

بِسْمِ اللّٰهِ الرَّحْمٰنِ الرَّحِيمِ

آشنایی با نرم افزار آماری



مهدی جباری نوqابی، دانشگاه فردوسی مشهد، گروه آمار
کارگاه آموزشی، دانشکده ادبیات و علوم انسانی..... ۹۴/۱۱/۲۷

۱ مقدمه‌ای بر R

زبان R، یک زبان برنامه‌نویسی و محیط نرم‌افزاری برای محاسبات آماری و تحلیل داده است. امروزه این زبان به عنوان یک استاندارد غیر رسمی برای کارهای آماری و داده‌کاوی مطرح می‌باشد [۴]. این زبان در حقیقت نسخه متن باز نرم‌افزار S می‌باشد [۵]. زبان R توسط نرم‌افزاری به همین نام که شامل مفسر زبان و محیط اسکریپت‌نویسی است پشتیبانی می‌گردد. این نرم‌افزار، بازمند بوده و تحت اجازه‌نامه عمومی همگانی گنو عرضه می‌شود. نسخه‌های R بصورت رایگان و برای انواع سیستم‌های عامل (ویندوز، مک و انواع توزیع‌های لینوکس) ارائه شده‌است. هسته اصلی نرم‌افزار R به همراه بیش از ۴۳۰۰ کتابخانه مرتبط با آن، در شبکه CRAN (comprehensive R archive network) در دسترس کاربران می‌باشد. این شبکه که مخزن منابع مرتبط با R می‌باشد، از سرورهای دانشگاه‌های مختلف سراسر جهان برای نگهداری و گرفتن نسخه پشتیبان از این داده‌ها استفاده می‌کند^۱. در میهن عزیز اسلامی ما نیز، دانشگاه فردوسی مشهد یکی از مراکز نگهداری نسخه‌های R می‌باشد^۲.

در حال حاضر اگر چه هیچ شرکت تجاری پشتیبان رسمی R را بر عهده ندارد، اما شبکه پشتیبانی غیررسمی آن از طریق پیام‌های اینترنتی r-help قابل دسترس است. در حال حاضر R نرم‌افزاری کامل و بی‌نقص نیست و از آنجا که آزاد و رایگان هم می‌باشد، از پیشنهادات کاربران برای اصلاح و توسعه آن استقبال می‌کند.

۲-۱ مروری بر امکانات R

R یک مجموعه کامل از امکانات نرم افزاری برای کارکردن با داده‌ها و محاسبه و رسم نمودار می‌باشد. از جمله امکانات این مجموعه می‌توان به موارد زیر اشاره کرد:

- زبان برنامه‌نویسی ساده و پیشرفته شامل عبارت‌های شرطی، حلقه و توابع بازگشته و
- امکانات ذخیره، بازیابی و دستکاری داده‌ها
- مجموعه‌ای قوی از عملگرهای محاسباتی آرایه‌ها و ماتریس‌ها
- بسته‌های نرم‌افزاری قدرتمند برای تجزیه و تحلیل آماری
- کتابخانه‌های انجام عملیات داده‌کاوی و یادگیری ماشین مانند دسته‌بندی، خوشبندی، تحلیل شبکه‌اجتماعی، یادگیری تقویتی و ...
- امکانات گرافیکی برای تجزیه و تحلیل داده‌ها و رسم نمودار
- کتابخانه‌های خاص منظوره برای انجام عملیات تحلیلی در زمینه‌های مختلف علمی
- دارای مستندات فرمتبندی شده و منظم برای استفاده از زبان و کتابخانه‌های مرتبط

طرز نصب نرم افزار

ابتدا فایل اجرایی R-2.7.0-win32.exe را از سایت R دانلود^۵ نموده و با دوبار کلیک متوالی رزی آن نصب می شود. پس از پایان عمل نصب رزی desktop کامپیوتر شما یک آیکون به شکل حرف R قرار می گیرد. اگر رزی حرف R دوبار کلیک کنید، صفحه ای باز می شود که R Console نام دارد. در این صفحه یک مقدار توضیحاتی وجود دارد و پس از آن علامت «>» ملاحظه می شود که در مقابل آن می توان عملیات مورد نظر را انجام داد.

۱-۱ تاریخچه پروژه R

پروژه R در سال ۱۹۹۱ در گروه آمار دانشگاه Auckland کشور نیوزیلند کلید خورد. بنیان‌گذاران این پروژه آقایان Robert Gentleman و Ross Ihaka بودند. وجه تسمیه این زبان نیز ابتدای نام این در نفر می‌باشد (در دپارتمان آمار این دانشگاه این پروژه به "R&R" نیز معروف می‌باشد). در حال حاضر تیمی متشكل از ۱۹ نفر در حال توسعه این طرح می‌باشند.

R برای اولین بار در سال ۱۹۹۳ به طور عمومی معرفی گردید. در ۱۹۹۵ مارتین ماچلر، راس و رابت را متلاعند نمود تا تحت مجوز گنو، R را به یک نرمافزار رایگان تبدیل نمایند. یک سال بعد لیست رایانامه عمومی این پروژه ایجاد گردید (R-devel و R-help) که به کمک آن توسعه‌دهندگان و کاربران در سراسر جهان با یکدیگر مرتبط می‌شدند. در ۱۹۹۷ هسته اصلی توسعه‌دهنده R که شامل برخی از اعضای پروژه S-Plus نیز بودند ایجاد شد. این گروه، وظیفه کنترل و نظارت بر کد برنامه را به عهده داشت. با تلاش‌های توسعه‌دهندگان، در سال ۲۰۰۰ اولین نسخه R ارائه گردید. آخرین نسخه ارائه شده این نرمافزار ۲.۱۳.۱ می‌باشد که در ۸/۷/۲۰۰۱ منتشر شده است.

داده‌ها در R

همانطور که ملاحظه شد R با شی‌ها کار می‌کند که خود آن‌ها توسط نام و محتوی مشخص می‌شوند. هم‌چنین نوع داده که در شی قرار دارد با خصوصیت^۸ معین می‌گردد. تمام شی‌ها دارای دو خصوصیت است:

- mode: نوع عناصر یک شی را مشخص می‌کند. چهار نوع اصلی mode وجود دارد: عددی، کاراکتر، مختلف و منطقی. البته mode‌های دیگری نیز وجود دارد که در مورد data به کار نمی‌رود. برای مثال می‌توان از تابع يا عبارت نام برد.
- طول (length): تعداد عناصر یک شی را نشان می‌دهد.
اکنون به مثال‌های زیر توجه کنید.

```
> a<- "sahar"; b<- TRUE; c<- 1i  
> mode(a); mode(b); mode(c)  
[1] "character"  
[1] "logical"  
[1] "complex"
```

داده‌های آماده در زبان R

در زبان R تعدادی داده آماده برای استفاده در مثال‌ها قرار داده شده است که در این نوشتار نیز از آن استفاده می‌شود. مانند trees، Nile، LakeHuron، iris، cars و . . . البته می‌توان فهرست کامل آن‌ها را با استفاده از دستور `zir` در R یافت.

```
> data()
```

```
> data(cars)
```

```
> cars
```

```
 speed dist
```

1	4	2
2	4	10
3	7	4
4	7	22
5	8	16
6	9	10
7	10	18

خواندن داده‌ها از فایل

زیان R داده‌های متنی (text) را از روزی فایل می‌خواند. برای این کار می‌توان از دو روش استفاده نمود.

دستور خواندن **read.table**

اولین دستور مورد استفاده تابع `read.table()` است. اگر نام فایلی `data.txt` باشد و مثلاً در درایو c و در پوشه‌ای به نام `test` ذخیره شده باشد، آنگاه دستور خواندن به صورت زیر عمل می‌کند.

```
> mydata <- read.table("c:\\\\test\\\\data.txt")
```

با اجرای دستور فوق یک جدولی از داده‌ها به نام `mydata` تشکیل می‌شود که هر متغیر آن دارای نام است. به‌طور پیش‌فرض ... `V1`, `V2`, ... نامیده می‌شود و دسترسی به آن‌ها به صورت‌های ... `mydata$V1`, `mydata$V2`, ... و `read.table` `mydata[, 1]`, `mydata[, 2]`, ... `mydata["V1"]`, `mydata["V2"]`, ... می‌باشد. دستور `read.table` شامل خصوصیات اختیاری است که می‌توان حسب مورد از آن استفاده نمود.

اکنون به مثال زیر توجه کنید. فایلی به صورت زیر data.txt ذخیره شده است.

Author: John Davis

Date: 18-05-2007

Some comments...

Col1, Col2, Col3, Col4

23, 45, A, John

34, 41, B, Jimmy

12, 99, B, Patrick

حالا در زبان R فراخوانده می‌شود.

```
> mydata <- read.table("c:/test/data.txt",skip=3,sep=",",header=T)
> mydata
```

در تابع () آرگومان skip از سه سطر اول فایل که مربوط توضیحات است عبور می‌کند و آرگومان sep ویرگول بین داده‌ها را حذف می‌نماید و بالاخره آرگومان header که از نوع منطقی است و در اینجا «T» که مخفف TRUE است ذکر شده، بنابراین اسمی داده‌ها را حفظ می‌کند. اکنون به خروجی توجه کنید.

	Col1	Col2	Col3	Col4
1	23	45	A	John
2	34	41	B	Jimmy
3	12	99	B	Patrick

در حال حاضر بسیاری از داده‌ها قبلاً در نرم‌افزار Excel ذخیره شده است. زبان R به تهایی قادر به خواندن مستقیم فایل‌های Excel (یعنی پسوند‌های *.xlsx و یا *.xls) نیست. برای خواندن چنین داده‌هایی سه راه حل وجود دارد.

۱) می‌توان داده‌ها را در Excel به فرمت *.txt ذخیره نمود، سپس با تابع `read.table()` آنها (فایل متند *.txt) را خواند.

۲) می‌توان داده‌ها را در Excel به فرمت *.csv ذخیره نمود، سپس با تابع ("نام و آدرس فایل") `read.csv()` آنها را خواند.

۳) استفاده از package مربوطه که با استفاده از آن زبان R مستقیماً فایل‌های Excel را می‌خواند.

```
> read.csv("H:\\sahar\\book1.csv")
```

تولید داده‌ها

دنباله منظم از اعداد صحیح:

```
> 1:10  
[1] 1 2 3 4 5 6 7 8 9 10
```

تابع `seq()` می‌تواند دنباله‌ای از اعداد حقیقی را تولید کند. به عنوان مثال:

```
> seq(1,5,0.5)  
[1] 1.0 1.5 2.0 2.5 3.0 3.5 4.0 4.5 5.0
```

در این تابع، اولین عدد شروع دنباله، دومین عدد خاتمه دنباله و سومین عدد میزان افزایش را نشان می‌دهد.

تابع دیگری تحت عنوان `rep()` وجود دارد که اولین آرگومان آن بردار و دومین آرگومان آن تعداد تکرار عناصر آرگومان اول است. به مثال زیر توجه کنید.

```
> rep(1:5,2)  
[1] 1 2 3 4 5 1 2 3 4 5
```

ایجاد دنباله‌های تصادفی از داده‌ها

این نوع دنباله توسط توزیع‌های آماری قابل تولید است. بنابراین شرح مختصری در این باره ذکر می‌گردد. زبان R شامل تعداد قابل ملاحظه‌ای از توابع جرم و چگالی احتمال است. شکل عمومی این توابع به صورت $rfunc(n, p1, p2, \dots)$ است که حرف r از واژه random به معنای تصادفی اخذ شده است. در آن‌ها n تعداد عددی است که قرار است تولید شود. حروف \cdot , $p1$, $p2$, \dots مقادیر پارامترهای تابع را نشان می‌دهد. به مثال زیر توجه کنید.

```
> rnorm(4)
[1] -0.5484634 -0.3182905  1.8343405
0.1463850
```

ساختار داده‌ها

در زبان R می‌توان داده‌ها را به صورت‌های زیر نگهداری نمود.

- بردار (vector)
- ماتریس (matrix)
- آرایه (array)
- داده‌های چارچوب‌دار (data frame)
- داده‌های سری زمانی (time series)
- فهرست (list)

اکنون به شرح مجزای هر یک از آن‌ها پرداخته می‌شود.

بردارها

ساده‌ترین ساختار داده‌ها در زبان R، بردارها هستند. بردار موجودیتی است که شامل چند داده با نوع یکسان هستند، تماماً عدد و یا تماماً منطقی و ... می‌باشند. همانطور که قبلاً نیز ملاحظه شد می‌توان با تابع `c` بردار را ساخت. به مقاله زیر توجه کنید.

```
> x<-c(10,5,3,6)
```

محاسبات ریاضی روی بردارها

محاسبات روی بردارهای عددی معمولاً روی هر عنصرش انجام می‌شود. برای مثال `x*x` هر عنصر بردار `x` را مربع می‌کند.

```
> z<-x*x
```

```
> z
```

```
[1] 100 25 9 36
```

می‌توان توابع را روی عناصر یک بردار اثر داد. مثلاً تابع لگاریتم را روی بردار `x` اعمال نمود.

```
> log(x)
```

```
[1] 2.302585 1.609438 1.098612  
1.791759
```

ایجاد زیربردار

به دو صورت می‌توان یک زیربردار را ایجاد نمود.

- شماره عناصری که باید انتخاب شود را مشخص کنید. مثال

```
> x[c(2,3)]  
[1] 5 3
```

- با استفاده از اعداد منفی (شماره عناصر) می‌توان عناصر غیر لازم را حذف نمود.

```
> x[-c(1,4)]  
[1] 5 3
```

ماتریس‌ها

در واقع ماتریس بسط بردار است. مانند بردار تمام عناصر یک ماتریس دارای نوع داده‌های یکسان است. برای ساختن ماتریس کافی است برای عناصر تابع `(c)` سطر و ستون تعریف نمود. به مثال زیر توجه کنید.

```
> a<-matrix(c(1,2,3,4),nr=2,nc=2)
> a
 [,1] [,2]
[1,]    1    3
[2,]    2    4
```

توجه داشته باشید که عناصر ماتریس در زبان R به صورت ستونی (پیش‌فرض) ذخیره می‌شوند. اگر بخواهید که نحوه ذخیره شدن به شکل سطري باشد باید از عبارت `byrow=T` استفاده نمود. به مثال زیر توجه کنید.

```
> xx<-matrix(1:6, nc=3,byrow=T)
> xx
 [,1] [,2] [,3]
[1,]    1    2    3
[2,]    4    5    6
>
```

تابع rbind() و cbind() می‌توانند دو آرایه و یا دو ماتریس را بر حسب سطر و یا ستون به یکدیگر متصل نمایند. به عنوان مثال اولین ماتریس را در نظر بگیرید.

```
> m1<-matrix(1,nr=2,nc=2)
> m2<-matrix(2,nr=2, nc=2)
> rbind(m1,m2)
 [,1] [,2]
[1,] 1 1
[2,] 1 1
[3,] 2 2
[4,] 2 2
> cbind(m1,m2)
 [,1] [,2] [,3] [,4]
[1,] 1 1 2 2
[2,] 1 1 2 2
>
```

با تابع apply() می‌توان یک تابع را روی ستون، سطر و یا سطر و ستون اعمال نمود و نیازی به برنامه‌نویسی نیست. نحو کلی به صورت (...apply(X, MARGIN, FUN,...) است، که در آن X ماتریس، MARGIN نشان‌دهنده سطر (۱)، ستون (۲) و یا هر دو (1,2) و FUN تابعی است که قرار است اعمال گردد و ... آرگومان‌های اختیاری تابع است. به مثال

```
> x<-rnorm(10,-5,0.1)
> y<-rnorm(10,5,2)
> X<-cbind(x,y)
> X
      x     y
[1,] -5.004049 5.410928
[2,] -4.949671 7.843164
[3,] -4.887482 3.551941
[4,] -4.859480 7.046951
[5,] -5.012243 7.027064
[6,] -5.097387 4.890546
[7,] -5.021634 7.474694
[8,] -4.924094 3.644602
[9,] -5.075319 7.052260
[10,] -4.975315 8.312414
> apply(X,2,mean)
      x     y
-4.980667 6.225456
> apply(X,2,sd)
      x     y
0.0770022 1.7252354
```

زیر توجه کنید.

در زبان R، داده‌ای وجود دارد که `trees` نامیده می‌شود و شامل سه ستون است. تابع `apply()` به عنوان مثال روی آن اعمال می‌گردد.

```
> data(trees)
> apply(trees,2,sum)
Girth Height Volume
410.7 2356.0 935.3
```

اکنون اگر بخواهید که فقط مثلاً جمع یک ستون (Height) را محاسبه کنید، می‌توان به دو صورت زیر عمل نمود.

```
> sum(trees[,2])
[1] 2356
```

اما بالاخره در هر دو صورت فوق برای محاسبه جمع، میانگین و ... فقط از نام ستون داده‌های `trees` نمی‌توان استفاده نمود. برای این کار از تابعی در زبان R به نام `attach()` می‌توان استفاده نمود. ابتدا نام داده را با تابع مذکور فرا می‌خوانید و سپس می‌توان با نام ستون‌ها عملیات فوق را انجام داد.

```
> attach(trees)
> sum(Height)
[1] 2356
```

مشاهده ساختار یک شبیه

می‌توان از تابعی استفاده نمود که `str()` نامیده می‌شود. نام تابع `str` از کلمه `structure` به معنای ساختار ناشی می‌گردد. این تابع می‌تواند ساختار هر شبیه (اعم از داده‌ها، متغیرها، توابع و ...) را نشان دهد. به مثال زیر توجه کنید.

```
> str(trees)
'data.frame': 31 obs. of 3 variables:
 $ Girth : num 8.3 8.6 8.8 10.5 10.7 10.8 11 11 11.1 11.2 ...
 $ Height: num 70 65 63 72 81 83 66 75 80 75 ...
 $ Volume: num 10.3 10.3 10.2 16.4 18.8 19.7 15.6 18.2
22.6 19.9 ...
```

در اینجا علاوه بر تعداد و اسمی متغیرها می‌توان نوع داده‌ها، تعداد داده‌ها و قسمتی از داده‌های هر متغیر را مشاهده نمود.

ماتریس و عملیات آن

برای ضرب دو ماتریس از عملگر «%*%» استفاده می‌شود. برای مثال به حاصل ضرب دو ماتریس $m1, m2$ توجه کنید.

```
rbind(m1,m2)%*%cbind(m1,m2)
```

```
[,1] [,2] [,3] [,4]  
[1,] 2 2 4 4  
[2,] 2 2 4 4  
[3,] 4 4 8 8  
[4,] 4 4 8 8
```

ترانهاده یک آرایه توسط تابع $t()$ حاصل می‌گردد. تابع $diag()$ برای استخراج و یا تغییر درآیه‌های قطری و یا ساختن یک ماتریس قطری به کار می‌رود.

```
> t(xx)  
[,1] [,2]  
[1,] 1 4  
[2,] 2 5  
[3,] 3 6  
> diag(m1)  
[1] 1 1  
> diag(m1)<-10  
> m1  
[,1] [,2]  
[1,] 10 1  
[2,] 1 10
```

زبان R توابع خاصی برای محاسبات ماتریسی دارد. دستور `det()` برای محاسبه دترمینان، دستور `solve()` برای معکوس نمودن ماتریس و دستور `eigen()` برای بدست آوردن مقادیر و بردارهای ویژه بهکار می‌رود.

```
> det(m1)
[1] 99
> solve(a)
 [,1] [,2]
[1,] -2  1.5
[2,]  1 -0.5
> eigen(m1)
$values
[1] 11  9

$vectors
 [,1]      [,2]
[1,] 0.7071068 -0.7071068
[2,] 0.7071068  0.7071068
```

داده‌های چارچوب‌دار^{۱۲}

در واقع این نوع داده‌ها بسط ماتریس است. داده‌های چارچوب‌دار دارای ستون‌های با نوع داده‌های مختلف است و مناسب‌ترین ساختار داده‌ها در تجزیه و تحلیل در R می‌باشد. در واقع، اکثر روال‌های آماری در زبان R نیازمند داده‌های ورودی از این دست است. اکنون به مثال زیر توجه کنید.

> mtcars

	mpg	cyl	disp	hp	drat	wt	qsec	vs	am	gear	carb
Mazda RX4	21.0	6	160.0	110	3.90	2.620	16.46	0	1	4	4
Mazda RX4 Wag	21.0	6	160.0	110	3.90	2.875	17.02	0	1	4	4
Datsun 710	22.8	4	108.0	93	3.85	2.320	18.61	1	1	4	1
Hornet 4 Drive	21.4	6	258.0	110	3.08	3.215	19.44	1	0	3	1
Hornet Sportabout	18.7	8	360.0	175	3.15	3.440	17.02	0	0	3	2

این داده‌ها شامل اطلاعات خودروهای مختلف است. در جدول بالا هر سطر نماینده یک خودرو و ستون‌ها نمایش‌دهنده متغیرها است. در این مثال متغیر carb عدد کاربراتور را نشان می‌دهد.

ایجاد داده‌های چارچوب‌دار

برای ایجاد این نوع داده‌ها راه‌های مختلفی وجود دارد.

استفاده از تابع `data.frame()` می‌باشد.

```
> test<-matrix(rnorm(21),7,3)
> test<-data.frame(test)
> test
```

	X1	X2	X3
1	0.66277779	-0.3840960	-1.3595135
2	-0.04913578	0.8492189	2.0007778
3	0.34517674	-1.2079345	1.2743033
4	-0.15967494	-0.6256712	0.6585888
5	0.06225548	-0.3743871	2.7837282
6	0.39921940	0.5412310	0.1212971
7	0.41148286	-0.8607701	-0.0723364

زبان R به صورت خودکار اسامی ستون‌ها را X1, X2, X3 نامیده است. شما می‌توانید اسامی دلخواه خود را قرار دهید.

```
> names(test)<-c("Price","length","income")
> row.names(test)<-c("Ali","saeed","navid","babak","Majid","Amir","Hamid")
> test
```

	Price	length	income
Ali	0.66277779	-0.3840960	-1.3595135
saeed	-0.04913578	0.8492189	2.0007778
navid	0.34517674	-1.2079345	1.2743033
babak	-0.15967494	-0.6256712	0.6585888
Majid	0.06225548	-0.3743871	2.7837282
Amir	0.39921940	0.5412310	0.1212971
Hamid	0.41148286	-0.8607701	-0.0723364

```
> sum(test[,2])
[1] -2.062409
```

موجودیت‌های سری زمانی

در زبان R شیء سری‌های زمانی با تابع `ts()` ایجاد می‌گردد. دو مؤلفه در آن‌ها وجود دارد.

- داده‌ها، بردار یا ماتریسی از داده‌های عددی است که هر ستون یک سری زمانی مجزا را تشکیل می‌دهد.
- تاریخ داده‌ها، فواصل مساوی تاریخی است.

```
> my.ts<-
ts(matrix(rnorm(36),ncol=3),start=c(1987),freq=12)      اکنون به مثال زیر توجه کنید.
> my.ts
```

	Series 1	Series 2	Series 3
Jan 1987	1.9162493	-0.1661033	-1.9808024
Feb 1987	-0.5805433	1.8552607	0.7985123
Mar 1987	0.2521222	1.3434837	1.2004464
Apr 1987	0.3422510	2.5013974	-0.1498149
May 1987	0.2963408	0.2188443	0.1390155
Jun 1987	1.6654425	-0.7643525	-0.8574981
Jul 1987	0.1306895	-0.2848434	1.0944074
Aug 1987	0.4957888	-1.6637329	-0.1741922
Sep 1987	-0.2235258	0.5657969	0.6776202
Oct 1987	-0.9107982	1.0308249	0.3528864
Nov 1987	0.3451822	-0.7520748	0.4318638
Dec 1987	0.2092638	-0.5056582	-0.9681399

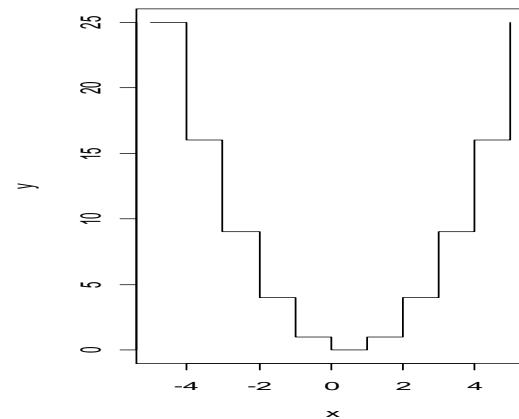
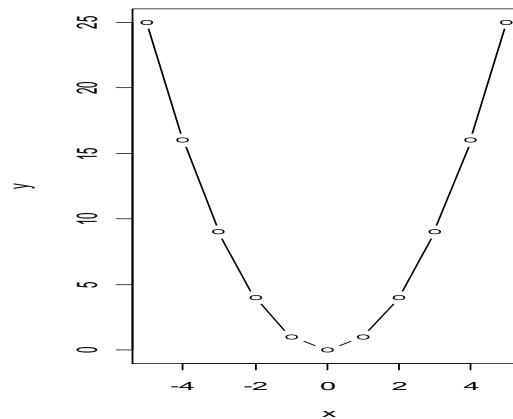
رسم نمودار

برای آشنایی با دستورات رسم نمودار در زبان R، تعدادی از آن‌ها ارایه خواهد شد.

توابع نموداری

در این قسمت تعدادی از توابع سطح بالای نموداری ملاحظه می‌گردد. تابعی که کاربرد فراوانی در ترسیم دارد، تابع `plot()` است.

```
> x<-seq(-5,5,1)
> y<-x^2
> par(mfrow=c(1,2))
> plot(x,y,type='b')
> plot(x,y,type='s')
```



تابع curve()

این تابع زبان R می‌تواند توابع پیوسته را روی یک فاصله معین رسم نماید. شکل کلی آن به صورت زیر است.

`curve(expr, from, to, add = FALSE, ...)`

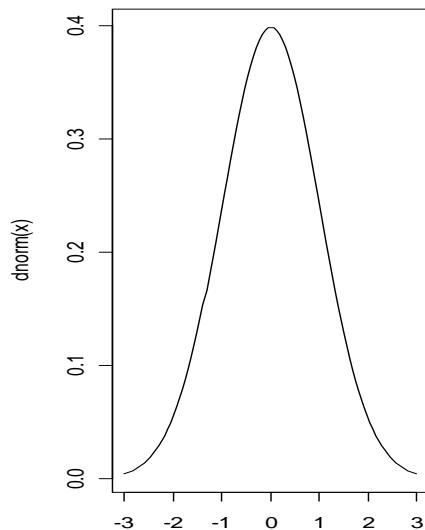
شرح آرگومان‌ها:

:expr عبارتی که بر حسب x نوشته شده است.

:from, to دامنه‌ای است که تابع باید روی آن رسم گردد.

:add منطقی است و اگر «TRUE» باشد شکل تابع به شکل حاضر اضافه می‌شود.

```
> curve(dnorm(x),from=-3,to=3)
```



توابع نموداری آماری

در زبان R می‌توان از توابع نمودار آماری استفاده نمود، که کاربرد فراوانی دارد.

hist(x): این تابع هیستوگرام ایجاد می‌کند.

qqnorm(x): این تابع چندک‌ها را روی دو محور ایجاد می‌کند. که چندک‌های نرمال روی محور x‌ها قرار دارد.

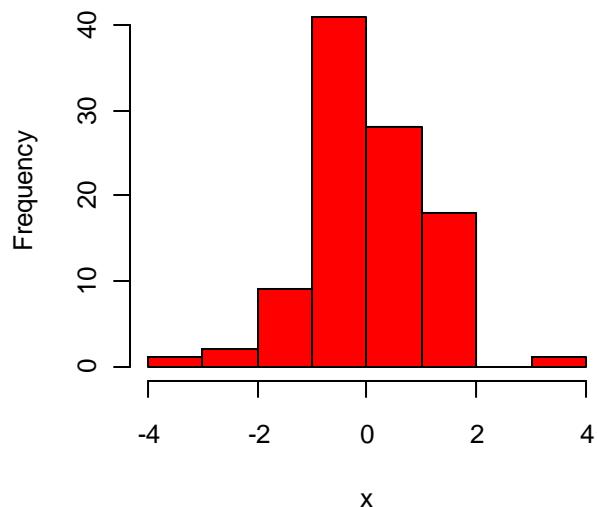
qqplot(x,y): این تابع چندک x را بر حسب y رسم می‌کند.

boxplot(x): این تابع نمودار box & whisker را ایجاد می‌نماید.

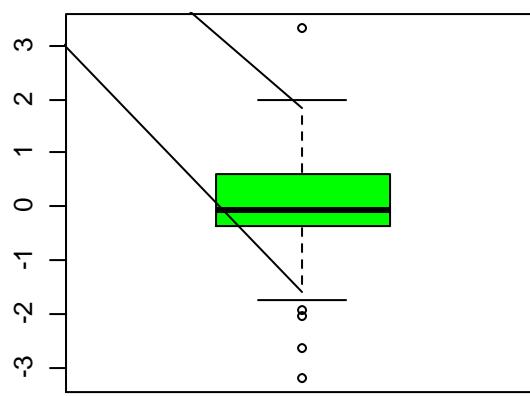
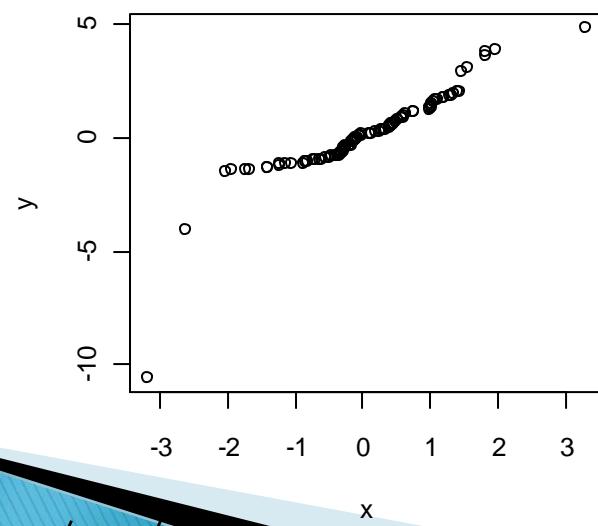
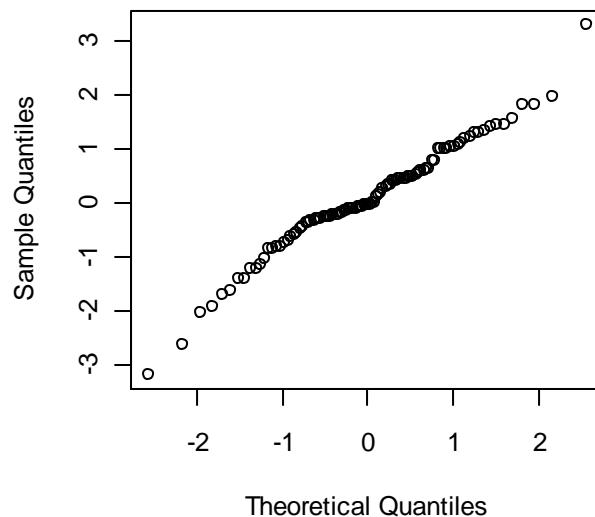
اکنون به مثال زیر توجه کنید.

```
> x<-rnorm(100)
> y<-rt(100,df=3)
> par(mfrow=c(2,2))
> hist(x,col=2)
> qqnorm(x)
> qqplot(x,y)
> boxplot(x,col="green")
```

Histogram of x



Normal Q-Q Plot



چند نمودار روی یک صفحه

با استفاده از پارامترهای `mfrow` و یا `mfcol` می‌توان روی یک صفحه چند نمودار را قرار داد. `mf` مخفف واژه `multiframe` است و `row` سطر و `col` ستون را بیان می‌کنند. هر دو پارامتر به شرح زیر تنظیم می‌شوند.

```
par(mfrow=c(r,k))  
par(mfcol=c(r,k))
```

که در آن `r` تعداد سطرها و `k` تعداد ستون‌های صفحه‌ای که در آن نمودار رسم می‌گردد را نشان می‌دهد. پارامتر گرافیکی `mfrow` بیانگر چیدمان سطري و `mfcol` بیانگر چیدمان ستونی است.

تنظیم‌های خارجی

فهرست زیر، پارامترهای بیشتر و جزیی‌تر از نمودارها را نشان می‌دهد. برای مثال `plot(x,y, col=2)` با این پارامتر می‌توان ضخامت خطوط نمودار را تعیین کرد. `lwd`: با این پارامتر می‌توان نوع خطوط مورد استفاده در نمودار را تعیین کرد. مقدار این پارامتر می‌تواند عدد و یا کاراکتر `lty` باشد. برای مثال `lty="dashed"`

col: با این پارامتر می‌توان رنگ نمودار تعیین کرد. مقدار این پارامتر می‌تواند عدد و یا کاراکتر باشد. برای مثال `col.lab = "red"`. برای تغییر رنگ عنوان و زیرعنوان از `col.main` و `col.sub`، برای تغییر رنگ عناوین محورها از `col.lab` و بالاخره برای تغییر رنگ محورها از `col.axis` استفاده می‌شود.

font: مقدار عددی این پارامتر قلم نوشته‌های نمودار را معین می‌کند.

pch: با پارامتر `pch` می‌توان نشانه‌های نمودار را معین نمود. مثلاً نشانه دایره به مربع تبدیل شود.

xlab, **ylab**: با این پارامتر می‌توان اسمی محورهای مختصات را مشخص کرد. البته در پاره‌ای از توابع سطح بالا، این عمل خود به خود انجام می‌شود.

xlim, **ylim**: با این پارامتر می‌توان مقادیر حداقل و حداکثر محورهای `x` و `y` را تعیین نمود. برای این کار می‌توان از دستورات `ylim=c(low,high)` و `xlim=c(low,high)` استفاده نمود، که در آن `low` مقدار حداقل و `high` مقدار حداکثر را نشان می‌دهد.

cex: با این پارامتر می‌توان نشانه‌ها و متون نمودار را بزرگ‌تر نمود. اگر بخواهید اندازه عنوان را بزرگ کنید از `cex.main` و برای زیرعنوان از `cex.sub` استفاده کنید. برای بزرگ‌تر نمودن اسمی محورها از `cex.lab` می‌توان کمک گرفت.

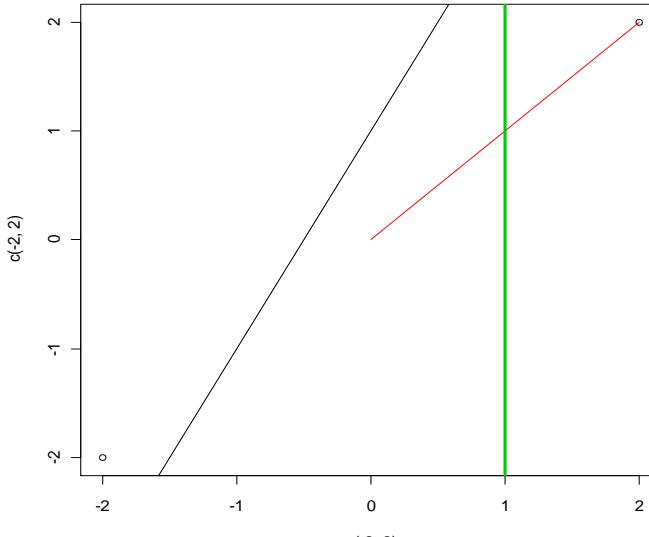
پاره‌ای از توابع سطح پایین

شما یک نمودار ایجاد می‌کنید، سپس می‌خواهید که بعضی از موارد را به آن اضافه کنید. این کار توسط تابع سطح پایین امکان‌پذیر است.

افزودن خطوط

تابع `lines()` برای افزودن خطوط به نمودار موجود استفاده می‌شود. تابع `lines` نقاط بردار ورودی را به هم وصل می‌کند. تابع `abline` خطوط راست با شیب و عرض از مبداء معین را ترسیم می‌کند. به مثال زیر توجه کنید.

```
plot(c(-2,2),c(-2,2))
> lines(c(0,2),c(0,2), col="red")
> abline(a=1, b=2)
> abline(v=1,col=3,lwd=3)
```



آمار و احتمال

زبان R شامل تعداد زیادی تابع برای محاسبات آماری، تحلیل داده‌ها و مدل‌سازی آماری است. علاوه بر آن‌ها تعداد قابل ملاحظه‌ای تابع در package‌ها وجود دارد. در اینجا روی تعداد محدودی از آن‌ها بحث خواهد شد.

توابع پایه آماری

توابع با کاربری زیاد

فهرست توابع در زبان R بسیار زیاد است. فهرست زیر دارای کاپرد فراوان می‌باشد.

: مجموع عناصر x را می‌دهد. **sum(x)**

: جمع تجمعی عناصر x را می‌دهد. **cumsum(x)**

: حاصل ضرب عناصر x را می‌دهد. **prod(x)**

: حداقل عناصر x را می‌دهد. **min(x)**

: حداقل عناصر x را می‌دهد. **max(x)**

: اندیس بزرگترین عنصر x را می‌دهد. **which.max(x)**

: **which.min(x)** اندیس کوچکترین عنصر x را می‌دهد.

: **range(x)** این تابع معادل $c(\min(x), \max(x))$ است.

: **length(x)** تعداد عناصر x را می‌دهد.

: **mean(x)** میانگین عناصر x را می‌دهد.

: **median(x)** میانه عناصر x را می‌دهد.

: **var(x)** واریانس عناصر x را می‌دهد.

: **sd(x)** انحراف معیار عناصر x را می‌دهد.

: **cor(x)** ماتریس همبستگی را محاسبه می‌کند، اگر x یک ماتریس باشد.

: **cor(x,y)** ضریب همبستگی خطی را بین x و y بدست می‌دهد.

: **chisq.test(x)** آزمون نکویی برآش به روش خی دو است.

: **ks.test(x)** آزمون نکویی برآش به روش کلموگروف-اسمیرنف است.

: **t.test(x)** آزمون t استودنت برای یک یا دو نمونه است.

: **var.test(x,y)** آزمون برابری واریانس x و y است.

توزیع‌های احتمالی و اعداد تصادفی

بیشتر توابع احتمالی در زبان R گذاشته شده است. هر تابع دارای چهار شکل متفاوت است، که به صورت زیر هستند.

- دستور (\dots , dfunc(x, \dots), عرض تابع را در نقطه x نشان می‌دهد.

- دستور (\dots , pfunc(x, \dots), مقدار احتمال تجمعی را تا نقطه x نشان می‌دهد.

- دستور (\dots , qfunc(p, \dots), مقدار چندک تابع را به ازی $p < 0$ نشان می‌دهد.

- دستور (\dots , rfunc(x, \dots), نمونه تصادفی از تابع را شبیه‌سازی می‌کند.

برای بدست آوردن احتمال تجمعی $F_X(x) = \Pr(X \leq x)$ یک توزیع به مثال زیر توجه کنید.

```
> pnorm(1.96)
[1] 0.9750021
```

اکنون می‌توان با یک امکان اضافی احتمال $(F_X(x) = \Pr(X > x) - 1)$ را نیز بدست آورد.

برای بدست آوردن مقادیر بحرانی و یا P-value در آزمون آماری مورد استفاده قرار می‌گیرد.

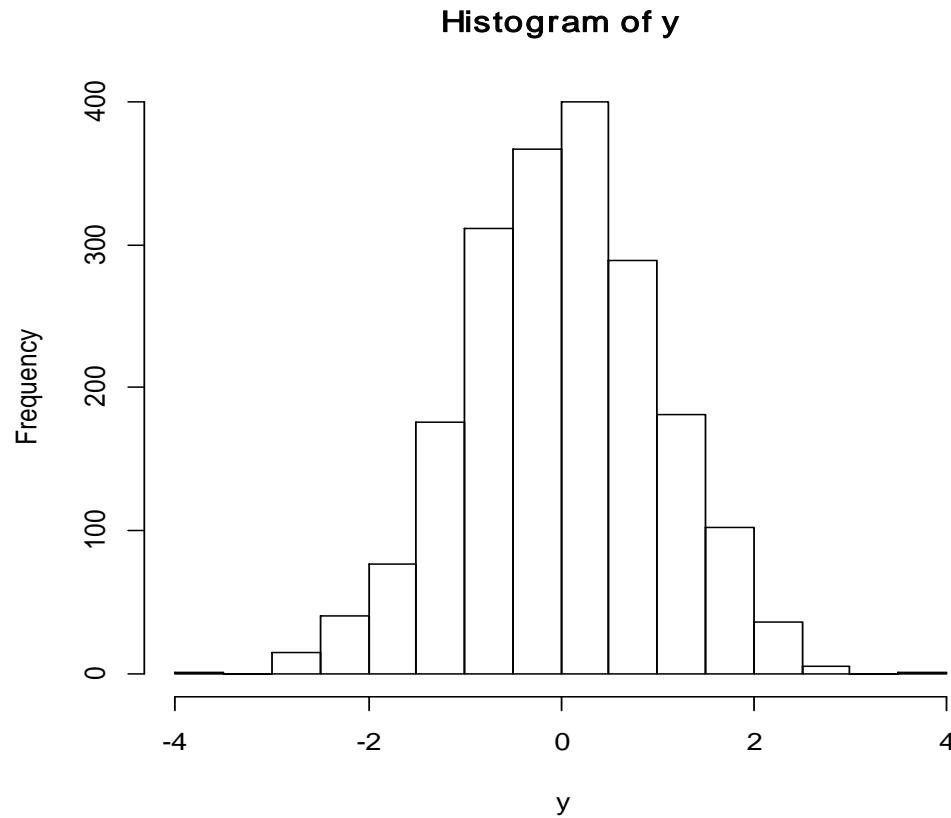
مقدار P-value برای آزمون $\chi^2 = 3.84$ با $df=1$ برابر است با:

```
> 1-pchisq(3.84,1)
[1] 0.05004352
```

هیستوگرام

در آمار و احتمال هیستوگرام، نمودار معروفی است

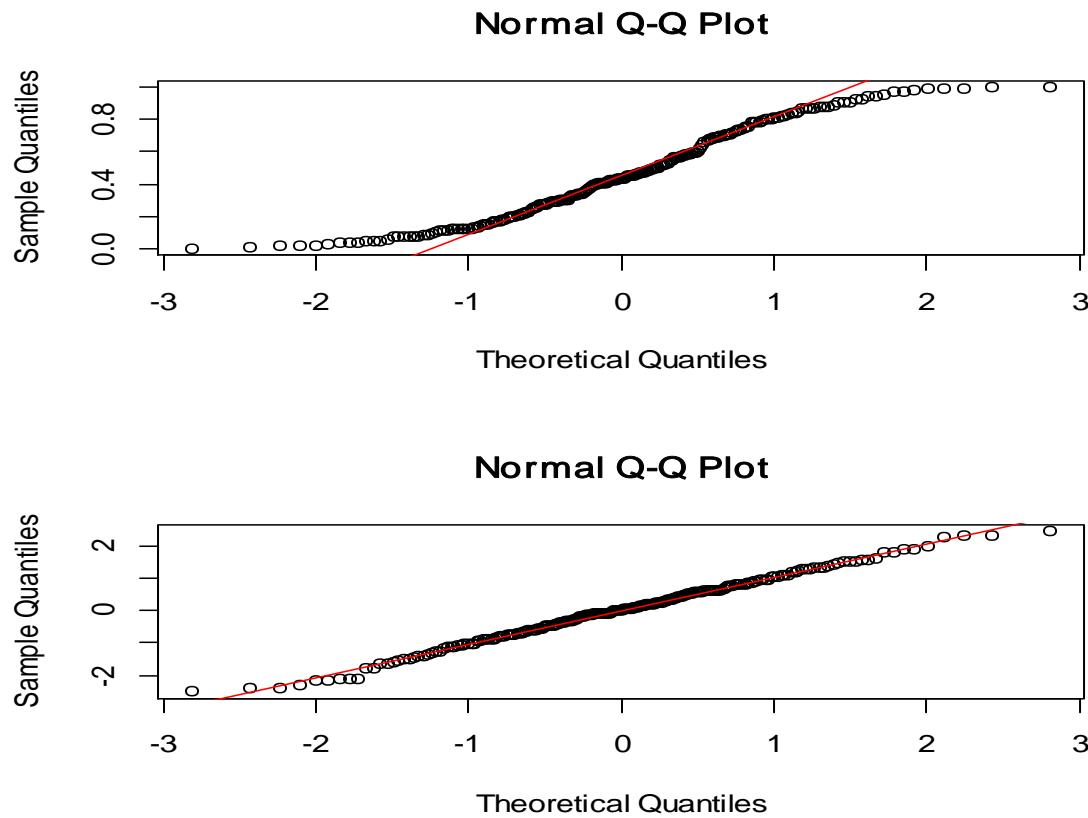
```
> y<-rnorm(2000)  
> hist(y)
```



تابع گرافیکی (`qqplot()`, `qqnorm()` و `qqline()`)

می‌توان نرمال بودن یک سری داده را با تابع `qqnorm()` نشان داد. اگر داده‌ها نرمال باشند، آنگاه یک خط راست را نمایش می‌دهند. ترسیم خط راست از تابع `qqline()` حاصل می‌شود که برای مقایسه بهکار می‌رود. به مثال زیر توجه کنید.

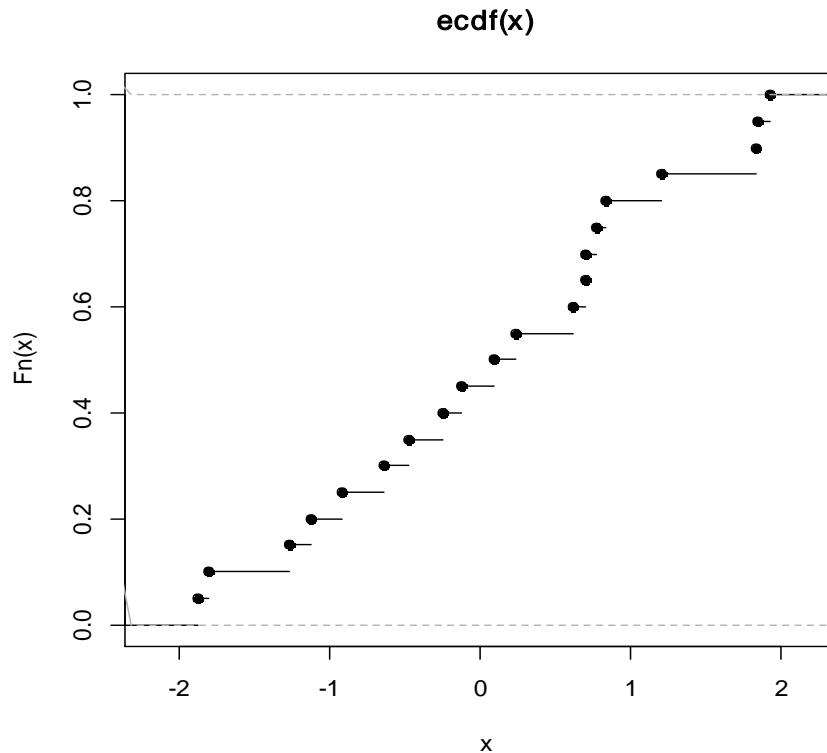
```
x<-runif(200)
> y<-rnorm(200)
> par(mfrow=c(3,1))
> qqnorm(x)
> qqline(x,col="red")
> qqnorm(y)
> qqline(y, col="red")
```



تابع $\text{ecdf}()$

همانطور که قبلاً ملاحظه شد، می‌توان تابع توزیع تجمعی را محاسبه و ترسیم کرد. اما تابعی وجود دارد که $\text{ecdf}()$ نامیده می‌شود و توزیع تجمعی تجربی را بدست می‌دهد. به مثال زیر توجه کنید.

```
> x<-rnorm(20)  
> plot(ecdf(x))
```



نمونه‌گیری تصادفی

تجربه‌های ساده احتمالی مانند انتخاب تصادفی اعداد از ۱ تا ۱۰۰ و کشیدن سه توب از یک کيسه را می‌توان توسط زبان R شبیه‌سازی نمود. تابع `sample()` به صورت کلی زیر است.

```
sample(x, size, replace = FALSE, prob = NULL)
```

که در آن،

`x`: بردار مورد نظر است که می‌تواند عدد و یا کاراکتر باشد.

`size`: تعدادی که باید انتخاب گردد.

`replace`: نمونه‌گیری بدون جایگذاری و یا با جایگذاری انجام گردد.

`prob`: بردار اختیاری است که می‌تواند به انتخاب نمونه‌ها وزن یدهد.

مثال‌ها:

انتخاب یک عدد به تصادف از ۱ تا ۱۰۰

```
> sample(1:100, 1)  
[1] 59
```

```
> sample(1:6,10, replace=T)
[1] 5 1 5 2 4 2 6 6 6 2
```

در گیسه‌ای 8 مهره قرمز 4 مهره آبی و 3 مهره زرد وجود دارد. اکنون 6 مهره به تصادف و بدون جایگذاری انتخاب کنید.

```
> ur=c(rep("red",8),rep("blue",4),rep("yellow",3))
> sample(ur,6,replace=F)
[1] "yellow" "yellow" "red"    "red"    "red"    "red"
```

برآوردهای پارامترهای یک تابع احتمال

همان طور که می دانید به روش های مختلف می توان پارامترهای یک تابع احتمال را برآورد نمود. از روش هایی مانند روش گشتاورها و روش حداقل درستمایی^۱ می توان نام برد و به آنها اشاره نمود.

در زبان R بسته‌ای تحت عنوان MASS وجود دارد که پارامترهای تابع احتمال را به روش حداقل درستمایی برآورد می‌کند. در این بسته تابعی به نام fitdistr موجود است که دارای دو آرگومان ضروری استه اول داده‌هایی که قرار است برآورده تابعی برآورده شوند و دوم تابع احتمال موردنظر که باید در داخل کوتیشن قرار گیرد.

مثال: در اینجا ابتدا یک سری اعداد تصادفی با توزیع گاما (با پارامترهای مشخص) تولید می‌شود. اکنون با فرض تابع احتمال گاما مجدداً پارامترهای تابع احتمال گاما که بر داده‌های مذکور برآورده شده‌اند، برآورده می‌گردد.

```
> x<-rgamma(500,8.5,2.5)
> fitdistr(x,"gamma")
  shape      rate
8.5924296  2.5304502
(0.5332122) (0.1617056)
```

روش‌های آماری

زبان R میزبان روش‌های آماری و آزمون فرض است. در اینجا ری مشهورترین آن‌ها تاکید می‌گردد.

آزمون یک و دو طرفه t

تابع اصلی برای این نوع آزمون `t.test()` است. فرض‌ها در اینجا با تابع چگالی احتمال t آزمون می‌شود.

```
t.test(x, y = NULL, alternative = c("two.sided", "less", "greater"), mu = 0,  
paired = FALSE, var.equal = FALSE, conf.level = 0.95)
```

که در آن:

`x, y`: بردارهای عددی هستند. اگر `y` داده نشود، آنگاه یک آزمون ساده موجود است.

`alternative`: فرض جایگزین توسط رشتی از کارکترها بیان می‌گردد. پیش‌فرض آن "greater" و "two.sided" و "less". شما می‌توانید از حروف اول آن نیز برای بهکارگیری استفاده کنید.

`mu`: عددی که مقدار درست میانگین را نشان می‌دهد (یا اختلاف میانگین‌ها را بیان می‌کند، اگر دو نمونه وجود داشته باشد). پیش‌فرض برابر صفر است.

`paired`: نشانه منطقی است اگر بخواهید آزمون دوتایی داشته باشید.

`var.equal`: متغیر منطقی است. اگر درست (T) باشد واریانس‌ها با هم برابرند و پیش‌فرض آن (F) است.

`conf.level`: سطح اطمینان (پیش‌فرض 95٪) برای برآورد فاصله‌ای میانگین بر حسب فرض جایگزین

مثال ۲: فرض کنید یک افزودنی به سوخت خودرو اضافه می‌گردد. اکنون سوال این است که آیا از مصرف آن‌ها کاسته می‌شود؟ برای این کار شش خودرو از آن استفاده می‌کند و شش خودروی دیگر از آن استفاده نمی‌کند. متغیر mpg (مايل بر گالان) اندازه‌گیری شده است که به صورت زیر است.

Car	1	2	3	4	5	6
mpg w additive	24.6	18.9	27.3	25.2	22.0	30.9
mpg w/o additive	23.8	17.7	26.6	25.1	21.6	29.6

```
> add<-
c(24.6,18.9,27.3,25.2,22.0,30.9)
> noadd<-
c(23.8,17.7,26.6,25.1,21.6,29.6)
F test to compare two variances
> var.test(add,noadd)
```

```
data: add and noadd
F = 1.0179, num df = 5, denom df = 5, p-value = 0.985
alternative hypothesis: true ratio of variances is not equal to 1
95 percent confidence interval:
0.1424311 7.2740660
```

sample estimates:
ratio of variances

1.01797

کارگاه آموزشی، دانشکده ادبیات و علوم انسانی.....

۱۳۰۷۲۷.....

```
> t.test(add,noadd,paired=T,alt="greater")
```

Paired t-test

data: add and noadd

t = 3.9994, df = 5, p-value = 0.005165

alternative hypothesis: true difference in means is greater than 0

95 percent confidence interval:

0.3721225 Inf

sample estimates:

mean of the differences

0.75

اگنون به یک مثال از آزمون مربع خی توجه فرمایید. فرض کنید که یک تاس 300 بار پرتاب شود و نتایج زیر حاصل گردد.

وجه تاس	1	2	3	4	5	6
فرلوانی	43	49	56	45	66	41

اگنون سوال این است که این تاس بی طرف است. یعنی احتمال آمدن هر وجه تاس $\frac{1}{6}$ است؟ برای این کار از آزمون مربع خی استفاده می شود. به گدھای زیر توجه کنید.

```
> count<-c(43,49,56,45,66,41)  
> pr=rep(1/6,6)  
> chisq.test(count,p=pr)
```

Chi-squared test for given probabilities

```
data: count  
X-squared = 8.96, df = 5, p-value = 0.1107
```

مدل‌های رگرسیون

زبان R دارای روتین‌های زیادی برای برازش مدل‌های آماری است. عموماً این مدل‌ها از طریق فراخواندن توابعی مثل `lm`, `glm`, ... عمل می‌کنند. شکل کلی یک مدل آماری برازش به صورت زیر است.

`response ~ expression`

مدل‌های رگرسیون خطی

موجودیت‌های فرمول

زبان R یک مدل خطی را به صورت زیر برازش می‌دهد.

$$y = \beta_0 + \beta_1 x_1 + \cdots + \beta_p x_p + \varepsilon$$

که $(\beta_0, \beta_1, \dots, \beta_p) = \beta$ عرض از مبدأ و ضرایب رگرسیون را نشان می‌دهد. جمله خطای عینی ε غالباً دارای توزیع نرمال با میانگین صفر و واریانس σ^2 است. برای رگرسیون با دو متغیر می‌توان با استفاده از تابع `lm` و فرمول زیر استفاده نمود.

`y ~ x1+x2`

که عبارت فوق به منزله فرمول $y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \epsilon$ است.
به طور پیش فرض، زبان R شامل عرض از مبداء می شود. اما رابطه فوق را به صورت زیر بنویسید عرض از مبداء حذف می گردد.

$$y \sim -1 + x_1 + x_2$$

توجه داشته باشید که عملگرهای * , \backslash , $^+$, $-$ دارای معانی خاصی در رگرسیون خطی هستند. به مثال های زیر توجه کنید.

$$y \sim x_1 + x_2 + x_1 : x_2$$

که عبارت فوق به منزله فرمول $y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \beta_{12}x_1x_2 + \epsilon$ است
استفاده از عملگر * جمله های یگانه و دودویی را به ترتیب ایجاد می کند.

$$y \sim (x_1 + x_2 + x_1 : x_2)^2$$

فرمول بالا معادل رابطه زیر است.

$$y \sim x_1 + x_2 + x_3 + x_1 : x_2 + x_2 : x_3 + x_1 : x_3$$

عملگر $-$ جمله و یا جملاتی را از معادله رگرسیون حذف می کند. همان طور که قبل ملاحظه شد -1 - عرض از مبداء را حذف نمود. به مثال زیر توجه کنید.

$$y \sim (x_1 + x_2 + x_1 \cdot x_2)^2 - x_2 \cdot x_3$$

فرمول بالا معادل رابطه زیر است

$$y \sim x_1 + x_2 + x_3 + x_1 \cdot x_2 + x_1 \cdot x_3$$

تابع I ضریبی را برای متغیر تکرار می کند. به مثال زیر توجه کنید.

$$y \sim I(x_1 + x_2)$$

که عبارت فوق به منزله فرمول $y = \beta_0 + \beta(x_1 + x_2) + \epsilon$ است. ضمناً اگر بخواهید متغیر x در مدل تغییر کند. مثلاً در دو ضرب شود. اگر به صورت زیر عمل کنید اشتباه کرده اید.

$$y \sim x_1 + 2 \cdot x_2$$

برای درست شدن مطلب به صورت زیر باید عمل نمود.

$$y \sim x_1 + I(2 \cdot x_2)$$

اگر مدل مورد نظر به صورت $y = \beta_0 + \beta_1 x + \beta_2 x^2$ باشد، آنگاه فرمول آن در زبان R به شرح زیر است.

$$y \sim \text{poly}(x, 2)$$

و نه به صورت زیر:

$$y \sim x + x^2$$

تواابع مدل سازی

مدل های رگرسیون خطی کاربرد وسیعی برای بیان روابط خطی بین متغیرها دارد. توابع زیادی بلایی برآورده و تحلیل رگرسیون خطی وجود دارد. تابع اصلی برای این کار (`lm`) است که پارهای از آرآرگومان های آن ها به شرح زیر است.

`lm(formula, data, weights, subset, na.action)`

به داده های زیر توجه کنید.

```
> y<-read.table("G:\\Seminar  
R\\reg.txt",header=T)
```

```
> y
```

	x1	x2
1	-1.06	-1.08
2	-0.81	-1.02
3	-0.48	-0.39
4	-0.42	-0.48
5	-0.30	-0.58
6	-0.35	-0.42
7	-0.31	-0.05
8	-0.18	-0.33
9	-0.20	0.51
10	-0.11	-0.53
11	-0.09	-0.47
12	0.16	0.01
13	0.45	0.39
14	0.53	0.11
15	0.67	0.52
16	0.80	0.34
17	0.87	1.08
18	0.92	1.21

ابتدا ضریب همبستگی و آزمون مربوط به آن را ملاحظه خواهید نمود. کدهای زیر آن را خوانده موارد مربوط به آنها را برسی می‌کند.

```
> cor.test(y$x1,y$x2)
```

Pearson's product-moment correlation

data: y\$x1 and y\$x2

t = 7.6264, df = 16, p-value = 1.026e-06

alternative hypothesis: true correlation is not equal to 0

95 percent confidence interval:

0.7138577 0.9568435

sample estimates:

cor

0.8855821

```
> lm(y$x1~y$x2)
```

Call:

lm(formula = y\$x1 ~ y\$x2)

Coefficients:

(Intercept)	y\$x2
0.0575	0.8008

تابع `summary()` برای بدست آوردن پاره‌ای از اطلاعات اضافی از مدل برآورده نظیر مقادیر t ، خطای استاندارد و همبستگی بین پارامترها مفید است. به مثال زیر توجه کنید.

```
> summary(lm(y$x1 ~ y$x2))
```

Call:

```
lm(formula = y$x1 ~ y$x2)
```

Residuals:

Min	1Q	Median	3Q	Max
-0.66591	-0.10313	-0.01195	0.17380	0.47023

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	0.05750	0.06621	0.868	0.398
y\$x2	0.80081	0.10500	7.626	1.03e-06 ***

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.2794 on 16 degrees of freedom

Multiple R-squared: 0.7843, Adjusted R-squared: 0.7708

F-statistic: 58.16 on 1 and 16 DF, p-value: 1.026e-06

با تابع `confint()` می‌توان برآورده فاصله‌ای ضرایب معادله رگرسیون را محاسبه نمود.

```
> confint(lm(y$x1~y$x2))
    2.5 %   97.5 %
(Intercept) -0.08285861 0.1978535
y$x2        0.57820813 1.0234092
```

```
> predict(lm(y$x1~y$x2),new=data.frame(x2=c(0.1,0.2)),int="conf")
    fit      lwr      upr
1 -0.80737591 -1.0728560234 -0.54189579
2 -0.75932739 -1.0135439623 -0.50511081
3 -0.25481792 -0.4119892506 -0.09764660
4 -0.32689070 -0.4942166362 -0.15956477
5 -0.40697157 -0.5875282243 -0.22641492
6 -0.27884218 -0.4391918478 -0.11849252
7  0.01745702 -0.1221813294  0.15709538
8 -0.20676940 -0.3582686575 -0.05527015
9  0.46590988  0.2764333567  0.65538640
10 -0.36693114 -0.5406419858 -0.19322029
11 -0.31888262 -0.4849916175 -0.15277362
12  0.06550554 -0.0750993937  0.20611048
13  0.36981284  0.1972722873  0.54235339
14  0.14558641  0.0006242462  0.29054858
15  0.47391797  0.2829292365  0.66490669
16  0.32977240  0.1635292220  0.49601559
17  0.92237082  0.6316604203  1.21308122
18  1.02647595  0.7100767704  1.34287512
```

Warning message:

'newdata' had 2 rows but variable(s) found have 18 rows

منابع:

- 1-“R language manual in Farsi” by Saeed Mousavi ([PDF](#), 2012-10-08, 179 pages).
- 2-“SNA in R Tutorial in Farsi” by Mohsen Raeesi ([PDF](#), 2011-09-01).
- 3-“Special topics with R in Farsi” by Saeed Mousavi ([PDF](#), 2012-09-26, 62 pages).
- 4-محاسبات آماری با R، مجید رضایی و همکاران،
دانشگاه بیرجند.

بَاشْكُر