

# R 入门

## 目录

<b>1</b>	<b>R 简介</b>	<b>2</b>
<b>2</b>	<b>体会 R</b>	<b>3</b>
<b>3</b>	<b>R object: 向量、矩阵、函数</b>	<b>5</b>
3.1	Object 的命名、类型、定义和基本运算	5
3.2	向量	6
3.3	矩阵	10
3.4	数组 (array)	10
3.5	数据集 (data frame)	11
3.6	序列 (sequence)	11
<b>4</b>	<b>数据的输入和输出</b>	<b>12</b>
4.1	直接输入数据	12
4.2	修改, 编辑	12
4.3	外部读入数据	12
4.4	输出数据: write, write.table, write.csv, write.csv2	13
4.5	读入, 输出一一般 R 对象	13
<b>5</b>	<b>基本运算及函数</b>	<b>13</b>
5.1	基本运算	13
5.2	运算有关的函数 (使用方式: function.name(x))	15
<b>6</b>	<b>运算与操作</b>	<b>16</b>
6.1	矩阵运算	16
6.2	字符操作	17
6.3	排序 (sort、order)	18
6.4	合并	18
6.5	分拆 (split, by, aggregate)	18
6.6	交叉分类 (cross-classificaiotn, tabulation): table, xtabs	19
<b>7</b>	<b>自定义函数</b>	<b>19</b>

# 1 R 简介

R 的早期版本是 S 和 S-plus 商用软件。

- S
  - 1980's 由 Bell Lab 的 John Chambers 开发。
  - 为什么叫作 “S”? Statistics
  - S 后来发展为 Splus, 成为商业软件 (Insightful Corporation)
- R
  - 1990's 由新西兰 Auckland 大学统计系 Ross Ihaka, Robert Gentleman 开发。
  - 与 S 基本相同, 但作为 GNU Project 的一部分, 开源免费。  
(GNU 是一个开源化运动, 将操作系统 Unix 开源化产生了 Linux, S 开源化产生了 R 等等。  
GNU 的递归定义: GNU = GNU's Not Unix)
  - 为什么叫作 “R”? 作者名字的首字母。
- 下载 R 以及 package (CRAN: The Comprehensive R Archive Network):  
<http://cran.r-project.org/>
- 入门教程:  
  
Quick-R 网上简明教程: <http://www.statmethods.net/>

## 2 体会 R

下载并安装 R 之后，打开进入 R 环境。执行下面的简单例子，体会一下 R 的基本操作和功能。注意 R 工作环境中的提示符为 `>`。

---

```
> 1+2
[1] 3
> log(2)
[1] 0.6931472
> 1:5
[1] 1 2 3 4 5
> 1:30 # 显示行的 [1],[21] 是编号
[1] 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20
[21] 21 22 23 24 25 26 27 28 29 30
> 1:5+10
[1] 11 12 13 14 15
> a=1:5 # 赋值
> a
[1] 1 2 3 4 5
> a+10
[1] 11 12 13 14 15
> b=c(3,1,1,0,2) #c(...) 将若干数字组成向量
> b
[1] 3 1 1 0 2
> a+b
[1] 4 3
> sum(a) # 求和
[1] 15
> sum(b)
[1] 7
> mean(a) # 求均值
[1] 3
> var(b) # 方差
[1] 1.3
> b^2 # 各个分量的平方
[1] 9 1 1 0 4

> A=matrix(1:6,nrow=2,ncol=3) #2x3 矩阵
> x=c(-1,0,1)
> x
[1] -1 0 1
> A%%x # 矩阵与向量乘法
[,1]
[1,] 4
[2,] 4
> t(A) # 转置
[,1] [,2]
[1,] 1 2
[2,] 3 4
[3,] 5 6
> A%%t(A)->B # 矩阵乘法
> solve(B) # 逆矩阵
[,1] [,2]
[1,] 2.333333 -1.833333
```

```
[2,] -1.833333 1.458333
> det(B) # 行列式
[1] 24
> eigen(a) # 特征分解/谱分解
eigen() decomposition
$'values'
[1] 90.7354949 0.2645051
$'vectors'
[,1] [,2]
[1,] 0.6196295 -0.7848945
[2,] 0.7848945 0.6196295
> a
[1] 1 2 3 4 5
> b
[1] 3 1 1 0 2
> a*b # 分量相乘
[1] 3 2 3 0 10
> sum(a*b) # 内积 a'b
[1] 18
> t(a)%*%b # 内积 a'b
[,1]
[1,] 18
> a%*%t(b) # 外积 ab'
[,1] [,2] [,3] [,4] [,5]
[1,] 3 1 1 0 2
[2,] 6 2 2 0 4
[3,] 9 3 3 0 6
[4,] 12 4 4 0 8
[5,] 15 5 5 0 10
> (x=rnorm(5)) # 产生 5 个标准正态随机数
[1] 0.465987000 0.475899021 -0.924722447 2.753912505 -1.007803783
> plot(x) # 散点图
> hist(x) # 直方图
```

---

### 3 R object: 向量、矩阵、函数

R 中的变量、数据、程序等都是 R object，主要指向量、矩阵、函数。

#### 3.1 Object 的命名、类型、定义和基本运算

##### 命名

Object 名称由字母、数字或 “.” (不能出现在开头) 构成。

- 区分大小写。
- 用户应避免定义与系统自带的 object 重名，避免如下 R 内部的固定名称：

```
无穷大: Inf
空值: NULL
缺失值: NA NaN
逻辑值: F T False TRUE
函数: c q t mean var rank sort order diff..
常数: pi letters LETTERS...
循环、判断: break else for function if in next repeat while...
```

##### 数据对象的类型

- 数据对象 (object) 包括：向量 (vector), 矩阵 (matrix), 数组 (array), 列表 (list), 数据集 (data frame), ...

判断类型 (is.something): is.vector(x), is.matrix(x), ...。

改变类型 (as.something): as.vector(x), as.matrix(x), ..

- 数据根据取值分为如下类型：数值 (numeric), 字符 (character), 逻辑 (logical), 缺失 (na), 因子 (factor), ...

判断类型 (is.something): is.numeric(x), is.character(x), ...。

改变类型 (as.something): as.numeric(x), as.character(x)

向量、矩阵、数组的元素取值通常都应是同一类型的。列表 (list) 是一种向量，数据集 (data frame) 类似于矩阵，但它们可以含不同取值类型的分量。首先看几个简单例子，后面会有细节。

---

```
例：
> 1:4 # 产生整数向量 (1,2,3,4) <---- “#” 代表注释
[1] 1 2 3 4
> c(2.5, 1.8, 4.3, 1.1) # 产生实数向量 (2.5,1.8, 4.3, 1.1)
[1] 2.5 1.8 4.3 1.1
> c("Linear", "Regression", "Anaysis") # 产生字符型向量
[1] "Linear" "Regression" "Anaysis"
> is.vector(1:4)
TRUE
> is.matrix(1:4)
FALSE
```

```

> is.character(1:3) # 判断类型
[1] FALSE
> as.character(1:3) # 改变类型
[1] "1" "2" "3"
> c(-1,1,3) > 2 # 向量 (-1,1,3) 的各分量是否大于 2?
[1] FALSE FALSE TRUE
> x=1:4 # 把向量 (1,2,3,4) 赋值给 x
> is.vector(x)
TRUE

```

---

## 数据对象的定义/赋值和基本操作

- 赋值: `myobject=3; myobject <-3; 3→ myobject`  
上述三种方式等价, 都是把数字 3 赋给 `myobject`.
- 运算结果: `myobject = f(x,y,...)` # `f` 是函数/程序, 其运算结果赋给 `myobject`.
- 外部读入 (# 首先需确认 `datafile.txt` 在当前工作目录下或指定路径):  

```

myobject = scan("datafile.txt")
myobject = read.table("datafile.xls")
myobject = read.table("http://.../datafile.xls")

```

### 3.2 向量

(1) 定义向量 (数值, 字符, 逻辑, 列表):

---

```

> mydata <- 1:5
> m = mean(mydata) # 求 mydata 即 1,2,3,4,5 的平均值, 并赋值给 m
> mydata=read.table("file.xls") # 将外部工作目录下的文档 file.xls 读入到 R

# 数值向量:
> x = 1:3
> 1:3 -> x
> x
[1] 1 2 3
> x <- c(9, 0, -5, 2, -1, 3) ## c: concatenate 粘结
> x
[1] 9 0 -5 2 -1 3

# 字符向量
> course=c("multivariate", "analysis")
> course
[1] "multivariate" "analysis"

# 逻辑向量
> x=c(F,F,T)
> x
[1] FALSE FALSE TRUE

> x = c(-1,1,3) > 2 # 判断每个分类是否大于 2
> x

```

```
[1] FALSE FALSE TRUE
```

# 因子向量（因子变量的值称为水平，代表分类或分组，不具有实数含义，对因子变量不能做代数运算）

```
> x=factor(c(2,3,2,1,1,7))
```

```
> x
```

```
[1] 2 3 2 1 1 7
```

```
Levels: 1 2 3 7
```

```
> y=c("red","red", "yellow","blue")
```

```
> y
```

```
[1] "red" "red" "yellow" "blue"
```

```
> y=factor(y)
```

```
> y
```

```
[1] red red yellow blue
```

```
Levels: blue red yellow
```

# 缺失

```
> x=c(1:3, NA, 4:6)
```

```
> x
```

```
[1] 1 2 3 NA 4 5 6
```

```
> is.na(x) # 判断 x 的哪些分量是 NA
```

```
[1] FALSE FALSE FALSE TRUE FALSE FALSE FALSE
```

# 列表向量（可把不同类型的数据集中在一起，是一种特殊向量）

```
> x=list(1:2, c("a","d"))
```

```
> x
```

```
[[1]] # [[1]] 是 x 的第一个分量
```

```
[1] 1 2
```

```
[[2]] # [[2]] 是 x 的第二个分量
```

```
[1] "a" "d"
```

```
> x[[1]]
```

```
[1] 1 2
```

```
> unlist(x) # 解除 list 结构，成为一般向量，但由于有两种取值类型，统一为字符型  
"1" "2" "a" "d"
```

---

注：list, data.frame 是两种把不同类型数据放置一起的方法，前者是“向量”，后者是“矩阵”

## (2) 判断或改变向量类型

---

```
> x=1:3
```

```
> is.numeric(x)
```

```
[1] TRUE
```

```
> is.logical(x)
```

```
[1] FALSE
```

```
> as.character(x)
```

```
[1] "1" "2" "3"
```

```
> y=as.factor(x) # 或 y=factor(x)
```

```
> x
```

```
[1] 1 2 3
```

```
> y
```

```
[1] 1 2 3
```

```
Levels: 1 2 3
```

```
> is.na( c(1:3, NA, 4:6)) # 判断哪个分量缺失
[1] FALSE FALSE FALSE TRUE FALSE FALSE FALSE
```

---

(3) 命名各个分量: `names(x) = 字符向量`

---

```
> x=1:3
> names(x)
NULL
> names(x)=c("a", "b", "c")
> x
a b c
1 2 3
> mylist = list(1:2, c("a","d"))
> names(mylist)=c("x1", "x2")
> mylist
$x1
[1] 1 2
$x2
[1] "a" "d"
> names(mylist)=NULL # 去除名称
> mylist
[[1]]
[1] 1 2
[[2]]
[1] "a" "d"
```

---

(4) 子集、下标操作: `x[sub]` 或 `x["变量名"]` 或 `x[logical]`

---

```
> x=-:(3:4)
> x
[1] -3 -4

> x=-3:4
> x
[1] -3 -2 -1 0 1 2 3 4
> x[3]
[1] -1
> x[c(3,6)]
[1] -1 2
> x[c(6,3)]
[1] 2 -1
> x[-(1:6)] # "-" 号代表 "不取"
[1] 3 4

> letters
[1] "a" "b" "c" "d" "e" "f" "g" "h" "i" "j" "k" "l" "m" "n" "o" "p" "q" "r"。。。
> letters[1:4]
[1] "a" "b" "c" "d"

> names(x)=letters[1:5]
> x
a      b      c      d      e
```



```
0.59601640 0.27809609 -1.10968357 0.02912560 -1.34511581
```

```
> x[c("a", "d")] # 使用名称 (name) 取子集在数据集较大时更方便  
a      d  
0.59601640 0.02912560
```

```
# 逻辑下标: 取出 T 对应的分量
```

```
逻辑运算: 交: &      并: |      否: !
```

```
> x=-2:2  
>  
> x>1  
[1] FALSE FALSE FALSE FALSE TRUE  
>  
> x[x>1] # 取出那些大于 1 的分量  
[1] 2  
>  
> x>1 | x<=-2  
[1] TRUE FALSE FALSE FALSE TRUE  
> x[x>1 | x< -2]  
[1] 2  
>  
> x>=0 & 1:5 < 4  
[1] FALSE FALSE TRUE FALSE FALSE  
> x[x>=0 & 1:5 < 4]  
[1] 0  
>  
> x[ c(T, T, F, F, F) ]  
[1] -2 -1  
>  
> x==2  
[1] FALSE FALSE FALSE FALSE TRUE  
  
> x!=2  
[1] TRUE TRUE TRUE TRUE FALSE  
  
> x[x!=2]  
[1] -2 -1 0 1  
  
# 对于 list, 使用 x[[ sub ]]  
> mylist  
[[1]]  
[1] 1 2  
  
[[2]]  
[1] "a" "d"  
  
> mylist[[2]]  
[1] "a" "d"
```

---

### 3.3 矩阵

相关函数: matrix, dim, dimnames, is.matrix, as.matrix

---

```
> x=c(9,-5,-1,0,2,3)
> x1 = matrix(x, nrow=2, ncol=3) # 生成 2x3 矩阵, 元素为 x, 首先是第一类, 其次第二列..
> x1
[,1] [,2] [,3]
[1,]  9 -1  2
[2,] -5  0  3

> class(x1) #x1 的类别/属性
[1] "matrix"
> dim(x1)
[1] 2 3

> x2 = matrix(x, nrow=2, ncol=3, byrow=T)
> x2
[,1] [,2] [,3]
[1,]  9 -5 -1
[2,]  0  2  3

> dimnames(x2)=list(c("Group1", "Group2"), c("x1", "x2", "x3")) # 行, 列命名
> x2
x1 x2 x3
Group1 9 -5 -1
Group2 0 2 3

> dimnames(x2)
[[1]]
[1] "Group1" "Group2"

[[2]]
[1] "x1" "x2" "x3"

# 下标 : mat[sub1,sub2]

> x1[1:2, c(1,3)] # 1,2 行,1,3 列
> x1[2:1, c(1,3)] # 2,1 行,1,3 列
> x1[, c(3,1)] # 所有行, 3,1 列
> x1[2,] # 第 2 行, 所有列
> x1[c(T,F,T), ] # 第 1,3 行
```

---

### 3.4 数组 (array)

(较少使用, 可略过)

---

```
> a = array(1:12, c(2,3,2))
> a
, , 1
[,1] [,2] [,3]
[1,]  1  3  5
```

```

[2,] 2 4 6
, , 2

[,1] [,2] [,3]
[1,] 7 9 11
[2,] 8 10 12

# 命名:
> dimnames(a) =list(c("Group1", "Group2"), c("x1","x2","x3"), c("Region1", "Region2"))
> a

```

---

### 3.5 数据集 (data frame)

data frame 具有“矩阵”形式，但不是矩阵，不同的列可以是不同的数据类型，而矩阵的所有元素都是实数。一般的数据格式都是 data.frame。

```

# 生成数据集：使用 data.frame, 或从外部读入 (read.table,read.csv...).

> x=1:5
> y=letters[1:5]
> z=factor(c(1,2,2,1,2))
> mydataframe = data.frame(x=x, y=y, z=z)
> mydataframe
  x y z
1 1 a 1
2 2 b 2
3 3 c 2
4 4 d 1
5 5 e 2

## 从外部文档读入数据
> read.table("http://staff.ustc.edu.cn/~ynyang/vector/databook/pottery.txt", header=T,sep="\t")

```

---

### 3.6 序列 (sequence)

特殊的向量或数组，函数 seq, rep 等可以方便地产生数值、字符或因子序列。

```

> 1:4
> 4:1
> (-4):1
> -4:1
> -(4:1)
# seq(start, end, by=, length= ) 等差序列
> seq(0,1, by=0.1) #by: 间隔
> seq(1,3, length=10)
# rep 重复
> rep(1, 4) # 产生向量 1,1,1,1
> rep(1:2, 3) # 1,2,1,2,1,2
> rep(1:2, c(3,2))# 1,1,1, 2,2
> rep(letters,2)

```

---

## 4 数据的输入和输出

### 4.1 直接输入数据

---

```
> x=c(2.9, 3.1, 3.4) # 向量
> x=scan() # 手工输入向量
1: 2.9 3.1 3.4
4:
Read 3 items
> x
[1] 2.9 3.1 3.4

> x =matrix(1:4,2,2) # 矩阵
> x
[,1] [,2]
[1,] 1 3
[2,] 2 4

> cbind(1:2, 3:4) # 按列合并成矩阵
> rbind(c(1,3), c(2,4)) # 按行合并成矩阵

> data.frame(x1=1:3, x2=LETTERS[1:3], x3=factor(6:8)) # 将几个向量/矩阵案例合并成 data frame
  x1 x2 x3
1 1  A  6
2 2  B  7
3 3  C  8
```

---

### 4.2 修改, 编辑

---

```
> fix(x)

> x[2] = -3.1

> x =matrix(1:4,2,2)
> x
[,1] [,2]
[1,] 1 3
[2,] 2 4

> as.vector(x) # 按列拉直
[1] 1 2 3 4

> as.matrix(1:4) # 转成 4x1 矩阵

> data.frame(x) # 将矩阵转化成 data frame
  X1 X2
1 1 3
2 2 4
```

---

### 4.3 外部读入数据

向量: scan,

矩阵: data.frame: read.table, read.csv, read.csv2, read.delim, read.delim2

---

```
x=scan("mydata.txt") ## scan 读入的数据是向量。如果 mydata.txt 不在你的工作目录，需指定路径，
# 比如， scan("c:\mywork\mydata.txt"),
# scan("http://staff.ustc.edu.cn/~ynyang/matrix/databook/pottery.txt")

read.table(mydata.xls, header=FALSE, sep = "\t", ...) # 同样指定 mydata.xls 的路径

# 其中 header=T: 指定数据文件第一行为列变量名， sep="\t": tab 键分隔各数字单元;

> read.csv("mydata.xls", head=T)
> read.csv2("mydata.csv", sep="\t")
```

---

#### 4.4 输出数据: write, write.table, write.csv, write.csv2

---

```
write(x, file = "data",
ncolumns = if(is.character(x)) 1 else 5,
append = FALSE, sep = " ")

write.table(x, file = "", append = FALSE, quote = TRUE, sep = " ",
eol = "\n", na = "NA", dec = ".", row.names = TRUE,
col.names = TRUE, qmethod = c("escape", "double"))
```

---

#### 4.5 读入, 输出一般 R 对象

将 R object 以 binary, ascii 形式储存成外部文件, 或读入外部储存的 R 源码

```
dput: dput(x, "mydata.txt")
dget: dget("mydata.txt") -> x
save: save(x1, x2, file="mydump.rda") # binary
load: load("mydump.rda")
dump: dump(ls(), "mydump.txt")
sink
```

## 5 基本运算及函数

### 5.1 基本运算

---

#### 1. 运算

```
> 1+2  
[1] 3
```

```
> x=1:3  
> y=c(1,-1,0)  
> x  
[1] 1 2 3  
> y  
[1] 1 -1 0
```

```
> x+y # 逐分量相加  
[1] 2 1 3  
> x*y  
[1] 1 -2 0  
> x/y  
[1] 1 -2 Inf
```

```
> x^2 # 每个分量平方  
[1] 1 4 9
```

```
> 2^x
```

2. 循环规则（两个长度不同的向量运算时，将短的向量循环扩展至长度相同）

```
> 1:3 + 1 # 1 --> c(1,1,1)  
[1] 2 3 4
```

```
> a=1:4  
> b=1:2  
> a+b ## 把 b 扩为 c(1,2,1,2), 然后相加  
[1] 2 4 4 6
```

```
> a=1:5; b=1:2  
> a*b # 把 b 扩为 c(1,2,1,2,1), 然后相乘  
[1] 1 4 3 8 5
```

#### 3. 标准运算符

```
/ 除法  
* 乘法  
+ 加法  
- 减法  
%% 整除  
%% 余数  
%%*% 矩阵相乘 A%%*%B  
^ 幂次 a^b
```

#### 4. 逻辑运算

```
& #AND #x&y: 逐分量运算, 结果为向量  
| #OR  
! #NOT
```

```
any(x) # true if any of x is true  
all(x) # true if all are true  
isTRUE(x) # test if x is true  
is.na(x) # 判断是否缺失 (NA)  
>  
<  
>=  
<=  
==, (判断相等)  
!= (判断不等)
```

```
> (x=c(-5,0, 5:2)) # 赋值命令放在 () 中, 既执行赋值, 也把复制后的结果列出  
[1] -5 0 5 4 3 2  
> x>3  
[1] FALSE FALSE TRUE TRUE FALSE FALSE  
> x>=3  
[1] FALSE FALSE TRUE TRUE TRUE FALSE  
> (i=x>=3)  
[1] FALSE FALSE TRUE TRUE TRUE FALSE  
> i  
[1] FALSE FALSE TRUE TRUE TRUE FALSE  
> x[i]  
[1] 5 4 3  
> x[!i]  
[1] -5 0 2  
> x>2 & x<4  
[1] FALSE FALSE FALSE FALSE TRUE FALSE  
> x<0 | x>3  
[1] TRUE FALSE TRUE TRUE FALSE FALSE  
> any(x>6)  
[1] FALSE  
> any(x>4)  
[1] TRUE  
> all(x>=0)  
[1] FALSE  
> x==0 # 判断 x 的各分量是否为 0  
[1] FALSE TRUE FALSE FALSE FALSE FALSE  
> x!=0 # 判断非 0  
[1] TRUE FALSE TRUE TRUE TRUE TRUE  
> log(x)  
[1] NaN -Inf 1.6094379 1.3862944 1.0986123 0.6931472  
Warning message:  
In log(x) : 产生了 NaNs  
> is.na(log(x))  
[1] TRUE FALSE FALSE FALSE FALSE FALSE  
> x[!is.na(log(x))]  
[1] 0 5 4 3 2
```

---

## 5.2 运算有关的函数（使用方式：**function.name(x)**）

---

```
abs    # 绝对值 abs(x) 给出所有 x 元素的绝对值
sign   # 符号
log    # 对数, log(x) 自然对数; log(x, base=2) 以 2 为底
sqrt   # 开方
exp    # 指数
sin; asin; cos; acos; tan; atan; cosh; acosh; tanh; atanh
gamma  # Gamma 函数
lgamma # log-gamma 函数

round  # round(x,d)
# 截取至  $10^{(-d)}$ , 例如: round(839.1982, 2) : 839.20; round(839.1982, -2): 800

sum    # sum(x): x 的所有分量相加
prod   # prod(x): x 的所有分量相乘
cumsum # 累积求和
cumprod # 累积乘积

max    # max(x): x 所有元素的最大值
min    # 最小
cummax # 累积最大
cummin
range  # 最大及最小值

pmax; pmin # pmax(x,y): 逐点取最大或最小

diff   # 差分

# 集合运算:

unique  # 去掉重复值
duplicated # 判断每个分量是否重复出现
> c(1:4, 1, 2, 9,1)
> unique(x)
[1] 1 2 3 4 9
> duplicated(c(1:4, 1, 2, 9,1))
[1] FALSE FALSE FALSE FALSE TRUE TRUE FALSE TRUE

union   # 并集 union(1:2, c(1,3,5)) 1,2,3,5
intersect # 交集
setdiff # 集合之差
```

---



## 6 运算与操作

### 6.1 矩阵运算

---

```
A%%B      # 矩阵乘积, A, B 为矩阵或向量
A*B       # 同阶矩阵元素相乘; 若 B 是向量, 则 A 每一列乘 B (即按循环法则)

t(A)      # 转置
solve(A)  # 逆
eigen(A)  # 特征值和特征向量
svd(A)    # 奇异值分解
qr(A)     # Q-R 分解
chol(A)   # Cholsky 分解
x%%t(y)   # xy'
x%%A%%x   # x'Ax

outer(x,y, FUN="*") # 外积, (i,j) 元素 =xi*xj
## 等于 x%%t(y) 或 x%%o%y
outer(x,y, "+")    # (i,j) 元素 =xi+xj
```

---

### 矩阵行、列操作

`apply(X, MARGIN, FUN,...)` # 按行 (MARGIN=1) 或列 (MARGIN=2) 运行 FUN

`sweep(x, MARGIN, STATS, FUN="-",...)` # 按行 (MARGIN=1) 或列 (MARGIN=2) 与 STATS 进行 FUN 的运算

`scale` # 标准化

---

```
> x=matrix(1:12, 3,4, byrow=T)
> x
[1,] [2,] [3,] [4,]
[1,]  1  2  3  4
[2,]  5  6  7  8
[3,]  9 10 11 12

> apply(x, 1, sum) # 行和 (1 代表行)
[1] 10 26 42

> apply(x, 2, sum) # 列和 (2 代表列)
[1] 15 18 21 24

> sweep(x, 2, 1:4, "**")
[1,] [2,] [3,] [4,]
[1,]  1  8 21 40
[2,]  2 10 24 44
[3,]  3 12 27 48

# 矩阵标准化
> scale(x)
```

---

## 6.2 字符操作

paste # 粘结字符  
substring # 提取或替换字符向量的子串  
substr  
nchar  
strsplit  
特殊字符:

\\ , \\b, \\t, \\n, \\r

---

```
> paste("x", 1:4, sep="")
[1] "x1" "x2" "x3" "x4"
> paste("x", 1:4, sep="_")
[1] "x_1" "x_2" "x_3" "x_4"
> paste(letters[1:5], collapse="")
[1] "abcde"
> paste("今天是", date())
[1] "今天是 Tue Mar 13 15:16:01 2012"

> substr("abcdef",2,4)
[1] "bcd"
```

---

## 6.3 排序 (sort、order)

---

```
> x=c(3, 1, -3, 5, -2)
> sort(x) # 次序统计量
[1] -3 -2 1 3 5
> rank(x) # x 各个分量的排名 (从小到大)
[1] 4 3 1 5 2
> order(x) # 次序统计量在原数据集中的下标
[1] 3 5 2 1 4
> x[order(x)]
[1] -3 -2 1 3 5
> x
[1] 3 3 -1 -4 3 2
> y
[1] 9 8 7 6 5 4
> sort(x)
[1] -4 -1 2 3 3 3
> order(x)
[1] 4 3 6 1 2 5
> order(x,y) # 求 x 的 order, 有结, 按 y 再排
[1] 4 3 6 5 2 1
```

---

## 6.4 合并

---

```
> c(1,3)
> c("a", "d")
> c(x,y,z) # 合并向量 x,y,z
```

```
> cbind(x,y,z) # 合并成矩阵
> rbind(x,y,z)
> cbind(A, B) # 按列合并矩阵 A,B
> rbind(A,B) # 按行合并矩阵
> merge(x, y, z) # 合并 data frames x,y,z
```

---

## 6.5 分拆 (split, by, aggregate)

```
split(x, f) # x=vector, f=factor
```

```
by(data, INDICES, FUN, ..., simplify = TRUE) # data=dataframe, INDICES=factor, FUN=function
applied.
```

---

```
> x=1:5
> group=c(1,1,2,2,1)
> split(x, group)
$`1` [1] 1 2 5

$`2` [1] 3 4

> warpbreaks
breaks wool tension
1    26   A     L
2    30   A     L
...
53   16   B     H
54   28   B     H
> attach(warpbreaks)
> by(warpbreaks, wool, data.frame)
> by(warpbreaks[,1], wool, mean)
```

---

## 6.6 交叉分类 (cross-classificaiotn, tabulation): table, xtabs

---

```
> attach(quine)
> quine
Eth Sex Age Lrn Days
1   A  M  F0 SL  2 2   A  M  F0 SL  11 ...

> table(Age)
Age F0 F1 F2 F3 27 46 40 33

> table(Sex, Age)
Age
Sex F0 F1 F2 F3
F 10 32 19 19
M 17 14 21 14
> xtabs(~Sex+Age)
Age
Sex F0 F1 F2 F3
F 10 32 19 19
M 17 14 21 14

# tapply(X, INDEX, FUN = NULL) # 对 table 的各组应用函数 FUN
```

```
# lapply 类似，对列表的个分类应用某函数

> tapply(Days, Age, mean) # 对每个年龄组的 Days 求平均
F0    F1    F2    F3
14.85185 11.15217 21.05000 19.60606

> tapply(Days, list(Sex, Age), mean) # 对每个年龄，性别组的 Days 求平均
F0    F1    F2    F3
F 18.70000 12.96875 18.42105 14.00000 M 12.58824 7.00000 23.42857
27.21429
```

---

## 7 自定义函数

自定义函数的一般格式如下

```
myfun = function(arg1,arg2,...) { ... }
```

其中 `function(arg1,arg2,...)` 中的 `arg1, arg2,...` 是用户自定义的函数的参数 (arguments)，大括号中包含若干命令，最后一行为输出内容。例如计算  $x^2 + y$

```
myfun = function(x,y) {
  z=x^2+y
  return(z)
}
```