

쌩 조짜를 위한 R

정태훈


2014년 6월 15일

- 앞에선 `plot()` 함수를 이용해서 데이터를 가지고 어떻게 **산포도** (**scatter plot**) 같은 그림을 그릴 수 있는지 살펴 봤습니다. 실제 이 함수는 R의 가장 기본적인 그림 함수로 적절한 매개변수와 조합했을 때 웬만한 도표는 다 그릴 수 있을 만큼 아주 막강한 기능을 가지고 있습니다.
- 하지만 그림 가운데 일부는 편리를 위해 따로 독립된 함수로 제공됩니다. 이번엔 그런 그림을 둘 알아보겠습니다. 바로 **히스토그램**(**histogram**)과 **상자 그림**(**boxplot**)입니다.
- 히스토그램은 어떤 구간에 얼마나 데이터가 모여 있는지를 파악하는 가장 기본적인 그림이고 상자 그림은 여러 그룹의 데이터가 서로 어떤 분포를 보이는지 파악하는 가장 기본적인 그림입니다. 데이터 이해에 없어서는 안 될 그런 그림들이죠!

제4과. 그림 그리기


(2) 히스토그램

- 먼저 GDP 데이터의 `GDPperCapita2012` 변수와 HealthSys 데이터의 `PublicHealthExpensePercTotal` 변수에 대한 히스토그램을 그려보겠습니다.
- 히스토그램을 그리는 명령어는 간단합니다. `hist(...)`죠. 그래서 다음과 같이 하면 일단 히스토그램을 그릴 수 있습니다.
 - › `hist(GDP$GDPperCapita2012)`
 - › `hist(HealthSys$PublicHealthExpensePercTotal)`




- 문제는 뭐 물론 다른 그림도 마찬가지지만 기본적으로 나오는 히스토그램은 늘 뭔가 5% 부족하다는 겁니다. 우선 그림이나 x축 이름이 별로 마뜩지 않습니다. 그래서 이것들부터 좀 바꿔 보겠습니다. 여기엔 `xlab`과 `main`이라는 입력변수가 유용합니다.

```
> hist(GDP$GDPperCapita2012, xlab="US $ (2012)", main="GDP / Capita")
> hist(HealthSys$PublicHealthExpensePercTotal, xlab="% of Total", main="Public Health Expense")
```



- 그림과 x축의 이름은 이제 좀 나아졌네요. 그런데 히스토그램 구간의 개수가 좀 너무 작은 것 같지 않습니까? 이걸 좀 늘여보겠습니다. 이걸 조절하는 입력변수는 **break**라는 겁니다! (R은 똑똑해서 입력변수가 구분될 정도만 알려줘도 알아 듭습니다. 그래서 **break**를 굳이 다 안 쓰고 그냥 **br**만 써도 됩니다.)


```
> hist(GDP$GDPperCapita2012, xlab="US $ (2012)", main="GDP / Capita",
br=25)    ## 구간을 25개로 나눕니다!
> hist(HealthSys$PublicHealthExpensePercTotal, xlab="% of Total",
main="Public Health Expense", br=25)    ## 구간을 25개로 나눕니다!
```



- 그런데 그림에 색깔이 없으니까 너무 맛밋하네요. 그래서 색깔을 한 번 넣어보겠습니다.

> `hist(GDP$GDPperCapita2012, xlab="US $ (2012)", main="GDP / Capita", br=25, col="darkorange") ## 오렌지색!`


> `hist(HealthSys$PublicHealthExpensePercTotal, xlab="% of Total", main="Public Health Expense", br=25, col="purple") ## 보라색!`
- 그럼 R에서 쓸 수 있는 색깔은 어떻게 알아볼 수 있을까 궁금하시죠? 이 두 사이트를 참고하세요.
이름으로 지정할 때: <http://www.stat.columbia.edu/~tzheng/files/Rcolor.pdf>
좀더 일반적인 내용: <http://www.stat.tamu.edu/~jkim/Rcolorstyle.pdf>



- 참고로 히스토그램에는 색깔만 쓸 수 있는 건 아닙니다. 빛금을 쓸 수도 있습니다!

> `hist(GDP$GDPperCapita2012, xlab="US $ (2012)", main="GDP / Capita", br=25, density=30) ## 1인치에 30개의 45도 빛금!`


> `hist(HealthSys$PublicHealthExpensePercTotal, xlab="% of Total", main="Public Health Expense", br=25, density=30, angle=120) ## 120도 빛금!`
- “`density=30`”은 1인치에 30개의 빛금을 넣으라는 소리고 “`angle=45`”는 빛금의 각도를 45도로 하라는 말입니다. 원래 이 각도가 기본인데 90도면 수직선, 180도면 수평선입니다.




- 히스토그램에 추세선도 넣어 봅시다. 그런데 이건 다음과 같이 두 단계를 거쳐야 합니다.

› `hist(GDP$GDPperCapita2012, xlab="US $ (2012)", main="GDP / Capita", br=25, density=30, freq=F) ## 각 구간 빈도(frequency) 아니고!`

› `lines(density(GDP$GDPperCapita2012, na.rm=T)) ## 추세선을 그려요!`
- 추세선을 넣을 땐 각 구간에 든 데이터의 갯수가 아닌 전체 데이터 가운데 몇 개가 들었는지 비율(데이터 밀도 density)을 계산합니다. `hist(..., freq=F)!!!` 그래야 뒤에 `density(..)` 함수를 쓸 수 있습니다. 이게 전체적인 추세선을 계산해 주는데 그 결과를 이용해 `lines(..)`가 선을 그려주는 겁니다. `density(..)` 함수를 그냥 쓰면 없는 값을 불평해서 “`na.rm=T`”를 넣어줬습니다.




- 물론 히스토그램과 추세선에 다양한 변화를 줄 수도 있겠죠!
 - > `hist(GDP$GDPperCapita2012, xlab="US $ (2012)", main="GDP / Capita", br=25, density=30, freq=F)`
 - > `lines(density(GDP$GDPperCapita2012, na.rm=T), col="darkorange", lwd=2)`
 - > `hist(HealthSys$PublicHealthExpensePercTotal, xlab="% of Total", main="Public Health Expense", br=25, col="darkorange")`
 - > `lines(density(HealthSys$PublicHealthExpensePercTotal, na.rm=T), col="purple", lwd=2, lty=2)`



- 그런데 한국의 위치는 어디죠? 이걸 보기 쉽도록 한국 항목의 위치에 수직선을 그어 보겠습니다.
- ```

> indkor <- which(GDP$CountryCode == "KOR") ## 한국 항목의 위치
> hist(GDP$GDPperCapita2012, xlab="US $ (2012)", main="GDP / Capita", br=25,
density=30, freq=F) ## 우선 전체 히스토그램을 그리고
> abline(v=GDP$GDPperCapita2012[indkor], col="red") ## 한국 값에 수직선 긋기

```
- 여기 나온 `abline(..)` 함수는 원래  $y = a + b * x$  직선을 그리라는 뜻입니다. 그런데 수직선이나 수평선을 그을 때도 쓸 수 있는데 여기서처럼 `abline(v=..)`라고 하면 해당하는 값에서 수직선을 긋고 `abline(h=..)`라고 하면 해당하는 값에서 수평선을 긋는 겁니다.



제4과. 그림 그리기


(3) 상자 그림

- 이번엔 상자그림(boxplot)을 그려 보겠습니다. 많이들 보셨을텐데 상자그림이 뭐냐 하면 비교하려는 여러 데이터를 각 데이터별 묶음으로 그려주는 그런 그림입니다. 이렇게 해서 전체적인 분포구간을 데이터별로 비교하기 쉽게 해주는 그런 그림이죠.
- 예를 들어 2012년 일 인당 GDP를 OECD와 그렇지 않은 나라 이렇게 비교해 보겠습니다. 우선 OECD 국가와 여타 국가의 값은 이렇게 구할 수 있습니다:


```

> gdp.oecd <- GDP$GDPperCapita2012[GDP$OECD == "Y"] ## OECD인 (== "Y") 국가의 값
> gdp.other <- GDP$GDPperCapita2012[GDP$OECD != "Y"] ## OECD가 아닌(!= "Y") 국가의 값
그리고 상자그림을 그리는 겁니다!
> boxplot(list(gdp.oecd, gdp.other)) ## boxplot(..)은 항상 list(..)를 받습니다!

```




- 앞의 상자그림은 너무 허전한데요. 그림에 아무런 설명도 없고.
- 우선 두 상자에 이름을 넣어 보겠습니다. 이건 리스트를 만들 때 이름을 부여하면 됩니다.  
> gdplist <- list("OECD"=gdp.oecd, "Others"=gdp.other)  
> boxplot(gdplist)
- 보시는 것처럼 각 상자의 이름이 들어갔습니다. 이젠 구분이 수월하겠네요. 이렇게 놓고 보니 OECD 그룹이 뭔가 훨씬 큰 값을 가지고 있다는 걸 알 수 있겠습니다.



# 여기서 잠깐, 상자그림(BOXPLOT)의 이해

- 상자그림을 보실 때는 오른편의 위키피디아 그림처럼 이해하시면 됩니다.
- 우선 상자 가운데 굵은 선은 중간값(데이터의 한 가운데 값, median)입니다.
- 상자의 맨왼쪽과 맨오른쪽은 (수직으로 그림이 배열된 경우는 맨아래쪽과 맨위쪽) 전체 데이터를 0~100%로 재배열했을 때, 25%와 75%에 해당하는 값입니다. 이 둘 사이의 간격을 IQR이라고 합니다.
- 상자에서 왼쪽, 오른쪽으로 쭉 뻗어나간 선분을 휘스커(whisker)라고 하는데 이건 상자의 양끝에서 각각  $1.5 \times \text{IQR}$  만큼씩 뻗어나갑니다. 그리고 이 영역을 벗어난 곳에 있는 값은 소위 극단값(outlier)라고 취급합니다. 상자그림에도 따로 기호로 표시합니다.



# 여기서 잠깐, 리스트(LIST)란?

- R에서 리스트는 아주 요긴한 녀석인데 왜냐하면 거기에 넣을 녀석들이 굳이 다 같은 모양이 아니어도 상관 없기 때문입니다. 그러니까 첫번째 항목에는 문자, 두번째 항목에는 숫자, 세번째 항목에는 행렬, 네번째는 다른 리스트, ... 뭐 이런 식으로 아무렇게나 넣어도 된다는 말이죠.

- 리스트를 만드는 방법은 예를 들어 다음과 같습니다:

```
agent <- list("name"="Jason Bourne", "age"=26, "ops"=list(...))
```

어느 요원의 기록이 이렇게 리스트로 저장되면 이름이 "Jason Bourne"이고 나이는 26, 그간 수행한 작전은 다른 리스트 뭐 이런 식으로 채워지는 겁니다.

- 이럴 때 저 요원의 이름이 궁금하다면 이렇게 하면 됩니다:

```
agent$name (혹은) agent[["name"]] (혹은) agent[[1]]
```


어디서 본 듯 하지 않습니까? 예, 바로 데이터프레임에서 했던 그 방식입니다. (데이터프레임은 리스트 가운데서도 모든 항목에 들어간 원소의 개수가 동일한 녀석입니다!) 비슷하게 이름은 `agent$age`나 `agent[["age"]]` 이렇게 하시구요.

- 상자그림은 주로 리스트를 받아서 작업을 합니다. 그래서 첫번째 항목에는 OECD 34개국의 일 인당 GDP를 두 번째 항목에는 그외 180개국의 일 인당 GDP를 넣은 리스트를 직접 만들었습니다. 물론 이렇게도 가능합니다:


```
> gdplist <- list(gdp.oecd, gdp.other)
```

```
> boxplot(gdplist)
```

- 이번엔 그림 제목, x-축, y-축 이름 등을 넣어 보겠습니다. 이건 예상하셨겠지만 `boxplot(..)` 함수 안에서 해결합니다:
   
`> boxplot(gdplist, main="GDP / Capita", xlab="Group", ylab="US $ (2012)")`
- 보시는 것처럼 각각에 적절한 표시가 들어갔습니다. 그림이 슬슬 모양을 갖춰가고 있습니다.
- 그리고 이렇게 적절히 들어간 표시 덕분에 드디어 OECD 그룹이 일인당 GDP가 다른 그룹에 비해 월등히 크다는 게 그림만으로도 명확해 졌습니다!




- 극단값에 해당하는 데이터는 물론 상자도 그리는 방식을 조절할 수 있습니다:
   
> `boxplot(gdplist, main="GDP / Capita", xlab="Group", ylab="US $ (2012)", pch=17, cex=1.5, bg="darkblue", col="beige")`
- 극단값은 `pch`, `cex`, `bg` 등으로 각각 심볼 모양, 크기, 색 등을 조절했고 `col`을 이용해서 상자의 색을 바꿨습니다. (참고로 만약 `pch=1` 이었다면 `bg`로는 색을 조절할 수 없고 `col`로 밖에 조절이 되지 않습니다. 그래서 상자 색이랑 심볼 색이 같아집니다. `pch=17`이어서 지금 상자 색과 심볼 색이 달라진 겁니다. 이건 심볼의 특성에 따라 달라지는 겁니다.)




- 그리는 방향을 수직 방향에서 수평 방향으로 바꿔 봅니다. 이렇게 하면 x-축과 y-축이 바뀌니까 그 이름도 적절히 바꿔줘야 합니다:

```
> boxplot(gdplist, main="GDP / Capita", ylab="Group",
xlab="US $ (2012)", pch=17, cex=1.5, bg="darkblue",
col="beige", horizontal=T)
```

- horizontal=T를 통해 그림의 방향을 수평 방향으로 바꿨습니다!



- 이제 한국의 위치는 어디쯤 되는지 표시해 보겠습니다:
   
> `boxplot(gdplist, main="GDP / Capita", xlab="Group", ylab="US $ (2012)", pch=17, cex=1.5, bg="darkblue", col="beige")`
  
> `abline(h=GDP$GDPperCapita2012[indkor], col="red", lty=2)`
- 수평 방향으로 선을 그으라고 `abline(h=..)` 를 썼습니다!




바로 저 붉은색 수평 점선이  
한국의 위치입니다.  
OECD에서는 낮은 수준이지만  
기타 국가에 비해선  
월등히 높은 수준이군요.

제4과. 그림 그리기

(4) 2차원 산포도 한 번 더


- 그럼 마지막으로 GDP와 HealthSys 데이터를 엮어서 그림을 그려보도록 하겠습니다. 그러니까 바로 앞 강좌에서 다뤘던 내용을 그림으로 살펴보는 거죠. 기억을 되살려 보시면 그때 우린 우리나라의 일인당 GDP 수준과 공공부문이 담당하는 의료비용 부문을 비교했었는데요 그걸 그림으로 한 번 해보자는 거죠.
- 우선 `GDP$GDPperCapita2012`와 `HealthSys$PublicHealthExpensePercTotal`로 그림을 그려봅시다. 늘 그랬듯이 일단 가장 간단한 그림에서부터 시작합니다:  
`> plot(GDP$GDPperCapita2012, HealthSys$PublicHealthExpensePercTotal)`



히스토그램에서 이미 봤듯이  
대부분의 데이터가 GDP가  
작은 영역에 집중되어 있습니다!

- 각 축과 그림의 이름을 넣어 좀더 이해가 쉽게 하고 그림의 심볼을 바꾸겠습니다:

```
> plot(GDP$GDPperCapita2012, HealthSys
$PublicHealthExpensePercTotal, main="GDP vs Public Health
Portion", xlab="GDP / Capita (US $, 2012)", ylab="Public
Health Portion (%)", pch=21, bg="darkblue", col="lightblue")
```




“`pch=21`”로 했을 때 좋은 점은  
`bg`와 `col`의 적절한 색깔 조합으로  
이렇게 서로 겹쳐 있는 데이터의  
• 높두 관계가 잘 드러난다는 점입니다.

- 이제 한국의 위치를 색다르게 표시해 보겠습니다:

```

> plot(GDP$GDPperCapita2012, ...) ## 일단 기본 그림을 그리고
> points(GDP$GDPperCapita2012[indkor],
HealthSys$PublicHealthExpensePercTotal[indkor], pch=21, bg="darkorange",
col="yellow") ## 한국의 값을 따로 표시합니다
> abline(v=GDP$GDPperCapita2012[indkor], lty=2, col="orange")
> abline(h=HealthSys$PublicHealthExpensePercTotal[indkor], lty=2,
col="orange")

```




한국의 위치는 `points(...)`로  
두드러지게 표시하고 그 위치에 맞춰  
`abline(...)`으로 수평, 수직 절선을  
그었습니다.

- 이번엔 OECD의 위치를 표시해 보겠습니다:

```

> indoecd <- which(GDP$OECD == "Y") ## OECD 국가의 위치
> points(GDP$GDPperCapita2012[indoecd], HealthSys
$PublicHealthExpensePercTotal[indoecd], pch=21, bg="darkred", col="pink")
> points(GDP$GDPperCapita2012[indkor], HealthSys
$PublicHealthExpensePercTotal[indkor], pch=21, bg="darkorange",
col="yellow")

```




OECD의 점을 표시했더니  
한국까지 덮였습니다.  
그래서 한국의 점을  
다시 그렸습니다!  
그림을 봐서 OECD 가운데  
우리나라보다 공공부문의  
건강관련 지출이 적은  
나라는 고작 4곳 밖에  
없네요!

- 마지막으로 그림에 사용된 심볼을 범례로 표시해 보겠습니다:

```
> legend("bottomright", legend=c("OECD", "Korea"),
pch=21, col=c("pink", "yellow"), pt.bg=c("darkred",
"darkorange"))
```

이걸 쓰면 아래의 그림처럼 그림의 바닥 오른쪽에 사용된 심볼을 설명하는 범례가 들어섭니다!



# 여기서 잠깐, 범례(LEGEND)는?

- 범례를 그리는 함수는 `legend(...)`입니다. 이 함수를 쓰는 방법은 다음과 같습니다:  
`legend(<위치>, legend=<범례의 설명문>, <기타 그림 관련 입력 변수>)`
- 위치는 원래  $x, y$  자표값으로 4, 10 이런 식으로 표현하는데 지금처럼 쓰면 그림의 이쪽 저쪽 구석에 딱 맞춰 범례를 나타냅니다. 이렇게 표현할 수 있는 방식은 왼쪽 위(`“topleft”`), 오른쪽 위(`“topright”`), 왼쪽 아래(`“bottomleft”`), 오른쪽 아래(`“bottomright”`) 등이 있습니다.
- 범례 설명은 설명하는 글자를 죽 묶어서 쓰는데 이때 `c(...)` 함수를 씁니다. 이 함수는 여러 값을 한데 묶어 벡터값을 만들 때 씁니다. `c(“a”, “b”, “c”)`는 문자로 된 벡터를 만들고 `c(3, 6, 9, 12, 15)`는 숫자로 된 벡터를 만듭니다.
- 그림의 심벌은 다 같았으니 따로 구분할 필요가 없습니다. (그래서 `pch=21`는 한 값만 있습니다.) 하지만 안쪽의 색과 심벌의 테두리 색은 달랐습니다. 그래서 `col=c(“pink”, “yellow”)`로 심벌의 테두리 선을 표시하고 `pt.bg=c(“darkred”, “darkorange”)`로 안쪽 색을 표시합니다.
- 주의할 점은 `bg=“gray”` 이렇게 표현하면 이건 심벌의 안쪽 색을 결정하는 것이 아니라 범례 칸의 배경 색을 결정한다는 겁니다. 그래서 점의 안쪽 색을 결정하도록 `pt.bg`가 따로 있는 거죠.

# 여기서 잠깐, R에서 그림을 그리는 순서

- 이제 아시겠지만 R에서의 기본적인 그림을 그리는 패턴은 늘 이렇습니다.
  - 기본적인 그림을 `plot(..)`으로 그립니다. ( $x$ -,  $y$ -축 이름이나 그림 이름 등도 다 여기서 결정됩니다.)
  - 그 위에 선이나 다른 심볼을 덧씌웁니다. 예를 들어 선을 덧씌우려면 `lines(..)`를 심벌을 덧씌우려면 `points(..)`를 그냥 수직, 수평선을 덧씌우려면 `abline(..)`을 씁니다.
  - 마지막에 범례가 필요하다면 `legend(..)`를 써서 마무리합니다.
- 물론 이걸로 R 그림 그리는 끝은 아닙니다만 그래도 이 정도면 어느 정도 원하는 그림을 그릴 기본은 된 것이라고 볼 수 있습니다!