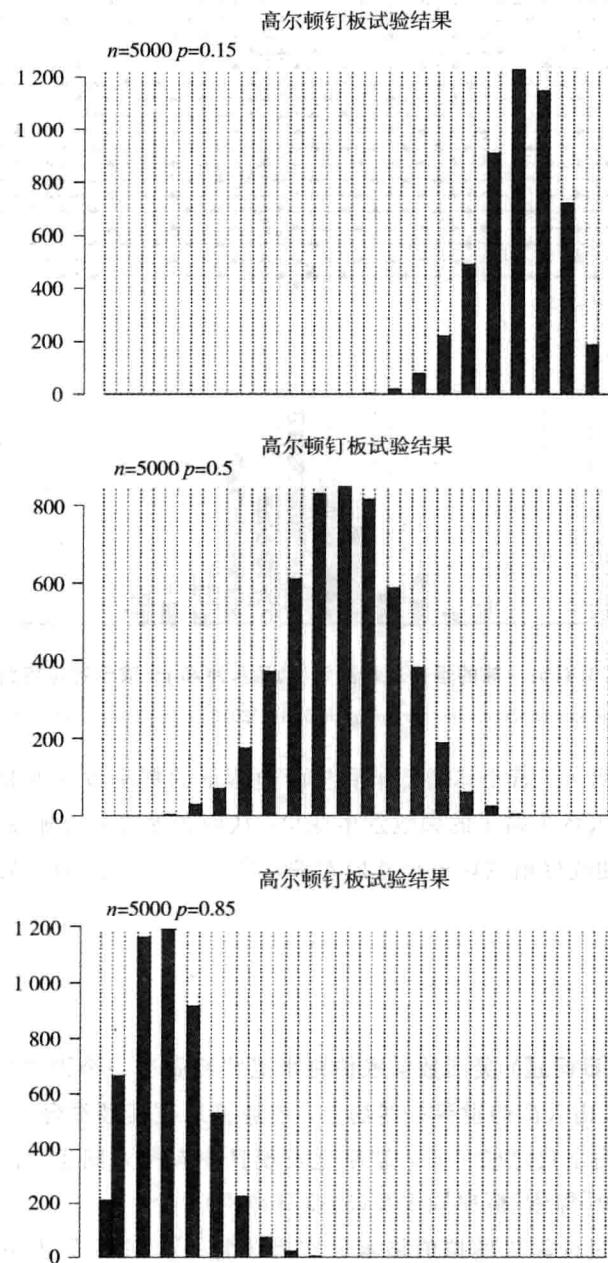


图 1.3.4(a) 最终落点的直方图

(2) 重复(1)1000 次, 统计试验结果并填入下表(表 1.3.2)中;

(3) 产生 40 个,50 个,64 个随机数, 重复(1),(2).

表 1.3.2 人群规模与出现生日相同的概率

$n = 1000$	$r$			
	$r = 22$	$r = 40$	$r = 50$	$r = 64$
出现同生日次数	506	878	969	999
出现同生日频率	0.506	0.878	0.969	0.999
$f(r)$	0.476	0.891	0.970	0.997

事实上, 设随机选取  $r$  人,  $A=\{\text{至少有两人同生日}\}$ , 则

$$\bar{A}=\{\text{生日全不相同}\}, P(\bar{A})=\frac{P_{365}^r}{(365)^r},$$

而

$$P(A)=1-P(\bar{A})=1-\frac{P_{365}^r}{(365)^r}=f(r),$$

### 【问题分析】

本程序的设计思路与前面相似。在前面的基础上, 这里应用了 `any()`、`diff()` 和 `sort()` 函数配合判断向量中是否有相同的数值。`sort()` 是对数据进行排序的函数, 默认按小到大排序。`diff()` 是计算相邻元素之间的差值, 在时间序列分析的差分过程经常使用。如果向量排序以后相邻元素的差值存在 0, 那么显然就是有重复的值了, 也即年龄相同的人。`any()` 的输入向量是逻辑值, 其取值只有真或假。`any()` 判断其中是否有真的, 只要有一个是真的, 那么输出真。当然, 向量中是否存在重复值这个问题, 也可以直接使用 `duplicated()` 函数判断。读者可以自己试试。

### 【输入命令】(程序 ch010302.R)

```
# 1-初始参数
N=1000 # 重复次数
n=c(22,40,50,64) # 样本数
y1=y2=y3=c() # 空向量, 用于保存频数、频率和理论频率

# 2-计算
# 随机抽取 n 个数并进行判断, 是则返回 TRUE, 否则返回 FALSE
fun0305=function(n){
  t1=round(runif(n,1,365),digits=0) # 在 1-365 中随机抽取 n 个数, 并四舍五入
  if (any(duplicated(t1))) { # 判断是否有人生日相同
    for (i in 1:n) {
      if (t1[i]==t1[i+1]) { # 如果相邻元素相等
        y1[i]=1 # 频数加 1
        break
      }
    }
  } else { # 如果没有人生日相同
    for (i in 1:n) {
      y1[i]=1 # 频数加 1
    }
  }
  y2[i]=length(y1)/n # 计算频率
  y3[i]=length(y1)/365 # 计算理论频率
}
```

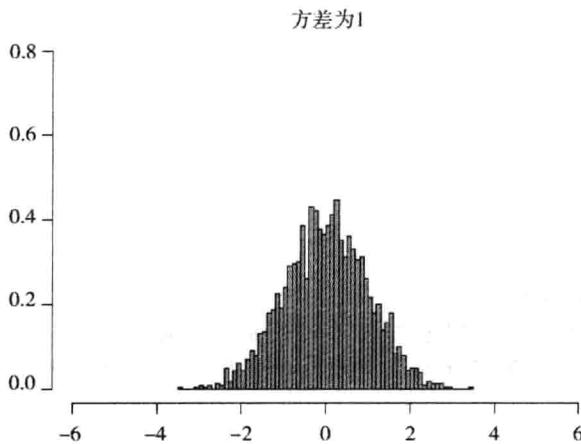


图 1.3.14 方差对正态分布的影响

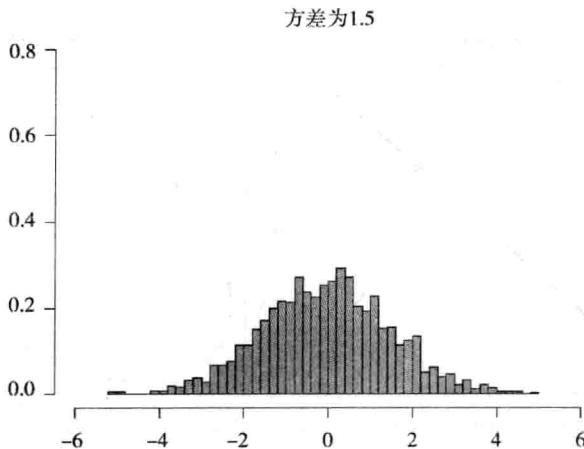


图 1.3.15 方差对正态分布的影响

## 协方差与相关系数

**【例 3.9】** 设  $B$  服从  $[0, 2\pi]$  上的均匀分布,  $X = \cos(B)$ ,  $Y = \cos(A + B)$  ( $A$  为常数),  $X$  和  $Y$  的相关系数为  $\rho = \cos(A)$ . 产生服从  $U[0, 2\pi]$  的  $N$  个随机数, 取  $N = 100$ , 对应  $A = 0$ ,  $A = \frac{\pi}{3}$ ,  $A = \frac{\pi}{2}$ ,  $A = \pi$  分别绘出  $X$  和  $Y$  的散点图, 观察  $\rho$  对散点图的影响.

输入命令(程序 ch010309.R)

5	270	9	0.09
6	810	0	0.00

将上述结果整理成下表(表 1.3.5)形式:

表 1.3.5 伯努利定理的演示

$n$	$\left  \frac{n_A}{n} - p \right  \geq \epsilon$ 出现的次数	$\left  \frac{n_A}{n} - p \right  \geq \epsilon$ 出现的频率
10	76	0.76
30	63	0.63
50	50	0.50
90	35	0.35
270	9	0.09
810	0	0.00

从上表可见,随着  $n$  的增大,伯努利实验中事件 A 的频率与概率的偏差不小于  $\epsilon$  的概率越来越接近于 0,即当  $n$  很大时,事件的频率与概率有较大偏差的可能性很小,由实际推断原理,在实际应用中,当试验次数很大时,便可以用事件发生的频率来代替概率.

### 中心极限定理的直观演示

**【例 3.11】**本例旨在直观演示中心极限定理的基本结论:“大量独立同分布随机变量的和的分布近似服从正态分布”.

按以下步骤设计程序:

- (1) 产生服从二项分布  $b(10, p)$  的  $n$  个随机数, 取  $p = 0.2, n = 50$ , 计算  $n$  个随机数之和  $y$  以及  $\frac{y - 10np}{\sqrt{10np(1-p)}}$ ;
- (2) 将(1)重复  $m = 1000$  组, 并用这  $m$  组  $\frac{y - 10np}{\sqrt{10np(1-p)}}$  的数据作频率直方图进行观察.

输入(程序 ch010311.R)

```

fun03.ex02=function(n){
  x=replicate(n, {which, max(runif(10))})
  y=table(x) #统计 10 所在位置
  barplot(y,main=paste("n=",n,sep="")) #绘图
}

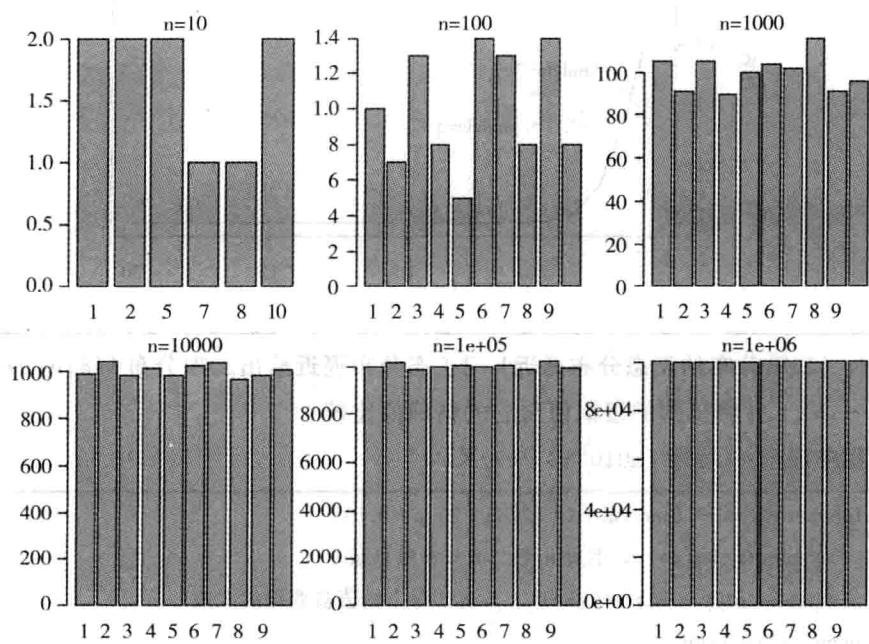
fun03.ex02(10)
fun03.ex02(100)
fun03.ex02(1000)
fun03.ex02(10000)
fun03.ex02(100000)
fun03.ex02(1000000)

```

则分别输出模拟实验 10 次、100 次、1000 次、10000 次等的结果，将实验结果进行统计分析，给出分析结果。

注：理论上，易证明每个人抽到大王的机会均等。

结果：



3. (泊松分布) 利用 R 语言在同一坐标系下绘出  $\lambda$  取不同值时泊松分布  $\pi(\lambda)$  的概率分布曲线，通过观察输出的图形，进一步理解泊松分布的概率分布的性质。