R for Data Science

(번역서) “R을 활용한 데이터과학” 발간에 맞춰

김설기

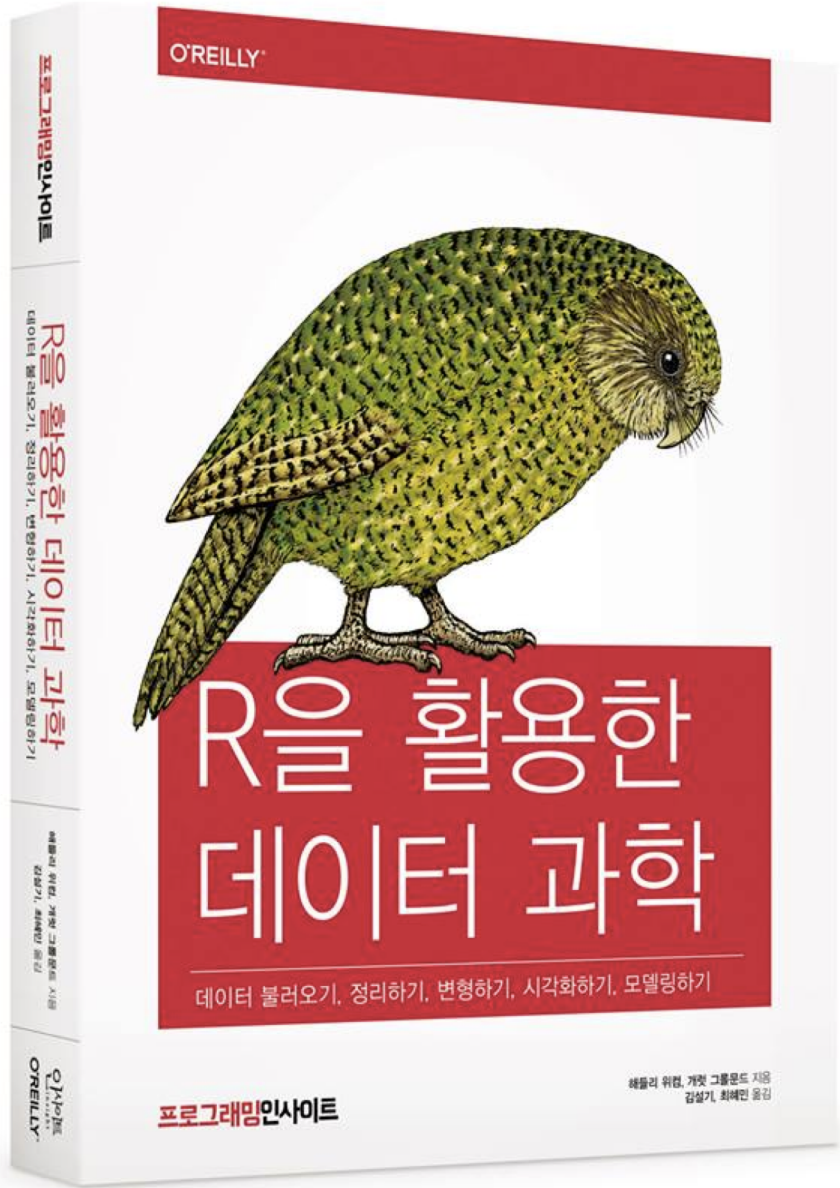
O'REILLY
R을 활용한
데이터 과학
데이터 불러오기, 정리하기, 변형하기, 시각화하기, 모델링하기
프로그래밍인사이트
해들리 위캄, 개릿 그롤문드 지음
김설기, 최혜민 옮김

유전통계학

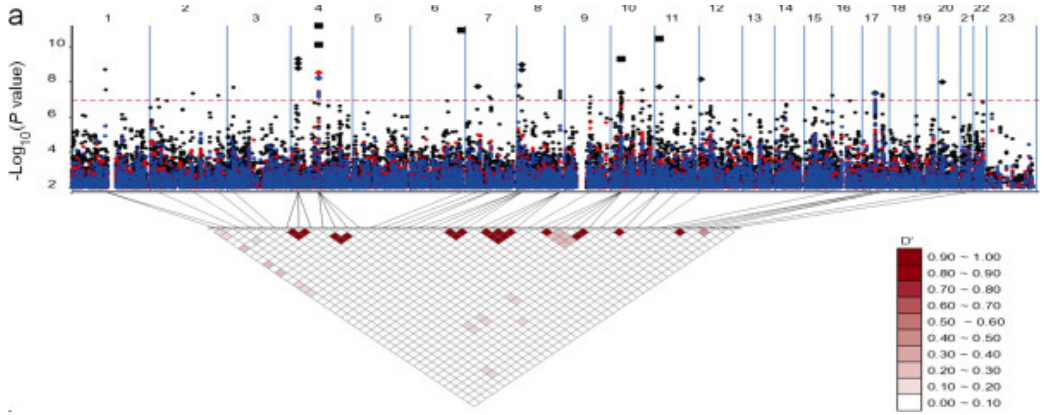

에너지, IoT

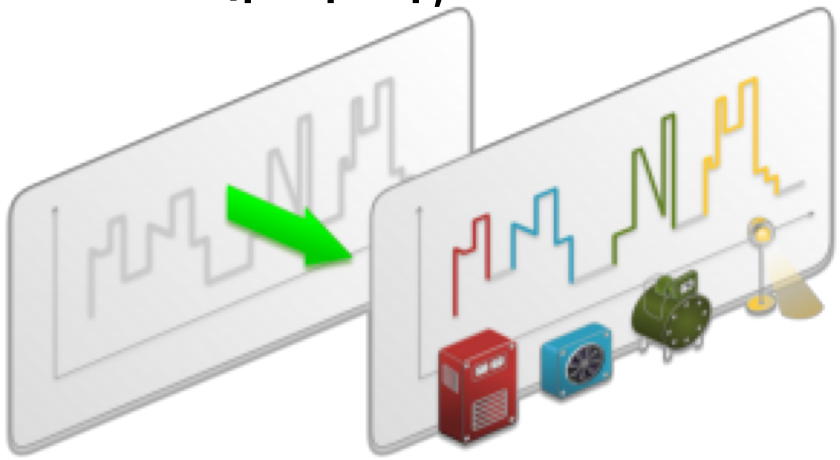

SAMSUNG

SAMSUNG SDS

ENCORED

Hyundai Card

NAVER

R 사용자 (2000년~)

이미지 출처: Smart Energy Efficiency

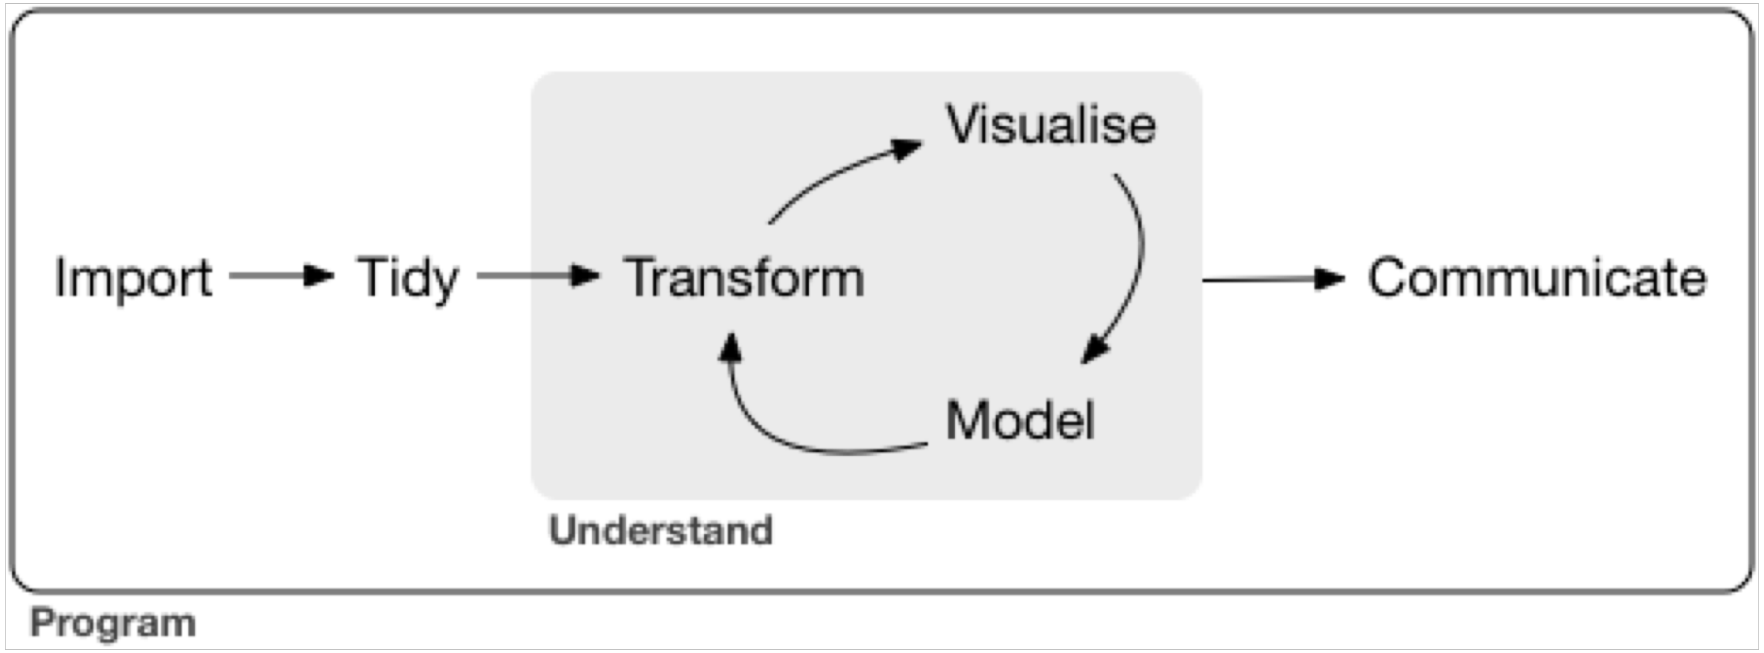

- 불러오기(Import)
- 정리하기, 타이디하게 하기(tidy)
- 변형하기(transform)
- 시각화하기(visualize)
- 모델링하기(model)
- 소통하기(communicate)

Tidy 데이터

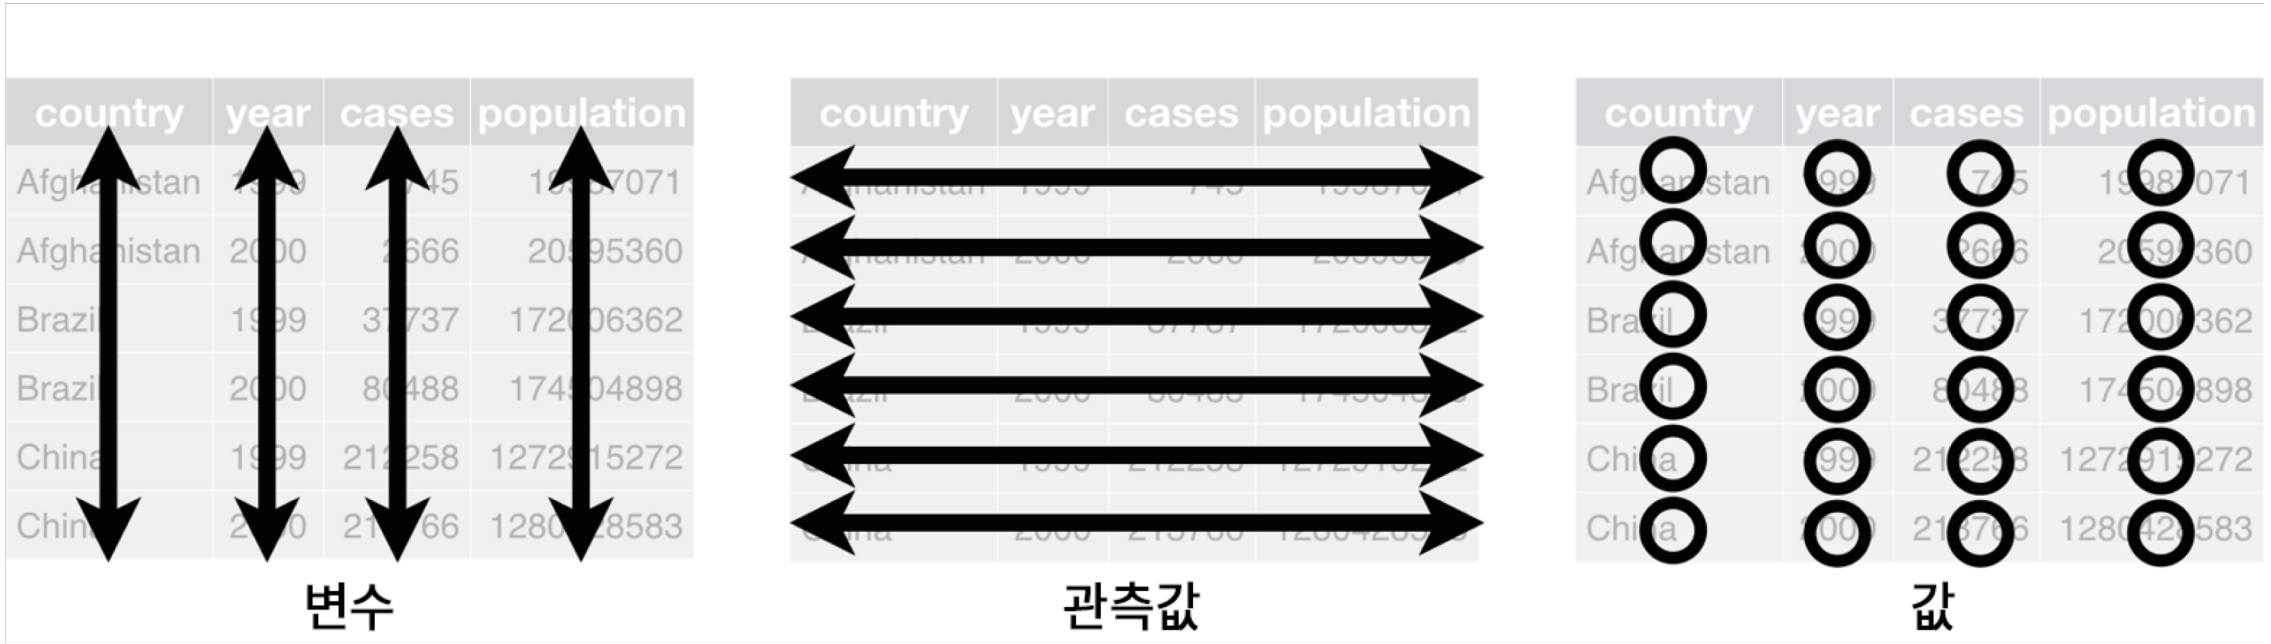

Tidy 하지 않은 데이터

```
table2
#> # A tibble: 12 x 4
#>    country      year type            count
#>    <chr>       <int> <chr>           <int>
#>  1 Afghanistan  1999 cases             745
#>  2 Afghanistan  1999 population   19987071
#>  3 Afghanistan  2000 cases            2666
#>  4 Afghanistan  2000 population   20595360
#>  5 Brazil       1999 cases           37737
#>  6 Brazil       1999 population  172006362
```

```
table3
#> # A tibble: 6 x 3
#>    country      year rate
#>  * <chr>       <int> <chr>
#>  1 Afghanistan  1999 745/19987071
#>  2 Afghanistan  2000 2666/20595360
#>  3 Brazil       1999 37737/172006362
#>  4 Brazil       2000 80488/174504898
#>  5 China        1999 212258/1272915272
#>  6 China        2000 213766/1280428583
```

```
# 티블 두 개로 나누어짐
table4a  # cases
#> # A tibble: 3 x 3
#>    country     `1999` `2000`
#>  * <chr>        <int>  <int>
#>  1 Afghanistan    745   2666
#>  2 Brazil       37737  80488
#>  3 China       212258 213766
table4b  # population
#> # A tibble: 3 x 3
#>    country         `1999`     `2000`
#>  * <chr>            <int>      <int>
#>  1 Afghanistan   19987071   20595360
#>  2 Brazil       172006362  174504898
#>  3 China       1272915272 1280428583
```

데이터 사이언스 도구

1. 데이터프레임 기반: python pandas, spark dataframe

Announcement: DataFrame-based API is primary API

The MLlib RDD-based API is now in maintenance mode.

As of Spark 2.0, the RDD-based APIs in the `spark.mllib` package have entered maintenance mode. The primary Machine Learning API for Spark is now the DataFrame-based API in the `spark.ml` package.

데이터 사이언스 도구

1. 데이터프레임 기반: python pandas, spark dataframe

2. pipe/pipeline

```
foo_foo <- hop(foo_foo, through = forest)
foo_foo <- scoop(foo_foo, up = field_mice)
foo_foo <- bop(foo_foo, on = head)
```

VS

```
foo_foo %>%
  hop(through = forest) %>%
  scoop(up = field_mice) %>%
  bop(on = head)
```

- 디버깅이 쉽다
- 동사(함수)가 주목된다
- 읽기가 쉽다

데이터 사이언스 도구

1. 데이터프레임 기반: python pandas, spark dataframe

2. pipe/pipeline

3. “많은 주제를 넓고 얕게 살펴보기다는 깊게 파면 더 빨리 할 수 있을 것이다.”

빅데이터와 R

- "전체 데이터는 클 수도 있지만, 특정 문제에 답을 얻는 데 필요한 데이터는 작은 경우가 많다."

- data.table, sparklyr 등

데이터 과학 컬쳐

- Communication
  - "다른 사람에게 설명할 수 없다면
    분석이 얼마나 훌륭한지는 중요하지 않다."
  - rmarkdown, bookdown

데이터 과학 컬쳐

- Communication
  - "다른 사람에게 설명할 수 없다면
    분석이 얼마나 훌륭한지는 중요하지 않다."
  - rmarkdown, bookdown

- open project for book

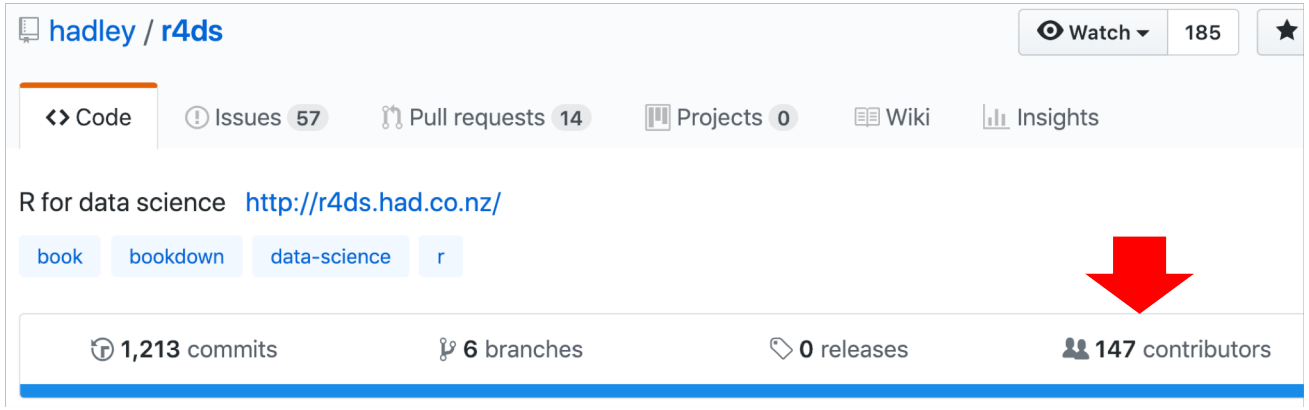

데이터 과학 컬쳐

- Communication
  - "다른 사람에게 설명할 수 없다면
    분석이 얼마나 훌륭한지는 중요하지 않다."
  - rmarkdown, bookdown
- open project for book
- twitter #rstats #r4ds #Tidytuesday

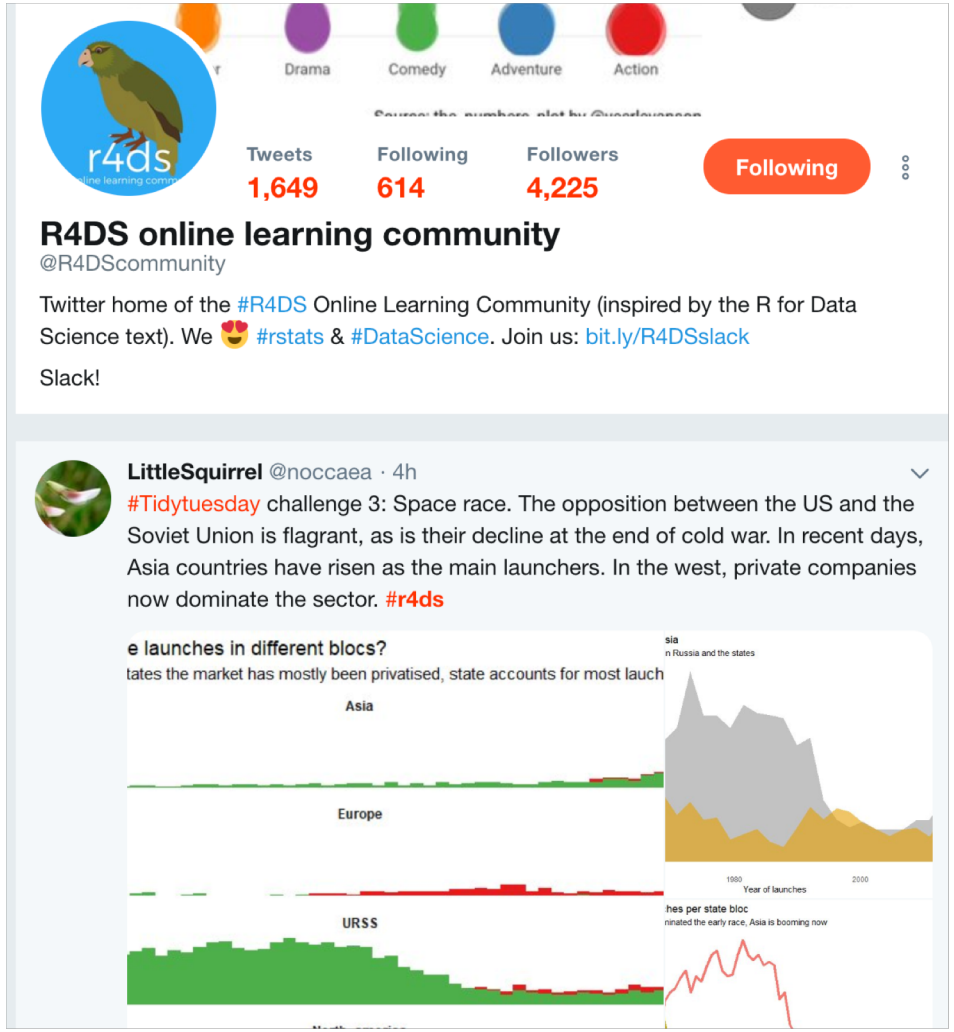

R 도움받기 – 문제 발생시

- 구글 검색
  - 오류메시지
  - ‘R’ 추가

- stackoverflow

R 도움받기 – 문제예방

- 블로그 (RStudio, R-bloggers)

- 트위터 (@hadleywickham, @statgarrett, @rstudiotips, #rstats, #r4ds) 팔로우

R 도움받기 – 한국어

- 페이스북 그룹

- 온라인, 오프라인 강의, 밋업
- 책
- https://sulgik.github.io/r4ds/