

データサイエンス 基礎

Fundamental Data Science

第5回 Rによるデータの視覚化



今日の内容

RStudio (クラウド版) を使って

- ▶ **RStudio の使い方**
- ▶ **データの読み込み, 抽出, 要約統計量の計算**
- ▶ **グラフ (ヒストグラム, 箱ひげ図, 散布図) の描き方**

※ インストール版 RStudio もクラウド版と使い方は基本同じ
違う箇所 (2か所) は適宜説明



RStudio (クラウド版) の使い方


起動と計算

Posit Cloud の使用



Your Workspace 内の作成済みのプロジェクトをクリック

<https://posit.cloud/>




※ インストール版 RStudio を使う場合

Windows

スタートメニュー

⇒ 「RStudio」と検索

⇒ RStudio のアイコンを
クリック



Mac

Finder

⇒ アプリケーション

⇒ RStudio のアイコンを
クリック



画面

**ここにコマンドを書く
その結果も出力される**

**読み込んだデータなどは
ここに表示される**

**出力したグラフや
ヘルプなど**

基本計算

```
≡ Your Workspace / Untitled Project + Click to name your project
File Edit Code View Plots Session Build Debug Profile Tools Help
Go to file/function Addins
R 4.2.1 . /cloud/project/

R version 4.2.1 (2022-06-23) -- "Funny-Looking Kid"
Copyright (C) 2022 The R Foundation for Statistical Computing
Platform: x86_64-pc-linux-gnu (64-bit)

R is free software and comes with ABSOLUTELY NO WARRANTY.
You are welcome to redistribute it under certain conditions.
Type 'license()' or 'licence()' for distribution details.

R is a collaborative project with many contributors.
Type 'contributors()' for more information and
'citation()' on how to cite R or R packages in publications.

Type 'demo()' for some demos, 'help()' for on-line help, or
'help.start()' for an HTML browser interface to help.
Type 'q()' to quit R.

> 1+2
[1] 3
> 3-5
[1] -2
> 6/3
[1] 2
> 4*2
[1] 8
> 3^2
[1] 9
> |
```

```
> 1+2      > 4*2
[1] 3      [1] 8
> 3-5      > 3^2
[1] -2     [1] 9
> 6/3
[1] 2
```

実行したいコマンド
を半角でかいて
Enter で実行

練習問題 (1)

Q.1 $20 - 40$ を計算せよ

Q.2 2の3乗を計算せよ

Q.3 $100^{1/2}$ と $100^{(1/2)}$ を計算してその違いを確かめよ

解答例：練習問題 (1)

```
> 20-40  
[1] -20  
> 2^3  
[1] 8  
> 100^1/2  
[1] 50  
> 100^(1/2)  
[1] 10  
>
```

1

2

3

3

計算するとき、
() の位置に注意!!

$100^{1/2}$ は
 100^1 を2で割る
という計算になります

$100^{(1/2)}$ は
 $\sqrt{100}$ と同じ計算ですね



データの読み込む前の下準備

成績データ

「seiseki.csv」

Data 中学2年生の成績データ (個体数=166, 杉山, 藤越, 小椋, 2014, より抜粋).

1. ID number
2. 国語 (点)
3. 社会 (点)
4. 数学 (点)
5. 理科 (点)
6. 音楽 (点)
7. 美術 (点)
8. 体育 (点)
9. 技家 (点)
10. 英語 (点)

	A	B	C	D	E	F	G	H	I	J
1	ID	kokugo	shakai	sugaku	rika	ongaku	bijutu	taiiku	gika	eigo
2	1	30	43	51	63	60	66	37	44	20
3	2	39	21	49	56	70	72	56	63	16
4	3	29	30	23	57	69	76	33	54	6
5	4	95	87	77	100	77	82	78	96	87
6	5	70	71	78	67	72	82	46	63	44
7	6	67	53	56	61	61	76	70	66	40
8	7	29	26	44	52	37	68	33	43	13
9	8	56	54	37	59	35	64	53	67	7
10	9	45	21	7	44	16	52	34	46	3

データの整理

- ❗ すべての変数に半角英数字で変数名をつける
- ❗ 変数名は1行目に1行だけでつける
- ❗ データのタイトルなど、変数名とデータ以外の行はすべて削除する

RStudio で読み込むために
データの下準備を
覚えてください

※ これらをしないと、データが読み込めてもその後エラーが起こることが多い

各変数名

		C	D	E	F	G	H	
1	ID	kokugo	shakai	sugaku	rika	ongaku	bijutu	taiiku
2	1	30	43	51	63	60	66	3
3	2	39	21	49	56	70	72	5
4	3	29	30	23	57	69	76	3



データの整理

おすすめの例

	A	B	C	D	E	F	G	H	
1	ID	kokugo	shakai	sugaku	rika	ongaku	bijutu	taiiku	gika
2	1	30	43	51	63	60	66	37	
3	2	39	21	49	56	70	72	56	
4	3	29	30	23	57	69	76	33	

- 変数名がすべて半角文字で
ついている
- 変数名とデータ (数値) 以
外の行がない

おすすめしない例

	A	B	C	D	E	F	G	H	
	成績データ								
		kokugo	shakai	sugaku	rika	ongaku	bijutu	taiiku	gika
									eigo
	1	30	43	51	63	60	66	37	44
	2	39	21	49	56	70	72	56	63
	3	29	30	23	57	69	76	33	54

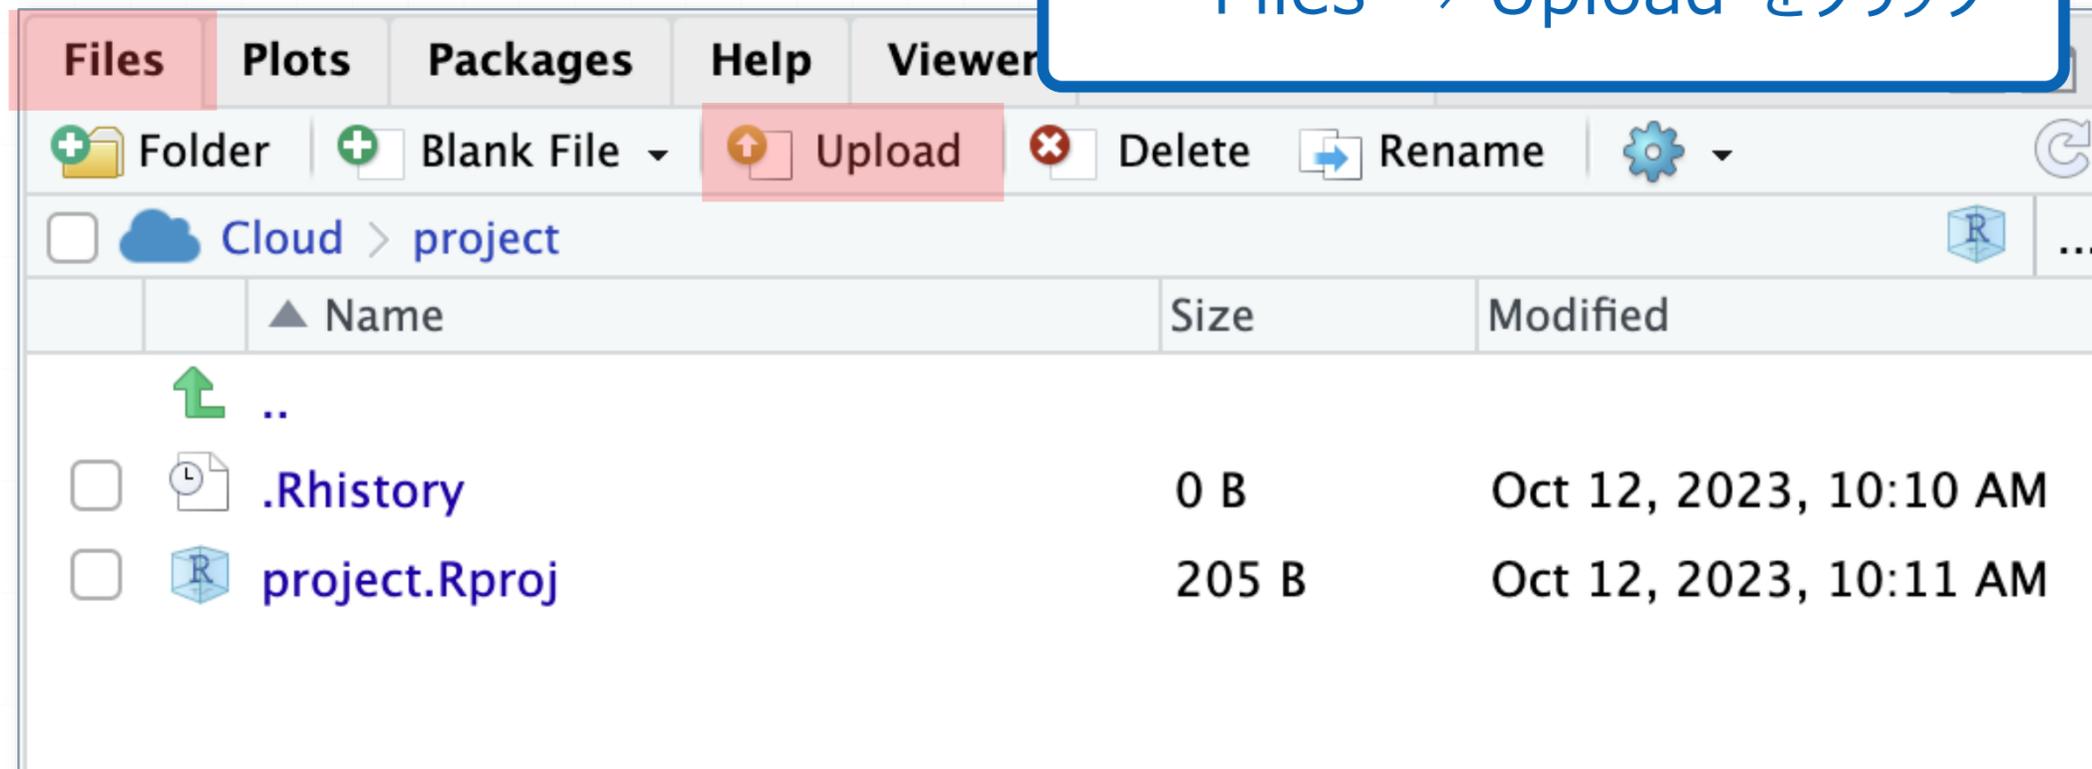
変数名が
ついていない

変数名とデータ (数値)
以外の行がある

RStudio (クラウド版) での下準備

使いたいデータをクラウド上に Upload する
⇒ クラウド上でそのデータが使用可能に!!

① 画面右下
Files ⇒ Upload をクリック

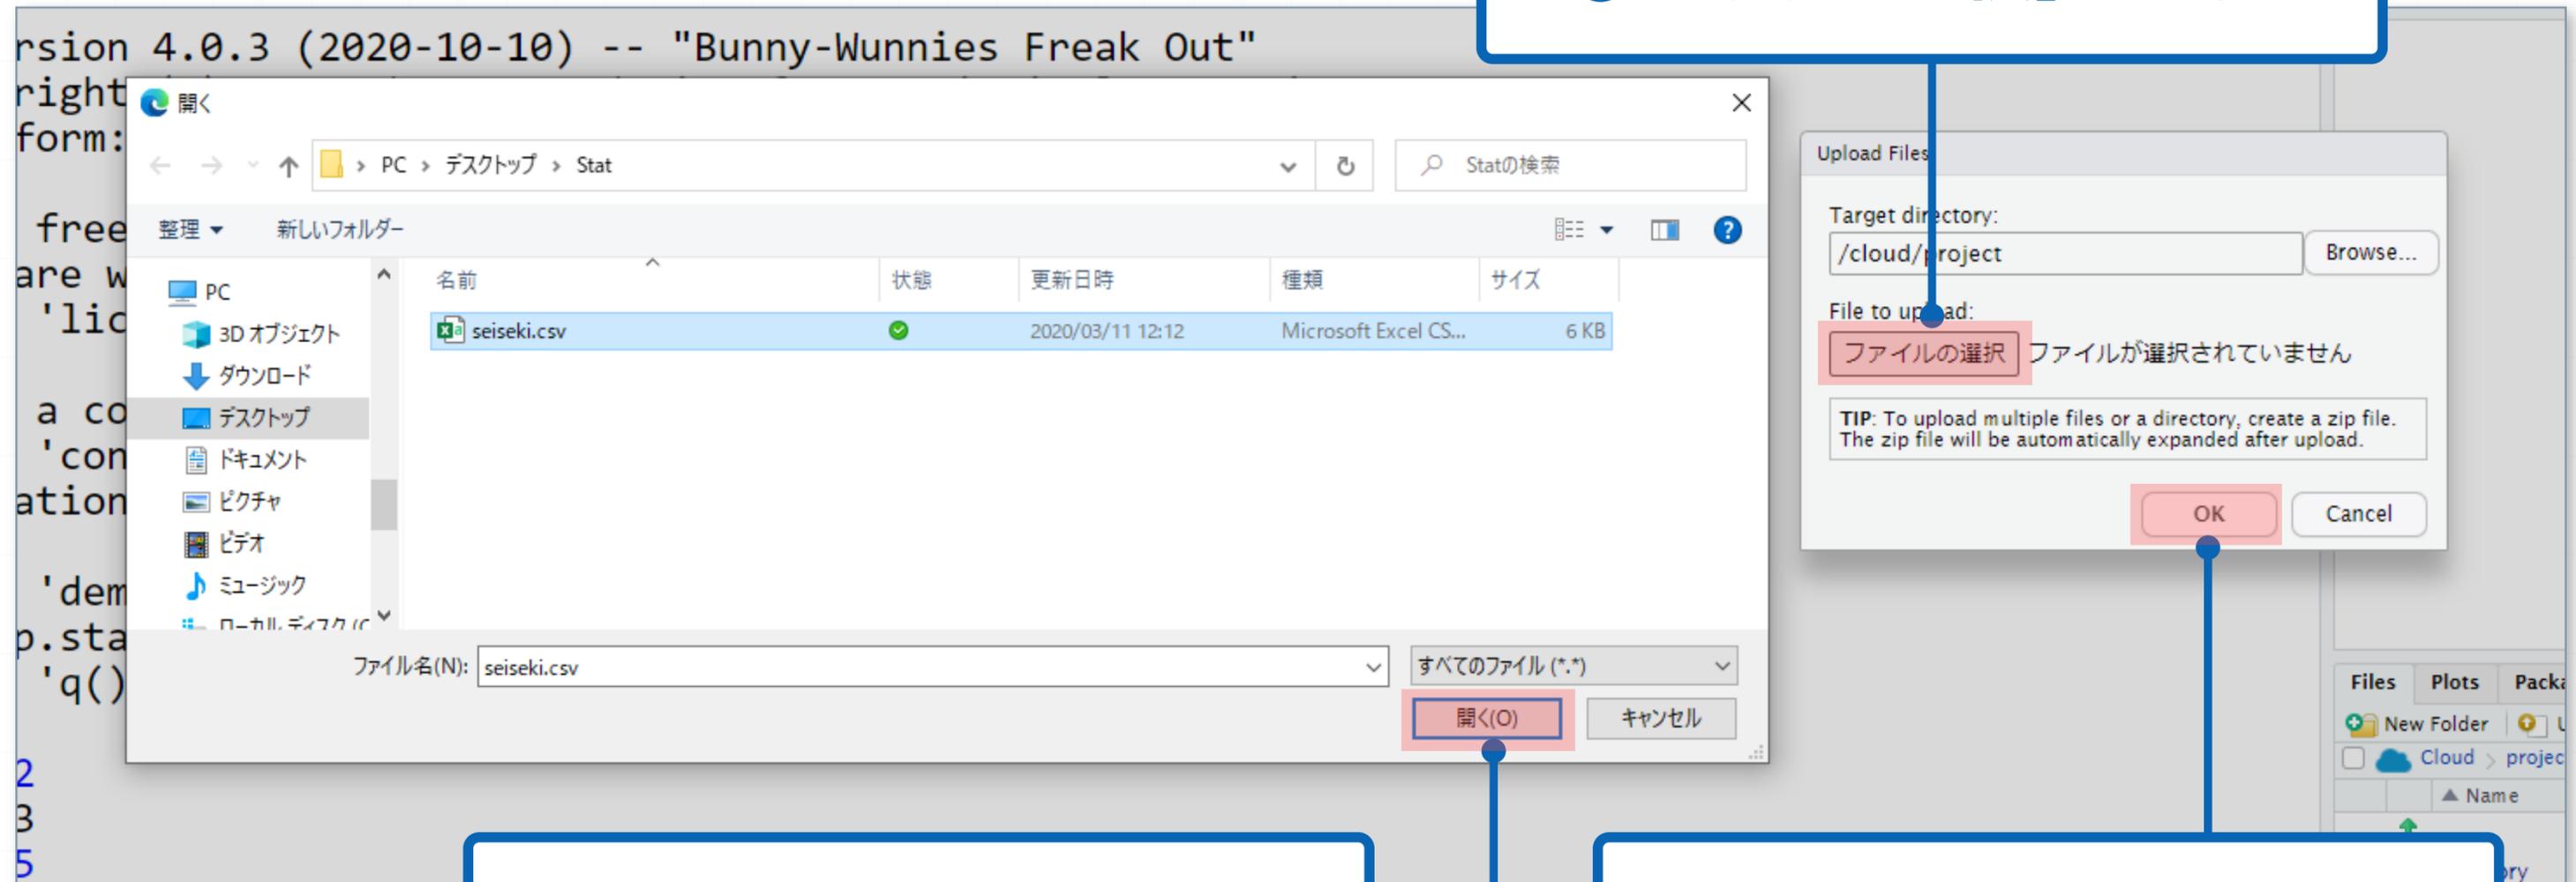


では, 実際に
使うデータはどうやって
読み込むんですか?



RStudio (クラウド版) での下準備

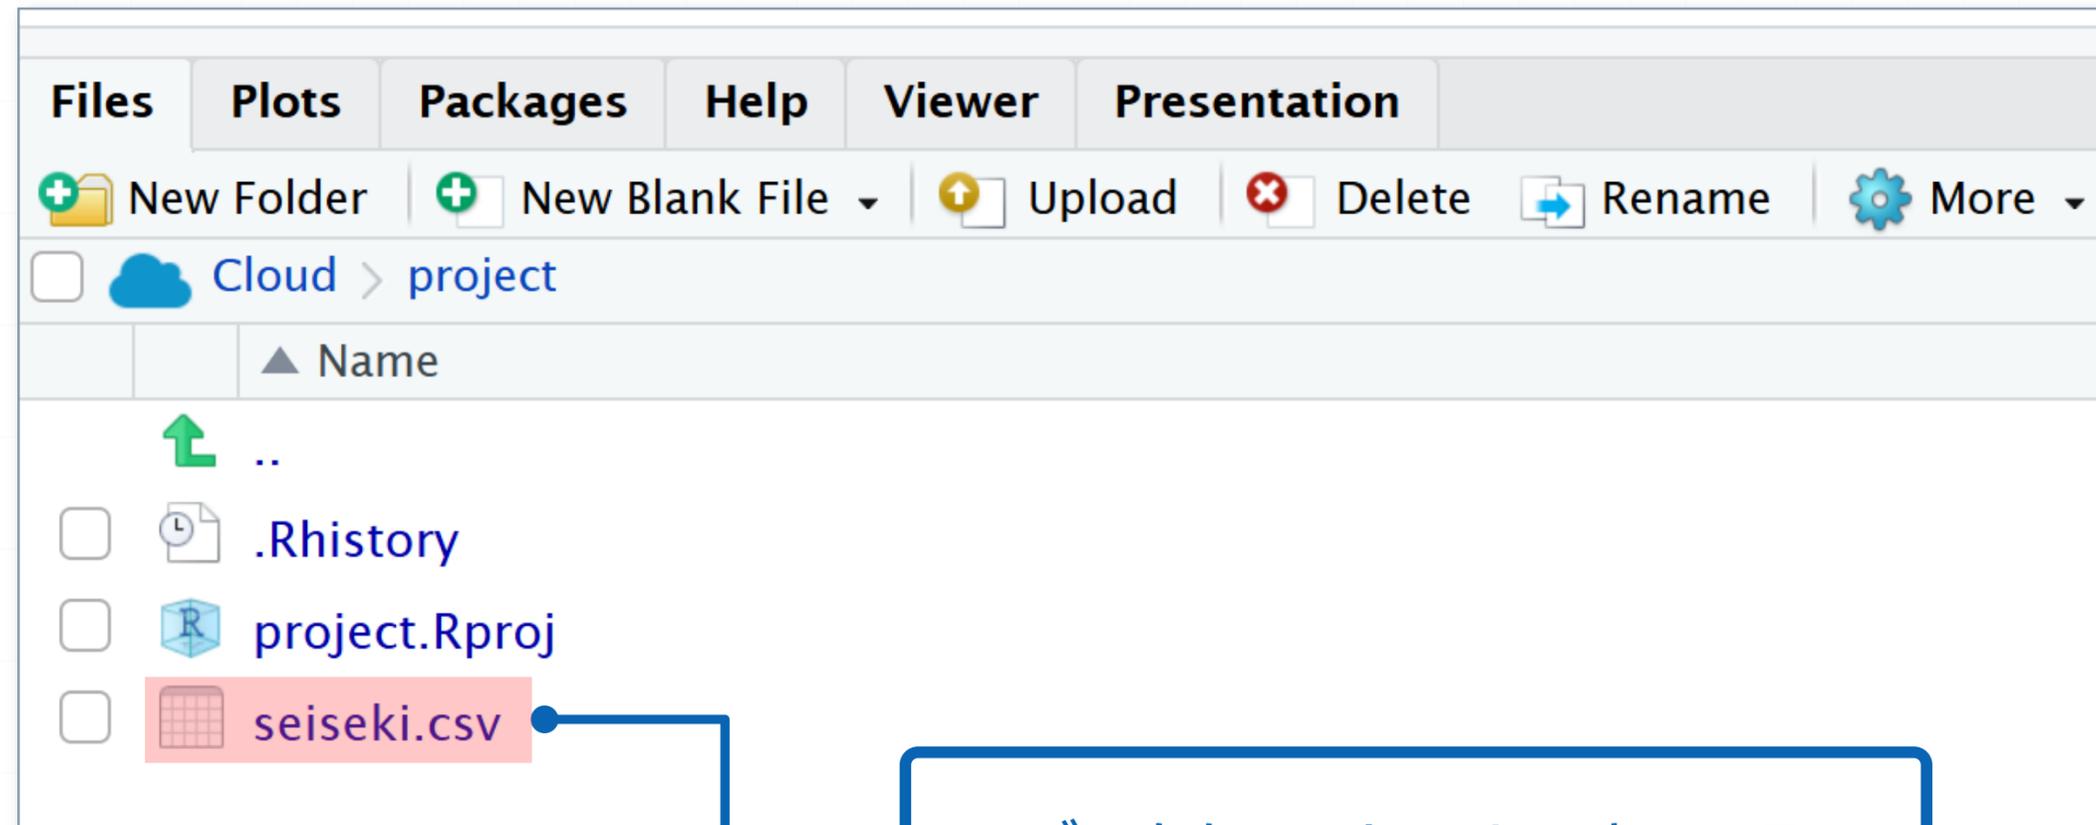
② 「ファイルを選択」をクリック



③ 使いたいデータを選択 ⇒ 開く

④ OK をクリック

RStudio (クラウド版) での下準備



データを Upload できている

ここまでがデータを
読み込むための下準備です



! 一度 Upload したデータはブラウザを閉じても残る
Upload は1回だけでよい

RStudio (インストール版) での下準備

ディレクトリの変更を行う!!

RStudio で**作業する場所 (ディレクトリ)** を指定する

読み込みたいデータが保存されている場所のこと。
デスクトップ上に保存しているならデスクトップを、
あるフォルダに保存しているならそのフォルダを指定する!!

ここからは
インストール版の RStudio
でのやり方の解説です

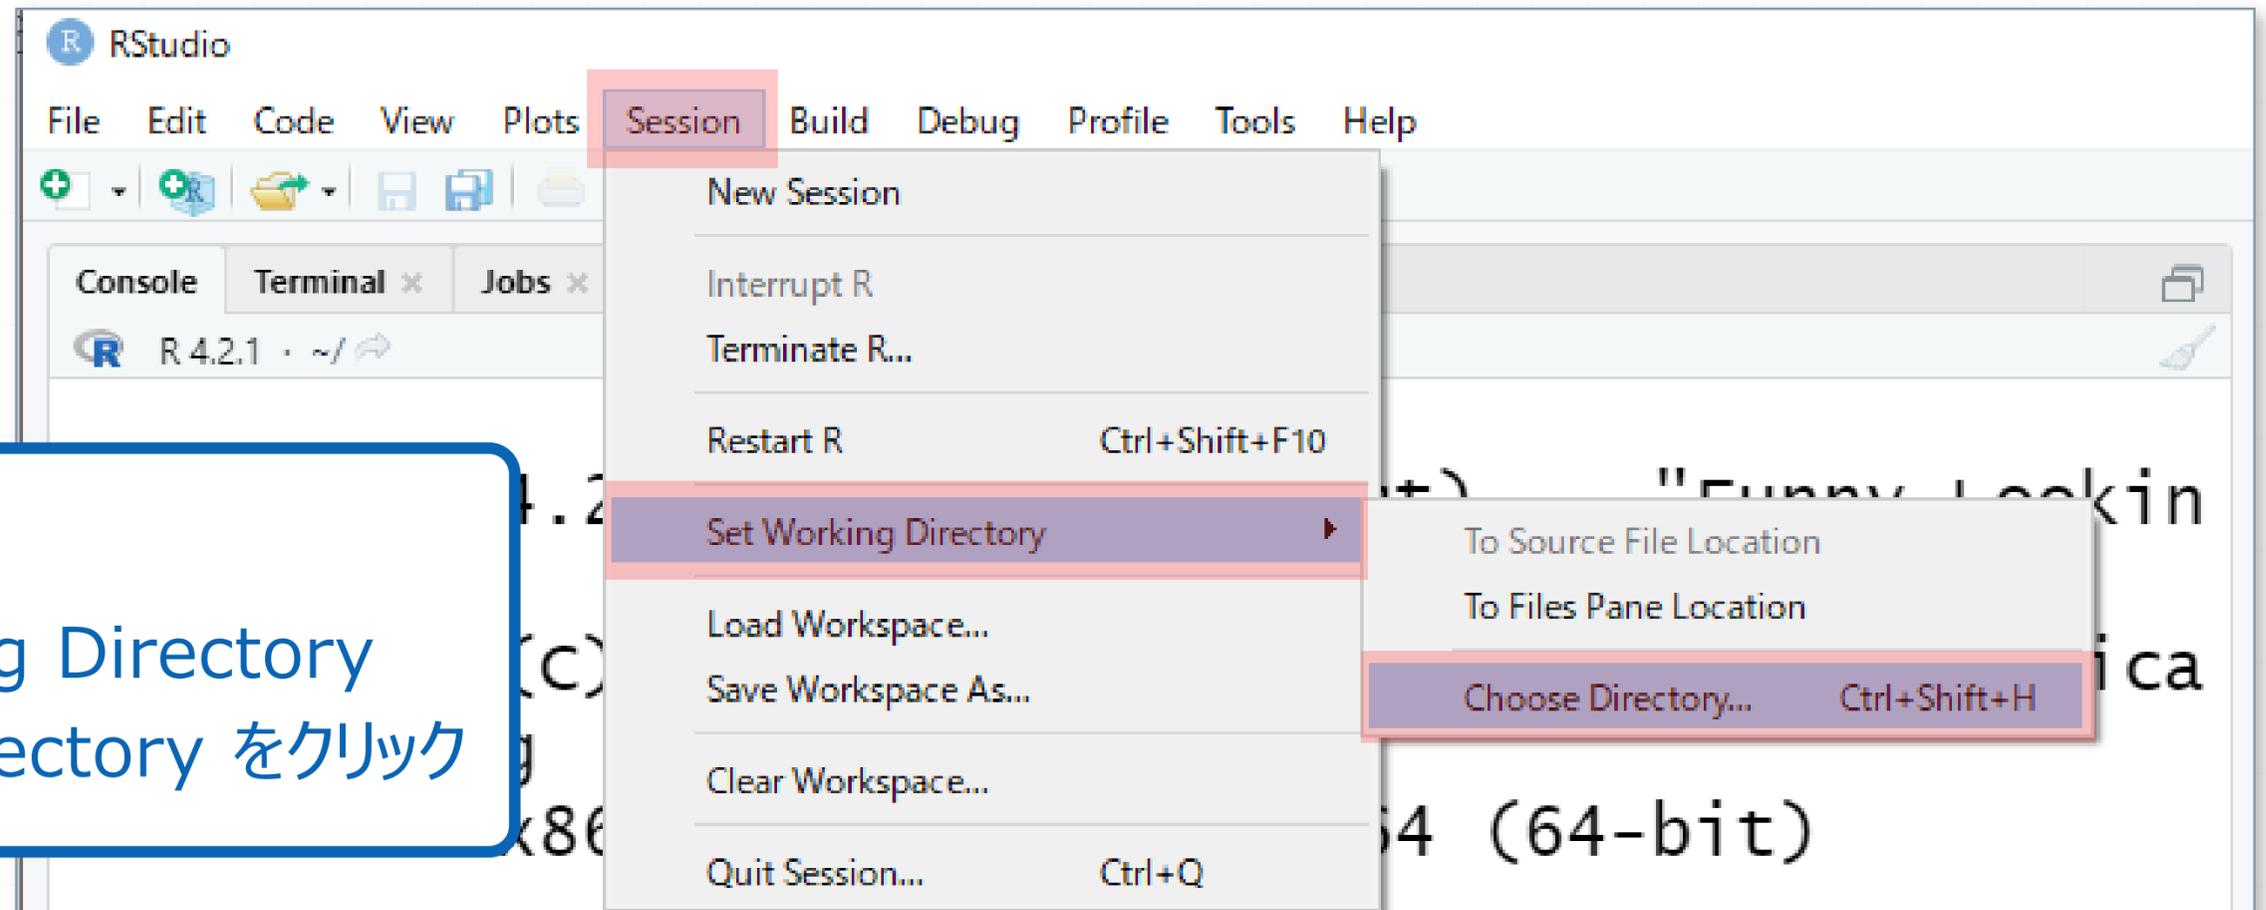


❗ これをしないと、データが読み込めないことが多い

❗ RStudio を起動するたびに指定しないといけない

RStudio (インストール版) での下準備

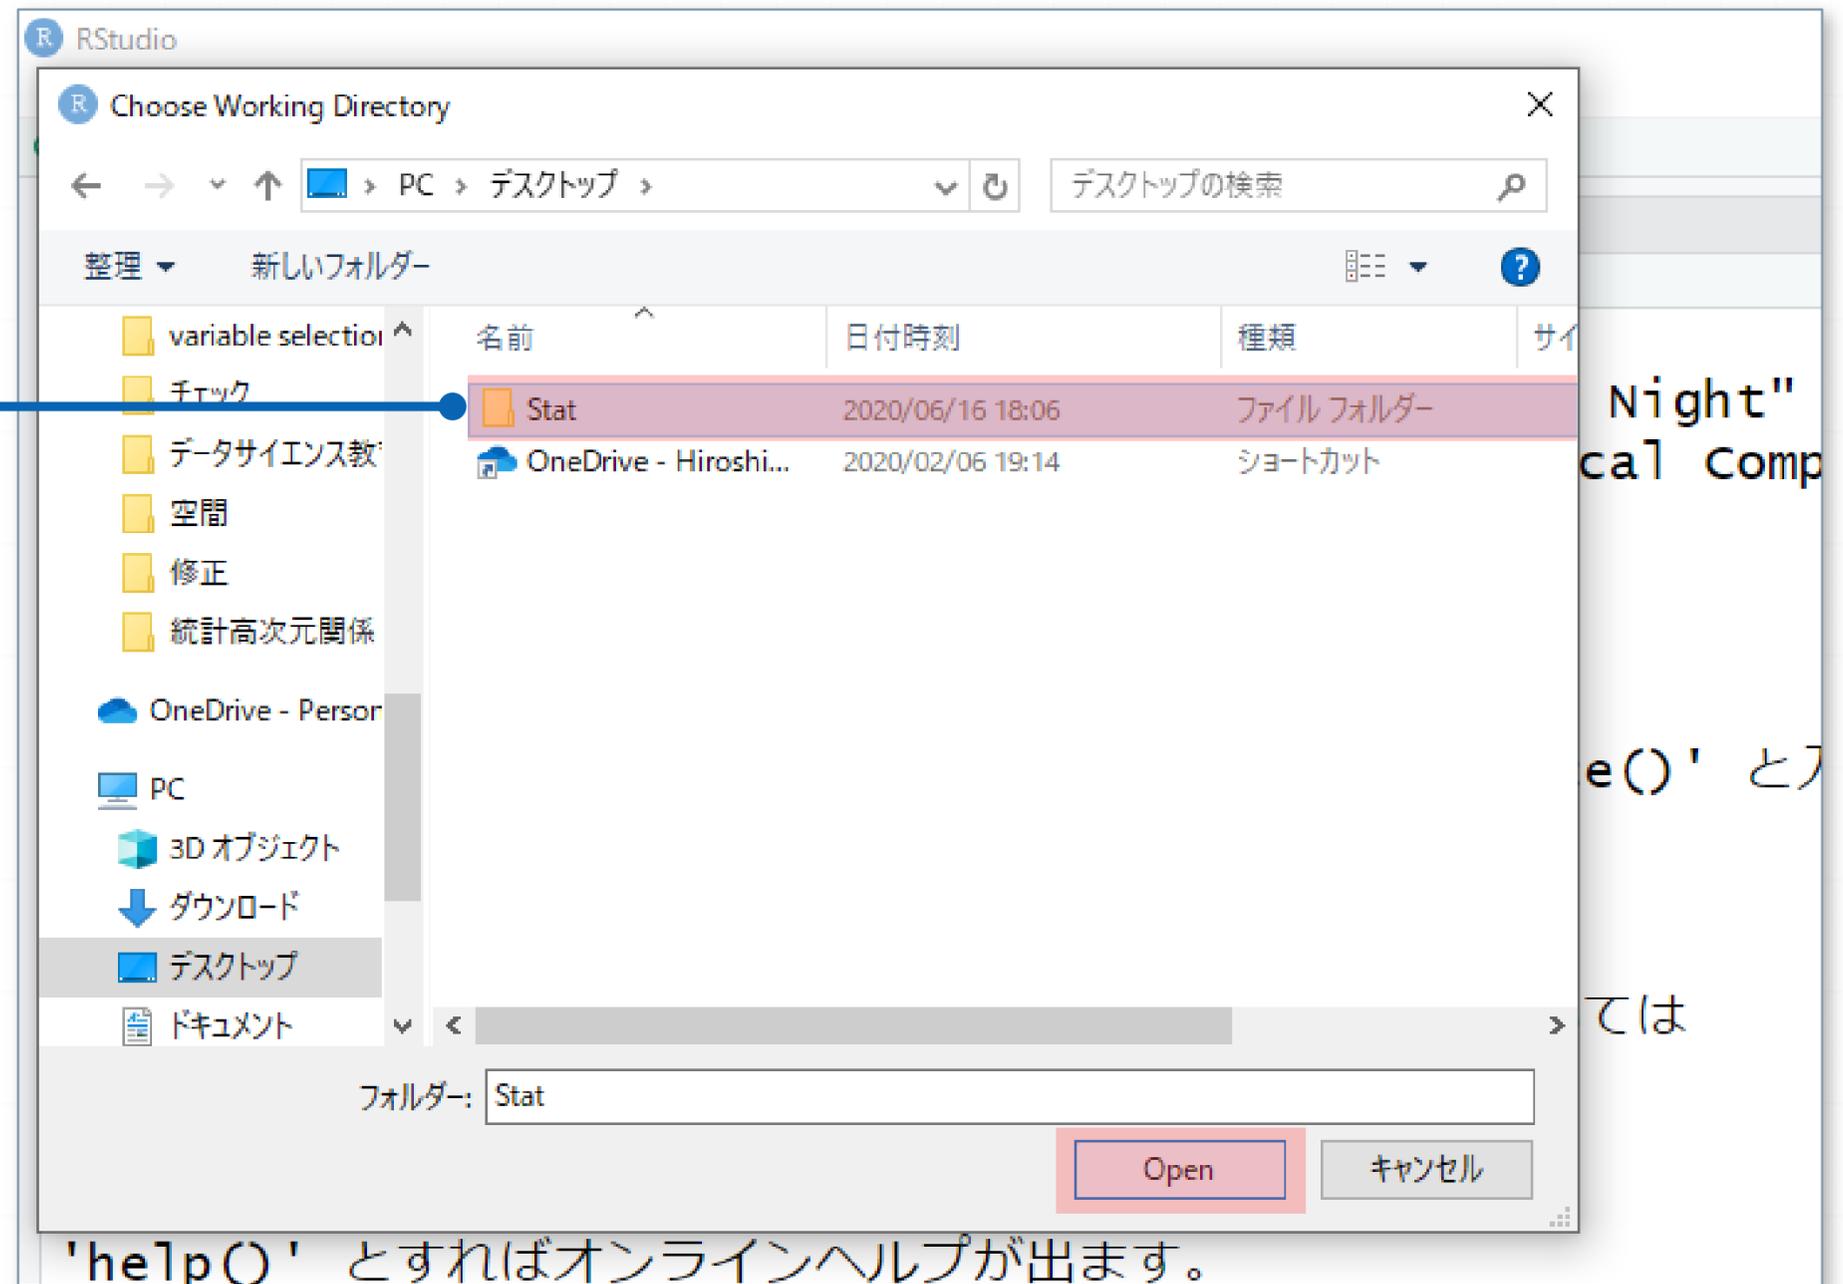
- ① Session
 - ⇒ Set Working Directory
 - ⇒ Choose Directory をクリック



R は、自由なソフトウェアであり、「完全に無保証」です。
一定の条件に従えば、自由にこれを再配布することができます。
配布条件の詳細に関しては、'`license()`' あるいは '`licence()`' と入力してください。

RStudio (インストール版) での下準備

② csvファイルが保存されている
フォルダを指定
⇒ Open



データの読み込みと抽出 要約統計量の計算

データの読み込み

```
# seiseki.csv を読み込んでオブジェクト X に保存する.  
X <- read.csv("seiseki.csv")
```

```
# X の先頭を確認する  
head(X)
```

```
# X の変数名を確認する  
colnames(X)
```

❗ #以降はコマンドとして認識されない

❗ もし、テキストファイルを読み込みたいなら,
`read.table("ファイル名.txt")` とする

それでは
実際に成績データを
読み込んでいきますよ



データの抽出

X 内の指定した変数のデータを抽出する

X\$kokugo

赤字の箇所は変数名をかく. kokugo のデータを取り出す.

X\$shakai # shakai のデータを取り出す.

! 指定する変数名は colnames で確認すること

ここまでは
データの読み込みと
一部のデータを取り出す
方法でしたね



要約統計量の計算

```
# 平均値  
mean (X$kokugo)
```

```
# 中央値  
median (X$kokugo)
```

```
# 最小値, 四分位点 (ヒンジ法), 最大値  
fivenum (X$kokugo)
```

```
# ; を使えば一行でかける  
mean (X$kokugo) ; fivenum (X$kokugo)
```

❗ 矢印キー (↑, ↓) でこれまで入力したコマンドを再利用できる

他にもいろんな
コマンドがあるので、
調べてみるのもいいですね



練習問題 (2)

Q.1 「seiseki.csv」のデータを読み込みオブジェクト X に保存せよ

Q.2 X の変数名を確認し, 数学データを抽出せよ

Q.3 数学データの平均値と中央値はどちらが大きいか

Q.4 国語データの四分位範囲を `fivenum` を利用して計算せよ

解答: 練習問題 (2)

Q.1 「seiseki.csv」のデータを読み込みオブジェクト X に保存せよ

Q.2 X の変数名を確認し, 数学データを抽出せよ

Q.3 数学データの平均値と中央値はどちらが大きいか

Q.4 国語データの四分位範囲を `fivenum` を利用して計算せよ

グラフを描く

※ 以下のようにデータを X に保存しておくこと

```
X <- read.csv("seiseki.csv")
```

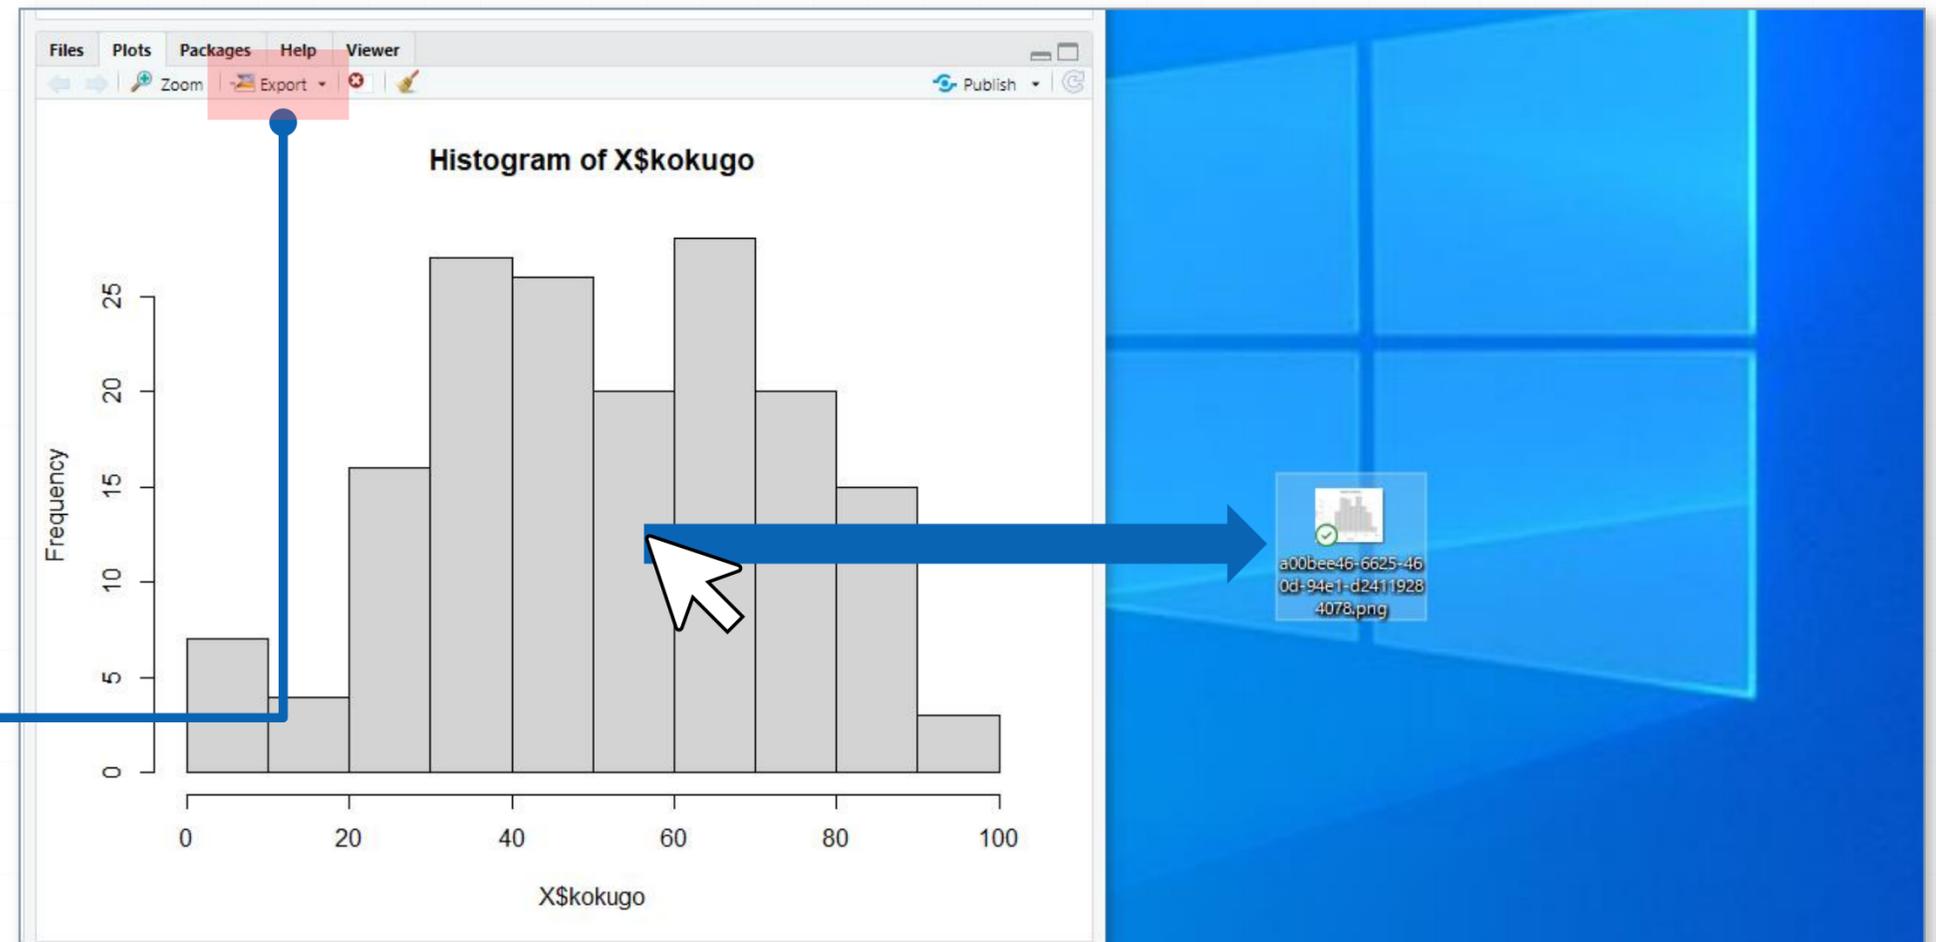
ヒストグラムを描く

ヒストグラムを描く

```
hist(X$kokugo) # 国語データのヒストグラム
```

図をドラッグして
ドラッグ先に保存

「Export」
→ 「Save as Image...」
でも保存は可能



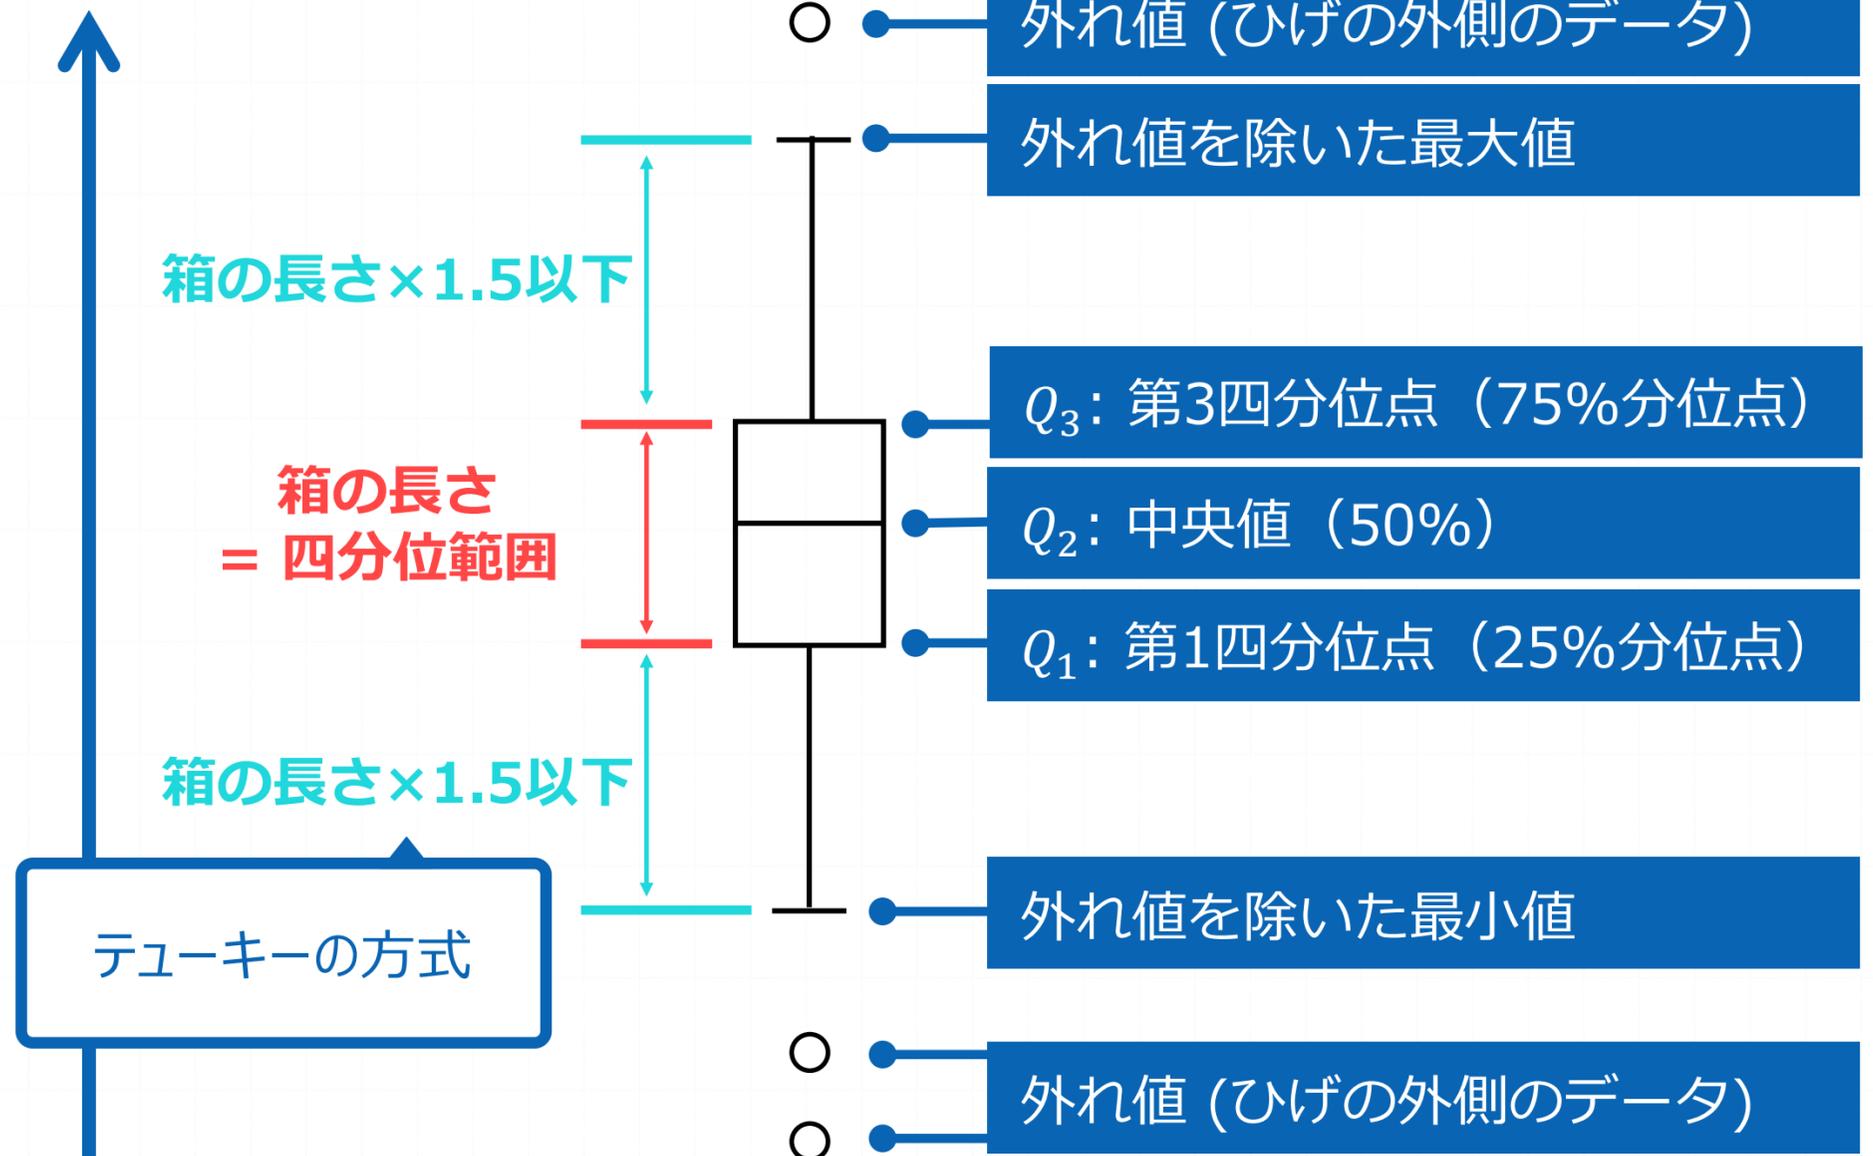
箱ひげ図

✓ 箱ひげ図

データの要点を
簡潔に表したグラフ

箱の長さ
= 散らばり具合

縦軸: データの値



箱ひげ図を描く

```
# 箱ひげ図を描く
```

```
boxplot (X$kokugo)
```

```
# 箱ひげ図を並べて描く
```

```
boxplot (X$kokugo, X$shakai)
```

```
# 左から国語, 社会の順で箱ひげ図が並ぶ
```

```
# 3つ以上も並べて描ける
```

```
boxplot (X$kokugo, X$shakai, X$sugaku)
```

```
# 描いた順と箱ひげ図の並びは同じ
```

実際に箱ひげ図を
かいてみましょう



練習問題 (3)

Q.1 理科データと英語データのヒストグラムをそれぞれ描け

Q.2 左から順に数学, 英語, 技家の箱ひげ図を並べて描き,
3科目のうち最もバラつきが大きそうな科目はどれか?

解答: 練習問題 (3)

Q.1 理科データと英語データのヒストグラムをそれぞれ描け

解答: 練習問題 (3)

Q.2 左から順に数学, 英語, 技家の箱ひげ図を並べて描き, 3科目のうち最もバラつきが大きそうな科目はどれか?

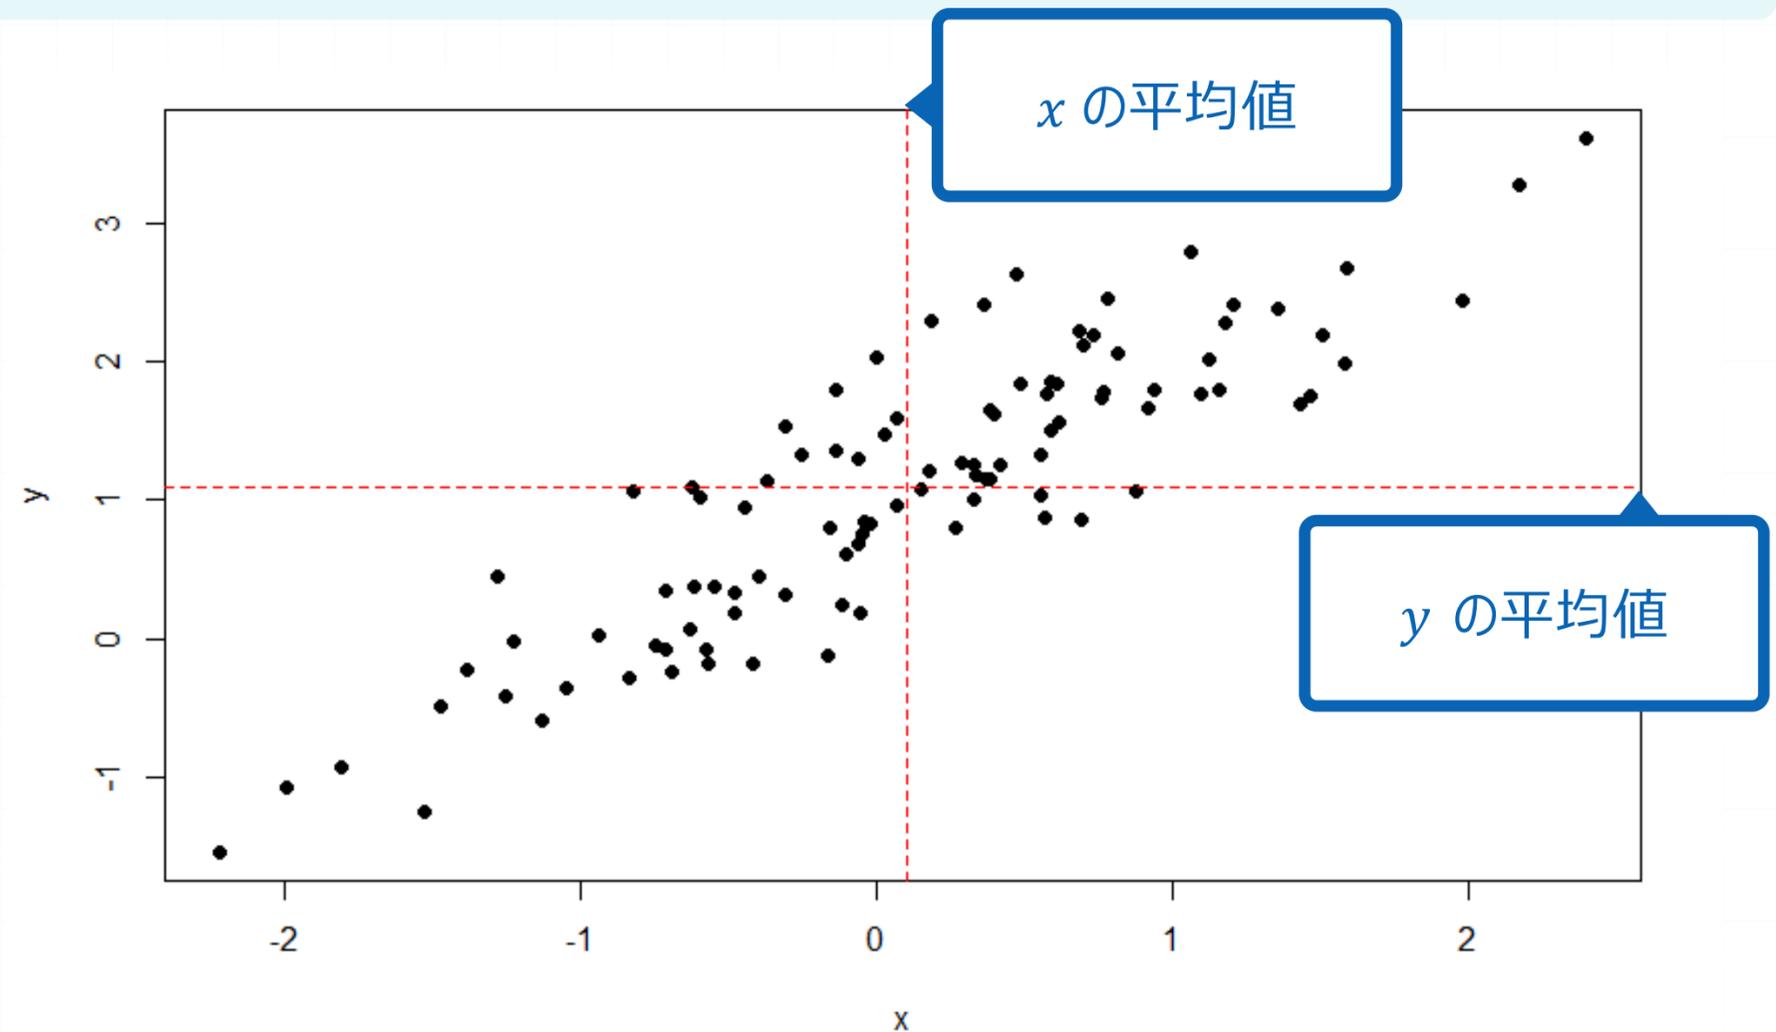
A

散布図

✓ 散布図

2つの変数 (x, y) の関係性を可視化したグラフ

- 1 2つの変数の平均値の直線を引いて4つの区画に分ける
- 2 データ点が**右上, 左下**に多い
→ **右上がりの (直線) 傾向**
右下, 左上に多い
→ **右下がりの (直線) 傾向**

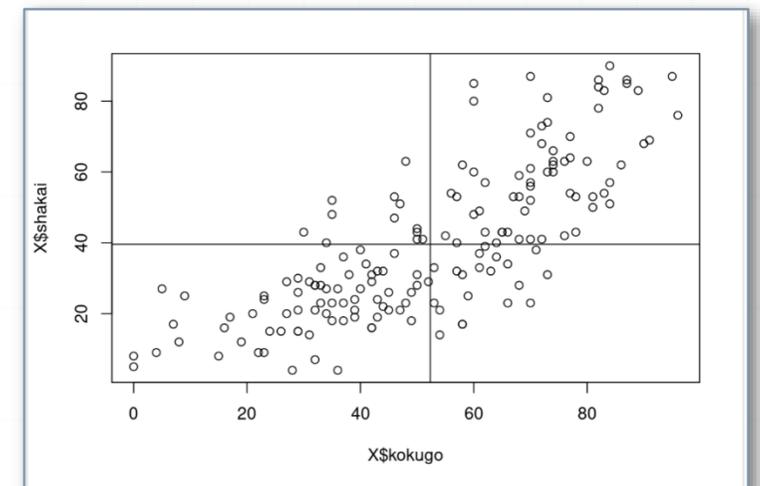


散布図を描く

```
# 国語, 社会データの散布図を描く  
plot(X$kokugo, X$shakai) # 先に書いたほうが横軸。  
つまり国語が横軸, 社会が縦軸となる
```

```
# 散布図を描く  
plot(X$kokugo, X$shakai)  
  
# 散布図に横軸の平均値の直線を追加  
abline(v=mean(X$kokugo)) # v= で横軸に垂直な直線を描く  
  
# 散布図に縦軸の平均値の直線を追加  
abline(h=mean(X$shakai)) # h= で縦軸に垂直な直線を描く
```

❗ abline は必ず plot の後に入力すること



練習問題 (4)



Q.1 以下の2つの散布図を平均値の直線も追加して, それぞれ描け:

横軸が数学, 縦軸が英語の散布図

横軸が数学, 縦軸が体育の散布図

Q.2 1で描いた各散布図から, データの傾向を視覚的に判定せよ.

解答: 練習問題 (4)

横軸が数学, 縦軸が英語の散布図

A

解答: 練習問題 (4)

横軸が数学, 縦軸が体育の散布図

A

補足: オプション (マーカー, 色変更)

```
# 散布図のマーカーを変更
plot(X$sugaku, X$taiiku,
     pch=16 # マーカーを黒丸に指定 (デフォルト 1: 白丸)
     )

# 散布図に横軸の平均値の直線を追加
abline(v=mean(X$sugaku),
       col="red", # 直線の色を変更
       lty=2 # 直線を破線にする (デフォルト 1: 実線)
       )

# 散布図に縦軸の平均値の直線を追加
abline(h=mean(X$taiiku), # h= で縦軸に垂直な直線を描く
       col="red",
       lty=2
       )
```

今までの図だと
少し見づらいですね…
見栄えを良くしましょう



今日のまとめ

- ▶ **RStudio の使い方**
- ▶ **データの読み込み, 抽出, 要約統計量の計算**
- ▶ **グラフ (ヒストグラム, 箱ひげ図, 散布図) の描き方**
 - ヒストグラム: `hist`
 - 箱ひげ図: `boxplot`
 - 散布図: `plot`

※ オプション追加で色や線の太さなど変更可能
ネットで検索すれば, いろいろ出てきます

実践的になってきましたね!
次回も頑張りましょう

