Data Analysis Tools and Practice(Using R)

2019.03.08

R编程结构

北京大学 软件与微电子学院
School of Software and Microelectronics, Peking University

Huiping Sun(孙惠平)
sunhp@ss.pku.edu.cn

内容回顾

- 矩阵运算: *t(); det(); array(); crossprod(); tcrossprod(); diag(); solve(); eigen();*
- 缺失值: *NA; is.na(); na.rm = TRUE; na.omit();*
- 类型函数: *is.numeric(); is.integer(); is.logical(); is.character(); as.xxxx()*
- 字符处理： *nchar(); substr(); strsplit(); toupper(); tolower(); paste();*
- 日期和时间： *Sys.Date(); date(); difftime(); format(); as.Date(); %d, %a,%A, %m, %b, %B, %y,%Y;*
- 统计函数： *mean(); median(); sd(); var(); max(); min(); range(); sum(); quantile(); diff(); scale();*
- 数据集合合并: *rbind(); cbind();*
- 其余: *apply();*

本次课程内容

- 输入输出
- 流程控制
- 循环控制
- 自写函数

输入输出

输入输出概述

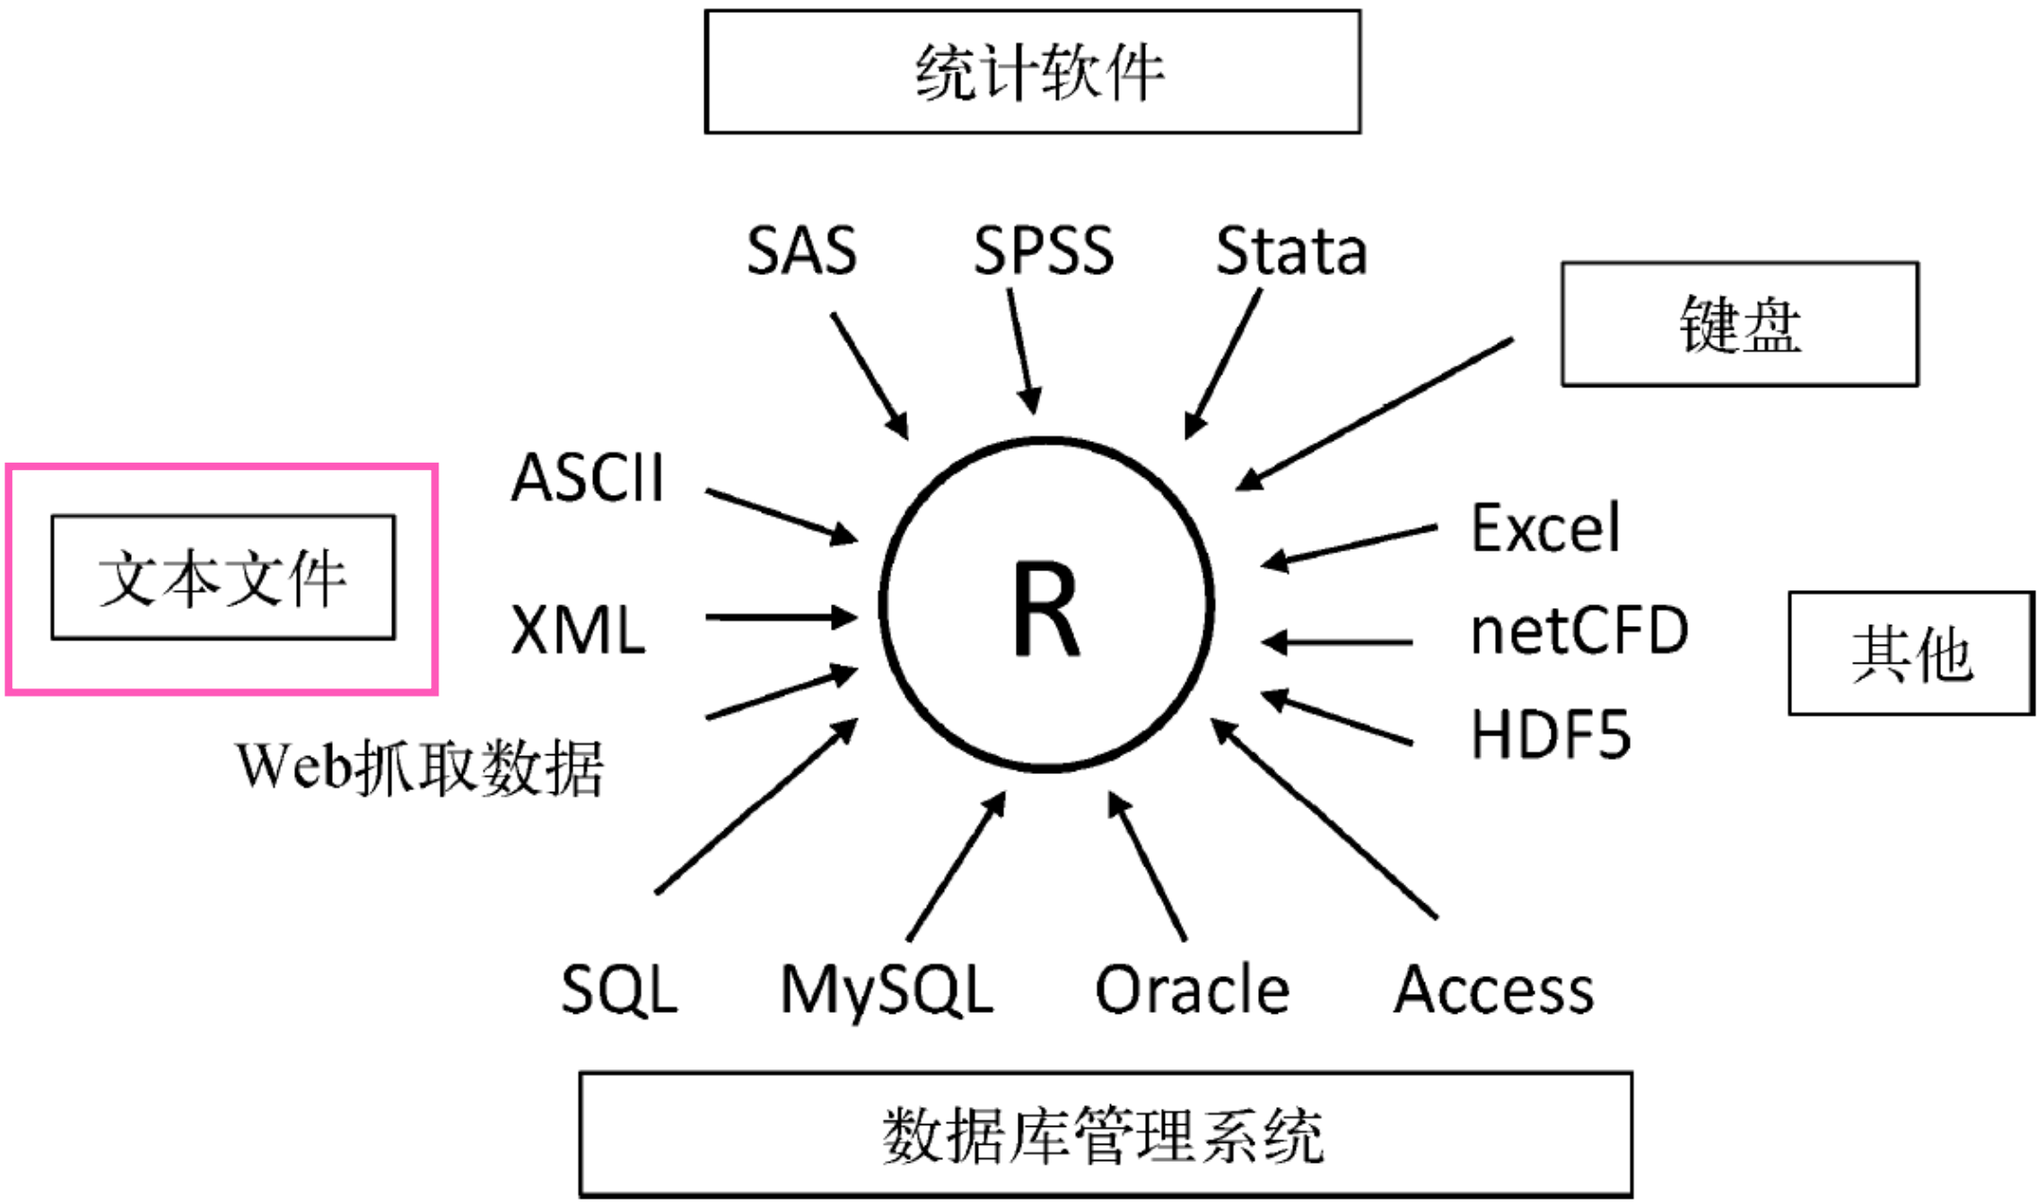

图2-2　可供R导入的数据源

read.table()

表2-2　函数read.table()的选项

选　项	描　述
header	一个表示文件是否在第一行包含了变量名的逻辑型变量
sep	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割行内数据的文件
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=FASLE），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
colClasses	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负床。默认值是双引号（"）或单引号（'）
skip	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
stringsAsFactors	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 colClases 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

read.table()例子

```
StudentID,First,Last,Math,Science,Social Studies
011,Bob,Smith,90,80,67
012,Jane,Weary,75,,80
010,Dan,"Thornton, III",65,75,70
040,Mary,"O'Leary",90,95,92
```

```
> grades <- read.table("studentgrades.csv", header=TRUE,
+                      row.names="StudentID", sep=",")
> grades # print data frame
   First           Last Math Science Social.Studies
11   Bob          Smith   90      80             67
12  Jane          Weary   75      NA             80
10   Dan Thornton, III   65      75             70
40  Mary       O'Leary   90      95             92
```

```
> str(grades) # view data frame structure
'data.frame':   4 obs. of  5 variables:
 $ First          : Factor w/ 4 levels "Bob","Dan","Jane",..: 1 3 2 4
 $ Last           : Factor w/ 4 levels "O'Leary","Smith",..: 2 4 3 1
 $ Math           : int  90 75 65 90
 $ Science        : int  80 NA 75 95
 $ Social.Studies: int  67 80 70 92
```

read.table()例子

```
> grades <- read.table("studentgrades.csv", header=TRUE,
+                      row.names="StudentID", sep=",",
+                      colClasses=c("character", "character", "character",
+                                   "numeric", "numeric", "numeric"))
> grades # print data frame
     First          Last Math Science Social.Studies
011    Bob         Smith   90      80             67
012   Jane         Weary   75      NA             80
010    Dan Thornton, III   65      75             70
040   Mary       O'Leary   90      95             92
> str(grades) # view data frame structure
'data.frame':   4 obs. of  5 variables:
 $ First         : chr  "Bob" "Jane" "Dan" "Mary"
 $ Last          : chr  "Smith" "Weary" "Thornton, III" "O'Leary"
 $ Math          : num  90 75 65 90
 $ Science       : num  80 NA 75 95
 $ Social.Studies: num  67 80 70 92
```

其余函数

```
read.table(file,
           header=FALSE,
           sep="",
           row.names="")
```

```
write.table(file,
            append=FALSE,
            sep="",
            row.names=TRUE,
            col.names=TRUE)
```

read.csv()
write.csv()

练习 – 0010

2.5 已知有 *5* 名学生的数据，如表 *2.3* 所示．用数据框的形式读入数据．

表 2.3: 学生数据

序号	姓名	性别	年龄	身高 (cm)	体重 (kg)
1	张三	女	14	156	42.0
2	李四	男	15	165	49.0
3	王五	女	16	157	41.5
4	赵六	男	14	162	52.0
5	丁一	女	15	159	45.5

2.6 将例 *2.5* 中的数据表 *2.3* 的数据写成一个纯文本文件，用函数 `read.table()` 读该文件，然后再用函数 `write.csv()` 写成一个能用 *Excel* 表能打开的文件，并用 *Excel* 表打开．

5分钟完成

随机找学生讲解

流程控制

流程控制

if-else	*if(cond) statement* *if(cond) statement1 else statement2*
ifelse	*if(cond, statement1, statement2)*

```
> if(FALSE)
+ {
+   message("This won't execute...")
+ }else
+ {
+   message("and you'll get an error before you reach this.")
+ }
and you'll get an error before you reach this.
```

一个表达式，不能是NA

```
> ifelse(rbinom(10, 1, 0.5), "Head", "Tail")
 [1] "Tail" "Head" "Head" "Head" "Tail" "Head" "Head" "Tail"
 [9] "Tail" "Tail"
```

流程控制

switch	*switch(expr, …)*

```
> feelings <- c("sad", "afraid")
> for (i in feelings)
+   print(
+     switch(i,
+            happy  = "I am glad you are happy",
+            afraid = "There is nothing to fear",
+            sad    = "Cheer up",
+            angry  = "Calm down now"
+     )
+   )
[1] "Cheer up"
[1] "There is nothing to fear"
```

循环控制

repeat	***repeat(statement)***
for	***for(var in seq) statement***
while	***while(cond) statement***

```
> repeat
+ {
+   message("Happy Groundhog Day!")
+   action <- sample(
+     c(
+       "Learn French",
+       "Make an ice statue",
+       "Rob a bank",
+       "Win heart of Andie McDowell"
+     ),
+     1
+   )
+   message("action = ", action)
+   if(action == "Win heart of Andie McDowell") break
+ }
```

```
Happy Groundhog Day!
action = Make an ice statue
Happy Groundhog Day!
action = Rob a bank
Happy Groundhog Day!
action = Win heart of Andie McDowell
```

break

next

循环控制

```
> for(i in 1:10 ) print("Hello")
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
```

```
> i <- 10
> while(i > 0)
+ {
+   print("Hello");
+   i <- i -1 }
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
[1] "Hello"
```

自写函数

自写函数

```
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
```

例子1

代码清单5-8　mystats(): 一个由用户编写的描述性统计量计算函数

```
mystats <- function(x, parametric=TRUE, print=FALSE) {
  if (parametric) {
    center <- mean(x); spread <- sd(x)
  } else {
    center <- median(x); spread <- mad(x)
  }
  if (print & parametric) {
    cat("Mean=", center, "\n", "SD=", spread, "\n")
  } else if (print & !parametric) {
    cat("Median=", center, "\n", "MAD=", spread, "\n")
  }
  result <- list(center=center, spread=spread)
  return(result)
}
```

```
set.seed(1234)
x <- rnorm(500)
```

```
y <- mystats(x)
```

```
y <- mystats(x, parametric=FALSE, print=TRUE)
```

```
Median= -0.0207
MAD= 1
```

例子2

```
mydate <- function(type="long") {
  switch(type,
    long =  format(Sys.time(), "%A %B %d %Y"),
    short = format(Sys.time(), "%m-%d-%y"),
    cat(type, "is not a recognized type\n")
   )
}
```

```
> mydate("long")
[1] "Monday July 14 2014"
> mydate("short")
```

```
[1] "07-14-14"
> mydate()
[1] "Monday July 14 2014"
> mydate("medium")
medium is not a recognized type
```

练习 - 0011

2.7 编写一个 R 程序 *(函数)*. 输入一个整数 n, 如果 $n \leq 0$, 则中止运算，并输出一句话：“要求输入一个正整数”; 否则，如果 n 是偶数，则将 n 除 2, 并赋给 n; 否则，将 $3n+1$ 赋给 n. 不断循环，只到 $n=1$, 才停止计算，并输出一句话：“运算成功”. 这个例子是为了检验数论中的一个简单的定理.

- 0011-1

例 2.4 编写一个用二分法求非线性方程根的函数，并求方程

- 0011-2

$$x^3 - x - 1 = 0$$

在区间 $[1,2]$ 内的根，精度要求 $\varepsilon = 10^{-6}$.

二分法计算过程如下：取中点 $x = \frac{a+b}{2}$, 若 $f(a)$ 与 $f(x)$ 异号，则置 $b = x$; 否则 $a = x$. 当区间长度小于指定要求时，停止计算.

10分钟完成

随机找学生讲解

提问时间！

孙惠平

sunhp@ss.pku.edu.cn

R Language

练习 – 0012

2.3、5.4、5.5

例子5-6、5-8

第四章

R Language

练习 – 0013

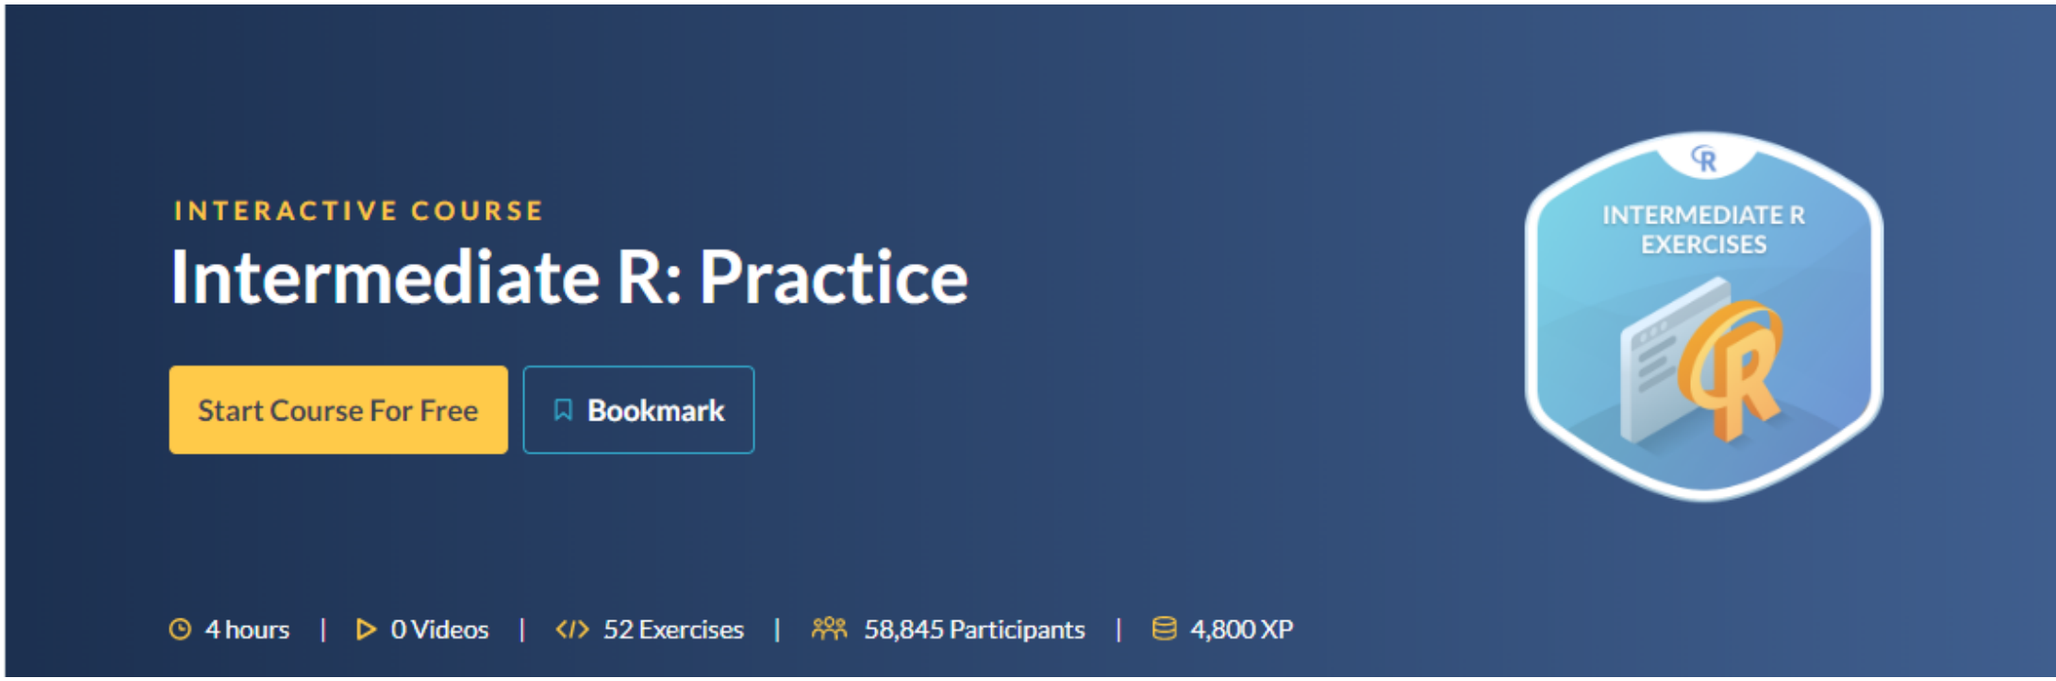

提交方式和上节课一样！

https://www.datacamp.com/courses

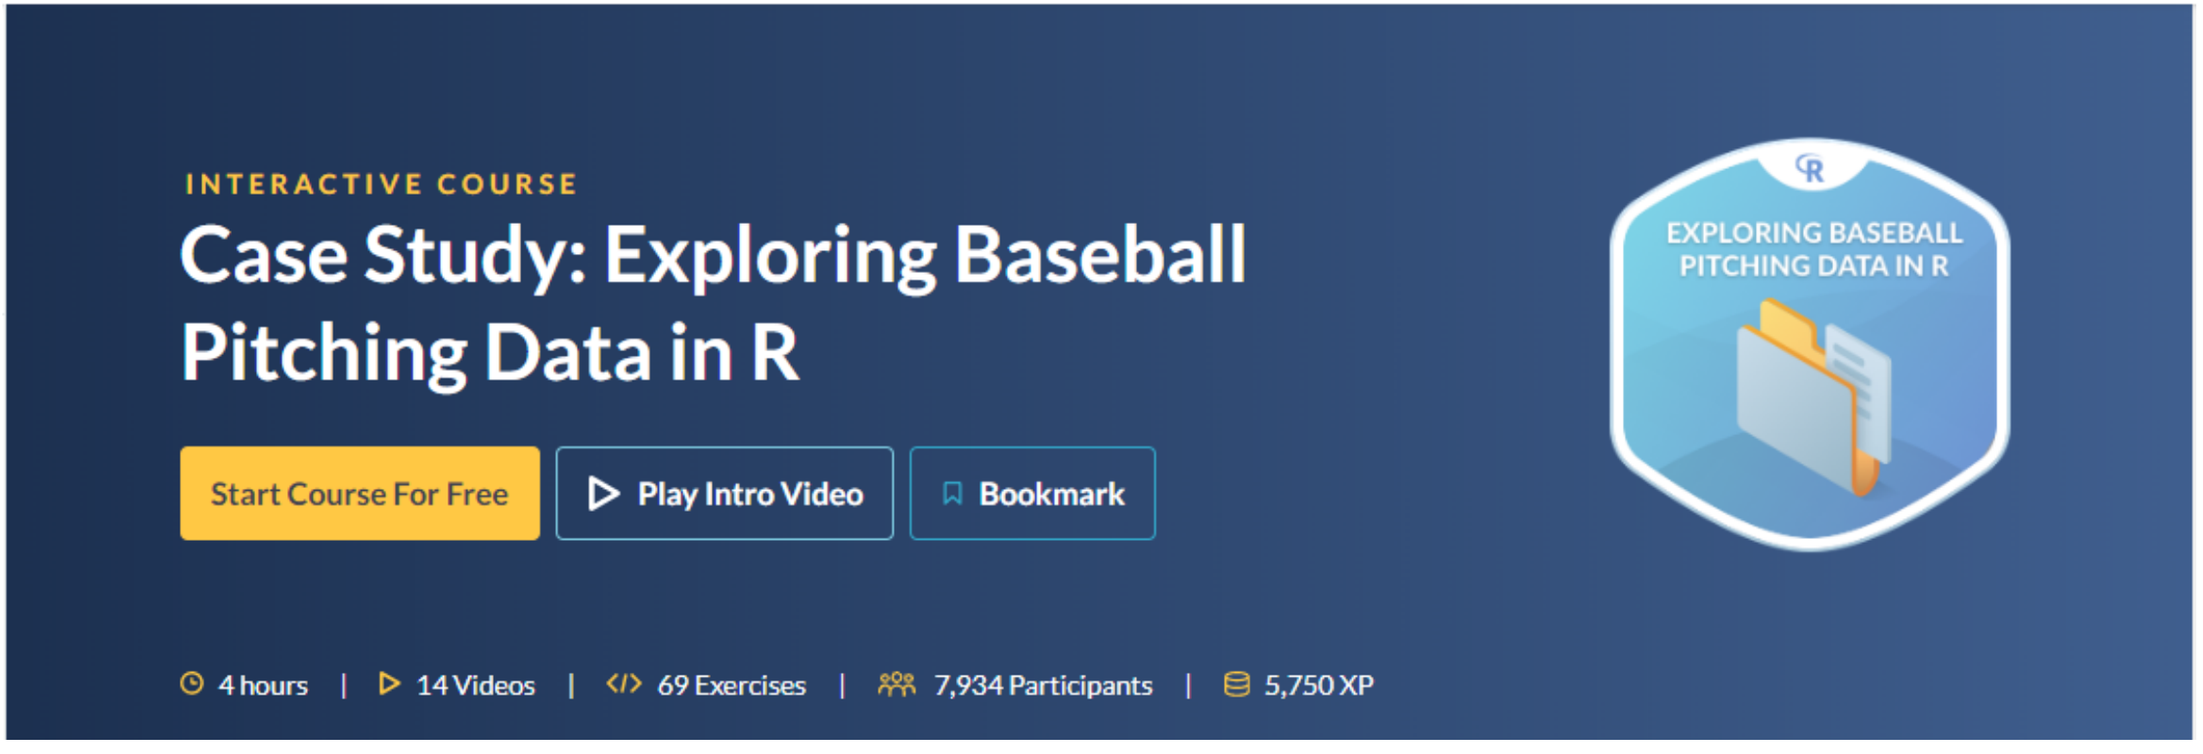

谢谢！

孙惠平

sunhp@ss.pku.edu.cn