

数据挖掘与R软件实战演练 中级课程

主讲人：程豪

ssstudy.com
科学软件学习网


第三章 R软件数据描述性分析

第一节 R软件数据描述性分析（一）


- 何为统计描述性分析
- R数据描述性分析
- R语言绘图

数据特征度量


集中趋势
(位置)



离中趋势
(分散程度)



偏态和峰态
(形状)



集中趋势(central tendency)

1. 一组数据向其中心值靠拢的倾向和程度。
2. 测度集中趋势就是寻找数据水平的代表值或中心值。
3. 不同类型的数据用不同的集中趋势测度值。

顺序数据：中位数和分位数

数值型数据：平均数

集中趋势(central tendency)

4. 低层次数据的测度值适用于高层次的测量数据，但高层次数据的测度值并不适用于低层次的测量数据。


即：集中趋势是平均数或中位数或众数，低层次数据是指定性数据，如性别，它的集中趋势只能是众数或中位数。高层次数据是定量数据，如身高，它的集中趋势是平均数。不能用平均数去测度性别的集中趋势。

分类数据：众数

1. 一组数据中出现次数最多的变量值；
2. 适合于数据量较多时使用；
3. 不受极端值的影响；
4. 一组数据可能没有众数或有几个众数；
5. 主要用于分类数据，也可用于顺序数据和数值型数据。


众数、中位数和平均数的比较

均值 中位数 众数




左偏分布

均值 = 中位数 = 众数



对称分布

众数 中位数 均值



右偏分布

众数、中位数、平均数的特点和应用

1. 众数

- 不受极端值影响
- 具有不惟一性
- 数据分布偏斜程度较大且有明显峰值时应用

2. 中位数

- 不受极端值影响
- 数据分布偏斜程度较大时应用

3. 平均数

- 易受极端值影响
- 数学性质优良
- 数据对称分布或接近对称分布时应用

众数、中位数、平均数的特点和应用


数据类型和所适用的集中趋势测度值

数据类型	分类数据	顺序数据	间隔数据	比率数据
适用的测度值	※众数	※中位数	※平均数	※平均数
	—	四分位数	众数	几何平均数
	—	众数	中位数	中位数
	—	—	四分位数	四分位数
	—	—	—	众数

峰态与偏态的度量


与标准正态分布比较！

偏态



左偏分布

峰态



扁平分布

右偏分布

尖峰分布

离散程度的度量

分类数据：

异众比率

顺序数据：

四分位差

数值型数据：

方差和标准差

相对离散程度：

离散系数

1. 数据分布的另一个重要特征；
2. 反映各变量值远离其中心值的程度(离散程度)；
3. 从另一个侧面说明了集中趋势测度值的代表程度；
4. 不同类型的数据有不同的离散程度测度值。

第二节 R软件数据描述性分析（二）

- 何为统计描述性分析
- R数据描述性分析
- R语言绘图

R数据描述性分析

- R的统计分析分为统计描述和统计推断两部分。统计描述是通过绘制统计图形、编制统计表、计算统计量等方法来表述数据的分布特征。
- 描述统计量包括了均值、中位数、次序统计量、百分数、方差、标准差、变异系数、极差、偏度系数等，是数据的位置度量、分散程度和分布形状的体现。
- 还包括分布函数、直方图、经验分布图、QQ图、茎叶图、箱线图等等。

- 均值(mean)的基本用法是
- `mean(x, trim=0, na.rm=FALSE);`
- 其中x是要计算均值的那个量，trim是计算均值前，去掉x两端观测值的比例，na.rm如果是TRUE，则表示删除NA再计算均值，允许缺失数据。

- `x<-c(75, 76, 77); mean(x)`

```
[1] 76
```

- 若x是个矩阵，则mean(x)返回矩阵所有元素的均值。

- `x<-1:12`

- `dim(x)=c(3,4)`

```
mean(x)
```

```
[1] 6.5
```

- 若要分别求矩阵的行和列，则要用apply()函数

- `apply(x, 1, mean)`

```
[1] 5.5 6.5 7.5
```

- `apply(x, 2, mean)`

```
[1] 2 5 8 11
```

- 若x是个date frame, 则返回的是各列的平均值

- `mean(as.data.frame(x))`

```
V1 V2 V3 V4  
2 5 8 11
```

- 因此多元数据的输入采用数据框的形式，会便于后期数据的处理

- `w<-c(75, 64, 47.4, 66.9, 62.2, 62.2, 58.7, 63.5, 66.6, 64,57, 69, 56.9, 50, 72)`

- `w.mean <- mean(w, trim=0.1); w.mean`

```
[1] 62.53846
```

- trim的取值在0.1-0.5之间，可以消除极端值对均值的影响。

- 若数据当中含有缺失值NA时，可以加na.rm来处理

- `w.na<-c(75, 64, 47.4, 66.9, 62.2, 62.2, 58.2, 63.5, 66.6, 64,57, 69, 56.9, 50, 72, NA);`

```
mean(w.na);
```

```
NA
```

```
w.na.mean<-mean(w.na, na.rm=TRUE);
```

```
[1] 62.36
```

- 若要计算数据的加权平均，可以用 `weighted.mean()` 函数，其基本格式为：

`weighted.mean(x, w, na.rm=FALSE)`

- 其中 `w` 是数据 `x` 的权重系数，其维数与 `x` 相同，基本用法与 `mean()` 相同，唯一有区别的地方是：

`weighted.mean()` 不适用于数据框，它作用在数据框的时候，和作用于矩阵的时候，结果是一样的，返回全部数据的加权平均

- 另外，对向量就平均等价于 `sum(x)/length(x)`，`sum()` 的用法和 `mean` 类似，只不过前者是求和

- 顺序统计量sort()的基本用法如下：

```
sort(x, partial=NULL, na.last=NA,  
decreasing=FALSE, method=c("shell", "quick"),  
index.return=FALSE)
```

- **partial**是部分排序的指标向量；**na.last**是处理缺失数据的，默认值为NA，表示不处理缺失数据，若**na.last=TRUE**，则将缺失数据放在最后；**decreasing**是升序或降序的选择，默认值FALSE表示按从小到大的升序排列，否则降序排列；**method**是排序方法，默认值是"shell"；**index.return**返回排序下标(只有**na.last=NA**才可以用**index.return**这个参数)，默认值是FALSE，若TRUE，返回的是一个列表，列表的第一个变量**\$x**是排序的顺序，第二个变量**\$ix**是排序顺序对应的下标值。

- `x<-c(75, 64, 47.4, 66.9, 62.2, 62.2, 58.7, 63.5)`

- `sort(x, decreasing=TRUE)`

```
[1] 75 66.9 64.0 63.5 62.2 62.2 58.7 47.4
```

- 若数据当中含有缺失值NA时，可以加`na.rm`来处理

- `x.na<- c(75, 64, 47.4, NA, 66.9, 62.2, 62.2, 58.7, 63.5)`

```
sort(x.na);
```

```
[1] 47.4 58.7 62.2 62.2 63.5 64.0 66.9 75.0
```

```
sort(x.na, na.last=T)
```

```
[1] 47.4 58.7 62.2 62.2 63.5 64.0 66.9 75.0 NA
```

```
sort(x.na, na.last=F)
```

```
[1] NA 47.4 58.7 62.2 62.2 63.5 64.0 66.9 75.0
```

- `x<-c(75, 64, 47.4, 66.9, 62.2, 62.2, 58.7, 63.5)`
- `sort(x, index.return=T)`

`$x`

`[1] 47.4 58.7 62.2 62.2 63.5 64.0 66.9 75.0`

`$ix`

`[1] 3 7 5 6 8 2 4 1`

- 中位数函数`median()`的基本格式为
- `median(x, na.rm=FALSE)`
- `median(x.na)`

`[1] NA`

`median(x.na, na.rm=T)`

`[1] 62.85`

- **百分数**是中位数的推广，将数据按从小到大的顺序排列后，取p分位数，若np是整数，则取第np和第np加一个数的平均；若np不是整数，取第[np]+1那个数。
- 计算百分数要用到的函数是`quantile()`，基本格式为：
`quantile(x, probs=seq(0,1,0.25), na.rm=FALSE, names=TRUE, type=7, ...)`
- **probs**给出相应的百分位数，默认值是0，0.25，0.5，0.75，1；**na.rm**是处理缺失数据的，`na.rm=TRUE`时，NA和NaN将从数据中移走，向量取值中若有NA或NaN，要添加这一参数，否则会出错；**names**若为TRUE，返回值当中有**names**这个属性；**type**是取值1-9的整数，选择了九种分位数算法(具体算法见帮助文件)中的一种。

• `w.quantile <- quantile(w); w.quantile`

0%	25%	50%	75%	100%
47.40	57.85	65.50	66.75	75.00

• `attributes(w.quantile)`

`$names`

`[1] "0%" "25%" "50%" "75%" "100%"`

• `quantile(w, probs=seq(0,1, 0.2))`

0%	20%	40%	60%	80%	100%
47.4	56.98	62.20	64.00	67.32	75.00

数据的分布

- 数据的分布主要考察分布函数(p), 密度函数(d), 分位数函数(q)及产生随机数(r).

- 以正态分布为例：

$$z_{\alpha/2} = \text{qnorm}(1-0.025, 0, 1) = 1.959964.$$

- ```
data<-rnorm(100, mean=0, sd=1);
dnorm(data, mean=0, sd=1, log=F);
pnorm(data, mean=0, sd=1, lower.tail=T,
log.p=F);
p<-c(0.975, 0.95)
qnorm(p, mean=0, sd=1, lower.tail=T, log.p=F);
[1] 1.959964 1.644854 # 0.05/2, 0.1/2分位数
```

| 分布                | R 中的名称  | 附加参数                |
|-------------------|---------|---------------------|
| beta              | beta    | shape1, shape2, ncp |
| binomial          | binom   | size, prob          |
| Cauchy            | cauchy  | location, scale     |
| chi-squared       | chisq   | df, ncp             |
| exponential       | exp     | rate                |
| F                 | f       | df1, df2, ncp       |
| gamma             | gamma   | shape, scale        |
| geometric         | geom    | prob                |
| hypergeometric    | hyper   | m, n, k             |
| log-normal        | lnorm   | meanlog, sdlog      |
| logistic          | logis   | location, scale     |
| negative binomial | nbinom  | size, prob          |
| normal            | norm    | mean, sd            |
| Poisson           | pois    | lambda              |
| Student's t       | t       | df, ncp             |
| uniform           | unif    | min, max            |
| Weibull           | weibull | shape, scale        |
| Wilcoxon          | wilcox  | m, n                |

## 第三节 R软件数据描述性分析（三）

---

- 何为统计描述性分析
- R数据描述性分析
- **R语言绘图**


# 直方图、经验分布图与QQ图

---

- `cl<-read.table("chapter4-cl.txt", header=T);`
- 用`hist()`函数可以绘制直方图。
- `hist`的一般用法为：
- `hist(x, breaks="Sturges", freq=NULL, probability=!freq,... )`
- `break`规定了直方图的组距(必须覆盖数据的范围)；`freq`是逻辑变量，`TRUE`是频率直方图，`FALSE`是密度直方图；`probability`和`freq`相反，`TRUE`是密度直方图，`FALSE`是频率直方图。其他参数详见帮助文档。

> hist(Weight)

Histogram of Weight



- 用density()函数可以绘制与直方图配套的核密度估计。
- density的一般用法为：
- `density(x, bw="nrd0", adjust=1, kernel=c("gaussian", "..."), window=kernel, width...)`
- `bw`是带宽，默认值R画出光滑图形；`kernel`是核函数；`adjust`表示实际带宽是`adjust*bw`。其他参数详见帮助文档。

- `w<-c(75, 64, 47.4, 66.9, 62.2, 62.2, 58.7, 63.5, 66.6, 64,57, 69, 56.9, 50, 72)`
- `hist(w, freq=F);`
- `w.density <- density(w); w.density`


Call:

```
density.default(x = w)
```

```
Data: w (15 obs.); Bandwidth 'bw' = 3.478
```

| x             | y                 |
|---------------|-------------------|
| Min. :36.97   | Min. :9.044e-05   |
| 1st Qu.:49.08 | 1st Qu.:4.402e-03 |
| Median :61.20 | Median :1.603e-02 |
| Mean :61.20   | Mean :2.061e-02   |
| 3rd Qu.:73.32 | 3rd Qu.:3.409e-02 |
| Max. :85.43   | Max. :5.518e-02   |

- `lines(w.density, col="blue");`
- `x<- 44:76;`
- `lines(x, dnorm(x, mean(w), sd(w)), col="red" );`



- 经验分布函数`ecdf()`可以估计总体的分布函数，一般用法为：

- `ecdf(x)`

- 若要在R中画出经验分布函数，则用`plot`函数：

- `plot(ecdf(x), ylab="Fn(x)", verticals=FALSE, col.01line="gray70")`


- `verticals`是逻辑变量，TRUE时表示画竖线，否则不画竖线；`col.01line`是0-1线的颜色。

- `plot(ecdf(w), verticals=TRUE, do.p=FALSE) ;`

`x<-44:78;`


`lines(x, pnorm(x, mean(w), sd(w)))`

ecdf(w)



- QQ图是用来鉴别样本的分布是否近似于某种类型的分布
- `qqnorm()`和`qqline()`提供了画正态QQ图和相应直线的方法
- `qqnorm(y, ylim, xlab=" ", ylab=" ", plot.it=TRUE, datax=FALSE)`
- `plot.it`是逻辑变量，TRUE时将结果画出来；`datax`是将样本数据放x轴，默认值是FALSE。
- `qqplot(x, y, plot.it=TRUE)`；
- 比较x和y的分布接近程度

qqnorm(w)  
qqline(w)



# 茎叶图、箱线图及五数总括

---

- 茎叶图stem()可以细致地看出数据分布的结构。
- stem()的一般用法为：
- `> stem(x, scale=1, width=80, atom=1e-08)`
- `scale`控制了茎叶图的长度，默认值是1，如果`scale=2`，则表示将0-9这10个个位数分成两段，0~4为一段，5~9为一段；`width`是绘图的宽度；`atom`是容差，一般选择默认值即可。

stem(x, scale=2)

The decimal point is 1 digit(s) to the right of the |

2 | 5

3 |

3 |

4 |

4 | 5

5 | 04

5 | 5

6 | 14

6 | 8

7 | 2

7 | 5589

8 | 13444

8 | 5667999

9 | 0112

9 |

10 | 0

- $x < -c(25, 45, 50, 54, 55, 61, 64, 68, 72, 75, 75, 78, 79,$   
81, 83, 84, 84, 84, 85, 86, 86, 87, 89,  
89, 89, 90,  
91, 91, 92, 100)

- `stem(x);`

The decimal point is 1 digit(s)  
to the right of the |

2 | 5

3 |

4 | 5

5 | 045

6 | 148

7 | 25589

8 | 134445667999

9 | 0112

10 | 0

- `stem(x, scale=0.5)`; # scale也可以是小数，等于0.5时，表示将0-9这10个个位数分成1/2段，即20个数为一组

The decimal point is 1 digit(s) to the right of the |

2 | 5

4 | 5045

6 | 14825589

8 | 1344456679990112

10 | 0

• 箱线图boxplot()直观地展现数据分布的主要特征。

• boxplot()有三种基本的用法：


• > boxplot(x, ...)

• > boxplot(x, ..., range=1.5, width, varwidth, notch=FALSE, outline=TRUE, ..., horizontal=FALSE, add=FALSE, at=NULL)

• > boxplot(formula, data, ..., subset, na.action=NULL);

- **x**是数据构成的数值型向量；**range**控制了“触须”的范围(默认值1.5)；**notch**=TRUE时，箱线图带有切口；**outline**是逻辑变量，TRUE时标出异常点；**horizontal**是逻辑变量，TRUE表示把箱线图绘制成水平状(默认值为FALSE)；**add**是逻辑变量，TRUE时表示在原图上画图，否则替换一张图(默认值为FALSE)。
- 若用最后一种形式，**fomular**是公式；**data**给出了公式作用的对象；**subset**是可选参数，可以给定要绘制的数据子集；**na.action**表示对NA数据作出处理，默认值为NULL，即忽略NA数据。


- `A<-c(79.98, 80.04, 80.02, 80.04, 80.03, 80.03, 80.04, 79.97, 80.05, 80.03, 80.02, 80.00, 80.02);`
- `B<-c(80.02, 79.94, 79.98, 79.97, 80.03, 79.95, 79.97)`
- `boxplot(A, B, names=c("A", "B"), col=c("red", "blue"));`
- `boxplot(A, B, notch=T, outline=T, names=c("A", "B"), col=c(3,5));`



SSStu  
科学

SSStudy.com  
科学软件学习网


SSStudy.com  
科学软件学习网



SSstudy.com  
科学软件学习网


SSstudy.com  
科学软件学习网

- `InsectSprays;`
- `boxplot(count~spray,  
data=InsectSprays, col="lightgray")`
- `boxplot(count~spray,  
data=InsectSprays, notch=T, col=2:7,  
add=T)`



SSstudy.com  
科学软件学习网

SSstudy.com  
科学软件学习网



SSstudy.com  
科学软件学习网

SSstudy.com  
科学软件学习网

# 正态性检验与分布拟合

---

- 前面介绍的茎叶图、箱线图直观地现实了数据的分布情况，直方图、经验分布图、QQ图配合了总体的分布或者密度曲线，可以考察总体和正态分布的接近程度。
- 然而，究竟所配的曲线是否合适，这种接近程度如何给出统计分析，还需要做正态性检验。
- 这里将简单地介绍两种正态性检验方法：  
Shapiro-Wilk  $W$ 检验和Kolmogorov-Smirnov 经验分布拟合检验。

# Shapiro-Wilk W检验

$$W = \frac{\left(\sum_{i=1}^n a_i x_{(i)}\right)^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

where

- $x_{(i)}$  (with parentheses enclosing the subscript index  $i$ ) is the  $i$ th order statistic, i.e., the  $i$ th-smallest number in the sample;
- $\bar{x} = (x_1 + \dots + x_n) / n$  is the sample mean;
- the constants  $a_i$  are given by<sup>[2]</sup>

$$(a_1, \dots, a_n) = \frac{m^\top V^{-1}}{(m^\top V^{-1} V^{-1} m)^{1/2}}$$

where

$$m = (m_1, \dots, m_n)^\top$$

and  $m_1, \dots, m_n$  are the expected values of the order statistics of independent and identically-distributed random variables sampled from the standard normal distribution, and  $V$  is the covariance matrix of those order statistics.

- R中调用shapiro.test()函数即可使用该检验，使用格式为：

shapiro.test(x)

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/936012033011010132>