

생 초짜를 위한 R

정 태 훈

2014년 6월 9일

- 이제 RStudio를 쓰는 기본적인 방법이나 이런 건 익숙해지셨을테니 (맞나요?) 그래픽으로 어떻게 하는지 이런 부분은 가급적 줄이고 어떤 걸 어떻게 하는지 하는 부분을 좀 더 많이 설명하도록 하겠습니다. 그래도 되겠죠?
- 근데 제가 저번에 올려 놓은 데이터를 보시면서 뭔가 허전함을 못 느끼셨나요? 그러니까 제가 국가별 건강체계, 위험인구, 과학기술투자 뭐 이런 걸 데이터로 준비해 드렸는데 달랑 이것들만 가지고 뭘 본다고 하면 결국 나오는 결론이라는 게 뭘까요? 아무리 생각해도 “아, 이 나라랑 저 나라는 이런 저런 게 서로 다르구나” 정도 밖에는 없을 겁니다, 그죠? 그런데 고작 (누구나 해보지 않고도 아는) “나라들끼리 서로 다르다”는 걸 알자고 이런 걸 하는 건 아닐 거잖아요. 하다 못 해 동네 애들끼리 키를 비교할 때도 나이가 비슷한 애들끼리 비교해서 누구랑 누구는 나이는 같은데 누가 누구보다 크네 작네 이러잖아요. 우리 모두 뭔가 이렇게 서로 같은 어떤 기준에 두고서 봐야 말에 설득력이 있다는 걸 아는데 하물며 나라끼리 비교할 때도 객관적으로 기준이 될 뭔가가 필요하지 않겠어요? 그래야 “이런 이런 게 비슷한 나라들끼리 비교해 보니 이 나라는 저 나라보다 크네, 작네” 이렇게 될 테니까요. 근데 그런 기준이 될 만한 게 없었죠. ㅎㅎ
- 그러니까 “뭔가 데이터가 더 필요하다”는 얘긴데 .. 근데 어떤 데이터가 있으면 될까요? 보통 이럴 땐 뭘 쓰나요? 뭐 사람마다 다를 수도 있겠지만 보통 일인당 GDP를 쓰지 않나요, 그죠? 그래서 GDP 데이터를 올려 놓은 겁니다.

단계 0. 데이터 분석의 목적

- 자 그럼 이제 이들 파일을 일단 읽어 들여 데이터를 분석해 봅시다. 그런데 이것도 뭘 할 건지 목적이 있어야 어떻게 할 건지 구체적인 계획이 설 거 아니겠어요? 그래서 이번엔 이런 걸 한 번 해볼까 합니다.

도대체 우리나라의 건강관리 관련 전체 지출에서 공공부문이 차지하는 비율은 전세계의 다른 나라와 비교해서 혹은 비슷한 경제 수준의 다른 나라와 비교해서 어떻게 될까요?

음 .. 눈치 채셨겠지만 이런 걸 하자고 제가 세계은행의 그 수 많은 데이터 가운데 저런 데이터만 뽑은 거겠죠? 그러니까 사실 데이터를 모은다는 건 원래부터 거기에 어떤 목적을 담고 있는 겁니다. ^^ 그런데 사실 여기서 사용한 “비슷한 경제 수준의 다른 나라”라는 표현은 참 애매한 겁니다. 그래서 좀더 구체적으로 **일 인 당 GDP가 일정 수준에 다다른 OECD의 다른 나라와 비교해서 어떤지를 비교해 보기로 하겠습니다.**

단계 1. 데이터 읽어 들이기.

- 저걸 하려면 어떻게 해야 할까요? 우선 어느 파일에 든 어느 데이터가 저 정보를 줄 수 있는지 알아야겠죠?
- 그럼 데이터 파일을 죽 한 번들 다 둘러보시고 찾아보세요. 혹시 전체 의료비 지출 가운데 공공부문과 개인이 부담하는 비율에 대한 데이터 열 발견하셨나요? 음 .. 이게 각 파일 데이터 열 이름을 저는 알 수 있게 줄여놔서 한 번에 확 눈에 들어오지는 않을 수도 있는데 아무튼 HealthSystem.txt 파일에 있는 두 데이터 열 PublicHealthExpensePercTotal, OutOfPocketPercTotal 이 녀석들이 바로 전체 의료비 지출 가운데 공공부문이 부담하는 퍼센트와 개인이 자기 주머니에서 부담하는 퍼센트입니다. 그러니까 우선 HealthSystem.txt 이 파일을 읽어 들여야 하는군요.
- 그럼 일 인 당 GDP는 어디 있죠? GDP.txt 파일에 GDPperCapita2012 데이터 열 찾으셨나요? 바로 이겁니다. 왜냐 하면 HealthSystem.txt 파일의 데이터 열은 대부분 2012년 자료이기 때문에 2012년의 일 인 당 GDP를 써야 했던 겁니다. 그러니까 GDP.txt 이 파일도 읽어 들여야 하는 거구요.
- 그러니까 우선 이 두 파일을 읽어 들입시다!

- 그런데 여기서 한 가지 간과하기 쉬운 게 있습니다. 지금 계획대로 하자면 우리는 두 개의 데이터 파일을 읽어 들일 겁니다. 이렇게 읽어 들인 두 데이터를 각각 **HealthSys**와 **GDP**라고 부르다고 칩시다. 결국 일 인 당 GDP에 따른 의료비 지출 문제니까 이 두 데이터를 합쳐야 합니다, 그죠? 그럼 과연 이 데이터를 어떻게 합치는 게 맞을까요?
- 이게 무슨 말인지 이해하기 쉽도록 이렇게 한 번 볼까요? **HealthSys**와 **GDP**는 각각 214개 국가의 건강관리체계와 국내 총생산(GDP)에 대한 정보가 들어 있습니다. 과연 두 데이터는 동일한 국가들에 대한 정보일까요? **HealthSys**와 **GDP**에 들어 있는 국가가 다르다면 어떻게 하죠? 이것을 어떻게 확인하죠?
- 그런데 뭐 어차피 같은 시스템에서 제공한 정보니까 양쪽 다 똑같은 국가 데이터라 칩시다. 그럼 과연 이들 국가 정보가 두 파일에 동일한 순서로 들어 있을까요? (이게 뭘 똥단지같은 소리냐 싶으십니까? 그럼 **GDP**Trend.txt 파일을 한 번 열어보세요. 이게 같은 세계은행 자료인데 희한하게 국가 순서가 다르더군요. 하긴 뭐 자료를 정렬하는 방식은 워낙 많으니까요. ^^) 만약 똑같은 국가들에 대한 정보가 똑같은 순서로 들어 있다면 그냥 있는 그대로 나란히 이어 붙이면 되겠지만 (사실 지금 데이터는 제가 다 순서를 맞춰놨다는 거! ㅋㅋ) 만약 그렇지 않다면 어떻게 해야 할까요? (이건 한 번 생각해 보세요!)

- 우선 **HealthSys**과 **GDP**는 이제 다들 아시겠지만 이렇게 불러 들입니다. (아래 각 줄의 맨 앞 “>”는 프롬프트입니다. 그러니까 R에서 사용자의 입력을 기다릴 때 그냥 늘 있는 그런 거라서 여러분이 직접 입력하실 필요가 없다는 말입니다.)

```
> HealthSys <- read.table(<...파일...>, header=T, sep="\t", quote="",  
as.is=T, check.names=F, comment.char="#")
```

```
> GDP <- read.table(<...파일...>, header=T, sep="\t", quote="",  
as.is=T, check.names=F, comment.char="#")
```

← 여기 T는 TRUE, F는 FALSE를 줄인 겁니다!

- 데이터가 궁금하시면 이걸 쓰시면 되죠? (이건 RStudio에서만 됩니다!)

```
> View(HealthSys)
```

```
> View(GDP)
```

- 데이터가 몇 개의 열(이걸 앞으로 **변수**라고 부르겠습니다)와 몇 개의 행(이걸 앞으로 **항목**이라고 부르겠습니다)으로 이뤄졌는지 궁금하시면 이렇게 하시면 됩니다. (밑에 **dim**은 dimension의 줄임 말입니다.)

```
> dim(HealthSys)
```

```
[1] 214 15
```

← 15개 변수에 각각 214개 항목 값이 들어있다는 소립니다!

```
> dim(GDP)
```

```
[1] 214 8
```

← 8개 변수에 각각 214개 항목 값이 들어있다는 소립니다!

- 데이터 내 변수의 이름 (그러니까 열의 이름)은 어떻게 하면 알 수 있을까요?

```
> names(HealthSys)
```

```
[1] "Country"           "CountryCode"
[3] "Region"            "OECD"
[5] "TotalHealthExpensePercGDP" "PublicHealthExpensePercTotal"
[7] "OutOfPocketPercTotal"
"HealthExpenseExternalResources"
...
```

```
> colnames(GDP)
```

```
[1] "Country"           "CountryCode"
[3] "Region"            "OECD"
[5] "GDPperCapita2012"   "GDP2012"
[7] "GDPperCapitaPPP2011" "GDPperCapitaPPPCurrent"
```

(데이터프레임의 경우 `names(...)`와 `colnames(...)`는 동일한 결과를 줍니다!)

- 이제 데이터 각 변수를 요약해 보고 싶다면 이렇게 하면 되겠죠?

```
> summary(HealthSys)
```

```
> summary(GDP)
```

각각 전체 변수(`HealthSys`는 15개, `GDP`는 8개)에 대한 요약 결과를 열을 맞춰 아주 줄줄 출력할 겁니다.

단계 2. 데이터의 변수.

- 그런데 우리 매번 데이터 전체를 가지고 일하지는 않습니다. 데이터의 특정 변수를 살펴보고 그 가운데 특정한 데이터 항목을 들여다 보기도 합니다. 예를 들어 “2012년 일인당 GDP 변수”를 들여다 봐야 할 때도 있습니다. 이런 건 어떻게 할 수 있을까요?
- 우선 변수에 접근해 봅시다. 예를 들어 `HealthSys`의 `PublicHealthExpensePercTotal`, `OutOfPocketPercTotal` 이런 변수는 어떻게 다룰 수 있을까요? 제가 잠깐 세어 봤더니 R에는 여섯 가지 정도 방법이 있던데 그 가운데 일단 연관된 세 가지만 보겠습니다.
 - > `HealthSys[[6]]`
 - > `HealthSys[["PublicHealthExpensePercTotal"]]`
 - > `HealthSys$PublicHealthExpensePercTotal`
- 왜 이렇게 많은가 싶으시죠? 이게 다 요긴한 상황이 달라서 그런데 예를 들어 우리가 원하는 변수가 몇 번 째 것인지를 아는 경우라면 첫번째 방법이 딱 입니다. 그런데 데이터에 변수가 수십 개 된다면 이 방법은 아주 불편하고 오히려 헛갈립니다. 이럴 땐 변수 이름이 더 찾기 쉽죠. 문제는 변수 이름에 “`Public Health Expense (% Total)`”처럼 특수한 문자나 빈칸 이런 게 뒤섞여 있는 경우인데 이럴 땐 볼 것 없이 두번째 방법입니다. 따옴표로 묶여 있어 통째로 이름이 되니까요. 하지만 지금 같은 상황이면 세번째 방법이 제일 낫습니다.(무엇보다 입력해야 할 문자 수가 달라집니다. “\$” 하나면, 끝! ^^)

- 그런데 이게 다가 아닙니다. 사실 세번째 방식은 보통은 표준적인 방식처럼 여겨지는데 이 방식을 쓰면 **RStudio가 제공하는 도움 기능**을 쓸 수가 있습니다! 무슨 말인가 하면 변수가 많아 일일이 다 외우기도 어렵고 변수 이름도 너무 길어 헛갈리고 귀찮을 땐 “<데이터 이름>\$”까지만 쓰고 바로 **탭** 키를 누르는 겁니다. 예를 들어 **HealthSys**의 **PublicHealthExpensePercTotal** 변수를 이용하려 한다면 “**HealthSys\$**”까지만 쓰고 **탭** 키를 눌러보는 겁니다. 무슨 일이 생깁니까? 글 상자가 생기면서 관련된 변수 목록이 죽 뜨죠? 바로 그 가운데서 고르면 되는 겁니다! 만세! (이건 RStudio가 제공하는 도움 기능입니다. 프로그램을 해본 분들은 많은 파일 에디터에 이와 비슷한 도움말 기능이 있는 걸 아실 겁니다.)
- 이쯤 되면 왜 “\$” 표시가 표준적인 방식으로 대접 받는지 아실 겁니다. 그리고 바로 이래서 데이터 변수 이름이 다들 저렇게 우스꽝스럽게 긴 겁니다. 변수 이름에 빈칸이나 이상한 글자가 들어가면 “\$”로 지정하지 못 합니다. 그러면 불편해집니다. 그러니까 변수 이름에 빈칸이나 특수 문자는 쓰지 않습니다. 그러면서도 변수의 의미를 전달할 수 있어야 합니다. 그래서 관련된 단어를 저렇게 그냥 죽 이어 쓰는 겁니다. ^^

- 그럼 이 변수 접근법을 써먹어 봅시다. 예를 들어 변수를 직접 보고 싶다면

```
> HealthSys[[6]]
```

```
[1] 20.8 47.6 84.1    NA 76.6 62.2 75.4 69.2 41.8    NA 66.9 75.5 22.8
[14] 46.1 71.9 34.4 65.6 77.2 75.9 64.9 51.5    NA 83.9 71.8 71.1 56.4
[27] 46.4 91.8 56.3 54.3 59.5 77.4 24.7 33.5 70.1    NA 49.7 31.3    NA
[40] 48.6 56.0    NA    NA 75.8 55.9 51.4 73.9 74.6 27.5 82.3 94.2    NA
```

...

```
> HealthSys$OutOfPocketPercTotal
```

```
[1] 74.4 52.2 15.0    NA 17.5 26.7 22.2 20.1 54.6    NA 18.5 15.2 69.0
[14] 29.1 16.5 63.3 34.4 19.5 19.7 24.5 44.3    NA 15.2 23.2 27.8 5.5
[27] 31.0 8.1 42.3 36.4 28.3 21.2 61.7 62.6 15.0    NA 45.6 66.4    NA
[40] 32.1 34.3    NA    NA 14.8 44.1 32.5 25.1 23.1 55.8 13.9 5.8    NA
```

...

이렇게 하면 되는데 .. 놀라셨죠? 숫자가 그냥 줄줄 나와서. ㅎㅎ 어쩔 수 없습니다.

- 그렇기 때문에 보통은 요약된 내용을 보는 겁니다. 이렇게 말이죠.

```
> summary(GDP$GDPperCapita2012)
```

```
Min. 1st Qu.  Median    Mean 3rd Qu.    Max.   NA's
 251    1605    5482   14170   15450   103900    29
```

보니까 최소값은 251, 최대는 103900, 평균값은 14170, 중간값은 5480 뭐 이런군요. 없는 값도 29개나 되구요.

- 내친 김에 몇 가지 더 해 볼까요? 변수의 최대값, 최소값, 평균값, 표준편차, 변수값의 범위 등만 볼 땐 물론 `summary(..)` 함수를 쓰진 않습니다. 이럴 땐 `max(..)`, `min(..)`, `mean(..)`, `sd(..)`, `range(..)` 이런 함수를 씁니다. 그럼 2012년 일인당 GDP 최대나 최소값을 봅시다.

```
> max(GDP$GDPperCapita2012) ## 2012년 일인당 GDP 최대값  
[1] NA
```

```
> min(GDP$GDPperCapita2012) ## 2012년 일인당 GDP 최소값  
[1] NA
```

그런데 .. 뭔가 이상하죠? 결과가 숫자가 아니고 “NA”입니다. 이걸 값이 없는 게 있어서 어떻게 해야 할지 모르겠다고 R이 불평하고 있는 겁니다. 그런데 그럼 `summary(..)` 함수는 도대체 어떻게 숫자를 구한 거죠? 뭔가 방법이 있다는 겁니다! 도움말 한 번 봐야겠습니다. 아하, “`na.rm`”이 있군요. 설명에 따르면 이건 논리값 (logical, 그러니까 참(TRUE) 아니면 거짓(FALSE))을 받아들이는 입력 변수로 “`na.rm=TRUE`”면 “NA”를 다 빼고 계산한다는군요. 진짜 그런지 한번 해 봅시다.

```
> max(GDP$GDPperCapita2012, na.rm=TRUE) ## 2012년 일인당 GDP 최대값  
[1] 103858
```

```
> min(GDP$GDPperCapita2012, na.rm=T) ## 2012년 일인당 GDP 최소값  
[1] 251.0145
```

단계 3. 데이터의 변수의 항목.

- 그런데 앞에서 데이터에 대해서 얘기했던 것과 마찬가지로 우리 매번 변수 전체를 가지고 일하지는 않습니다. 어떨 때는 변수의 특정 항목을 살펴봐야 할 때가 생깁니다. 예를 들어 “2012년 일 인 당 GDP 변수” 가운데 “한국의 항목”은 어떤지 궁금할 때도 있습니다. 그죠? 그럼 이런 건 어떻게 할 수 있을까요?
- 그런데 이 면에서 우리 상황이 좀 불리합니다. 왜냐하면 지금 한국의 2012년 일 인 당 GDP를 알아볼 방법은 딱 하나 밖에 없기 때문입니다. 그건 바로 한국이 몇 번째 항목인지 찾아보고 (살펴보니 103번째로군요) 그 값을 정해 보는 겁니다.

> `GDP$GDPperCapita2012[103]`

[1] 22589.96 ## 헉, 2012년 우리나라 일인당 GDP가 2만 2천 불이 넘었군요!!

- 차이를 찾으셨나요? 변수를 지정할 때는 “`[[..]]`”를 (혹은 “`$`”를) 썼는데 항목을 지정할 때는 “`[..]`”를 썼습니다. 뭐 그건 그런데 이 상황은 영 그렇습니다. 그럼 우리가 다른 나라를 찾으려면 다시 그 나라를 뒤져서 그 순서를 찾아본 다음에 다시 그 번호를 매번 써야 하는 거잖아요! 아니 변수를 지정할 때는 변수 이름을 썼었는데 (그러니까 위에서처럼 “`GDPperCapita2012`” 같은 문자로 썼었는데) 지금은 그럴 수가 없잖아요.
- 그런데 뭔가 이렇게 할 수 있을 것 같지 않으세요? 변수도 이름을 썼었는데 항목이라고 쓰지 말라는 법이 없을 것 같잖아요. 그죠?

- 물론 됩니다! 그런데 그럴려면 좀 준비를 해야 합니다. 무슨 준비가 필요할까요? 뭐 볼 것도 없죠. 당연히 항목 각각에 이름을 부여해야 합니다. 그죠? 그럼 해 봅시다!
- 2012년 일 인 당 GDP 변수는 아시는 것처럼 **HealthSys** 데이터 안에 있습니다. 그런데 애석하게도 데이터 안에 들어 있는 변수는 각각 이름을 지정하지 못 하고 전체 데이터의 “행 이름”을 지정해 쓰는 수 밖에 없더라구요. (이 부분은 설명이 제법 복잡해 지니까 나중에 중급 강좌 뭐 이런 거 할 때 자세히 설명드린다고 합시다요! ^^ 그런데 뭔가 R 시스템의 버그(?) 같은 느낌이 스멀스멀 ..)
- 어쨌거나 이제 데이터의 행 이름을 붙여 보겠습니다. (여기에 붙이는 이름은 “**Country**”가 말고 “**CountryCode**”를 쓰겠습니다. 왜 그런지는 아시겠죠? ^^)

```
> rownames(GDP) <- GDP$CountryCode
```

이렇게 해놓고 나면 한국의 2012년 일 인 당 GDP는 이렇게 알아볼 수 있습니다.

```
> GDP[“KOR”, “GDPperCapita2012”]  
[1] 22589.96
```

- 차이를 찾으셨나요? 변수를 지정할 때는 “[**..**]”를 (혹은 “**\$**”를) 썼는데 항목을 지정할 때는 “[**a,b**]” 형태를 썼습니다. 짐작 하시겠지만 이건 행렬을 표현하는 방식이죠. **a**는 행의 번호나 이름, **b**는 열의 번호나 이름이구요.

- 행렬의 원소를 지정하는 방식에 문자도 되고 숫자도 되니까 사실 다음과 같은 조합이 다 됩니다.

```
> GDP[103, 5]
[1] 22589.96
> GDP['KOR', 5]
[1] 22589.96
> GDP[103, 'GDPperCapita2012']
[1] 22589.96
```

- 한 가지 팁을 드리면 맨처음에 파일을 읽을 때 행이름을 지정할 수도 있습니다.

```
> GDP <- read.table(<...파일...>, header=T, sep="\t", quote="", as.is=T,
check.names=F, comment.char="#", row.names=2)
```

여기서 “row.names=2”는 “두번째 열을 행 이름으로 쓰테니 대신 개는 불러 들일 때 변수에서 넣지마라” 이런 뜻입니다. 해보시면 아시겠지만 이렇게 데이터를 불러들이면 두번째 열은 변수에 들어 있지 않습니다!

- 또 한 가지 팁을 드리자면 (첫번째 팁의 방식을 쓰지 않는 경우에 한 해) “**‘CountryCode’가 ‘KOR’인 녀석**”이라는 뜻으로 이렇게 항목의 위치를 정할 수도 있다는 겁니다. (실제 이 방식은 R에서 두고두고 요긴합니다!!)

```
> GDP$GDPperCapita2012[GDP$CountryCode == "KOR"]
[1] 22589.96
```

저 밑줄 그은 부분이 바로 “‘CountryCode’가 ‘KOR’인 녀석”을 나타내고 그 외적인 부분이 바로 “그 때의 2012년 일 인 당 GDP”를 나타냅니다.

- 앞 슬라이드의 두번째 팁은 워낙 활용도가 높은 녀석이니깐 좀더 설명을 드리죠. 예를 들어 OECD 국가들의 2012년 1인당 GDP를 다 보려면 이렇게 하시면 됩니다.

```
> GDP$GDPperCapita2012[GDP$OECD == "Y"]
```

```
[1] 67441.593 46791.781 43398.691 51206.156 15452.174 18689.967
[7] 56363.945 16832.801 45694.115 39746.293 42597.367 22441.521
[13] 12560.075 42339.463 45921.316 32567.089 33815.668 46730.918
...
```

- 여기서 “==”는 R에서 소위 논리연산자라고 부르는 겁니다. 그러니까 참(T), 거짓(F)을 결과 값으로 주는 그런 계산이라는 건데 “==”는 “같다”를 나타내고 “다르다”는 “!=”로 표현됩니다. 비슷하게 두 숫자 사이에서 “크다”, “크거나 같다”, “작다”, “작거나 같다” 등을 표현할 때는 각각 “>”, “>=”, “<”, “<=” 등을 씁니다. 그렇기 때문에 똑같은 것도 몇 가지로 표현할 수도 있는데 예를 들어 “OECD가 아닌 나라”를 찾으려면 `GDP$Country[GDP$OECD != "Y"]` 이렇게 할 수도 있고 아니면 `GDP$Country[GDP$OECD == ""]` 이렇게 할 수도 있는 겁니다.
- 논리적으로 따질 땐 당연히 여러 가지 논리값을 합칠 것인자를 고민해야 합니다. 말 그대로 “그리고”나 “또는”이 필요하다는 거죠. R에서 애들은 각각 “&”, “|” (이 문자는 보통 리턴 키 바로 위에 뒤로 누운 해시 “\”키 위에 그려져 있습니다. 그러니까 시프트+“\” 를 하면 나오는 문자죠 ^^)입니다. 그러니까 예를 들어 “100보다 크고 200보다 작은 x”라고 한다면 `x[x > 100 & x < 200]` 이렇게 되는 겁니다.

- 애네들을 쓰면 재미난 걸 금방 할 수 있습니다. 예를 들어 2012년 일 인 당 GDP가 10000이 넘는 나라는 어떤 나라들이 있을까요?

```
> GDP$Country[GDP$GDPperCapita2012 > 10000]
```

```
[1] NA NA
[3] "Antigua and Barbuda" "Argentina"
[5] NA "Australia"
[7] "Austria" "Bahamas, The"
```

...

음 .. 데이터가 없는 녀석들이 또 말썽이군요. 이 녀석들만 빼고 보고 싶으시다면 이렇게 하십시오. (이번엔 “`na.rm=T`”로 안 됩니다. $\pi\pi$)

```
> GDP$Country[which(GDP$GDPperCapita2012 > 10000)]
```

```
[1] "Antigua and Barbuda" "Argentina"
[3] "Australia" "Austria"
[5] "Bahamas, The" "Bahrain"
```

...

`which(A)` 이렇게 하면 `A`에서 (`NA`나 `FALSE`는 말고) 참(`TRUE`)인 녀석만 골라줍니다. ㅎㅎ 그래서 위의 표현은 “2012년 일 인 당 GDP가 10000이 넘지만 `NA`가 아닌 나라의 이름만 출력하라”는 뜻이 되는 겁니다.

- 2012년 일인당 GDP가 10000불에서 20000불 사이인 나라는 어디가 있을까요?

```
> GDP$Country[which(GDP$GDPperCapita2012 >= 10000 & GDP
$GDPperCapita2012 < 20000)]
```

```
[1] "Antigua and Barbuda" "Argentina"          "Barbados"
[4] "Brazil"              "Chile"              "Croatia"
[7] "Czech Republic"     "Estonia"            "Gabon"
```

...

총 24개 나라 중에 9개만 보여드렸습니다.

- 마지막으로 한국보다 일인당 GDP가 더 높았던 나라는 어디가 있을까요?

```
> GDP$Country[which(GDP$GDPperCapita2012 >
GDP$GDPperCapita2012[GDP$CountryCode == 'KOR'])]
```

```
[1] "Australia"          "Austria"
[3] "Bahrain"            "Belgium"
[5] "Bermuda"             "Brunei Darussalam"
```

...

총 36개 나라가 있는데 그 가운데 6개만 보여드렸습니다. 여기서 한국의 일인당 GDP가 어떻게 표현되었는지만 보시면 되겠죠? 위에서 밑줄 그은 부분 보이시죠? 바로 그 부분이 한국의 일인당 GDP를 나타냅니다.

- 참고로 앞의 예와 같은 경우 저렇게 죽 늘어놓으면 읽기도 불편하고 그렇습니다, 그죠? 이럴 땐 한국의 GDP를 새로운 변수로 지정해 읽기 편하게 만들기도 합니다.

```
> KORGDP <- GDP$GDPperCapita2012[GDP$CountryCode == 'KOR']
> GDP$Country[which(GDP$GDPperCapita2012 > KORGDP)]
[1] "Australia"          "Austria"
[3] "Bahrain"            "Belgium"
[5] "Bermuda"             "Brunei Darussalam"
...
```

- 마지막 참고로 이제까지는 변수만 고르는데 논리 연산을 썼지만 실제로는 그 쓰임새가 더 광범위합니다. 예를 들어 데이터 가운데도 일부를 고르는데 쓸 수도 있습니다. 즉, **HealthSys** 가운데 OECD의 것만 골라서 쓰고 싶다고 한다면 이렇게 하시면 됩니다.

```
> ind <- which(HealthSys$OECD == "Y")
> HealthSysOECD <- HealthSys[ind,]
> dim(HealthSysOECD)
[1] 34 15
> HealthSysOECD$Country
[1] "Australia"          "Austria"            "Belgium"
[4] "Cameroon"           "Chile"               "Czech Republic"
[7] "Denmark"            "Estonia"             "Finland"
...
```

HealthSys 행 가운데 ind에 있는 녀석들만 골라서 쓰겠다는 뜻입니다.

OECD 34개 회원국으로만 구성된 데이터가 되었습니다!

단계 4. 문제 풀이.

- 우리가 풀려고 했던 문제는 “도대체 우리나라의 건강관리 관련 전체 지출에서 공공부문이 차지하는 비율은 전세계의 다른 나라와 비교해서 혹은 비슷한 경제 수준의 다른 나라와 비교해서 어떻게 될까요?”였습니다. 이걸 이제 다뤄 봅시다.
- 이 문제를 여기서선 일단 “전체 국가 가운데 우리나라의 공공부문 지출은 순위가 몇 위인가”와 “OECD 국가 가운데 우리나라의 공공부문 지출 순위는 몇 위인가”로 나눠서 풀어보겠습니다. 보는 것처럼 한 문제를 풀면 다른 문제는 금방 풀립니다, 그죠?
- 우선 우리나라의 공공부문 지출 퍼센트를 구해보겠습니다.

```
> indkor <- which(HealthSys$CountryCode == "KOR")
> pubkor <- HealthSys$PublicHealthExpensePercTotal[indkor]
> pubkor
[1] 54.4
```

그러니까 우리나라는 공공부문이 전체 지출의 54.4%를 부담하고 있군요.

- 근데 이건 도대체 큰 건가요 작은 건가요? 그걸 위해 공공부문 지출을 전체적으로 요약해 볼까요.

```
> summary(HealthSys$PublicHealthExpensePercTotal)
   Min. 1st Qu.  Median    Mean 3rd Qu.    Max.   NA's
16.60  45.95   60.45   59.26  75.43   99.90    26
```

흐억 .. 우리나라 공공부문 지출은 중간값은 물론 전세계 조사대상국의 평균에도 미치지 못 하는군요. 저기엔 우리보다 못 사는 나라도 수도룩한데 ...

- 자 이걸 좀더 객관적으로 확인해 보겠습니다. 어떻게 하면 좋을까요? 음 .. 이런 걸 한 번 봅시다. 우리나라의 공공부문 지출은 전세계 국가를 대상으로 했을 때 도대체 몇 번째 정도 될까요?
- 이걸 알아보는데 쓸 함수는 `rank(..)`라는 녀석입니다. `?rank` 해보시면 설명이 죽 나올텐데 변수값을 넣어주면 각 값에 대해 전체 변수 범위에서의 등수를 보여 줍니다. 헛갈리지 말아야 하는 건 이 등수가 작은 값에서부터 시작한다는 거죠.

```
> rank(HealthSys$PublicHealthExpensePercTotal)[indkor]
[1] 74
```

헉! 그러니까 우리나라의 공공부문 지출은 아래에서부터 즉 공공부문 지출이 작은 순서로 74번째라는 겁니다. 그럼에도 불구하고 전체 214개 국가 가운데 밑에서 74번째는 아닙니다. 왜냐하면 `rank(..)`의 설명에 따르면 기본적으로 `na.last=TRUE`라고 되어 있으니까 데이터 값이 없는 26개 국가의 등수는 뒤에 둔 것이죠. 그러니까 214개 국가 가운데 아래에서 74번째가 아니라 188개 국가 가운데 아래에서 74번째인 것이죠. $\pi\pi$ 그러니까 전체 국가의 분포에서 하위 39% ($= 74 / 188$)에 해당하는 만큼의 돈만 공공부문이 쓰고 있다는 겁니다. 우리 생활이 달리 뻥뻥한 게 아니었군요. 다 데이터에 들어 있었습니다.

- 공공부문 지출이 우리보다 적은 나라 가운데 우리나라보다 일 인 당 GDP가 큰 나라는 얼마나 될까요?

```
> HealthSys$Country[HealthSys$PublicHealthExpensePercTotal < pubkor &
GDP$GDPperCapita2012 > KORGDP]
character(0)
```

불행히도 없군요! $\pi\pi$

- 그럼 우리나라의 공공부문 지출은 OECD를 대상으로 했을 때 몇 번째 정도 될까요?

```
> indkoroecd <- which(HealthSysOECD$CountryCode == "KOR")
> rank(HealthSysOECD$PublicHealthExpensePercTotal)[indkoroecd]
[1] 5
> dim(HealthSysOECD)
[1] 34 15
> summary(HealthSysOECD$PublicHealthExpensePercTotal)
   Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 33.50   63.80   74.65   70.95   80.50   85.50
```

역시 이 부분에서는 정말 초라하기 짝이 없군요. 아래에서부터 공공부문 지출이 작은 순서로 5 번째라는 겁니다. 전체 OECD 국가가 34개이고 이들 국가에서는 누락된 데이터가 없으니까 결국 34개 국가 가운데 밑에서 5번째라는 겁니다. ㅎㅎ 게다가 OECD 전체의 평균이나 중간값에도 미치지 못 할 뿐 아니라 OECD 국가 전체의 공공부문 지출 분포를 0 ~ 100%로 봤을 때 25% (1st Qu.)에도 미치지 못 합니다. 정말 가슴 답답한 수준이군요. $\pi\pi$