

DA-习题课

20210419

1. DataCamp
2. 课堂测试讲解

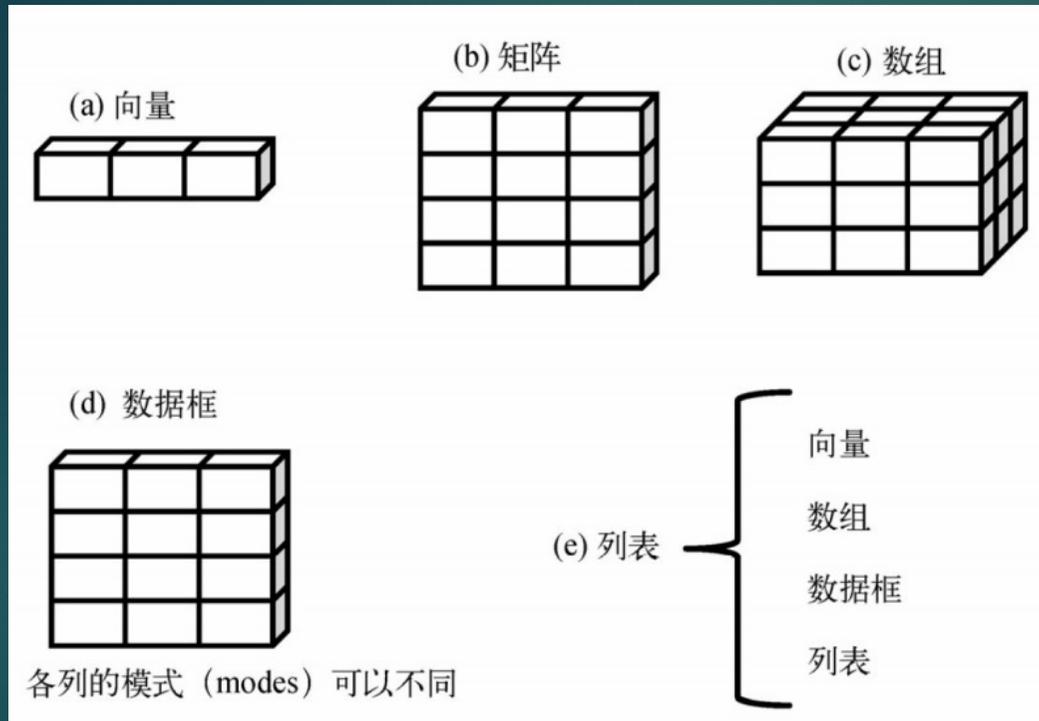
1.1 Introduction to R & Intermediate R

1. 基本数据结构的创建和使用
2. 基本运算
3. 常见函数的定义和使用
4. 自定义函数的使用与Apply族函数
5. 其他

更多详细内容参见课件DA-02和DA03

1.1 Introduction to R & Intermediate R

1. 基本数据结构的创建和使用



1.1 Introduction to R & Intermediate R

1. 基本数据结构的创建和使用

向量：

创建：`v <- c(1,2,3); seq(from=value1, to=value2,by=value3); rep(x,times=n)`

提取：`x[5]; x[1:3], x[c(1,3)], x[-5]`（去除）

矩阵：

创建：`m <- matrix(vector, nrow, ncol, byrow, dimnames=list(rownames, colnames))`

提取：`m[i, j], m[i,], m[, j]`

由矩阵可以引申到更高维的array

数据框：

不同的列可以包含不同模式的数据

创建：`df <- data.frame(col1_vec, col2_vec, ...)`, `col1_vec`为列向量，可以是任意类型

提取：`df[1:2], df$col1, df[c("col1", "col2")]`

列表：

一些数据对象的有序集合

创建：`l <- list(object1, object2, ...); l <- list(name1=object1, name2=object2, ...)`

提取：`l[[1]], l$name`

其他：

因子的创建和使用

`str()`查看数据对象的结构;

`summary()`查看数据对象的统计概要

1.1 Introduction to R & Intermediate R

2. 基本运算

<code>+</code>	加	<code>><</code>	大于, 小于
<code>-</code>	减	<code><=, >=</code>	大于等于, 小于等于
<code>*</code>	乘	<code>!=, ==</code>	不等于, 等于
<code>/</code>	除	<code>!x</code>	非x
<code>^, **</code>	求幂	<code>x y</code>	x或者y
<code>x %% Y</code>	求余	<code>x & y</code>	x和y
<code>x %/% Y</code>	整除	<code>isTRUE(x)</code>	x是否为TRUE

3. 常见函数的定义和使用

详见DA-02 P16-P18 & DA-03 P05-P15部分

1.1 Introduction to R & Intermediate R

4. 自定义函数的使用与Apply函数族

```
function(arg1,arg2,...) {  
  statements  
  return (object)  
}
```

```
myfun <- function() {  
  print("hello world")  
  return ()  
}
```

```
> f <- function(x,y) x + y  
> f  
function(x,y) x + y  
> f(1,2)  
[1] 3
```

1.1 Introduction to R & Intermediate R

4. 自定义函数的使用与Apply族函数

Description

Returns a vector or array or list of values obtained by applying a function to margins of an array or matrix.

Usage

```
apply(X, MARGIN, FUN, ...)
```

Arguments

X	an array, including a matrix.
MARGIN	a vector giving the subscripts which the function will be applied over. E.g., for a matrix `1` indicates rows, `2` indicates columns, `c(1, 2)` indicates rows and columns. Where `x` has named dimnames, it can be a character vector selecting dimension names.
FUN	the function to be applied: see 'Details'. In the case of functions like `+`, `%%`, etc., the function name must be backquoted or quoted.
...	optional arguments to `FUN`.

1.1 Introduction to R & Intermediate R

4. 自定义函数的使用与Apply族函数

Apply()函数族除了Apply()函数外，常见的还包括lapply(), sapply()等函数。

lapply(X, FUN, ...) , lapply()函数返回一个与输入X等长度的list ;

sapply(X, FUN, ...) , sapply是一个简化且使用更加友好的版本，其返回值是一个向量或矩阵

使用apply族函数的最大优势可以代替循环结构，简化编程并提高执行效率

更多详细的使用可在<https://www.rdocumentation.org/>中查询。

5. 其他

流程控制、循环语句等，参见DA-04。

1.2 Introduction to Importing Data in R

1. CSV文件
2. TXT文件
3. XLS文件
4. XLConnect

更多详细内容可参见<https://www.tutorialspoint.com/r/>

1.2 Introduction to Importing Data in R

R Language

read.table()

表2-2 函数read.table()的选项

选 项	描 述
<u>header</u>	一个表示文件是否在第一行包含了变量名的逻辑型变量
<u>sep</u>	分开数据值的分隔符。默认是 sep=" "，这表示了一个或多个空格、制表符、换行或回车。使用 sep="," 来读取用逗号来分隔行内数据的文件，使用 sep="\t" 来读取使用制表符来分隔行内数据的文件
row.names	一个用于指定一个或多个行标记符的可选参数
col.names	如果数据文件的第一行不包括变量名 (header=FALSE)，你可以用 col.names 去指定一个包含变量名的字符向量。如果 header=FALSE 以及 col.names 选项被省略了，变量会被分别命名为 V1、V2，以此类推
na.strings	可选的用于表示缺失值的字符向量。比如说，na.strings=c("-9", "?") 把 -9 和 ? 值在读取数据的时候转换成 NA
<u>colClasses</u>	可选的分配到每一列的类向量。比如说，colClasses=c("numeric", "numeric", "character", "NULL", "numeric") 把前两列读取为数值型变量，把第三列读取为字符型向量，跳过第四列，把第五列读取为数值型向量。如果数据有多余五列，colClasses 的值会被循环。当你在读取大型文本文件的时候，加上 colClasses 选项可以可观地提升处理的速度
quote	用于对有特殊字符的字符串划定界限的自反引号。默认值是双引号 (") 或单引号 (')
<u>skip</u>	读取数据前跳过的行的数目。这个选项在跳过头注释的时候比较有用
<u>stringsAsFactors</u>	一个逻辑变量，标记处字符向量是否需要转化成因子。默认值是 TRUE，除非它被 colClasses 所覆盖。当你在处理大型文本文件的时候，设置成 stringsAsFactors=FALSE 可以提升处理速度
text	一个指定文字进行处理的字符串。如果 text 被设置了，file 应该被留空。2.3.1 节给出了一个例子

1.2 Introduction to Importing Data in R

1. CSV文件

“逗号分隔值 (Comma-Separated Values, CSV, 有时也称为字符分隔值, 因为分隔字符也可以不是逗号), 其文件以纯文本形式存储表格数据 (数字和文本)” —— 百度百科

`read.csv()`

readr: `read_csv(file, skip, nmax)`

data.table: `fread(file, select, drop)`

2. TXT文件

`read.delim()` 注意header参数和colNames参数的搭配

readr: `read_delim(file, delim, quote = "\"", col_names = TRUE, na = c("", "NA"), skip = 0, n_max = Inf)`

1.2 Introduction to Importing Data in R

3. XLS文件

readxl库 :

`excel_sheets(filePath)`

获取xls文件中的每个sheet名

`read_excel(filePath, sheet=sheetName or sheetNumber)`

读取xls文件中具体某个sheet信息

Tips: 可以利用lapply函数读取所有sheet提高执行效率

`read_excel`常用的可选参数 :

`col_names` : FALSE or vector , 是否指定列名

`skip`: 读取数据前跳过若干行

gdata库:

`read.xls(path, sheet=sheetName or sheetNumber)`

1.2 Introduction to Importing Data in R

4. XLConnect库的使用

XLConnect库封装一系列接口来实现对XLS文件的读写，主要包括一些方法：

```
myBook <- loadWorkbook(filepath)
getSheets(myBook)
readWorksheet(my_book, sheet = Name/Number, startCol, endCol)
```

```
createSheet(my_book, sheetName)
writeWorksheet(my_book, sheet, sheetName)
saveWorkbook(my_book, file = "xxx.xlsx")
```

```
renameSheet(my_book, "data_summary", "summary")
removeSheet(my_book, 4)
```

1.3 Cleaning Data in R

1. 数据类型转换
2. 重复值处理
3. 异常值处理

1.3 Cleaning Data in R

1. 数据类型转换

`glimpse()` 查看数据框中所有列的数据类型

`summary()` 查看数据框概括信息

利用`mutate()`向数据框增加一列的数据：

```
df <- mutate(df, newscore = score2020)
```

```
OR df <- df %>% mutate(newscore = score2020)
```

(`%>%`，管道，提高编码的效率和可读性)

利用`as.TYPE()`进行数据类型转换

1.3 Cleaning Data in R

2. 重复值处理

`duplicated()`

`distinct()`

`df %>% count(col) %>% filter(n > 1)`

3. 异常值/缺失值处理

根据实际数据来判断是否异常，eg：年月日、时间

根据数据整体分布判断是否异常，eg：绘图查看

`is.na()`

`filter(!is.na(vec))`

1.4 Data Visualization & Visualizing Time Series Data in R

此部分为近期课程学习内容，如有疑问请参见课件DA-05 ~ DA-10

基础: `plot(x, y, ...)`

``main``

an overall title for the plot: see ``title``.

``sub``

a sub title for the plot: see ``title``.

``xlab``

a title for the x axis: see ``title``.

``ylab``

a title for the y axis: see ``title``.

``type``

what type of plot should be drawn. Possible types are

- ``"p"`` for points,
- ``"l"`` for lines,
- ``"b"`` for both,
- ``"c"`` for the lines part alone of ``"b"``,
- ``"o"`` for both 'overplotted',
- ``"h"`` for 'histogram' like (or 'high-density') vertical lines,
- ``"s"`` for stair steps,
- ``"S"`` for other steps, see 'Details' below,
- ``"n"`` for no plotting.

1.4 Data Visualization & Visualizing Time Series Data in R

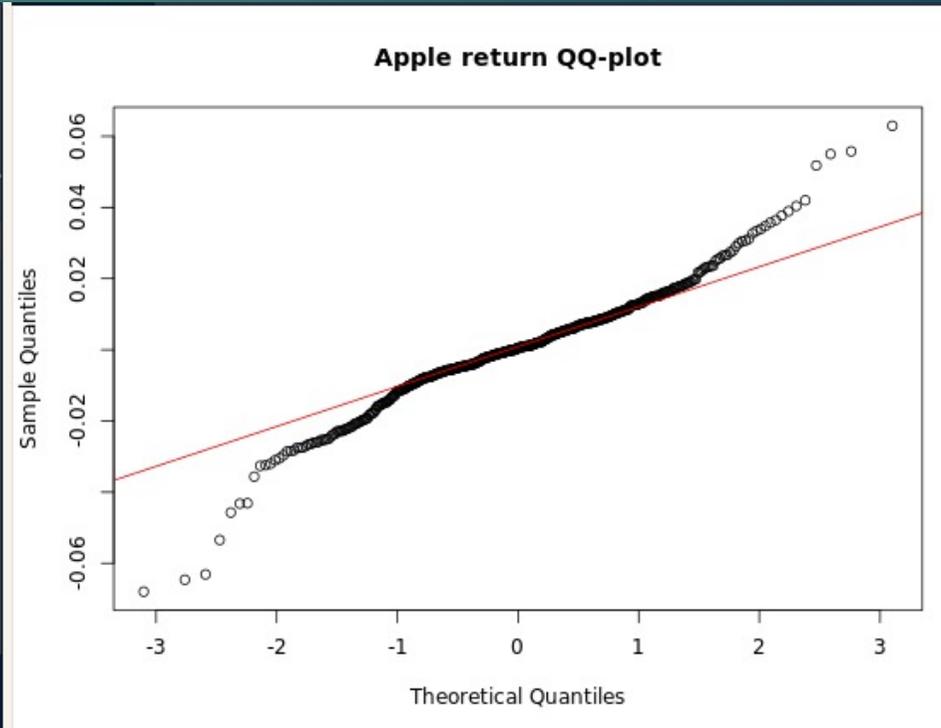
此部分为近期课程学习内容，如有疑问请参见课件DA-05 ~ DA-10

正态分布数据的展示：q-qplot

用qqnorm()和qqline()作正态QQ图。当变量样本来自正态分布总体时，图的散点近似在一条直线周围。

```
# Create q-q plot
qqnorm(rtn, main = "Apple return QQ-plot")

# Add a red line showing normality
qqline(rtn, col = "red")
```



1.4 Data Visualization & Visualizing Time Series Data in R

此部分为近期课程学习内容，如有疑问请参见课件DA-05 ~ DA-10

时序数据相关性展示：

```
acf(x, lag.max = NULL, type = c("correlation", "covariance", "partial"),  
    plot = TRUE, na.action = na.fail, demean = TRUE, ...)
```

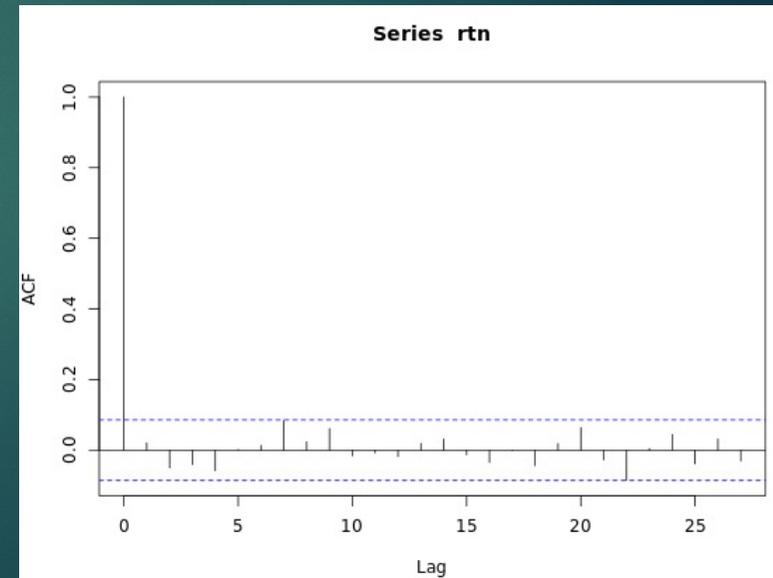
x: 一元或多元（不ccf）数字时间序列对象或一个数值向量或矩阵

lag.max: 计算acf的最大延迟，默认值为 $10 \cdot \log_{10}(N/m)$ ，其中N是观察数，m是序列维度

type: 指定具体的相关性计算指标，包括自相关、协方差和偏自相关

plot: 是否绘图

na.action: 缺失值处理方法

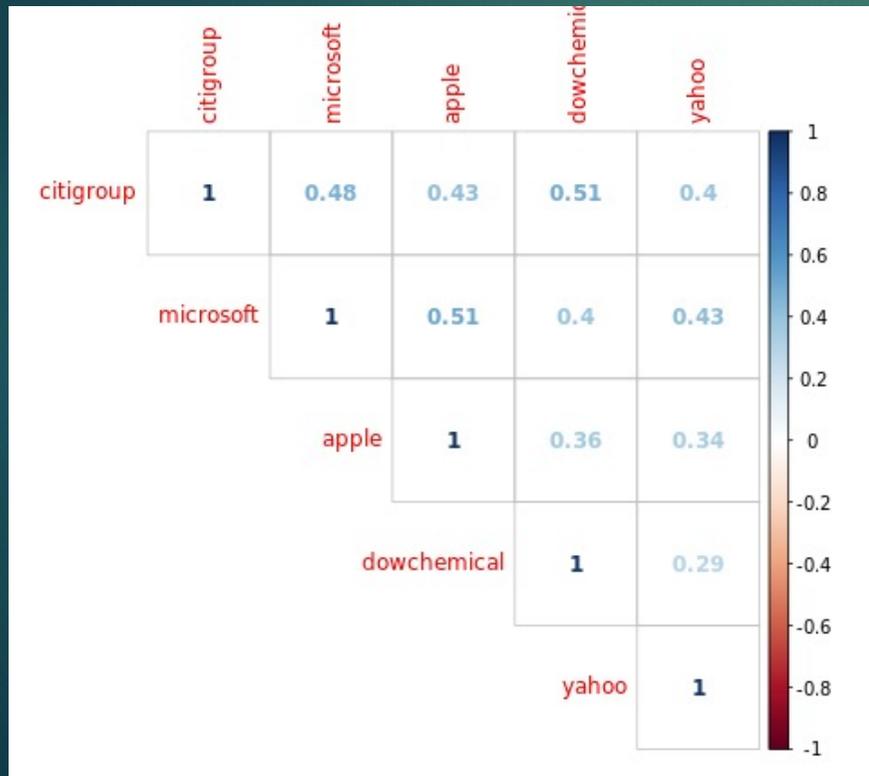


1.4 Data Visualization & Visualizing Time Series Data in R

此部分为近期课程学习内容，如有疑问请参见课件DA-05 ~ DA-10

相关性矩阵及其展示

```
cov(x, y = NULL, method = c("pearson", "kendall", "spearman"))  
corplot(M, ...)
```



1.4 Data Visualization & Visualizing Time Series Data in R

此部分为近期课程学习内容，如有疑问请参见课件DA-05 ~ DA-10

ggplot2绘图的整体流程

```
ggplot(data = <DATA>) +  
  <GEOM_FUNCTION> (  
    mapping = aes(<MAPPINGS>),  
    stat = <STAT> ,  
    position = <POSITION>  
  ) +  
  <COORDINATE_FUNCTION> +  
  <FACET_FUNCTION> +  
  <SCALE_FUNCTION> +  
  <THEME_FUNCTION>
```

Required

Not
required,
sensible
defaults
supplied

2. 课堂测试讲解

R Graphics II

课堂测试04

30分钟

1. 使用鸢尾花数据iris

- 1) 先用names()观察其结构，然后用花瓣长度和宽度做散点图
- 2) 在plot函数里面添加细节。修改点的形状和颜色由白色空心圆换成红色雪花；修改坐标轴名称并添加标题 "relationship between width and length of Iris petal"。

2. 使用 airquality 数据

- 1) 绘温度 Temp 直方图，加一个横坐标"Temperature",加一个标题"The Distribution of Temperature"
- 2) 频数变频率，并设置颜色为绿色
- 3) 四幅图放在一个面板里，两个一排。并使用MASS包的trueHist函数画出频率直方图：
 - 第一幅图，airquality里温度变量的直方图（频数）
 - 第二幅图，airquality里该变量的直方图（频率）并添加密度曲线，填充红色
 - 第三幅图，airquality里风速变量的直方图（频数）
 - 第四幅图，airquality里该变量的直方图（频率），并添加密度曲线，填充蓝色

3. 使用mtcars里的mpg做箱图

给箱图添加坐标轴：x轴为"Number of Cylinders"，y轴为="Miles Per Gallon"标题"Car Milage Data"。根据不同cyl变量下mpg的箱线图，并添加x轴"Number of Cylinders",y轴"Miles Per Gallon"

4. 按要求作图：

- 1) 创建字符向量colors,元素为"green","orange","brown";创建字符向量months,元素为"一月","二月","三月","四月","五月";创建字符向量regions,元素为"东部地区","西部地区","南部地区";创建矩阵values,元素为值
2,9,3,11,9,4,8,7,3,12,5,2,8,10,11，要求3行5列
- 2) 使用矩阵values创建推叠的条形图，添加标题为"总收入"，x轴名称为"月份"，y轴名称为"收入"，条形图的标签为字符向量months(使用names.arg参数)，推叠台型图的颜色设置为创建的字符向量colors
- 3) 添加图例，内容为字符向量regions，分别对应条形图中的三种颜色

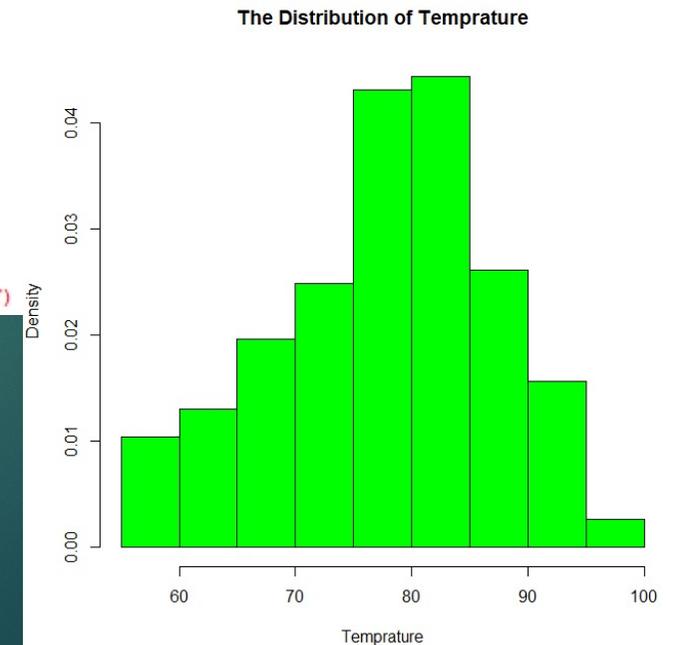
2.1 课堂测试4

1.

```
> names(iris)
[1] "Sepal.Length" "Sepal.Width" "Petal.Length" "Petal.Width" "Species"
>
>
>
>
> plot(iris$Sepal.Length, iris$Sepal.Width, xlab="length", ylab="width", col="red", pch=8, main="relation ship between width and length of its petal")
```

2.

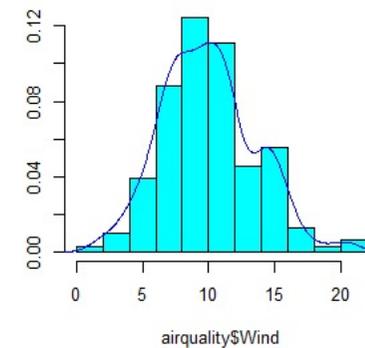
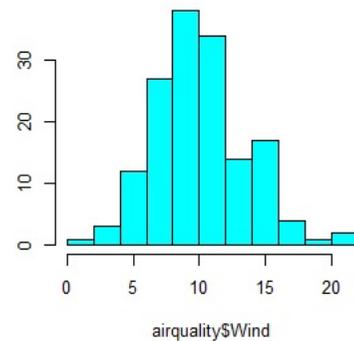
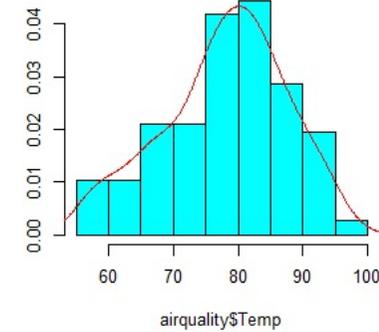
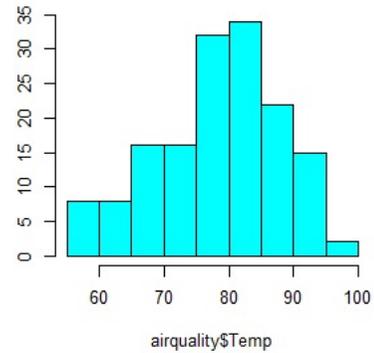
```
> names(airquality)
[1] "Ozone" "Solar.R" "Wind" "Temp" "Month" "Day"
> str(airquality)
'data.frame': 153 obs. of 6 variables:
 $ Ozone : int 41 36 12 18 NA 28 23 19 8 NA ...
 $ Solar.R: int 190 118 149 313 NA NA 299 99 19 194 ...
 $ Wind : num 7.4 8 12.6 11.5 14.3 14.9 8.6 13.8 20.1 8.6 ...
 $ Temp : int 67 72 74 62 56 66 65 59 61 69 ...
 $ Month : int 5 5 5 5 5 5 5 5 5 5 ...
 $ Day : int 1 2 3 4 5 6 7 8 9 10 ...
>
> hist(airquality$Temp, xlab="Temprature", main="The Distribution of Temprature", col="green", freq=F)
```



2.1 课堂测试4

2.

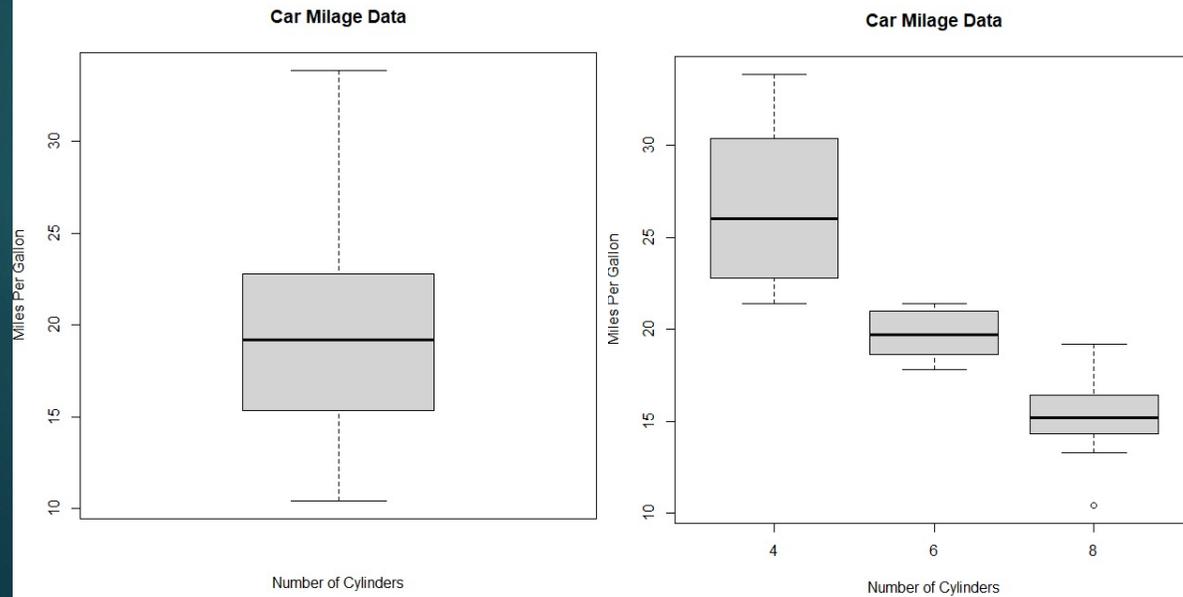
```
> library(MASS)
>
> par(mfrow=c(2,2))
> truehist(airquality$Temp, prob=FALSE)
> truehist(airquality$Temp, prob=TRUE)
> lines(density(airquality$Temp), col="red")
> truehist(airquality$Wind, prob=FALSE)
> truehist(airquality$Wind, prob=TRUE)
> lines(density(airquality$Wind), col="blue")
> |
```



2. 课堂测试4

3.

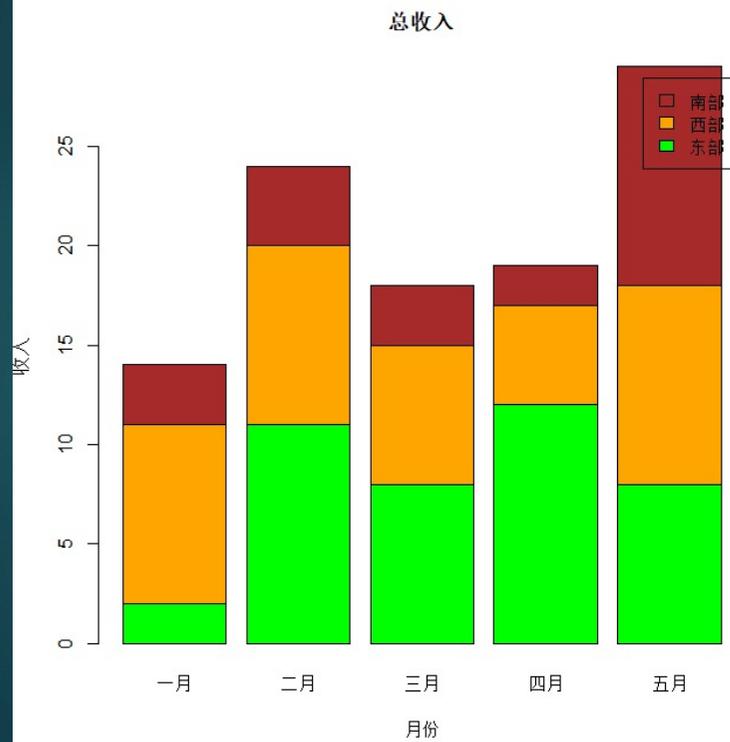
```
> str(mtcars)
'data.frame':   32 obs. of  11 variables:
 $ mpg : num  21 21 22.8 21.4 18.7 18.1 14.3 24.4 22.8 19.2 ...
 $ cyl : num  6 6 4 6 8 6 8 4 4 6 ...
 $ disp: num  160 160 108 258 360 ...
 $ hp  : num  110 110 93 110 175 105 245 62 95 123 ...
 $ drat: num  3.9 3.9 3.85 3.08 3.15 2.76 3.21 3.69 3.92 3.92 ...
 $ wt  : num  2.62 2.88 2.32 3.21 3.44 ...
 $ qsec: num  16.5 17 18.6 19.4 17 ...
 $ vs  : num  0 0 1 1 0 1 0 1 1 1 ...
 $ am  : num  1 1 1 0 0 0 0 0 0 0 ...
 $ gear: num  4 4 4 3 3 3 3 4 4 4 ...
 $ carb: num  4 4 1 1 2 1 4 2 2 4 ...
>
>
> boxplot(mtcars$mpg, xlab="Number of Cylinders", ylab="Miles Per Gallon", main="Car Milage Data")
> boxplot(mtcars$mpg ~ mtcars$cyl, xlab="Number of Cylinders", ylab="Miles Per Gallon", main="Car Milage Data")
```



2. 课堂测试4

4.

```
> colors <- c("green", "orange", "brown")
> months <- c("一月", "二月", "三月", "四月", "五月")
> regions <- c("东部", "西部", "南部")
> values <- matrix(c(2, 9, 3, 11, 9, 4, 8, 7, 3, 12, 5, 2, 8, 10, 11), nrow=3)
>
>
> barplot(values, xlab="月份", ylab="收入", main="总收入", col=colors, names.arg=months, legend=regions)
```



2.2 课堂测试5

Course Wrap-up

课堂测试05

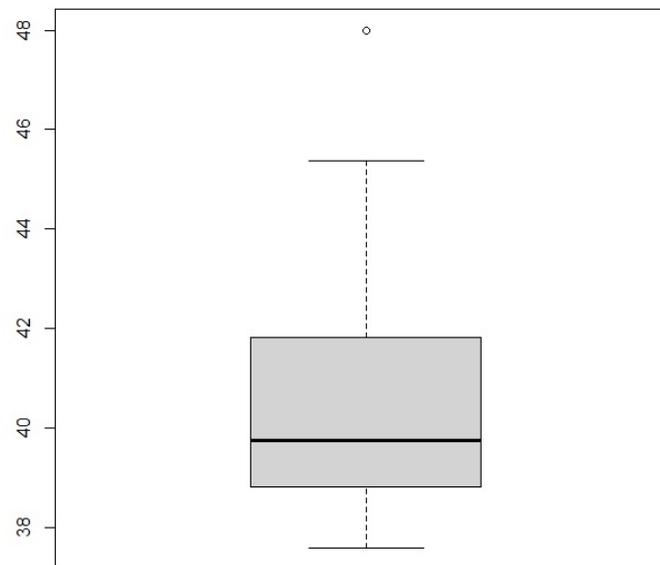
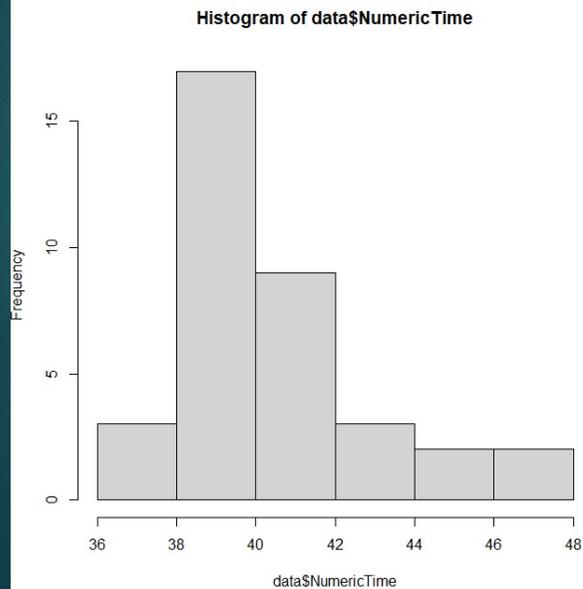
30分钟

- 1、数据集alpe_d_huez2描述了环法自行车赛期间Alpe d'Huez赛段的最快时间，以及关于年份和吸毒指控的背景信息。绘制出车手最快时间的分布。使用a) 直方图和b) 箱线图显示它们。
- 2、mtcars是datasets包中的数据集。请使用str()函数了解这个数据集的构成，并输出数据集，然后按要求画图：
 - * a. 我们要设置一个蓝色背景和红色的点或线。我们应该使用什么命令
 - * b. 画出cyl和mpg关系的散点图，并将结果输出为plot.png，要求输出为白底，360px*360px,点的大小为72
- 3、obama_vs_mccain数据集描述了2008年美国总统选举中的各州投票信息，以及关于收入，失业，种族和宗教的背景信息。
 - * a. 画出收入Income和参加选举比例Turnout之间的关系的散点图。提示：Turnout存在Na值。
 - * b. 将上述图形点的形状为黑色实心三角形(17)
 - * c. 数据集中有一个因子类型的列regions,请画出每个地区region下的收入Income和参加选举比例Turnout之间的关系的散点图。要求设置布局为5列，行优先。

2.2 课堂测试5

1.

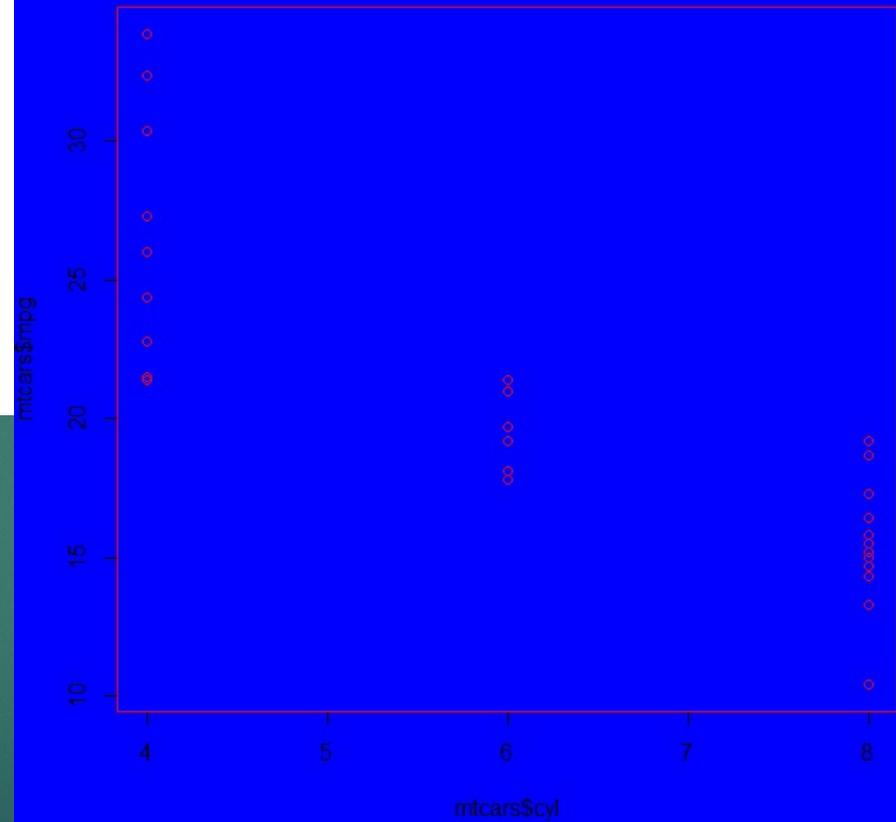
```
> getwd()
[1] "C:/Users/Melyn/Documents"
> data <- read.csv("alpe_d_huez2.csv")
> str(data)
'data.frame':  36 obs. of  7 variables:
 $ Time      : chr  "37' 35\" "37' 36\" "38' 00\" "38' 01\" ...
 $ NumericTime: num  37.6 37.6 38 38 38.1 ...
 $ Name      : chr  "Marco Pantani" "Lance Armstrong" "Marco Pantani" "Lance Armstrong" ...
 $ Year      : int  1997 2004 1994 2001 1995 1997 2006 2006 2004 1997 ...
 $ Nationality: chr  "Italy" "United States" "Italy" "United States" ...
 $ DrugUse   : logi  TRUE TRUE TRUE TRUE TRUE TRUE ...
 $ Allegations: chr  "Alleged drug use during 1997 due to high haematocrit levels." "2004 Tour"
> hist(data$NumericTime)
> boxplot(data$NumericTime)
```



2.2 课堂测试5

2.

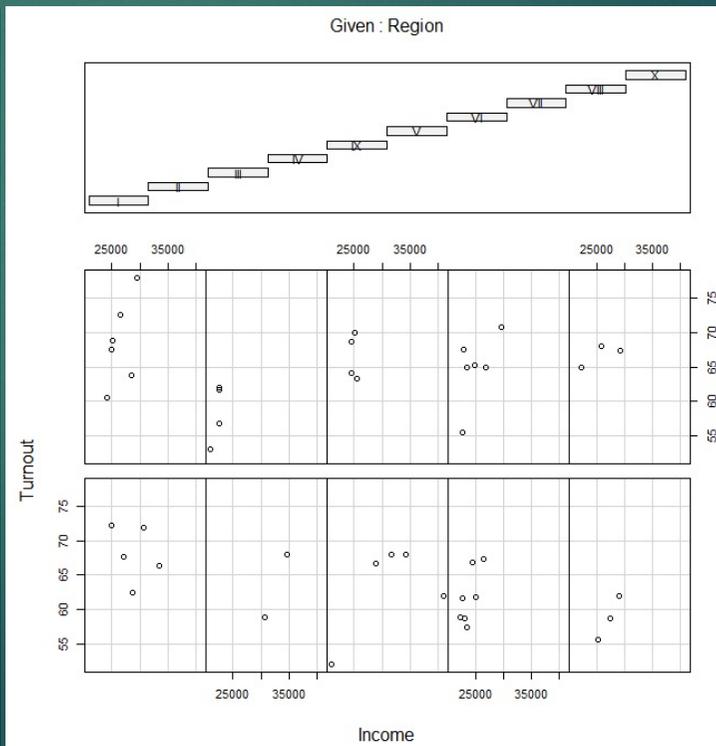
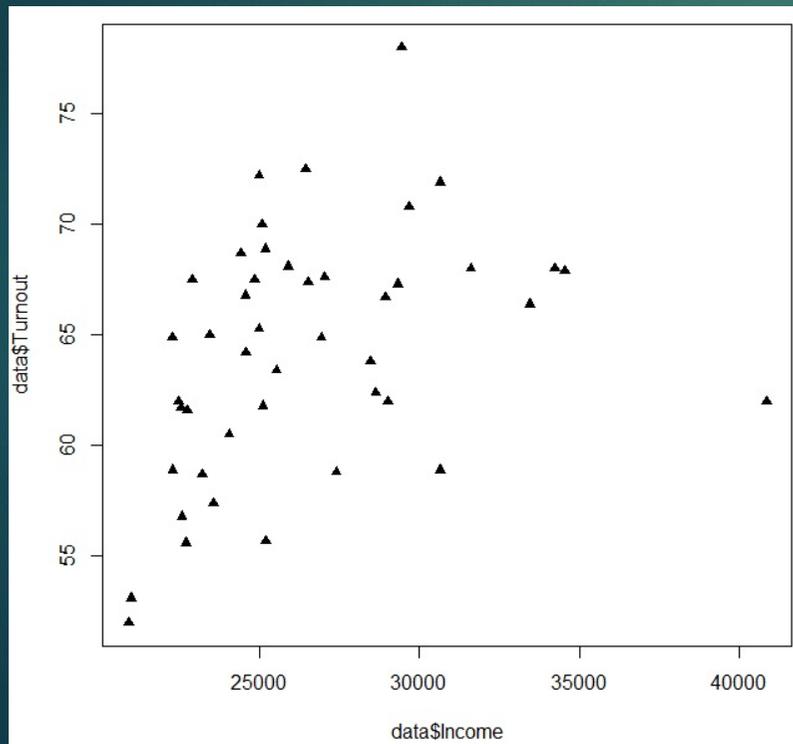
```
> str(mtcars)
'data.frame': 32 obs. of 11 variables:
 $ mpg : num  21 21 22.8 21.4 18.7 18.1 14.3 24.4 22.8 19.2 ...
 $ cyl : num  6 6 4 6 8 6 8 4 4 6 ...
 $ disp: num  160 160 108 258 360 ...
 $ hp  : num  110 110 93 110 175 105 245 62 95 123 ...
 $ drat: num  3.9 3.9 3.85 3.08 3.15 2.76 3.21 3.69 3.92 3.92 ...
 $ wt  : num  2.62 2.88 2.32 3.21 3.44 ...
 $ qsec: num  16.5 17 18.6 19.4 17 ...
 $ vs  : num  0 0 1 1 0 1 0 1 1 1 ...
 $ am  : num  1 1 1 0 0 0 0 0 0 0 ...
 $ gear: num  4 4 4 3 3 3 3 4 4 4 ...
 $ carb: num  4 4 1 1 2 1 4 2 2 4 ...
> par(bg="blue", col="red")
> plot(mtcars$cyl, mtcars$mpg, bg="white", col="red")
> png("plot.png", width=360, height=360, units="px", pointsize=72)
> |
```



2.2 课堂测试5

3.

```
> data <- read.csv("obama_vs_mccain.csv", header=TRUE)
> data <- na.omit(data)
> plot(data$Income, data$Turnout, pch=17)
>
> coplot(Turnout ~ Income | Region, data=data, column=5)
> |
```



2. 课堂测试讲解

ggplot2 II

课堂测试06

先用电脑完成
40分钟 然后誊抄纸上

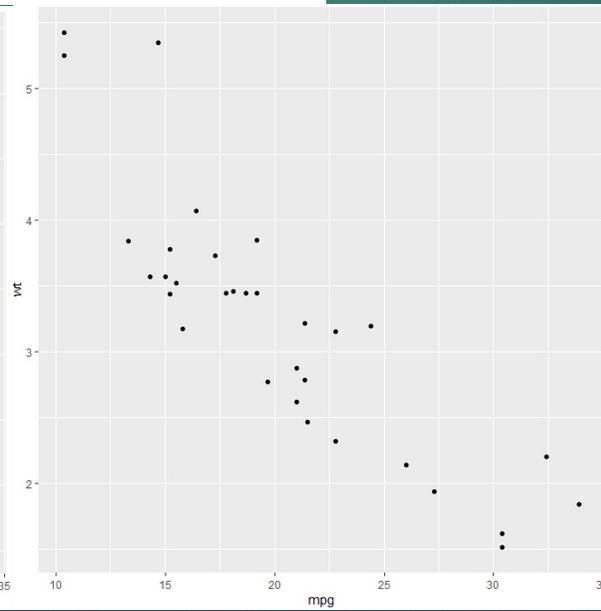
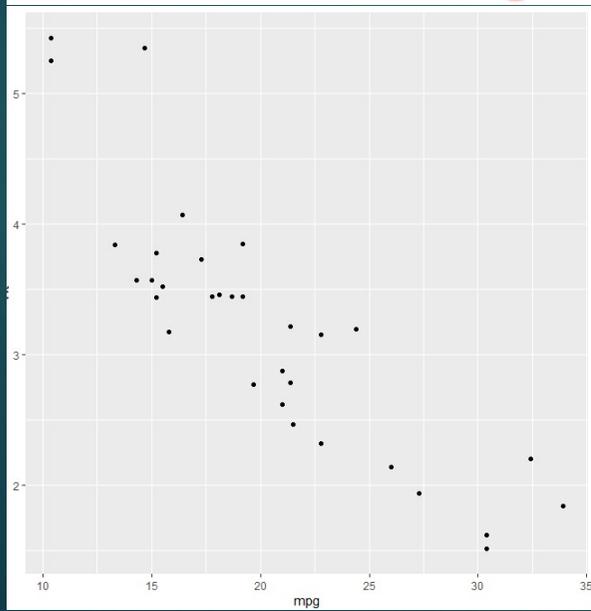
- 1、查看数据集mtcars，根据要求作图：
 - (1)分别使用qplot、ggplot函数画出mpg和wt关系的散点图；
 - (2)使用三种方式画出mpg列的直方图,同时在使用qplot和ggplot时指定每个小圆柱体的宽度是4；
 - (3)使用三种绘图函数画出mpg变量的密度曲线。
- 2、使用datasets包中的数据集pressure，查看其数据并按要求画图：
 - (1)请画出pressure和temperature关系的曲线图；
 - (2)分别使用qplot和ggplot画出pressure和temperature关系的散点图和折线图。
- 3、使用datasets中的数据 ToothGrowth，完成如下的绘图要求：
 - (1)以supp变量作为分类,分别使用三种绘图函数画出len变量的箱型图。
- 4、使用ggplot2包中数据集mpg，完成练习：
 - (1)使用mpg数据集定义一个 ggplot对象，表示hwy与cty的关系；
 - (2)画一个散点图，指定颜色有year列来指定，并在上边绘图的基础上画出平滑的拟合曲线；
 - (3)继续使用(1)中定义的ggplot对象画散点图，使用class来指定颜色，displ指定大小，透明度；指定为0.5,position指定为抖动，在散点图的基础上添加拟合曲线；
 - (4)使用qplot画出hwy与cty的关系的散点图，并根据year变量分面，同时添加拟合曲线。

2.3 课堂测试6

1.

```
> str(mtcars)
'data.frame':  32 obs. of  11 variables:
 $ mpg : num  21 21 22.8 21.4 18.7 18.1 14.3 24.4 22.8 19.2 ...
 $ cyl : num   6 6 4 6 8 6 8 4 4 6 ...
 $ disp: num  160 160 108 258 360 ...
 $ hp  : num  110 110 93 110 175 105 245 62 95 123 ...
 $ drat: num   3.9 3.9 3.85 3.08 3.15 2.76 3.21 3.69 3.92 3.92 ...
 $ wt  : num   2.62 2.88 2.32 3.21 3.44 ...
 $ qsec: num  16.5 17 18.6 19.4 17 ...
 $ vs  : num   0 0 1 1 0 1 0 1 1 1 ...
 $ am  : num   1 1 1 0 0 0 0 0 0 0 ...
 $ gear: num   4 4 4 3 3 3 3 4 4 4 ...
 $ carb: num   4 4 1 1 2 1 4 2 2 4 ...

> qqplot(mpg, wt, data=mtcars)
> ggplot(mtcars, aes(mpg, wt)) + geom_point()
```

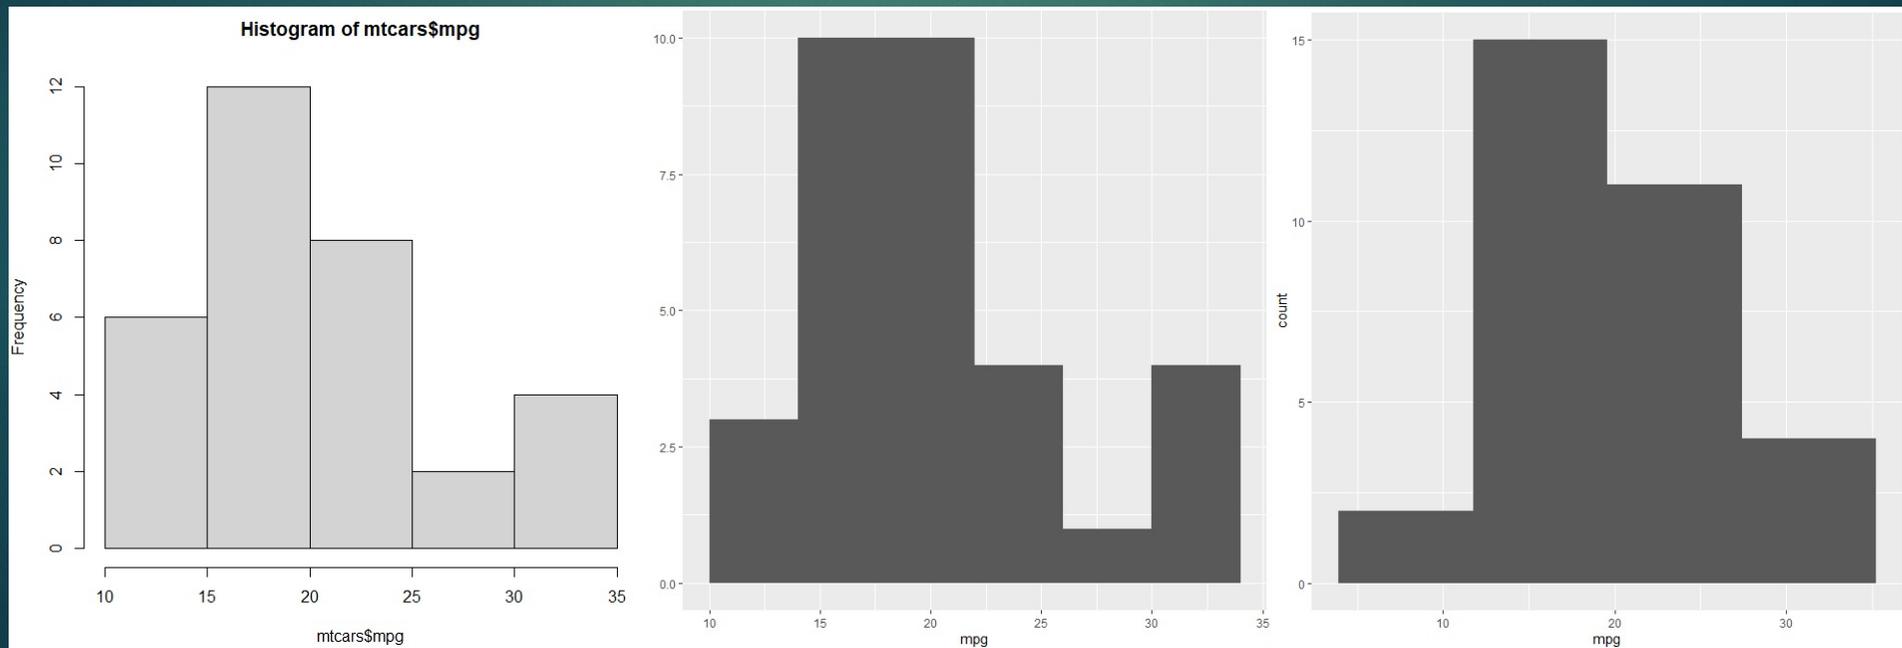


2.3 课堂测试6

1.

```
> hist(mtcars$mpg)
> qplot(mpg, data=mtcars, geom="histogram", binwidth=4)
> ggplot(mtcars, aes(x=mpg)) + geom_histogram(bins=4)
```

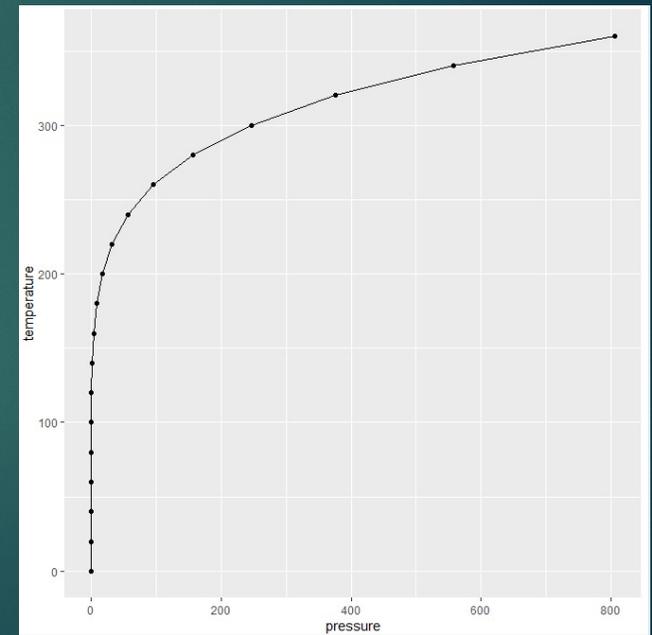
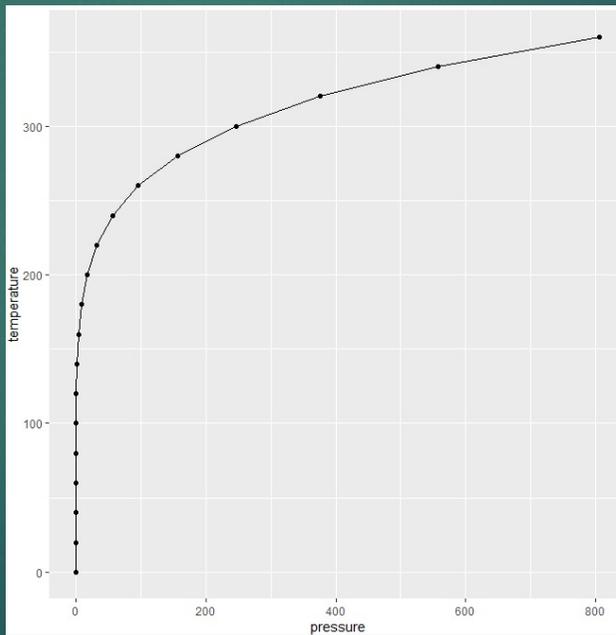
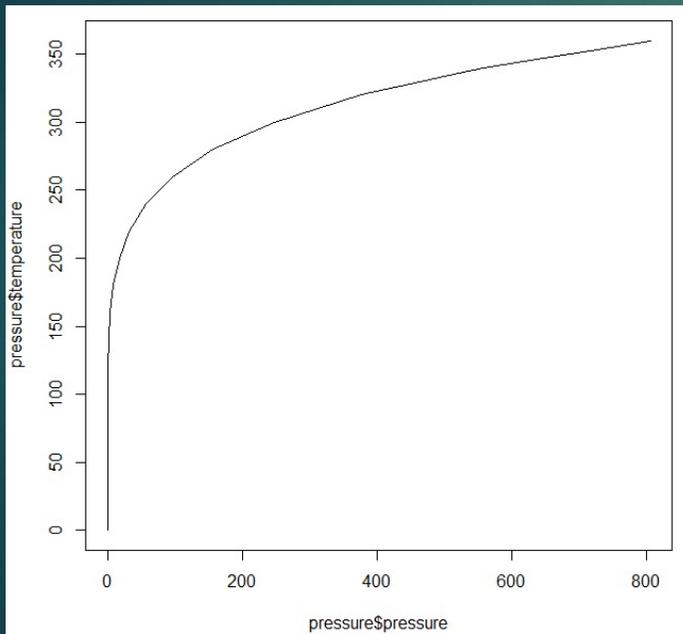
```
> plot(density(mtcars$mpg))
> qplot(mpg, data=mtcars, geom="density")
> ggplot(mtcars, aes(x=mpg)) + geom_density()
>
```



2.3 课堂测试6

2.

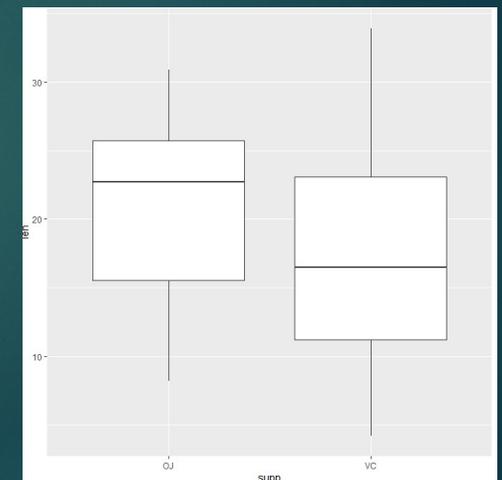
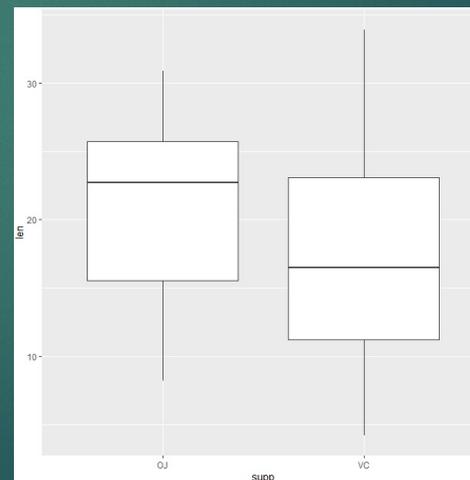
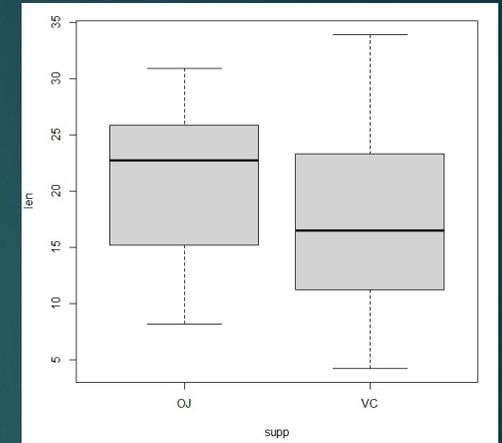
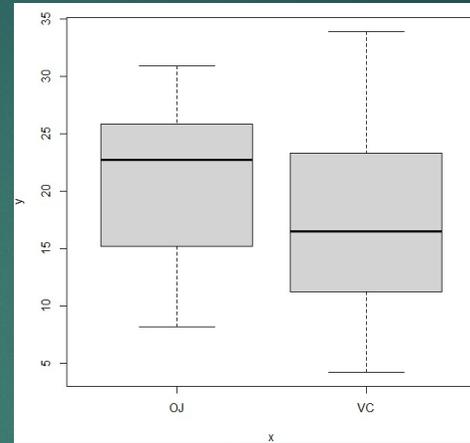
```
> str(pressure)
'data.frame':  19 obs. of  2 variables:
 $ temperature: num  0 20 40 60 80 100 120 140 160 180 ...
 $ pressure   : num  0.0002 0.0012 0.006 0.03 0.09 0.27 0.75 1.85 4.2 8.8 ...
> plot(pressure$pressure, pressure$temperature, type="l")
> qplot(pressure, temperature, data=pressure, geom=c("point", "line"))
> ggplot(pressure, aes(pressure, temperature)) + geom_line() + geom_point()
> |
```



2.3 课堂测试6

3.

```
> str(ToothGrowth)
'data.frame':  60 obs. of  3 variables:
 $ len : num  4.2 11.5 7.3 5.8 6.4 10 11.2 11.2 5.2 7 ...
 $ supp: Factor w/ 2 levels "OJ","VC": 2 2 2 2 2 2 2 2 2 2 ...
 $ dose: num  0.5 0.5 0.5 0.5 0.5 0.5 0.5 0.5 0.5 0.5 ...
> plot(ToothGrowth$supp, ToothGrowth$len)
> boxplot(len ~ supp, data=ToothGrowth)
> qplot(supp, len, data=ToothGrowth, geom="boxplot")
> ggplot(ToothGrowth, aes(supp, len)) + geom_boxplot()
> boxplot(supp ~ len, data=ToothGrowth)
```

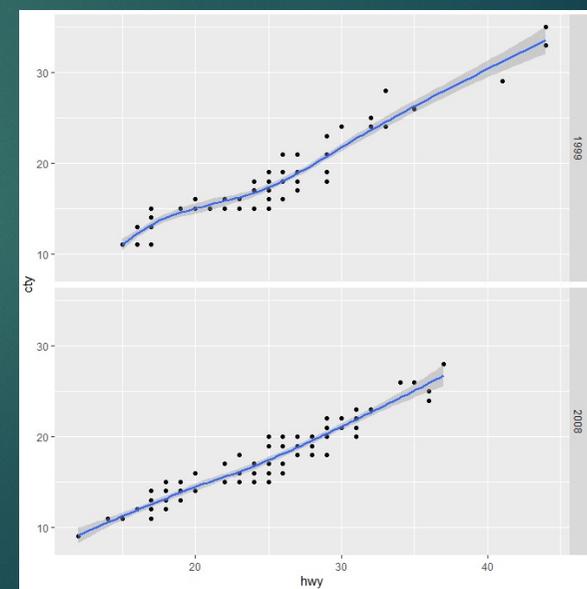
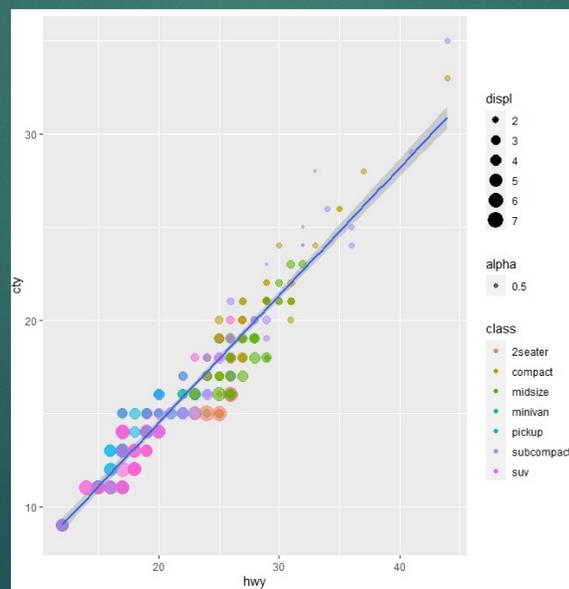
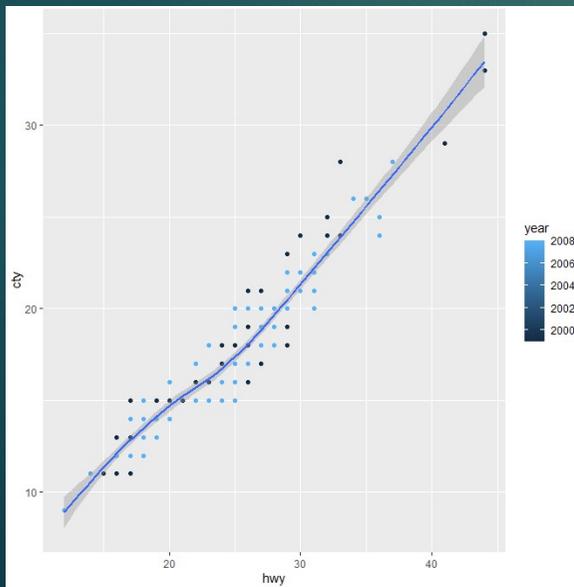


2.3 课堂测试6

4.

```
> str(mpg)
tibble[,11] [234 x 11] (S3: tbl_df/tbl/data.frame)
 $ manufacturer: chr [1:234] "audi" "audi" "audi" "audi" ...
 $ model       : chr [1:234] "a4" "a4" "a4" "a4" ...
 $ displ       : num [1:234] 1.8 1.8 2 2 2.8 2.8 3.1 1.8 1.8 2 ...
 $ year        : int [1:234] 1999 1999 2008 2008 1999 1999 2008 1999 1999 2008 ...
 $ cyl         : int [1:234] 4 4 4 4 6 6 6 4 4 4 ...
 $ trans       : chr [1:234] "auto(l5)" "manual(m5)" "manual(m6)" "auto(av)" ...
 $ drv         : chr [1:234] "f" "f" "f" "f" ...
 $ cty         : int [1:234] 18 21 20 21 16 18 18 18 16 20 ...
 $ hwy         : int [1:234] 29 29 31 30 26 26 27 26 25 28 ...
 $ fl          : chr [1:234] "p" "p" "p" "p" ...
 $ class       : chr [1:234] "compact" "compact" "compact" "compact" ...

> p <- ggplot(mpg, aes(hwy, cty))
> p + geom_point(aes(colour=year)) + geom_smooth()
`geom_smooth()` using method = 'loess' and formula 'y ~ x'
> p + geom_point(aes(colour=class, size=displ,alpha=0.5, position="jitter")) + geom_smooth(method="lm")
`geom_smooth()` using formula 'y ~ x'
Warning message:
Ignoring unknown aesthetics: position
> qplot(hwy, cty, data=mpg, facets=year~., geom=c("point", "smooth"))
```



2. 课堂测试讲解

RGCook

课堂测试07

先用电脑完成
40分钟 然后誊抄纸上

- 使用ggplot2里的画图函数完成以下的练习：

- * 1、将数据集Big_Mart_Dataset.csv,加载到R空间, 将数据框命名为mart,查看mart的维度和基本结构。
- * 2、画Item_MRP和Item_Visibility的关系图, 要求:(1)指定颜色属性为Item_Type;(2)设置x轴的标度(scale), x轴名字为Item_Visibility", x轴刻度为0-0.35以0.05为间隔的数值序列; 设置y轴的标度(scale), y轴名字为Item_MRP, y轴刻度为0-270以30为间隔的数值序列;(3)设置图形主题为theme_bw, 图形标题为Scatterplot。
- * 3、在2基础上, 根据因子类型的列Item_Type进行分面。
- * 4、画列变量Item_MRP的直方图, 要求:(1)每个小圆柱体的宽度为2,(2)设置x轴的标度(scale), x轴名字为Item_MRP, x轴刻度为0-270以30为间隔的数值序列; 设置y轴的标度(scale), y轴名字为Count, y轴刻度为0-200以20为间隔的数值序列;(3)设置标题为"Histogram"

- 使用ggplot2里的画图函数完成以下的练习：

- * 5、画出列变量Outlet_Establishment_Year的条形图, 要求(1): 填充色为"red"; (2): 主题为theme_bw和theme_gray;(3): 设置x轴的标度(scale), x轴名字为Establishment_Year, x轴刻度为1985-2010为间隔的数值序列; 设置y轴的标度(scale), y轴名字为Count, y轴刻度为0-1500以150为间隔的数值序列;(4): 设置标题为Bar Chart, 翻转坐标轴
- * 6、画出Outlet_Location_Type堆叠的条形图 (1): 使用 Outlet_Type设置填充色;(2): 设置图形的标题为Stacked Bar Chart, x轴的名称为Outlet Location Type", y轴的名称为Count of Outlets
- * 7、画Outlet_Identifier以Item_Outlet_Sales为分类变量的箱型图;(1): 填充色为红色;(2): y轴名称为"Item Outlet Sales", 坐标为0-15000以150为间隔的数值序列;(3): 设置标题为"Box Plot", x 轴坐标为"Outlet Identifier
- * 8、画列变量Item_Outlet_Sales面积图表 要求:(1)统计变换为 "bin", bin的宽度为30, 填充色为"steelblue";(2)x轴的标度为0-11000以1000间隔的数值序列;(3)图形标题为"Area Chart", x 轴命名为 "Item Outlet Sales", y轴命名为 "Count"。

2.4 课堂测试7



3. 作业

完成DataCamp课程 Market Basket Analysis in R



INTERACTIVE COURSE

Market Basket Analysis in R

[Start Course For Free](#) [Bookmark](#)

🕒 4 hours ▶ 16 Videos ↔ 60 Exercises 👤 2,001 Participants 📊 4,700 XP