初心者セッション：データハンドリング

BeginneR Session: Data Handling 101

18th April 2026, Tokyo.R #120

Yuta Kanzawa @yutakanzawa

Senior Data Scientist at ASKUL Corporation

神沢雄大 Yuta Kanzawa

- データサイエンティスト@アスクル株式会社
- Twitter: @yutakanzawa
- 好きなもの：オペラとワイン
  - ワーグナー
  - ブルゴーニュ
- 使用可能言語：7.5
  - 人間：日本語、英語、ドイツ語（+フランス語）
  - コンピューター：R, Python, SAS, SQL

ポートフォリオ

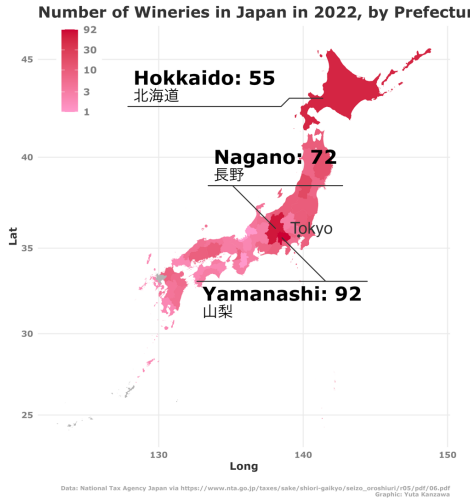

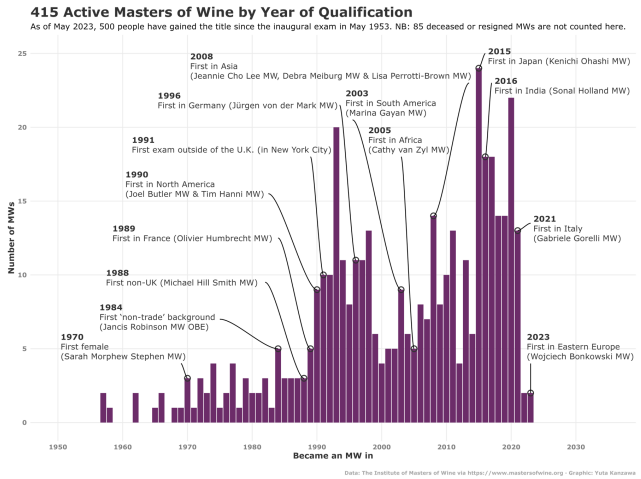

Source: Japan Sommelier Association https://www.sommelier.jp/exam/pdf/qualifiedholders.pdf
*Sommelier Excellence (2019-2020), Senior Sommelier (2013-2018), Senior Wine Adviser (2013-2015)

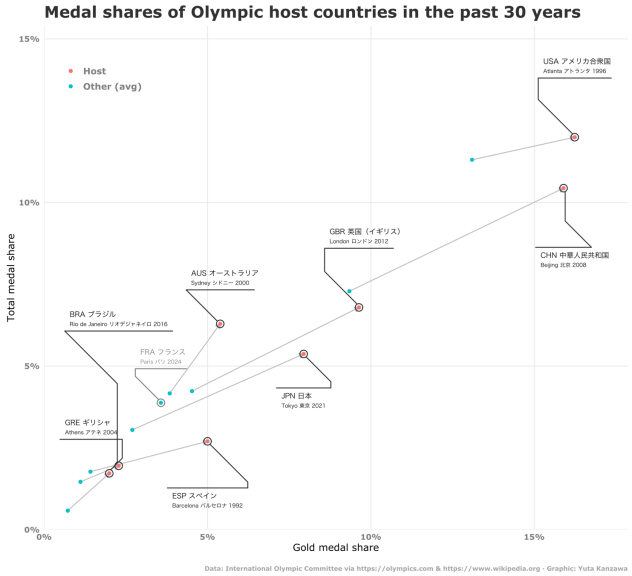

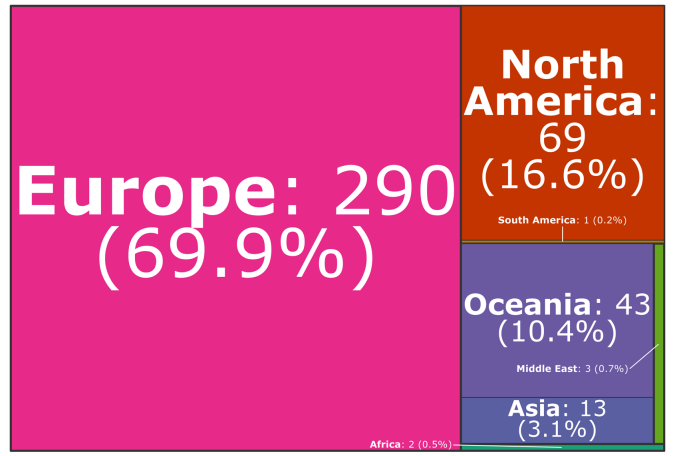

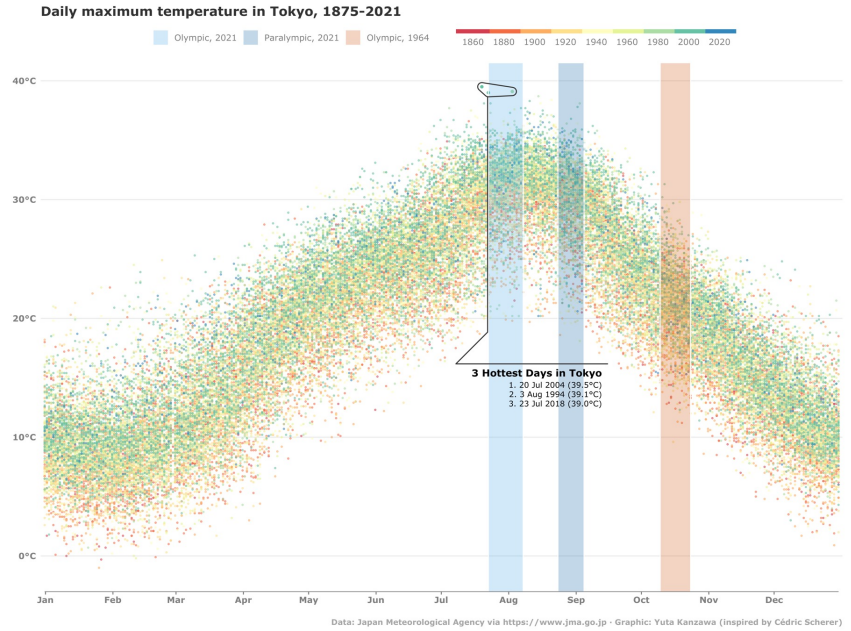

ポートフォリオ（参考までにR以外も）

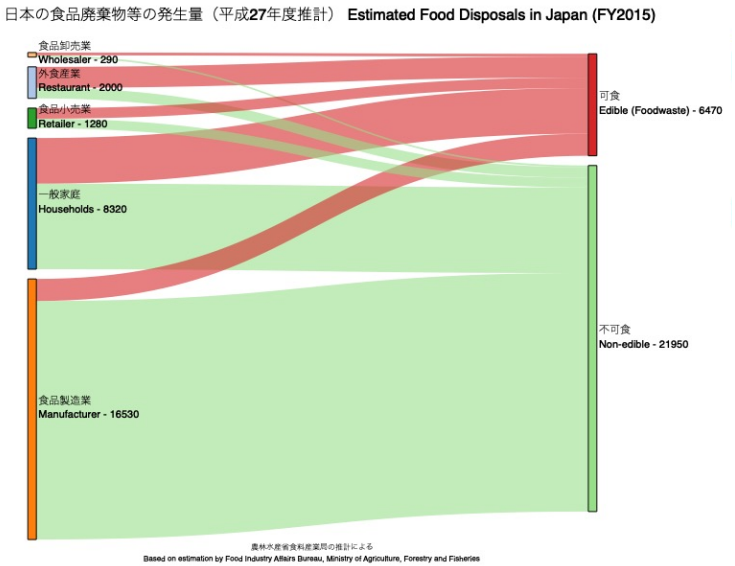

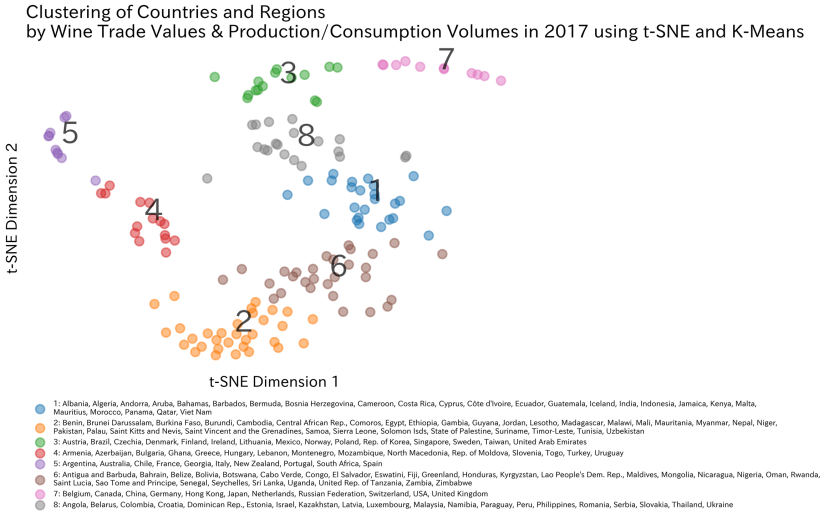

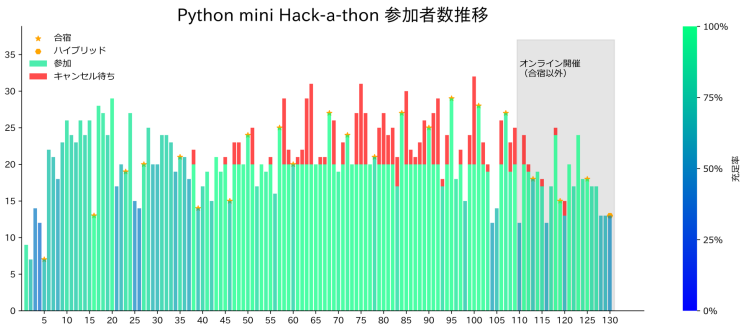

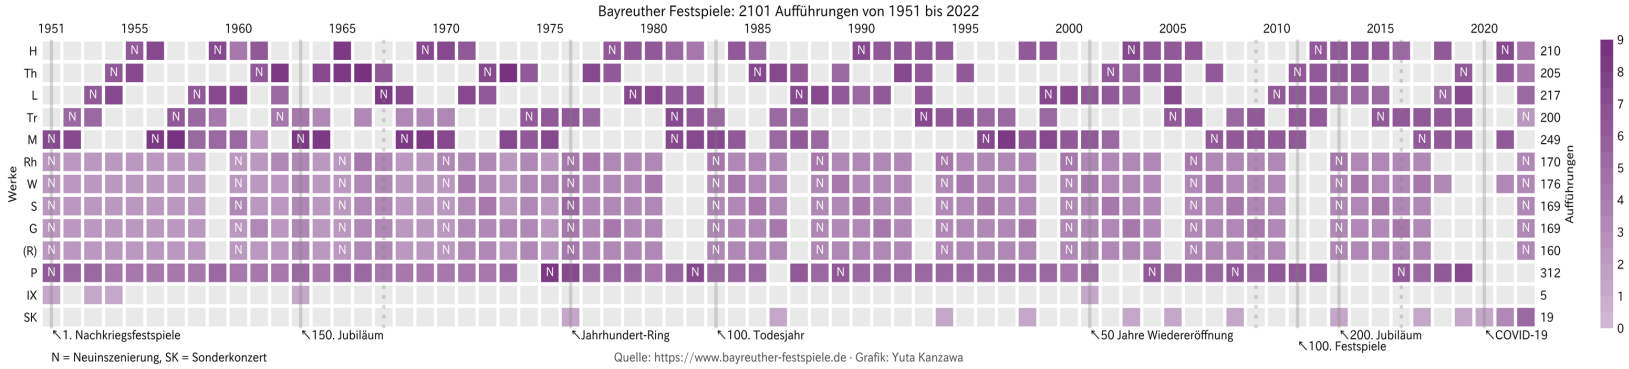

アジェンダ

- 今日話すこと
  - tidyverse（特にdplyr）
  - ペンギンデータ
- 対象（以下のいずれか）
  - tidyverseを初めて触る人
  - tidyverseをなんとなく使っている人

- 今日話さないこと
  - base RやExcelとの比較

→dplyrによる加工の理解

TL;DR

- データ型とデータ構造（特にベクトル、リスト、データフレーム）
- 値を入れるのは**代入演算子**「<-」で。
- ライブラリー（パッケージ）はコードの冒頭で呼び出しておく。
- コードを書くとき「スタイル」も意識する。→**フォーマッター**とリンター
- **パイプ演算子**を使って処理の流れを明確に！
- データの出力のおすすめは**parquet**形式！
- これからは**ペンギンデータ**！
- dplyrでのデータ加工は簡単！

R言語の基礎

R language 101

データ型

データ型	名称	例
文字列	character	"あーる", "1"
整数	integer	-1L, 0L, 1L, 2L
数値（浮動小数点数）	numeric	4.51
論理値	logical	TRUE, FALSE
日付	Date	2026-04-18
日時	POSIXct, POSIXlt	2026-04-18 14:00:00
ファクター（因子）	factor	（カテゴリー値）

※欠測値（欠損値）は「NA」で表す。

データ構造

Vector

`c(1, 2, 3)`

Matrix

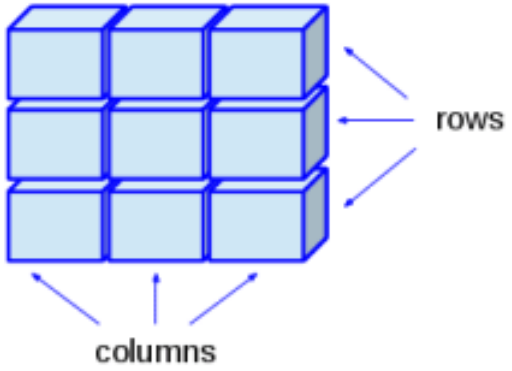

Array

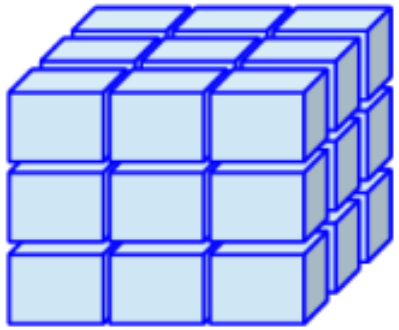

Data Frame
(Table)

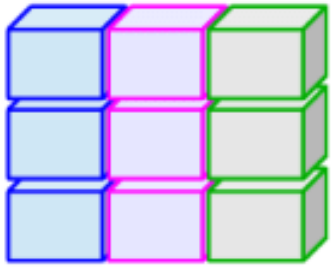

`data.frame()`

Lists

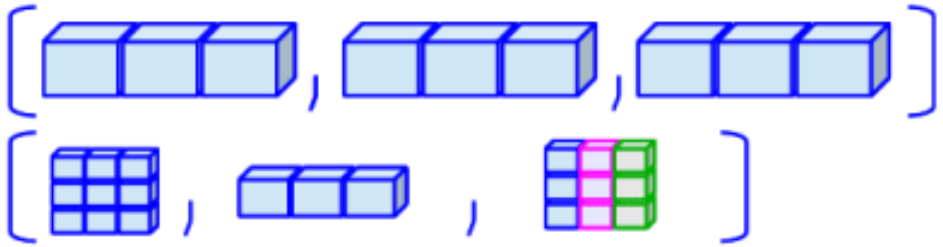

`list()`

* https://balachandark.com/2022/08/07/r-series-4-data-structures/

演算子

算術演算子	処理
+	加法
-	減法
*	乗法
/	除法
^	累乗
%/%	商
%%	剰余

比較演算子	処理
==	等しい
!=	等しくない
>	超
<	未満
>=	以上
<=	以下
%in%	含まれる

論理演算子	処理
&	AND
|	OR
!	NOT

代入演算子

- 左のオブジェクトに右の値を入れる。：「<-」
  - 「=」と同じ。
  - ショートカットキー
    - Win:「Alt+-」、Mac:「Option+-」
- 例：
  - `a <- 1`
  - `df <- read_csv(...)`

ライブラリー（パッケージ）

- 使う時に読み込む（呼び出す）必要がある。
  - library()がオススメ。1つずつ読み込む（コードの最初に1回だけ）。
    - 例：library(tidyverse)　←引用符なし！
- ::記法
  - 課題 → ::記法を使うと解決（ただし、コードが長くなりがちなのが欠点）。
    - どのライブラリーの関数なのか分かりにくい。
    - 関数名がライブラリー間で重複すると、最後に読み込んだライブラリーのものが有効。
  - ライブラリー名と関数名を「::」でつないで書く。
    - 例：
      - readr::read_csv()
      - tidyr::pivot_longer()

コードスタイルガイド

- コードを書く際の様式の**ルール**（名前、空白、改行、文字数、など）
  - 書式が整ったコードは**読みやすい**。→ デバッグや保守をしやすい。
  - 意識しながら書くのは大変 → **フォーマッターやリンター**の使用

- **tidyverse style guide**
  - https://style.tidyverse.org
  - Google's R Style Guideのオリジナル版*1がベース → styler、lintr
- Google's R Style Guide
  - GoogleのRコミュニティーがまとめ、tidyverse style guideの元になった*2。
  - 現行版： https://google.github.io/styleguide/Rguide.html

*1 オリジナル版（スタンフォード大学のコピー）： https://web.Stanford.edu/class/cs109l/unrestricted/resources/google-style.html
→日本語訳（RjpWiki）： http://www.okadajp.org/RWiki/?Google%27s+R+Style+Guide
*2 ただし、現行版はtidyverse style guideから派生したもの。

フォーマッターやリンターの使用

- フォーマッター（見た目を整えるツール）
  - **styler**[*1]: tidyverse style guide準拠
    - RStudioのアドイン同梱
  - formatR[*2]
    - RStudioのアドイン：addinexamples[*3]
  - どちらも**RStudio上でアドイン**として実行可能。
    - **ショートカットキー**も設定可能。
    - R Markdownでも利用可能。
- リンター（静的解析ツール）
  - lintr[*4]: 静的チェック（**バグにつながりやすいコード**をチェック）

*1 https://github.com/r-lib/styler
*2 https://yihui.org/formatr/
*3 https://rstudio.github.io/rstudioaddins/
*4 https://github.com/r-lib/lintr

tidyverse

tidyverse

tidyverseパッケージ

- データ分析用のパッケージ群（メタパッケージ）
  - `install.packages("tidyverse")`
  - `library(tidyverse)`

パッケージ名	機能	パッケージ名	機能
readr	データ読み込み	tibble	強化版データフレーム
dplyr	データ加工	stringr	文字列処理
tidyr	データ加工	forcats	ファクター型
ggplot2	データ可視化	lubridate	日時処理
		purrr	関数型プログラミング

* https://www.tidyverse.org

パイプ演算子

Pipe operator

パイプ演算子

- 値を左から右へ渡す。
  - 左側の処理の出力を右側の処理の第1引数に入れる。
    - `f(x) |> g(y)` は `g(f(x), y)` と同じ。
- dplyr：「%>%」、base R（4.1以降）「|>」
  - ショートカットキー
    - Win:「Ctrl+Shift+M」、Mac:「Cmd+Shift+M」
  - 切り替え：*Tools → Global Options → Code → Editing → Use native pipe operator, |> (requires R 4.1 +)*
- パイプ演算子を使うことで、処理の流れが明確になる！
  - 関数の入れ子は複雑で分かりにくい。

tidyなデータ（整然データ）

Tidy data

tidyなデータ

- 条件
  - 各**変数**が1つの列で構成されている
  - 各**観測**が1つの行で構成されている
  - 各**観測単位**が1つの表で構成されている（各**値**が1つのセルに入っている）
- 必ずしも縦長なデータとは限らない！
- 実務と折り合いをつける！
  - 結局のところ**使いやすさ**。

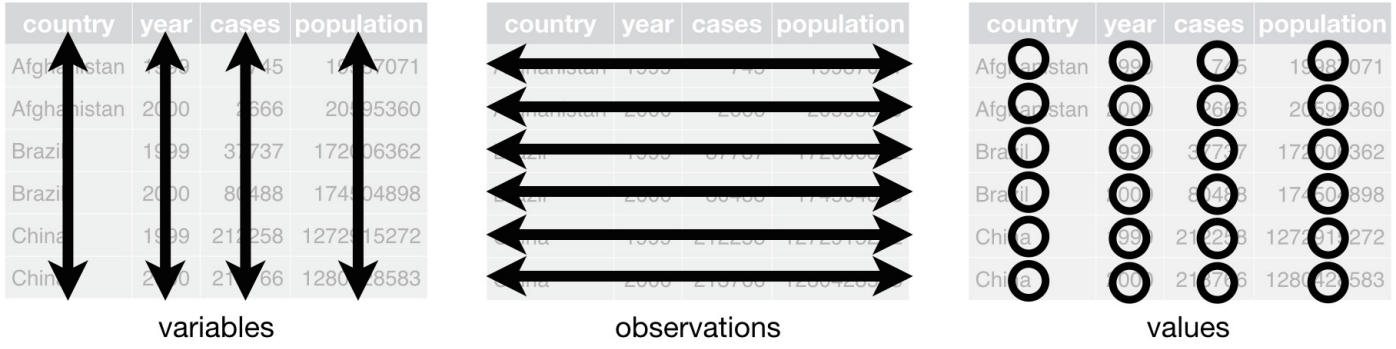

* https://r4ds.had.co.nz/tidy-data.html#fig:tidy-structure

tidyr::pivot_longer()とpivot_wider()

- 「縦持ち」、「横持ち」の変換

table4a

country	1999	2000
A	0.7K	2K
B	37K	80K
C	212K	213K

country	year	cases
A	1999	0.7K
B	1999	37K
C	1999	212K
A	2000	2K
B	2000	80K
C	2000	213K

```
table4a |> pivot_longer(
  cols = 2:3,
  names_to ="year",
  values_to = "cases"
)
```

これが「観測」

table2

country	year	type	count
A	1999	cases	0.7K
A	1999	pop	19M
A	2000	cases	2K
A	2000	pop	20M
B	1999	cases	37K
B	1999	pop	172M
B	2000	cases	80K
B	2000	pop	174M
C	1999	cases	212K
C	1999	pop	1T
C	2000	cases	213K
C	2000	pop	1T

country	year	cases	pop
A	1999	0.7K	19M
A	2000	2K	20M
B	1999	37K	172M
B	2000	80K	174M
C	1999	212K	1T
C	2000	213K	1T

```
table2 |> pivot_wider(
  names_from = "type",
  values_from = "count"
)
```

* https://rstudio.github.io/cheatsheets/tidyr.pdf

データ読み書き

Loading & saving data

データ読み込み

- **CSVファイル**：readr::read_csv()
  - 大規模なデータはfreadパッケージなども。
- **Excelファイル**：readxl::read_excel()
  - xlsxもxlsも読み込める！~~ただし、xlsは滅ぶべき。~~
- SAS、SPSS、Stataの出力ファイル：havenパッケージ
- JSON：jsonlite::fromJSON()
- parquet形式：arrow::read_parquet()
- Web関連：httrパッケージ、rvestパッケージ

データ出力

- テーブルデータ（表形式）は**parquet形式**がおすすめ！
  - データ型が保存される！
  - R以外の言語でも使える！（短所：言語独自のデータ型は使えない。）
  - 圧縮率が高い！
  - `arrow::write_parquet()`
- CSVファイル：`write.csv()`
- Excelファイル：writexlパッケージ、xlsxパッケージ
- R形式のバイナリー化：`save()`

データ加工の基礎

Basic data wrangling

ペンギンデータ

- 2007-9年の南極パーマー基地周辺におけるペンギンの調査データ
  - https://doi.org/10.1371/journal.pone.0090081
- R 4.5から標準搭載！
  - データセットは`data("penguins")`で呼び出す。
  - 4.5未満は`palmerpenguins`パッケージをインストール。
    - 注意：**カラム名が違う**。

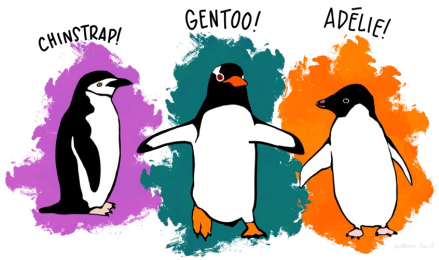


```
> head(penguins)
  species    island bill_len bill_dep flipper_len body_mass    sex year
1  Adelie Torgersen     39.1     18.7         181      3750   male 2007
2  Adelie Torgersen     39.5     17.4         186      3800 female 2007
3  Adelie Torgersen     40.3     18.0         195      3250 female 2007
4  Adelie Torgersen       NA       NA          NA        NA   <NA> 2007
5  Adelie Torgersen     36.7     19.3         193      3450 female 2007
6  Adelie Torgersen     39.3     20.6         190      3650   male 2007
```

* https://allisonhorst.github.io/palmerpenguins/

列の抽出

- `dplyr::select(列名1, 列名2, ...)`
  - m行n列のデータフレームとして取り出す。
  - 1列をベクトルとして取り出したい場合は`pull()`を使う。
- 例：
  - ペンギンデータから`bill_len`と`bill_dep`の2列を抽出。
    - `penguins |> select(bill_len, bill_dep)`

* https://rstudio.github.io/cheatsheets/data-transformation.pdf

列の追加

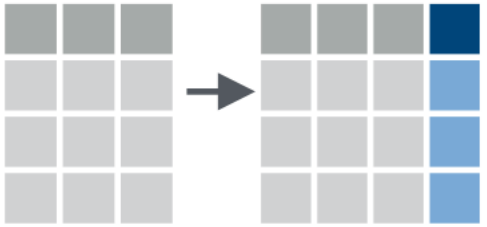

- `dplyr::mutate(追加する列名 = 値や計算式, ...)`
  - データセットに新しい列を追加（した新しいデータセットを作成）する。

- 例：
  - ペンギンデータにひれとくちばしの長さの比率を表す列を追加。
    - ```
      penguins |> mutate(
        flipper_bill_ratio = flipper_len / bill_len
      )
      ```

* https://rstudio.github.io/cheatsheets/data-transformation.pdf
      ```

行の抽出

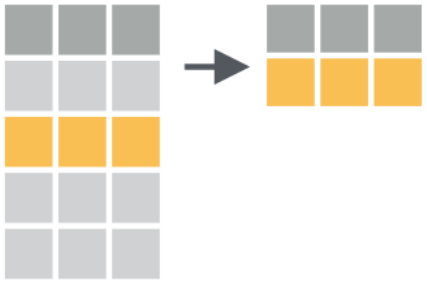

- `dplyr::filter(条件)`
  - 条件に該当する行をデータフレームとして取り出す。
- 例：
  - ペンギンデータから2007年のデータを取り出す。
    - `penguins |> filter(year == 2007)`
  - ペンギンデータから2007年のアデリーペンギンのデータを取り出す。
    - `penguins |> filter(year == 2007 & species == "Adelie")`

* https://rstudio.github.io/cheatsheets/data-transformation.pdf

行のソート

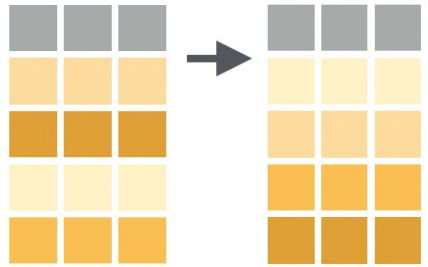

- dplyr::arrange(ソートの基準にする列名)
  - 指定された列を基準にデータセット全体をソートする（デフォルトは昇順）。
- 例：
  - ペンギンデータを体重の昇順にソート。
    - `penguins |> arrange(body_mass)`
  - ペンギンデータを体重の昇順にソートし、年の降順にソート。
    - `penguins |> arrange(body_mass, desc(year))`
      - 指定した順にソートされる。

* https://rstudio.github.io/cheatsheets/data-transformation.pdf

グループごとの集約

- group_by(グループを表す列) |> summarise(計算式)
  - group_by()で集約キーとなるグループを指定し、summarise()に記述した計算をグループごとに行う。
    - 米国式にsummarize()と綴ってもよい。
  - どちらもdplyrの関数。
- 例：
  - ペンギンデータから、それぞれの種のそれぞれの年の平均体重を算出する。
    - penguins |> group_by(species, year) |>
      summarise(mean(body_mass, na.rm = TRUE))
      - 注：mean(...)はsummarise()の処理内容を指定する引数の値なので入れ子にする。

* https://rstudio.github.io/cheatsheets/data-transformation.pdf

この他にも…

- **重複**を削除→`dplyr::distinct()`
- データセットを**列方向**に接着→`dplyr::bind_cols()`
- データセットを**行方向**に接着→`dplyr::bind_rows()`
  - SQLのUNION相当
- **列をキーに**したデータセットの結合→`dplyr::left_join()`など
  - SQLの各種JOIN相当
- データセットを**縦持ち**に変換→`tidyr::pivot_longer()`
- データセットを**横持ち**に変換→`tidyr::pivot_wider()`

まとめ

Long story short

Long story short (1/2)

- **データ型**を意識する。
- データ構造
  - よく使うのはベクトル、リスト、データフレーム。
    - ベクトルはc()で作る。
- 値を入れるのは**代入演算子**「<-」で。
- ライブラリー（パッケージ）はコードの冒頭で呼び出しておく。
  - ::記法もおすすめ。
- コードを書くとき「スタイル」も意識する。→**フォーマッター**とリンター

Long story short (2/2)

- **tidyverse**は便利！
  - パイプ演算子：dplyr「%>%」と標準「|>」
  - tidyなデータへの変換：pivot_longer()とpivot_wider()
- データの読み書きはファイル形式に応じて！おすすめは**parquet**！
- これからは**ペンギンデータ**！
- dplyrでのデータ加工
  - select(), mutate(), filter(), arrange(), group_by(), summarise()

ネットで公開されている便利なリソース（1/2）

- 『はじめよう！R』（小杉、2025年）
  - 第117回Tokyo.R初心者セッション
  - https://kosugitti.github.io/slides/TokyoR117/RforBeginner.html

ネットで公開されている便利なリソース（2/2）

- Posit社のチートシート集
  - https://posit.co/resources/cheatsheets/
- R Cookbook
  - R Cookbookの著者によるwebサイト
  - https://rc2e.com
- Cookbook for R
  - R Graphics Cookbookの著者によるwebサイト
  - http://www.cookbook-r.com

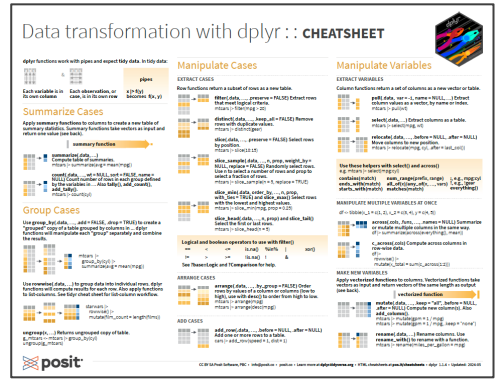

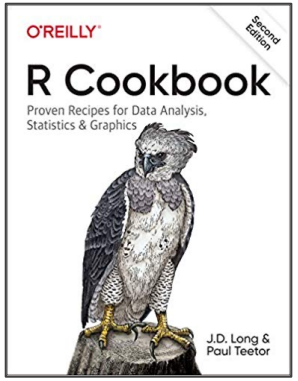

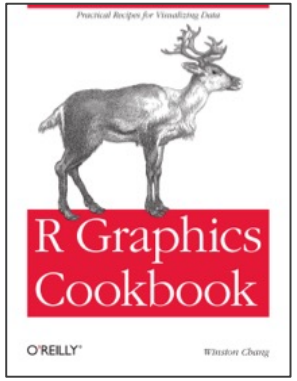

参考書

- 『RユーザのためのRStudio入門』改訂2版（松村、湯谷、紀ノ定、前田、2021年）
  - いわゆる「宇宙船本」
- 『Rクックブック』第2版（Long, Teetor、2020年）
- 『Rではじめるデータサイエンス』（Wickham, Grolemund、2017年）

Enjoy!