KUDH Basics

第2回 統計ソフトウェア『R』ワークショップ

①R/RStudioの使い方

藤本花音（京都大学）

2023.03.22.

トラブルがあれば質問してください

❑トラブルを受講者で共有し，解決しながらすすめましょう

●授業中，Rに関するトラブルがあれば遠慮なく教えてください
- 口頭での質問，zoomやSlackのチャット機能などでご連絡ください
- Slackの方が丁寧なサポートが可能です

●みんなでトラブルとその解決方法を共有しましょう
- オンサイトの方もオンラインの方も，ご自身のトラブルをzoomで画面共有してください
- 授業の一環として，トラブルの解決に努めます
- 深刻なトラブルな場合は，メイン講師の授業と同時並行して，
  サブ講師がトラブル解決に努めます

●もちろん，授業後や休憩時間に質問いただけてもOKです

はじめに

複雑すぎる世界を理解し，活動していくために

❑対象から情報（データ）を取得して，分析していくことが重要

現象が生じる「世界」

- 生物現象
- 物理現象
- 社会現象
- 顧客の行動

など

観測
データ収集

世界に関する
推測

データ

1001010
01 1001010
00 01 1001010
00 00 0100110
11 00 0000100
11 0000001
1101111

研究をするうえで欠かせない「データ」

❑データを用いてできること

●データ分析のモチベーション

- 目の前の現象を把握したい
- 現象の背後にあるメカニズムを解釈したい
- データから未来のことを予測したい
- データに基づいて意思決定や問題解決を行いたい

●必要なスキル・知識

- データの要約
- データの可視化
- 数理モデルの活用
- 統計学・機械学習の知識
- 扱おうとする現象についてのドメイン知識

統計ソフトウェア「R」

❑Rとは？

- ●フリーの統計ソフトウェア
- ●「R言語」とも呼ばれる
- ●The R Foundation for Statistical Computation (Vienna, Austria)が開発
- ●幅広い統計解析手法をカバー
- ●「パッケージ」による拡張

RStudioでRをもっと便利に扱う

❑RStudio

・Rのための統合開発環境

　－生のR＋いろいろ便利機能

RStudioの使い方

RStudioを起動する

❑**R/Rstudioをインストール済みの前提で進めます**

- ●未インストールの人は過去動画を参考にインストールしてください
- ●https://www.youtube.com/watch?v=NMmD_3QvFsY

❑『RStudio』を起動してください **(『R』ではなく『RStudio』)**

RStudioの起動画面

R

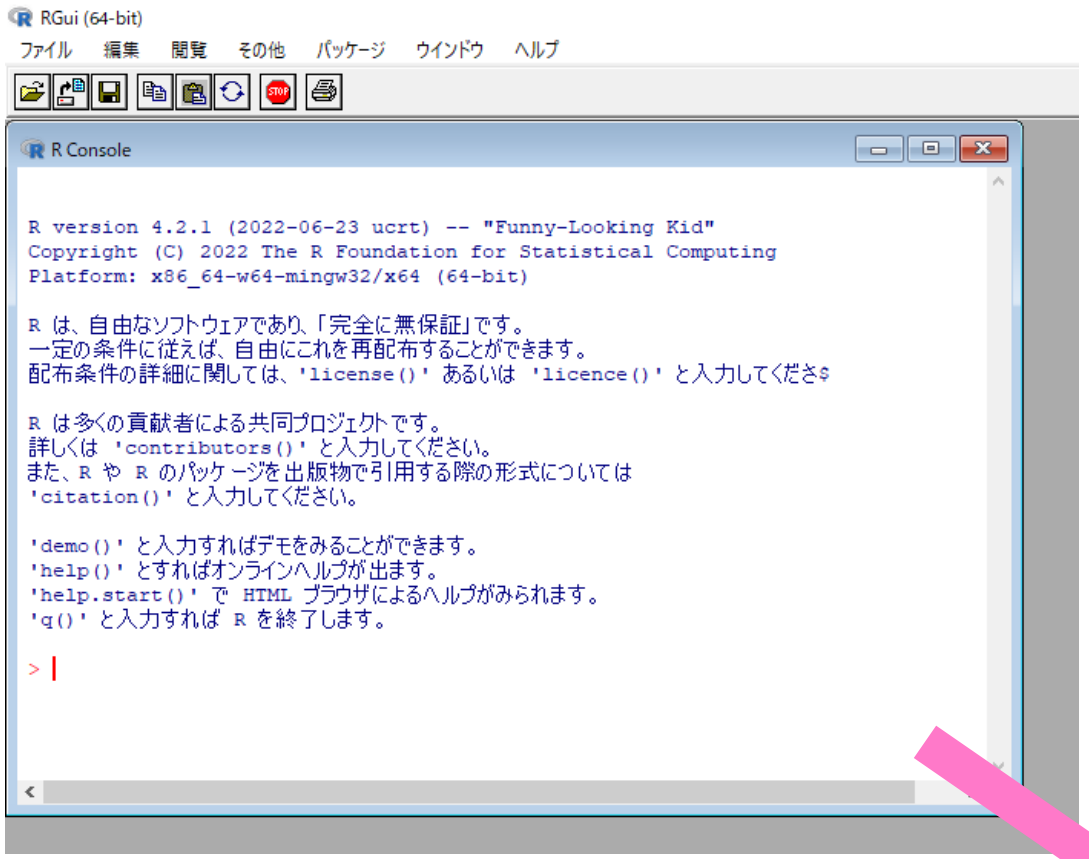

RStudio

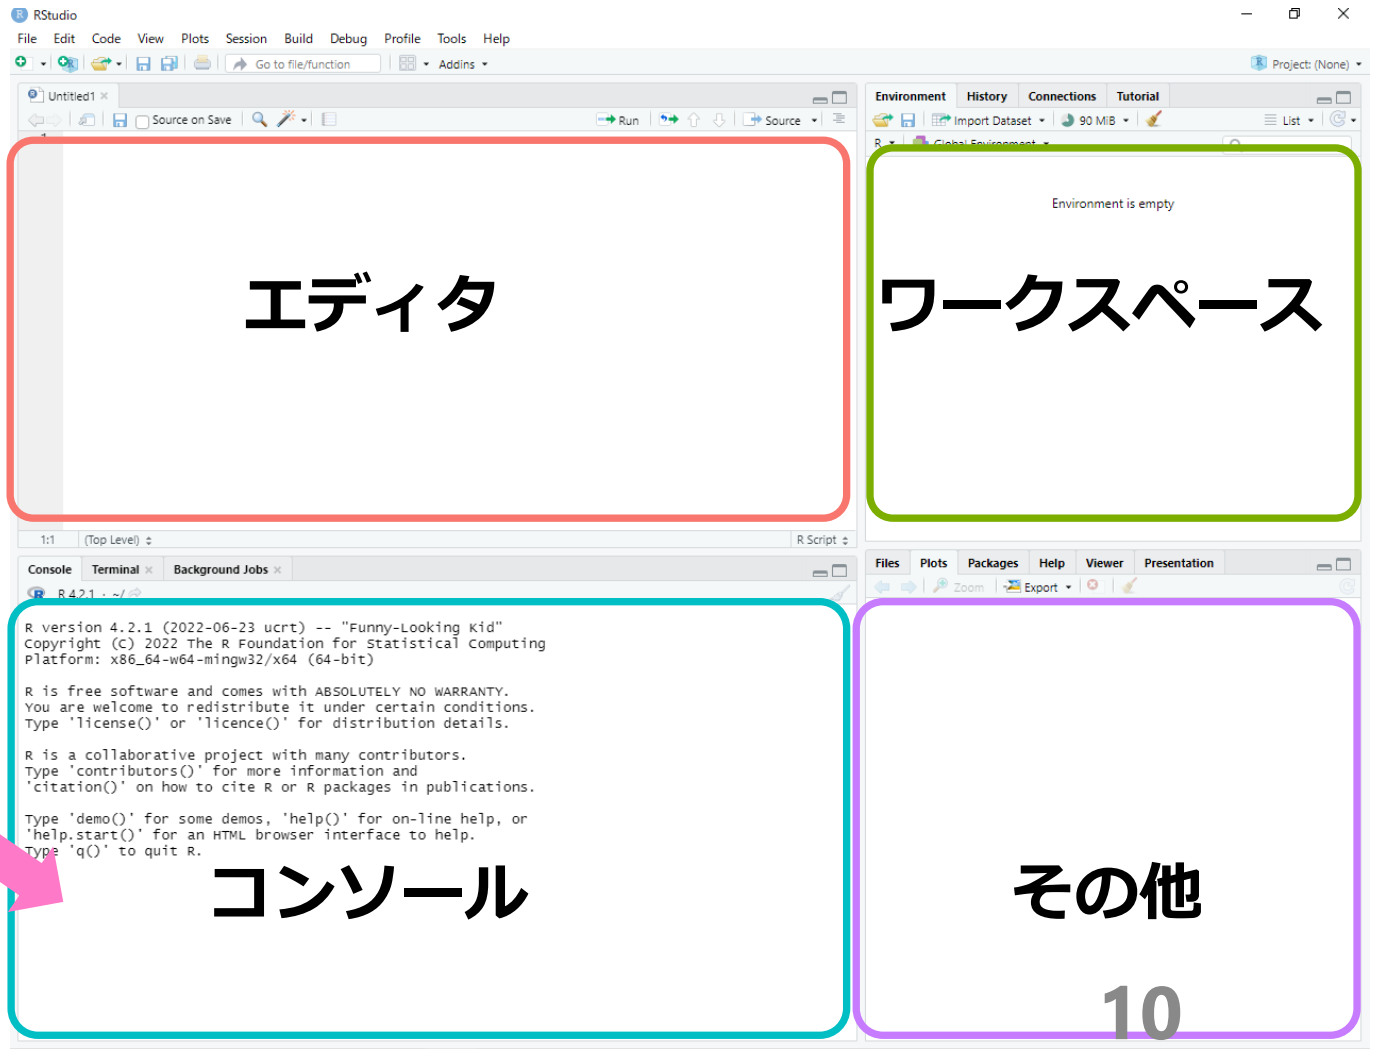

R Markdownを使ってコマンドを打ってみよう

❑画面左上の「+」ボタンから「R Markdown...」をクリック

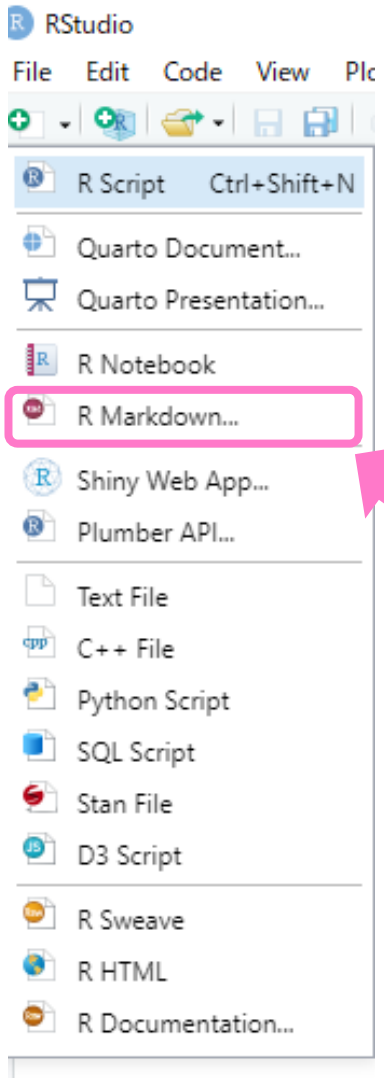

クリック

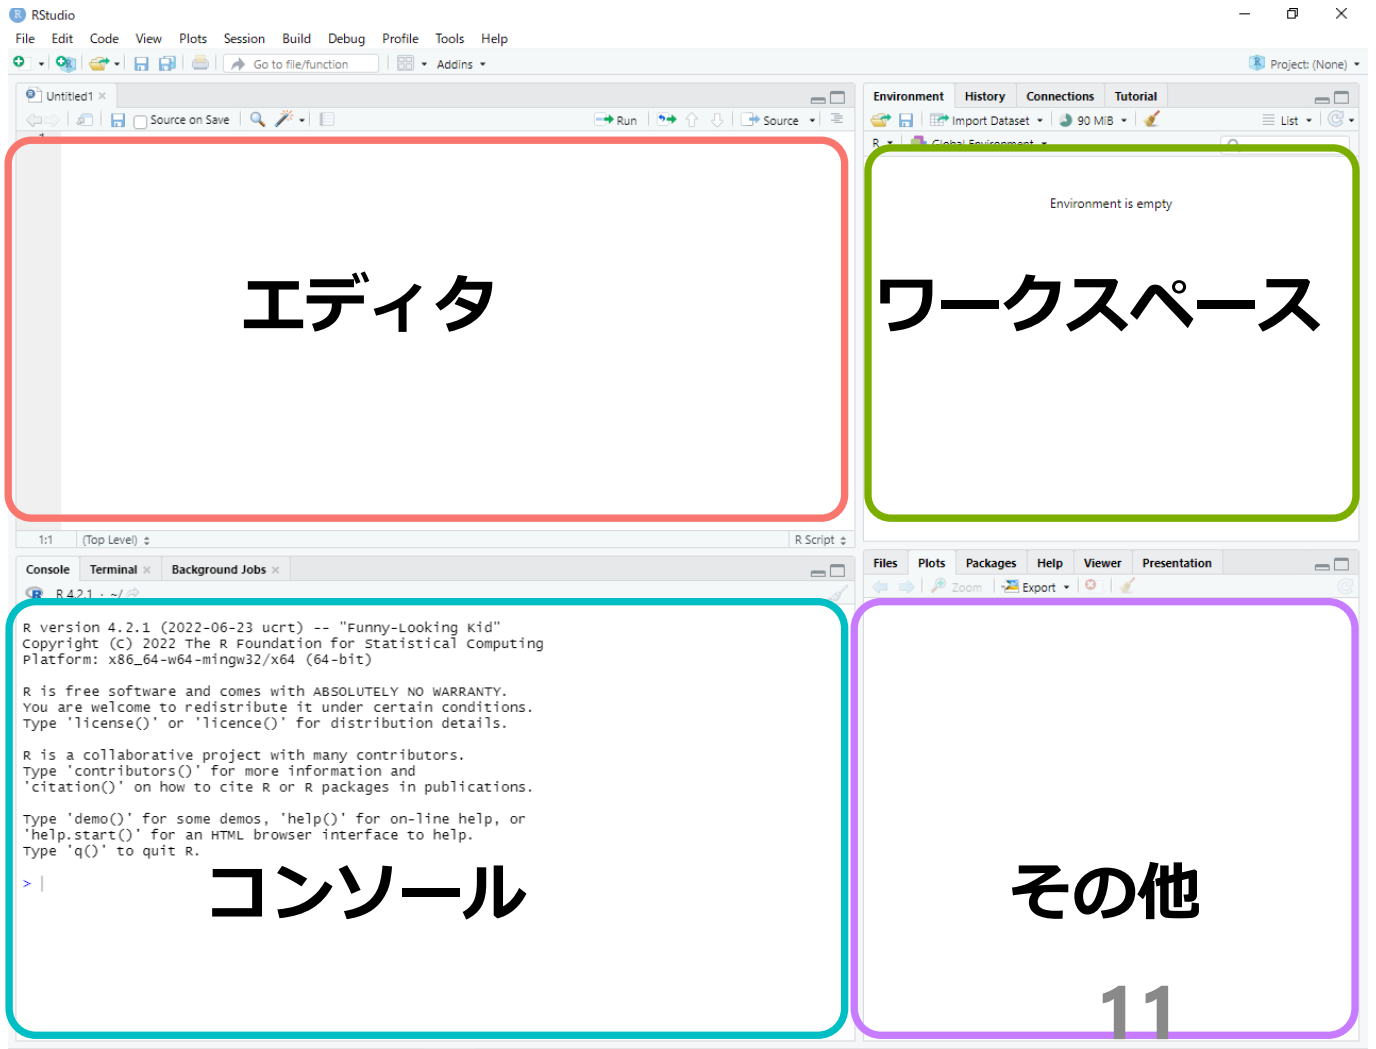

New R Markdownというウィンドウがでる

❑タイトルや著者欄など基礎情報を記入できる

・Title ： 「いまから行う分析の名称」
　－”Workshop1”としておきましょう。

・Author： 「分析者の名前」
　－ご自身の名前を入力ください。

・Default Output FormatではHTMLを選択

・「OK」をクリック

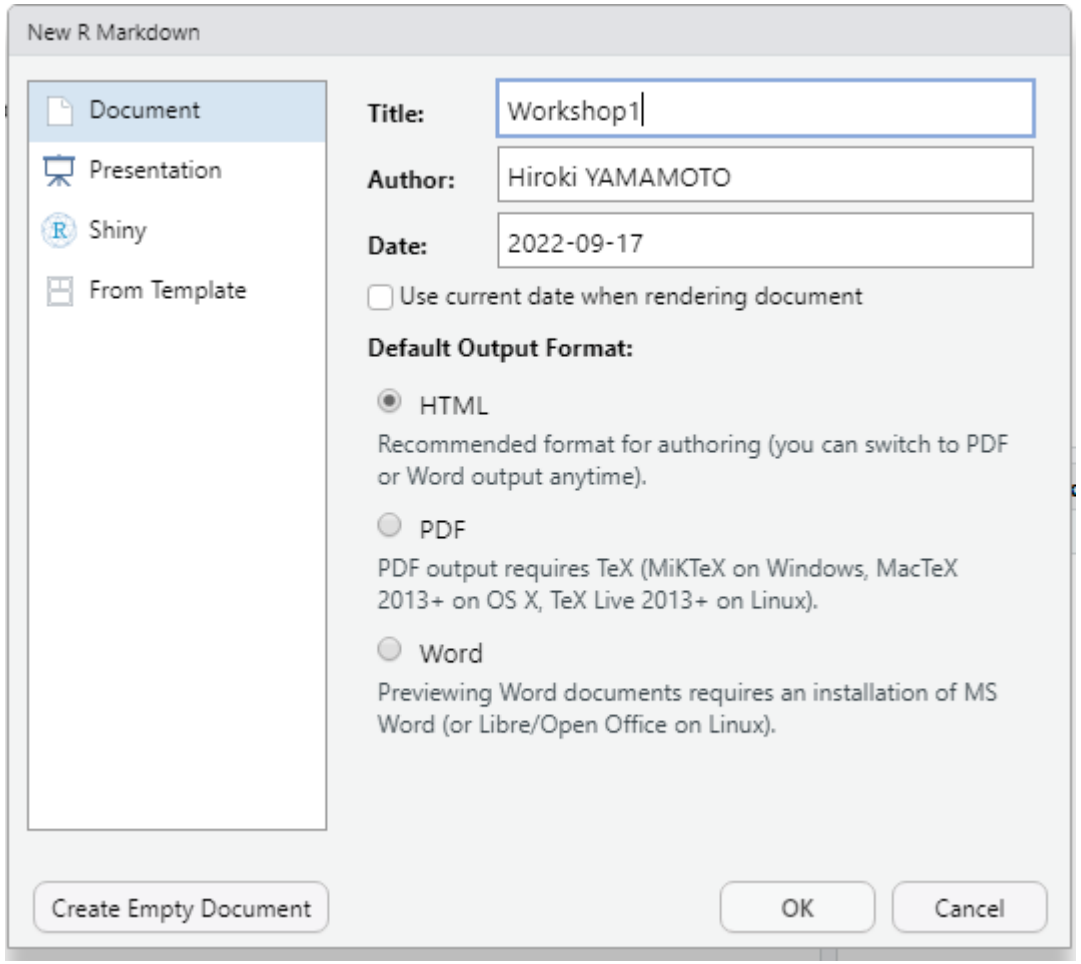

こんな画面が自動生成されます

Untitled1

Knit ▾ | Insert ▾ | Run ▾

```
1  ---
2  title: "Workshop1"
3  author: "Hiroki YAMAMOTO"
4  date: "2022-09-17"
5  output: html_document
6  ---
7
8  ```{r setup, include=FALSE}
9  knitr::opts_chunk$set(echo = TRUE)
10 ```
11
12 ## R Markdown
13
14 This is an R Markdown document. Markdown is a simple formatting syntax for authoring HTML, PDF, and MS Word documents.
   For more details on using R Markdown see <http://rmarkdown.rstudio.com>.
15
16 When you click the **Knit** button a document will be generated that includes both content as well as the output of
   any embedded R code chunks within the document. You can embed an R code chunk like this:
17
18 ```{r cars}
19 summary(cars)
20 ```
21
22 ## Including Plots
23
24 You can also embed plots, for example:
25
26 ```{r pressure, echo=FALSE}
27 plot(pressure)
28 ```
29
30 Note that the `echo = FALSE` parameter was added to the code chunk to prevent printing of the R code that generated
   the plot.
31
```

灰色の領域はコードチャンクと呼ばれます

Untitled1

Knit ▾ | Insert ▾ | Run ▾

```
1  ---
2  title: "Workshop1"
3  author: "Hiroki YAMAMOTO"
4  date: "2022-09-17"
5  output: html_document
6  ---
7
8  ```{r setup, include=FALSE}
9  knitr::opts_chunk$set(echo = TRUE)
10 ```
11
12 ## R Markdown
13
14 This is an R Markdown document. Markdown is a simple formatting syntax for authoring HTML, PDF, and MS Word documents.
   For more details on using R Markdown see <http://rmarkdown.rstudio.com>.
15
16 When you click the **Knit** button a document will be generated that includes both content as well as the output of
   any embedded R code chunks within the document. You can embed an R code chunk like this:
17
18 ```{r cars}
19 summary(cars)
20 ```
21
22 ## Including Plots
23
24 You can also embed plots, for example:
25
26 ```{r pressure, echo=FALSE}
27 plot(pressure)
28 ```
29
30 Note that the `echo = FALSE` parameter was added to the code chunk to prevent printing of the R code that generated
   the plot.
31
```

コードチャンク

コードチャンク

コードチャンク

先頭6行はyamlヘッダと呼ばれます

Untitled1

Knit ▾ | Insert ▾ | Run ▾

```
1  ---
2  title: "Workshop1"
3  author: "Hiroki YAMAMOTO"
4  date: "2022-09-17"
5  output: html_document
6  ---
7
8  ```{r setup, include=FALSE}
9  knitr::opts_chunk$set(echo = TRUE)
10 ```
11
12 ## R Markdown
13
14 This is an R Markdown document. Markdown is a simple formatting syntax for authoring HTML, PDF, and MS Word documents.
   For more details on using R Markdown see <http://rmarkdown.rstudio.com>.
15
16 When you click the **Knit** button a document will be generated that includes both content as well as the output of
   any embedded R code chunks within the document. You can embed an R code chunk like this:
17
18 ```{r cars}
19 summary(cars)
20 ```
21
22 ## Including Plots
23
24 You can also embed plots, for example:
25
26 ```{r pressure, echo=FALSE}
27 plot(pressure)
28 ```
29
30 Note that the `echo = FALSE` parameter was added to the code chunk to prevent printing of the R code that generated
   the plot.
31
```

yamlヘッダ

コードチャンク

コードチャンク

コードチャンク

コードチャンクの間はドキュメントチャンク

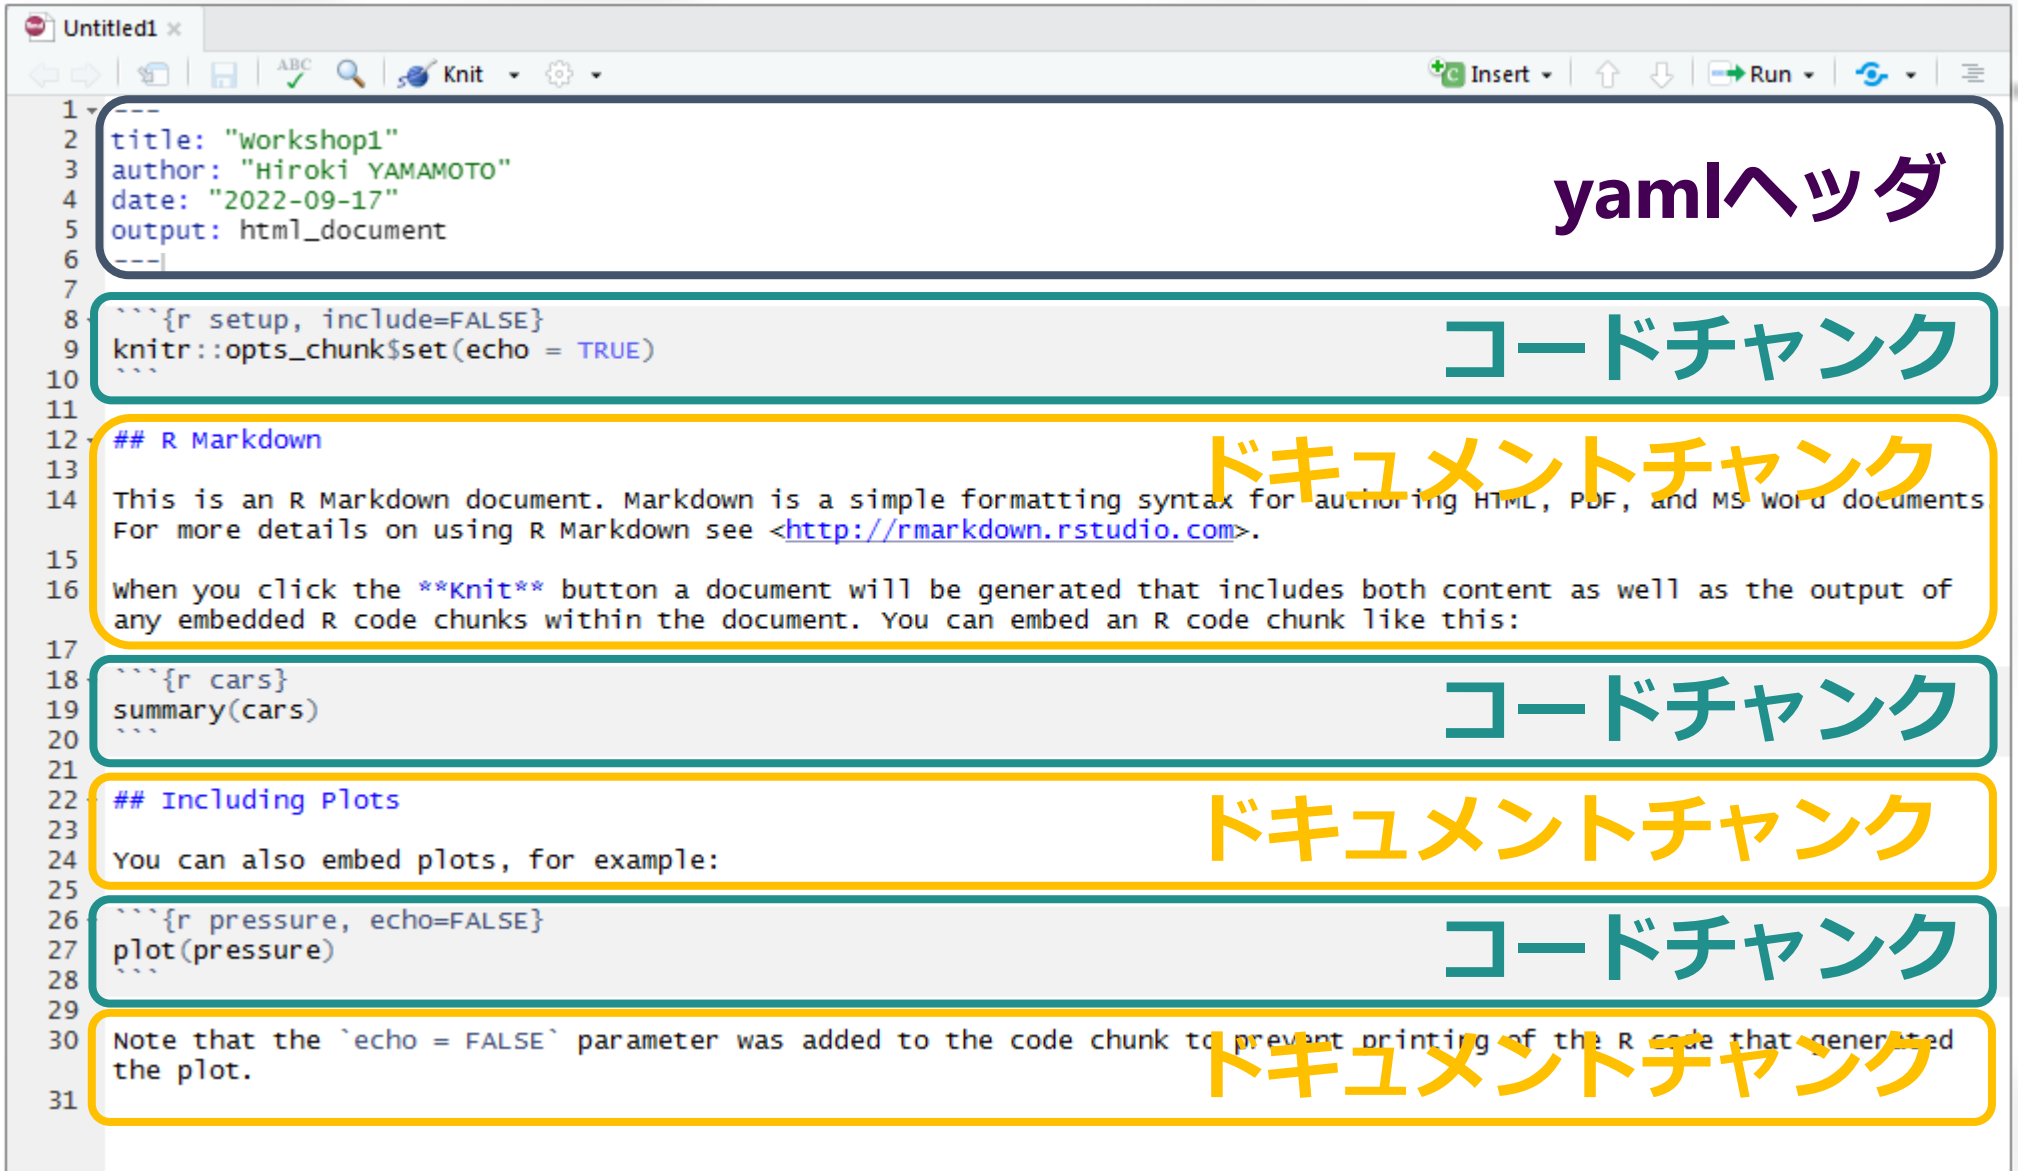


```
---
title: "Workshop1"
author: "Hiroki YAMAMOTO"
date: "2022-09-17"
output: html_document
---

```{r setup, include=FALSE}
knitr::opts_chunk$set(echo = TRUE)
```

R Markdown

This is an R Markdown document. Markdown is a simple formatting syntax for authoring HTML, PDF, and MS Word documents. For more details on using R Markdown see <http://rmarkdown.rstudio.com>.

When you click the **Knit** button a document will be generated that includes both content as well as the output of any embedded R code chunks within the document. You can embed an R code chunk like this:

```{r cars}
summary(cars)
```

Including Plots

You can also embed plots, for example:

```{r pressure, echo=FALSE}
plot(pressure)
```

Note that the `echo = FALSE` parameter was added to the code chunk to prevent printing of the R code that generated the plot.
```

Rmarkdownを使ってコードをうってみよう

❑コードチャンクとyamlヘッダ

- **コードチャンク**
  - **Rへのコマンドを書く箇所**
  - 「```{r} 」から「```」まで
  - 「 `」が3つ並んでないと機能しないので注意

- **yamlヘッダ**
  - 「 --- 」から「 --- 」まで
  - 全体的な設定などを扱う箇所
  - この授業ではいじりません

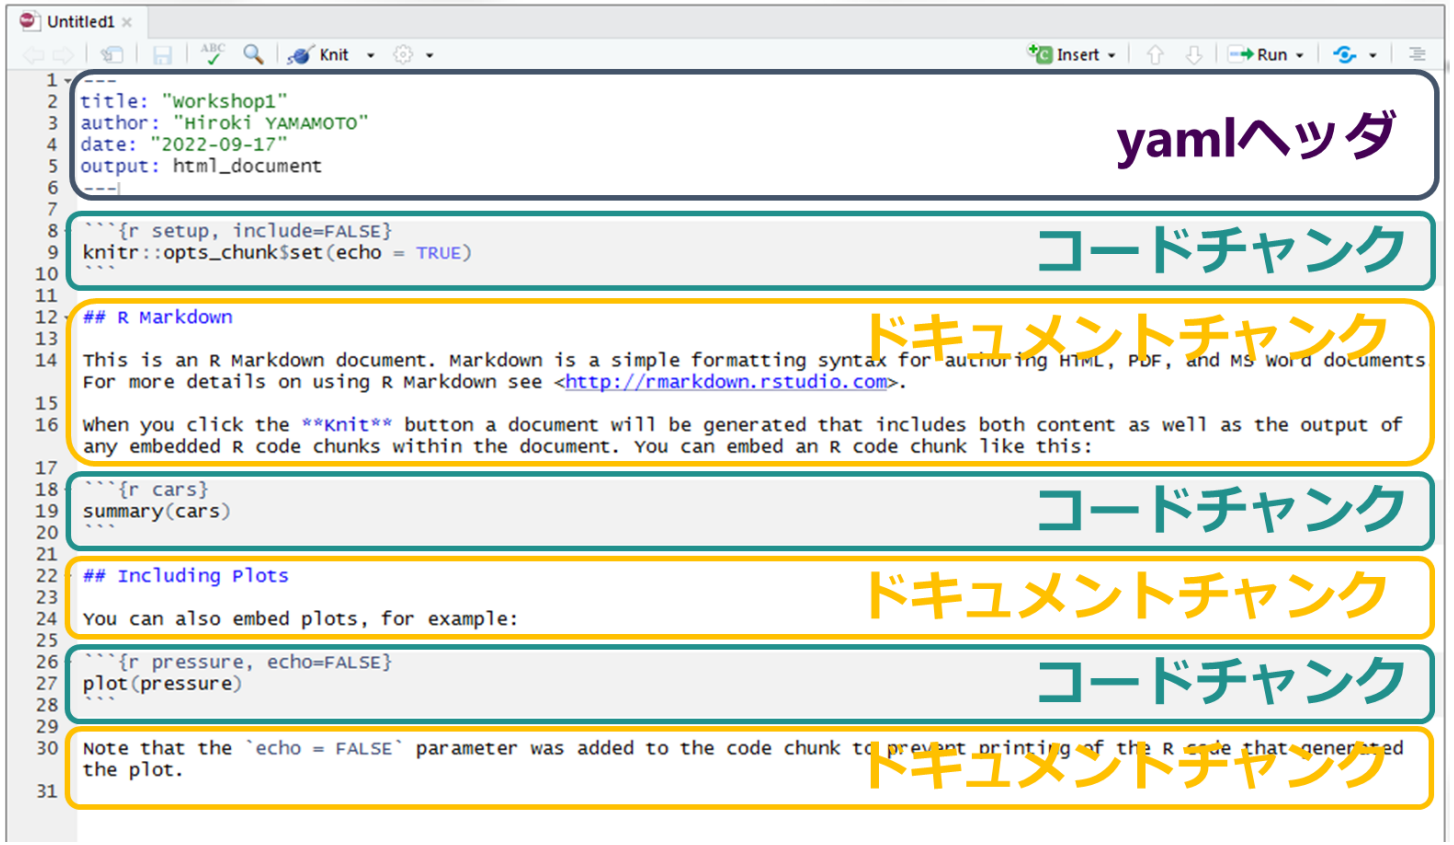

yamlヘッダより下の部分をDeleteしましょう

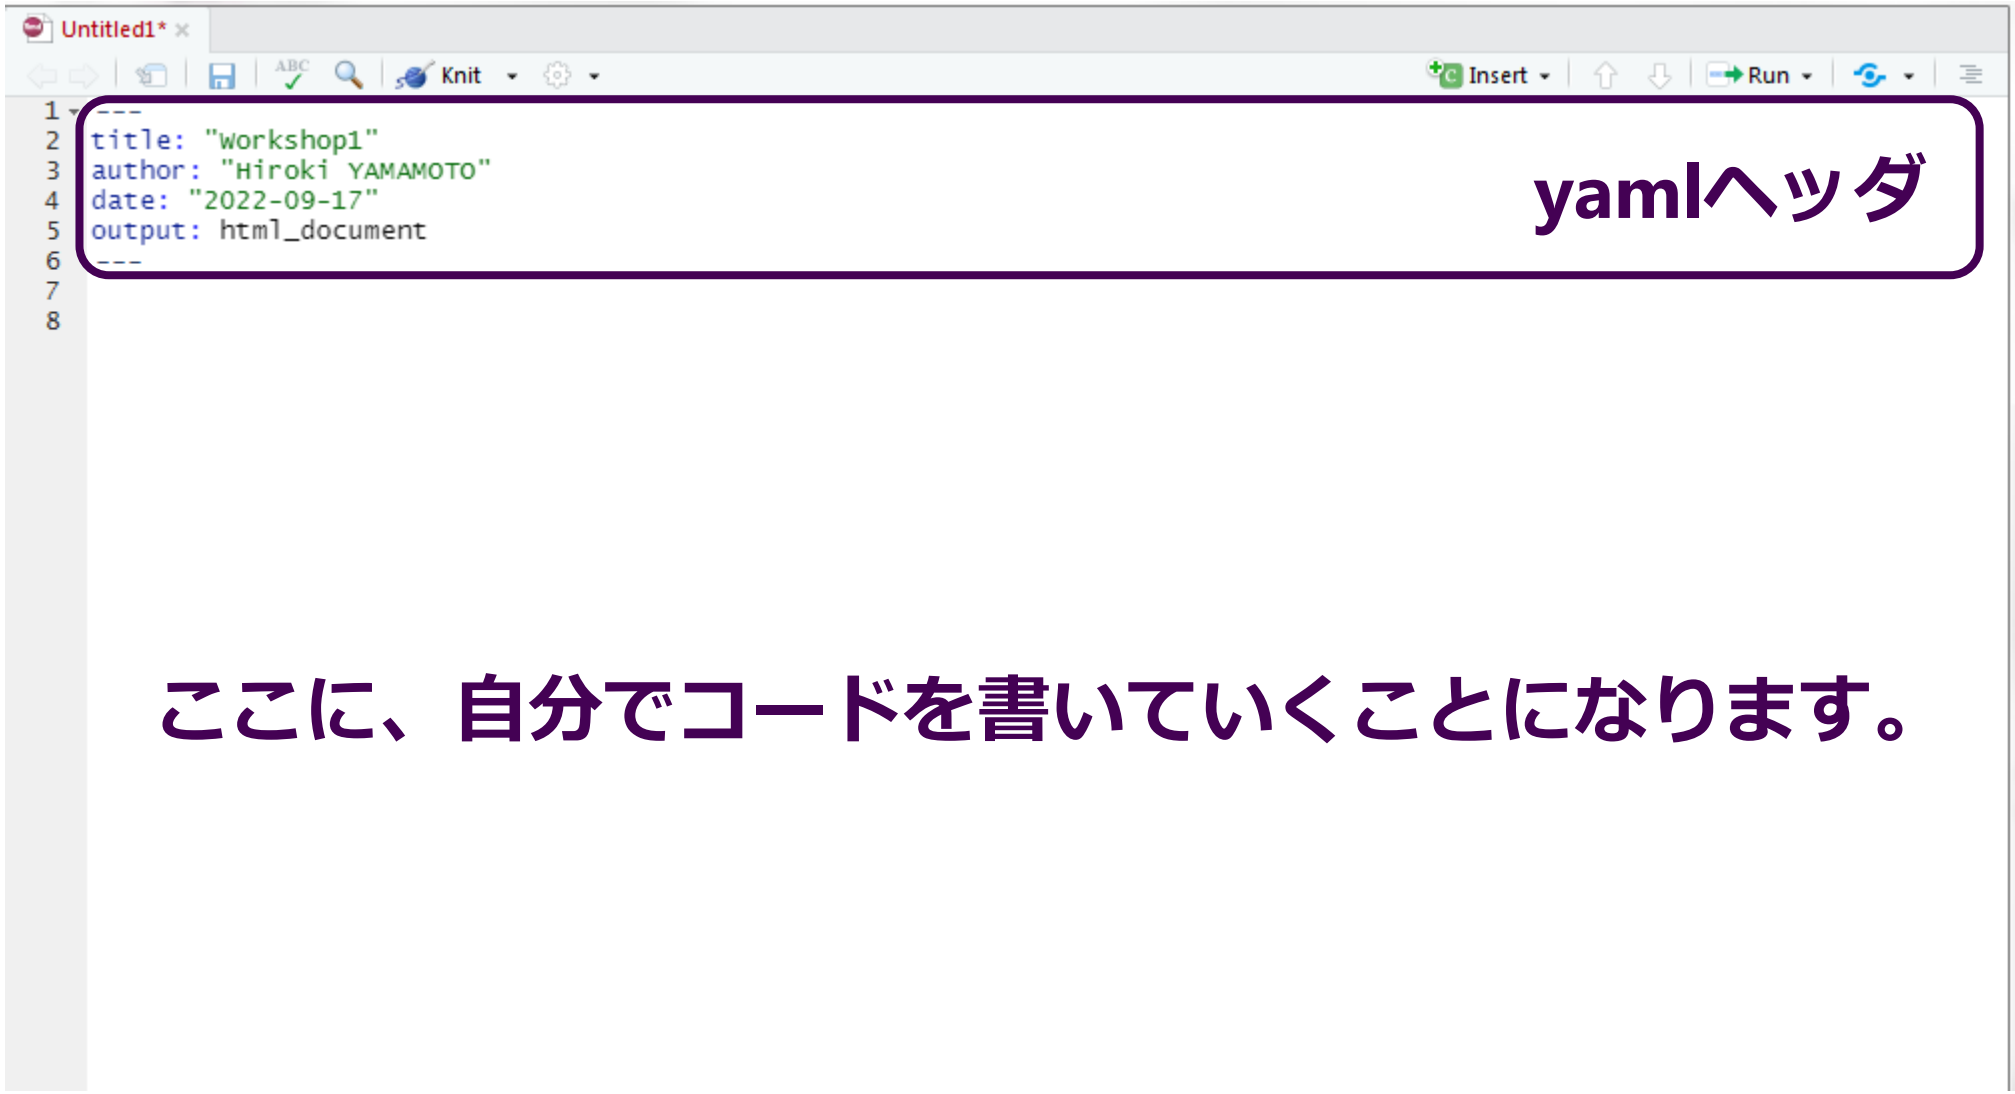

ここに、自分でコードを書いていくことになります。

Ctrl+Alt+I でコードチャンクを挿入

❑コードチャンクの挿入

① yamlヘッダの下部に
　カーソルを置いて

② Ctrl + Alt + I

　※macOSではCommand + Option + I

③チャンクがでてきた！

　ここにコードをうっていきます

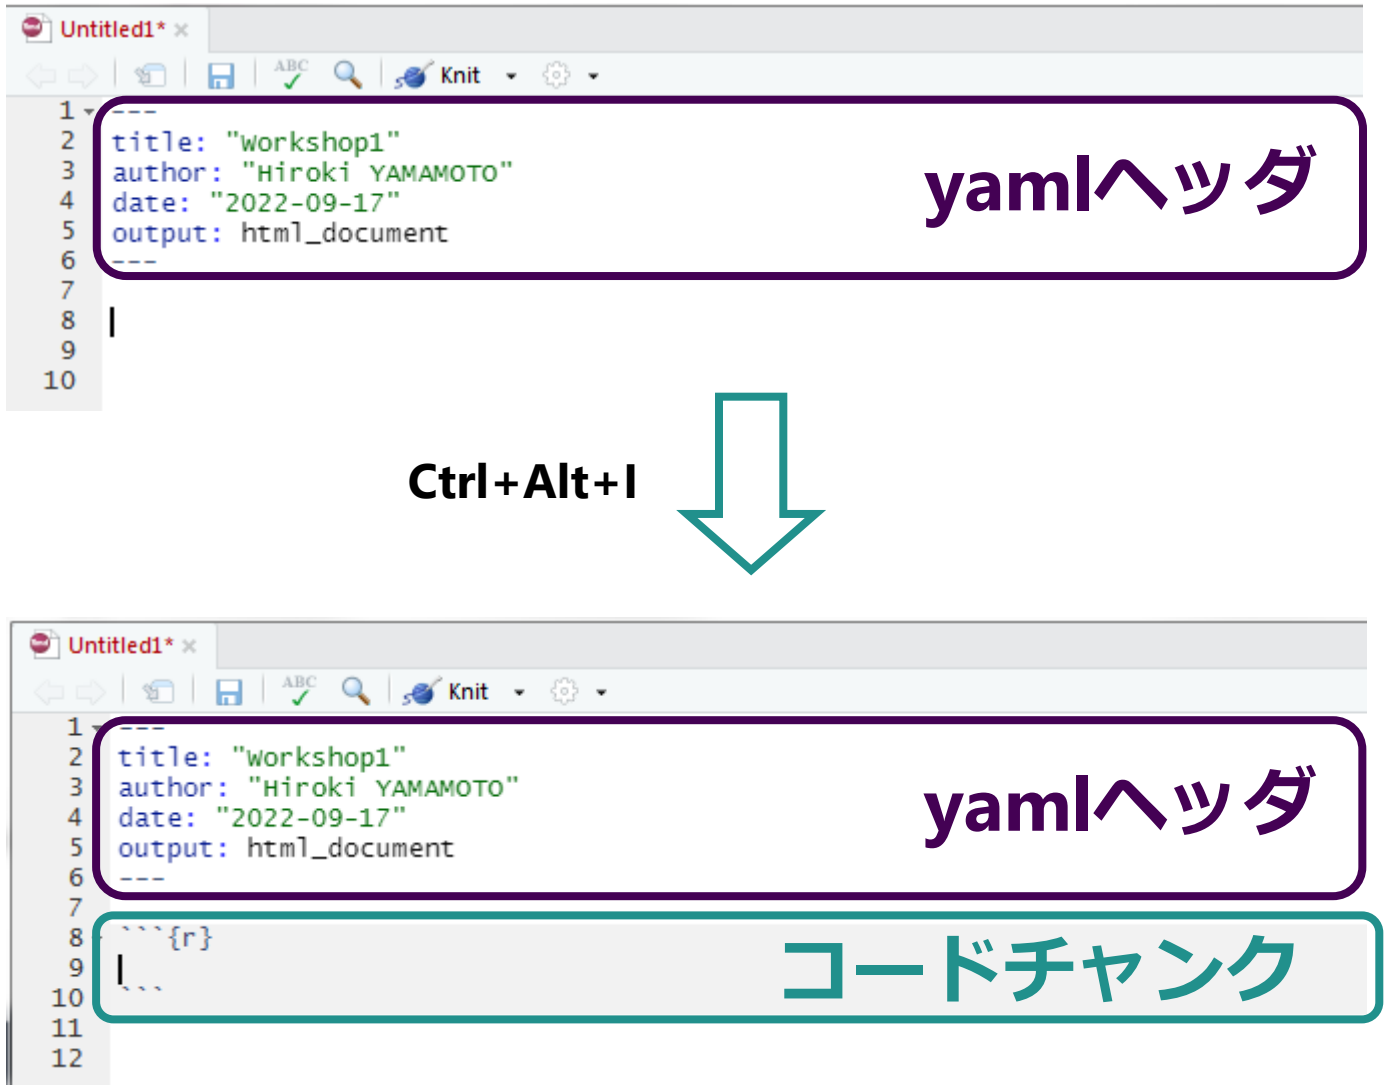

コードチャンクにコードをうちましょう

```{r}
a <- 1 + 1
b <- 3
a*b
```

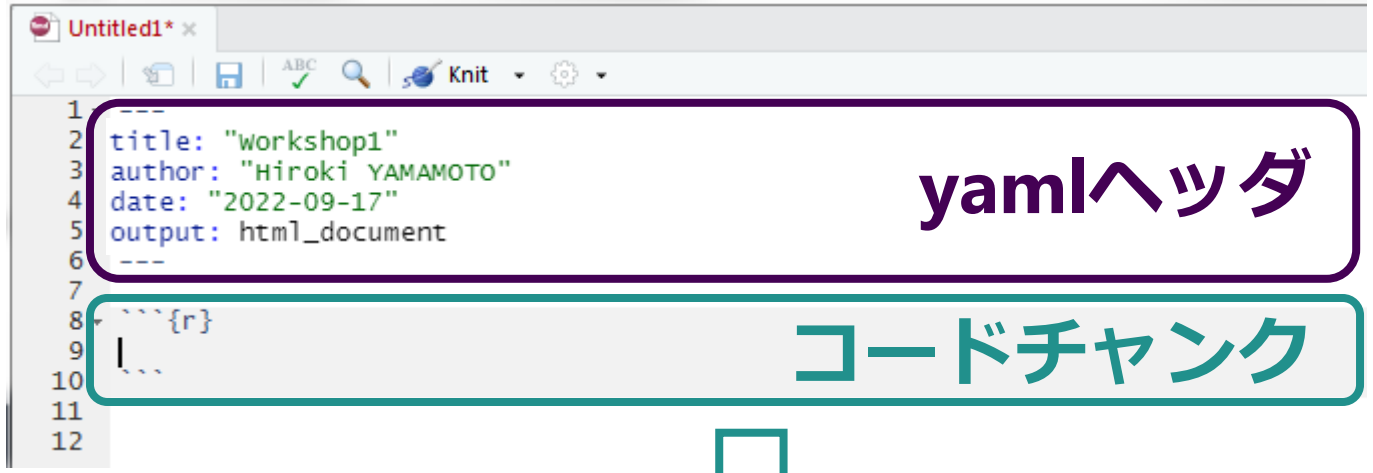

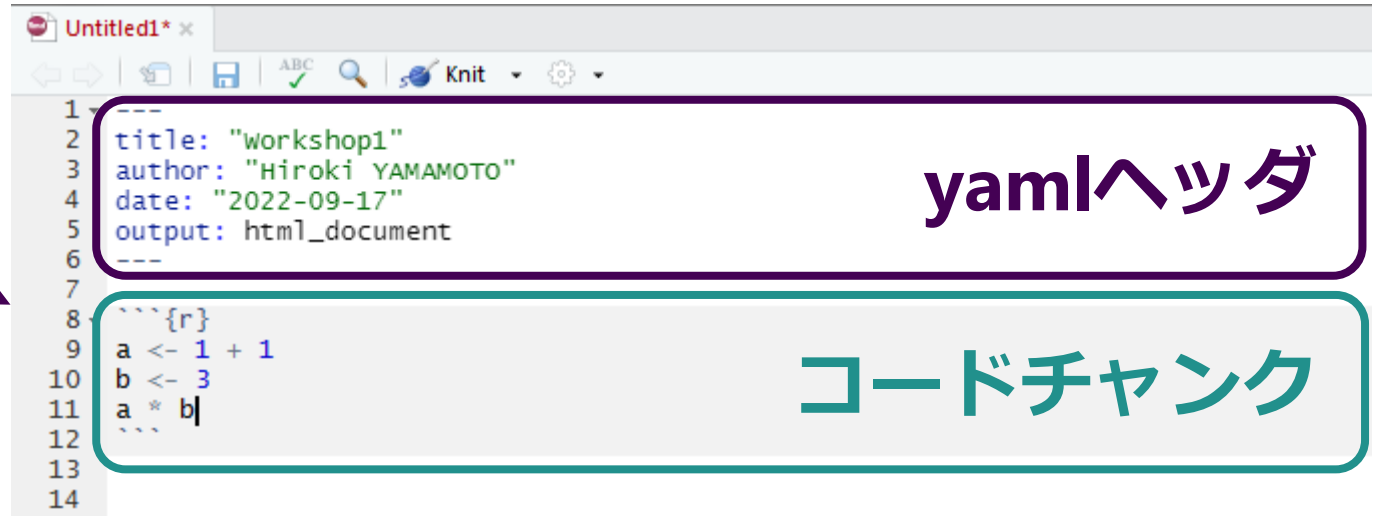

Ctrl+Enterでカーソル行のコードを実行

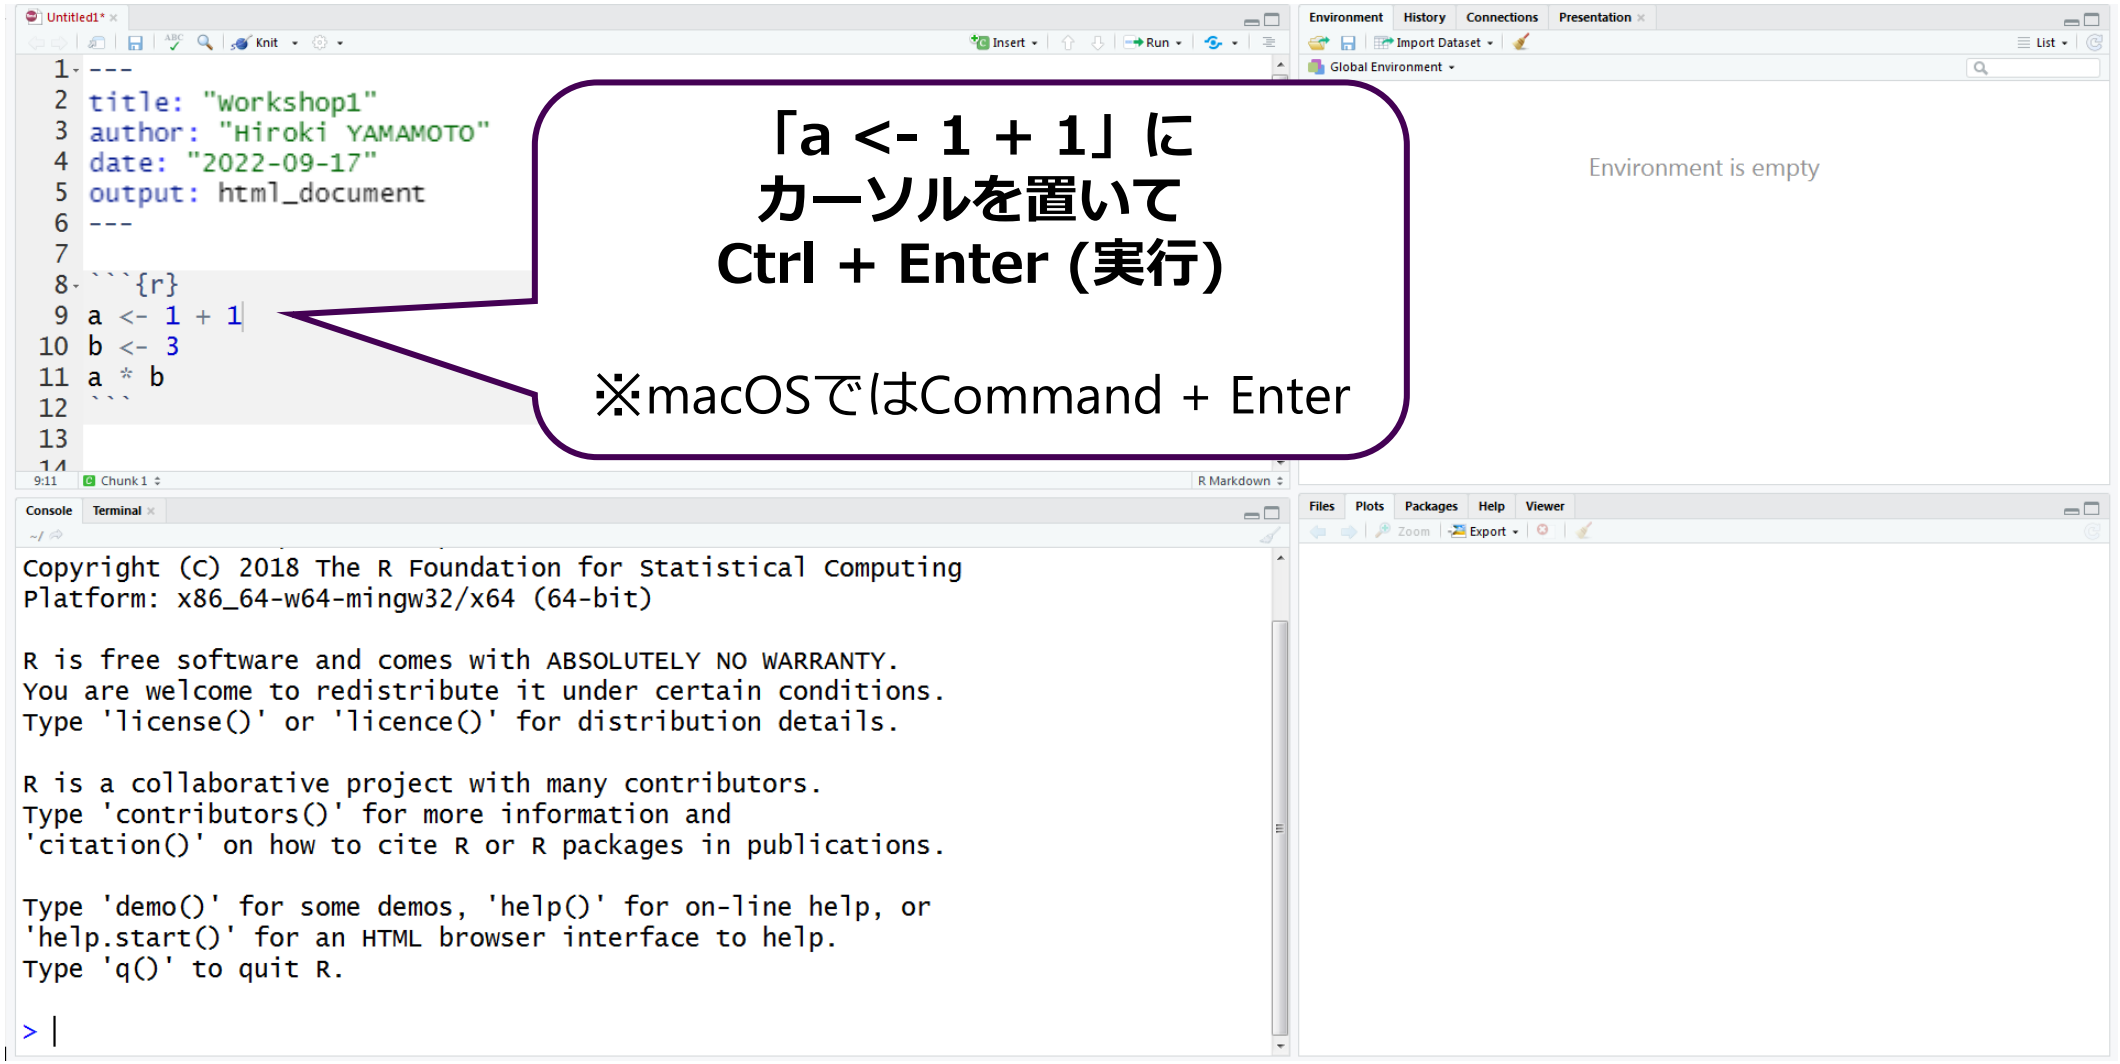

Ctrl+Enterでカーソル行のコードを実行

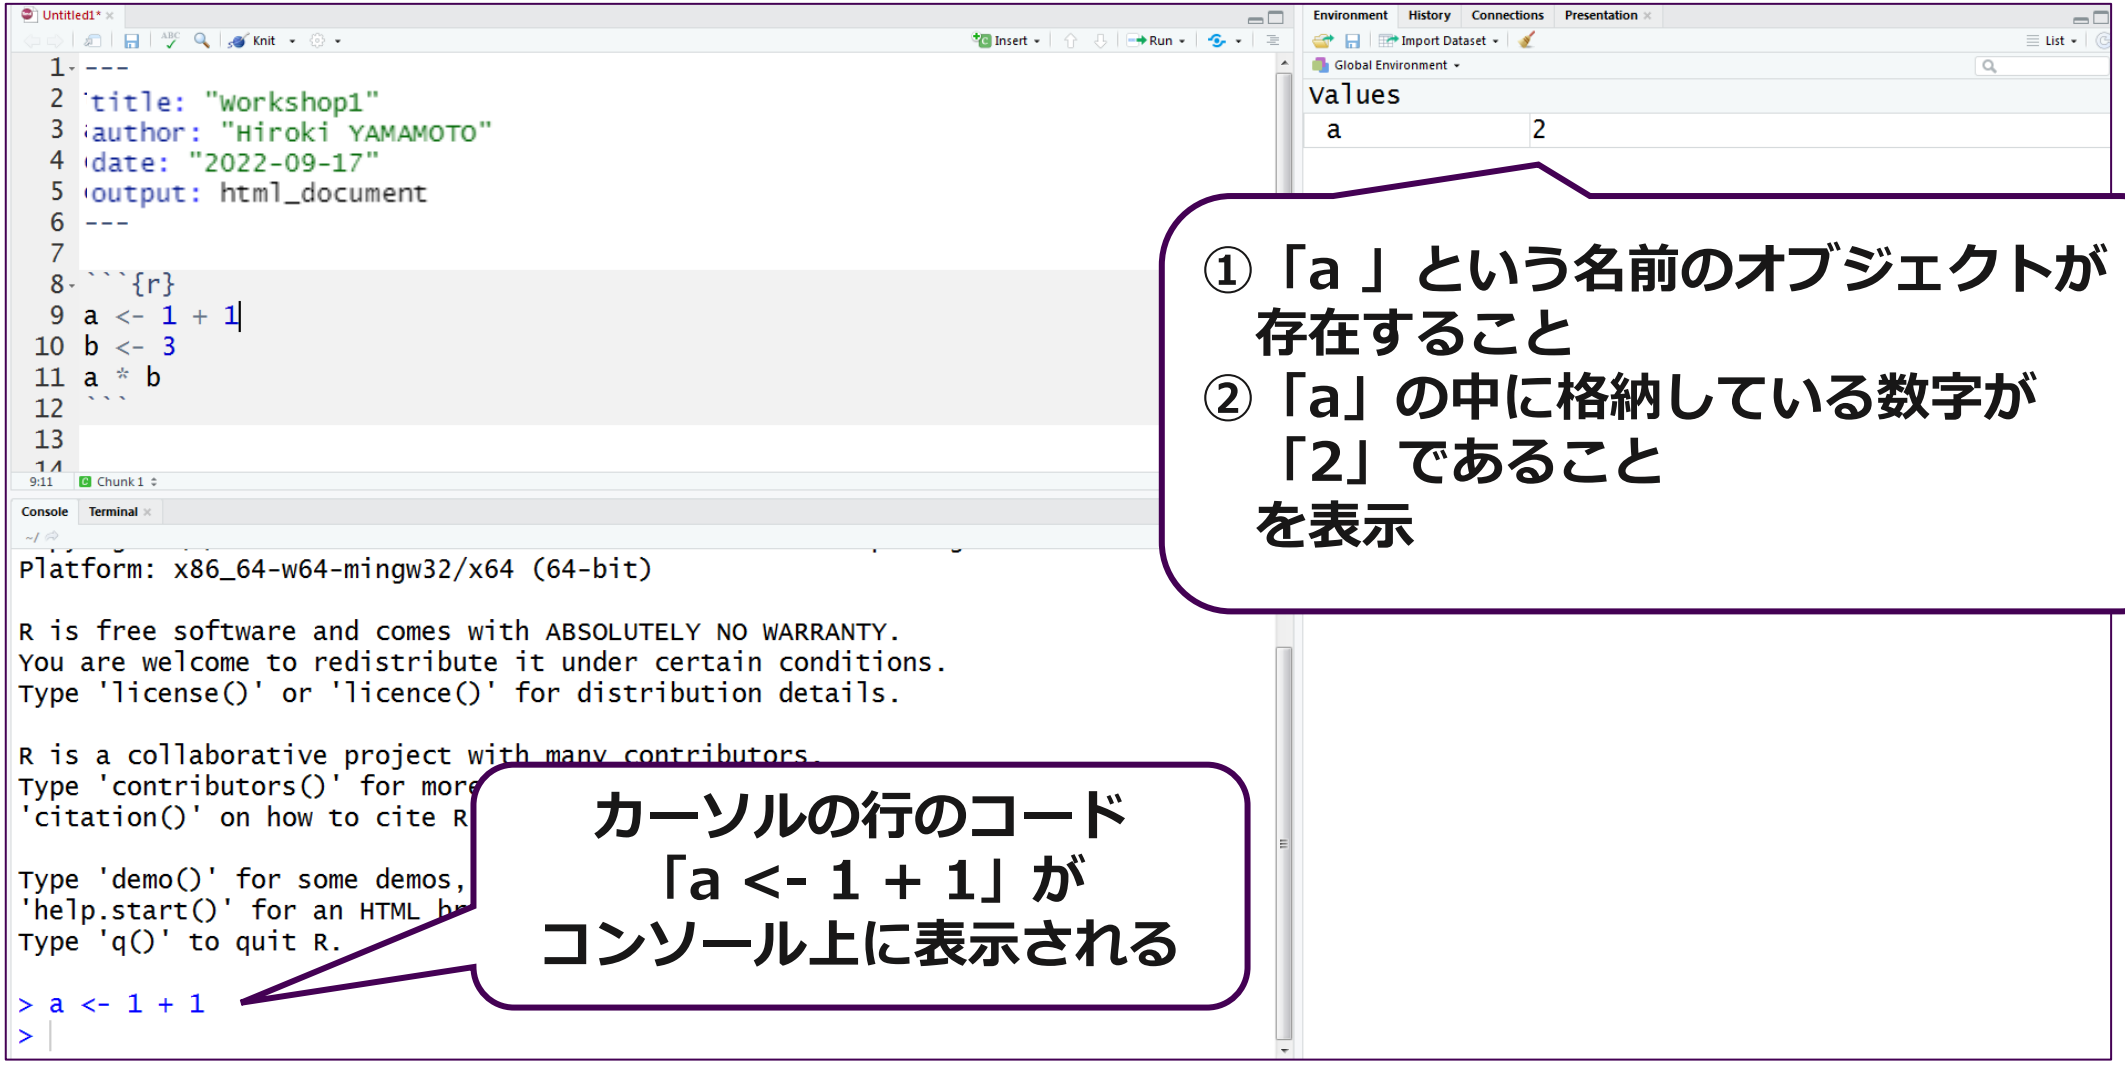

結果をドキュメントチャンクに記述

Untitled1*

Knit

```
---
title: "workshop1"
author: "Hiroki YAMAMOTO"
date: "2022-09-17"
output: html_document
---

```{r}
a <- 1 + 1
b <- 3
a * b
```

aとbの積は6だ
```

結果についてメモしておきたいことは
チャンクの外側の領域に
書いておこう

メモしたいことがない場合は
特に書かなくてもいい

RStudio+Rmarkdownの基本的な使い方

❑RStudioとRmarkdownを用いたコーディングのワークフロー

・前準備

(a) エディタにRmarkdown画面を生成

(b) yamlヘッダを残して下部をDelete

・コードをかく（以下の①～⑤を繰り返す）

①コードチャンクを挿入(Ctrl+Alt+I)

②コードチャンクにコードをかく

③カーソルの行のコードを実行(Ctrl+Enter)

④コンソール・ワークスペースで出力を確認

(⑤メモをドキュメントチャンクに記述)

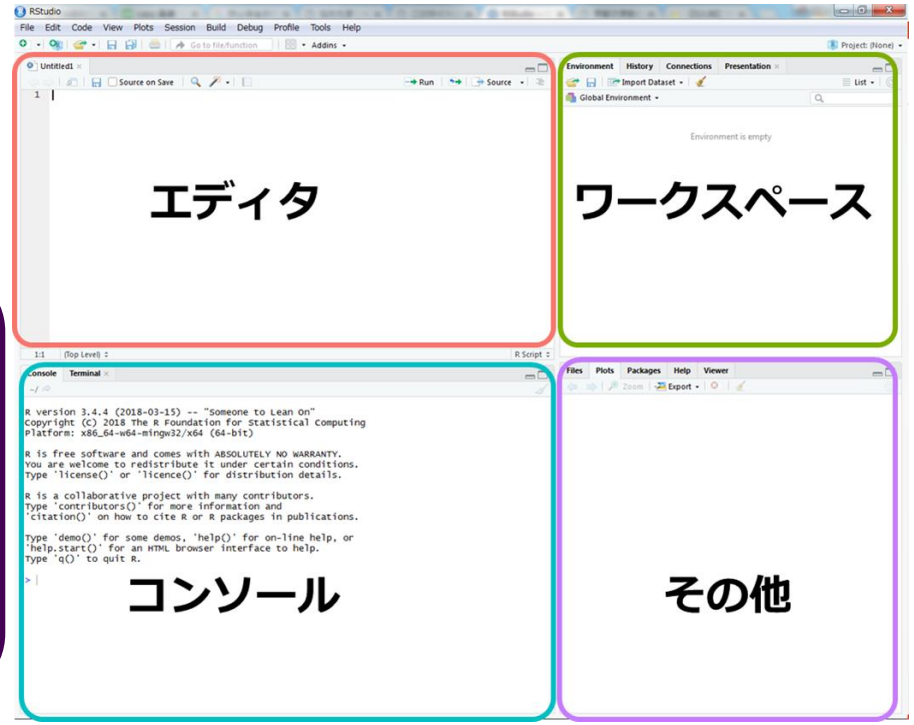

覚えておくと便利なショートカット (Windows)

- **Ctrl + Enter**
  - カーソルのある行を実行する

- **Ctrl + Alt + I**
  - コードチャンクを挿入する

- **Ctrl + Alt + C**
  - カーソルのあるコードチャンクのコードをすべて実行する。

- **Ctrl + Alt + R**
  - Rmarkdownファイル内にあるコードチャンクをすべて実行する。

覚えておくと便利なショートカット (macOS)

- **Command+ Enter**
  - カーソルのある行を実行する

- **Command + Option + I**
  - コードチャンクを挿入する

- **Command + Option + C**
  - カーソルのあるコードチャンクのコードをすべて実行する。

- **Command + Option + R**
  - Rmarkdownファイル内にあるコードチャンクをすべて実行する。

データフレームの操作

Rの基本操作

❑基本的な計算

記号	意味
+	足し算
-	引き算
*	掛け算
/	割り算
^	べき乗

```
> 10+10
[1] 20
>
> 10-10
[1] 0
>
> 10*10
[1] 100
>
> 10/10
[1] 1
>
> 10^2
[1] 100
>
>
```

オブジェクト：データを格納する「箱」

❑Rのオブジェクト

●数字・文字列などを格納したり、
一部を取り出し・変更したりできる「箱」

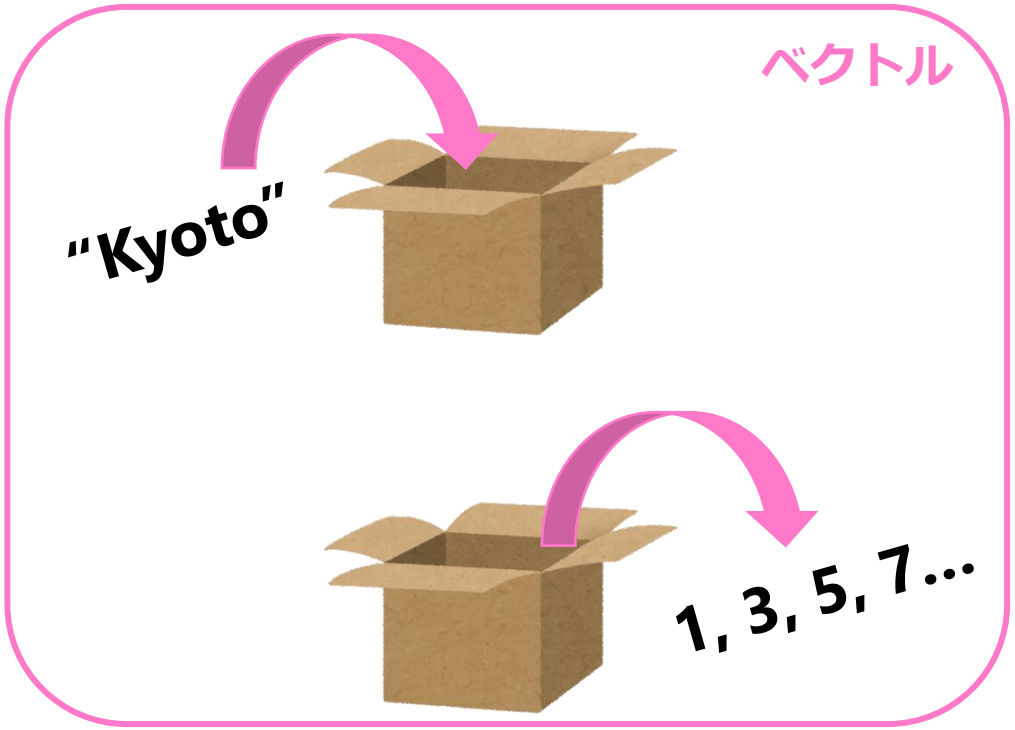

●格納するデータの種類によって、
「箱」の種類も変わる。

- ベクトル
- **データフレーム**
- マトリックス
- リスト

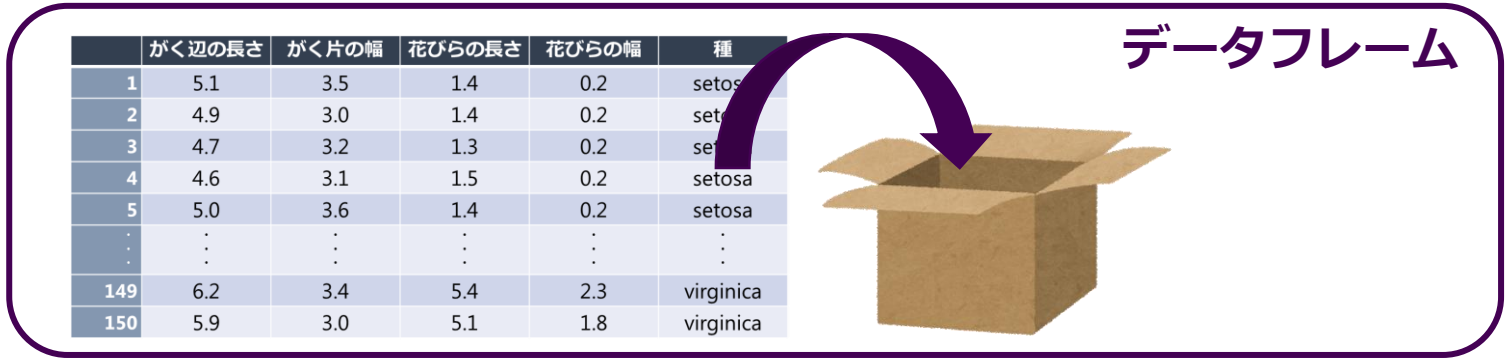

	がく辺の長さ	がく片の幅	花びらの長さ	花びらの幅	種
1	5.1	3.5	1.4	0.2	setos
2	4.9	3.0	1.4	0.2	set
3	4.7	3.2	1.3	0.2	se
4	4.6	3.1	1.5	0.2	setosa
5	5.0	3.6	1.4	0.2	setosa
⋮	⋮	⋮	⋮	⋮	⋮
149	6.2	3.4	5.4	2.3	virginica
150	5.9	3.0	5.1	1.8	virginica

オブジェクト：データを格納する「箱」

❑オブジェクトへの代入

- 「<-」でオブジェクトへの代入を表す。

```
> a<-1+1
>
> a
[1] 2
>
> b<-3
>
> a*b
[1] 6
>
```

- 「１＋１」という計算に「a」という名前をつける
- 名前をつけた後で「a」を呼び出すと、「1+1」という計算の結果（つまり２）が返される
- 「３」という数値に「b」という名前をつける
- 「a*b」という計算を行うと、「(1+1)×3」という計算の結果（つまり6）が返される

データフレーム

❑サンプルデータiris

```
iris
```

```
##     Sepal.Length Sepal.Width Petal.Length Petal.Width   Species
## 1            5.1         3.5          1.4         0.2    setosa
## 2            4.9         3.0          1.4         0.2    setosa
## 3            4.7         3.2          1.3         0.2    setosa
## 4            4.6         3.1          1.5         0.2    setosa
## 5            5.0         3.6          1.4         0.2    setosa
## 6            5.4         3.9          1.7         0.4    setosa
## 7            4.6         3.4          1.4         0.3    setosa
## 8            5.0         3.4          1.5         0.2    setosa
## 9            4.4         2.9          1.4         0.2    setosa
## 10           4.9         3.1          1.5         0.1    setosa
## 11           5.4         3.7          1.5         0.2    setosa
## 12           4.8         3.4          1.6         0.2    setosa
```

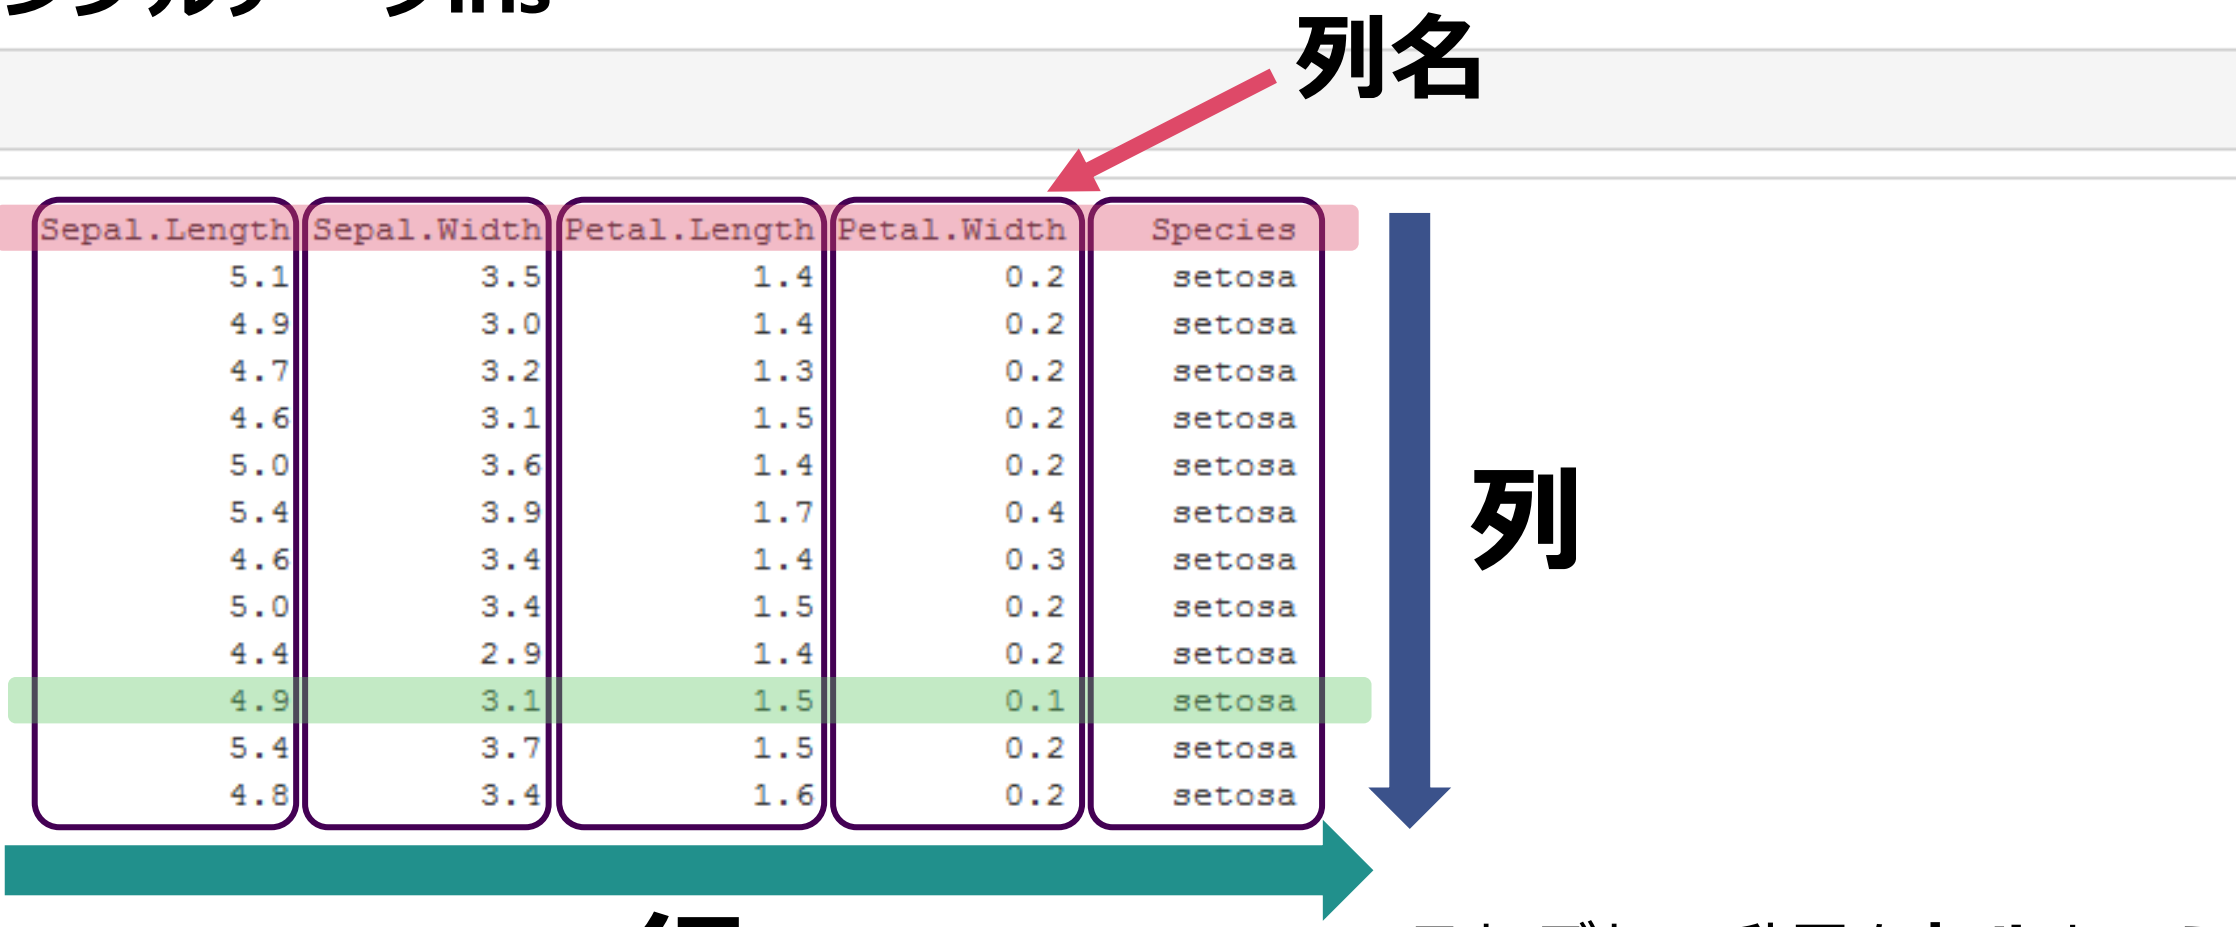

それぞれの升目を**セル**という

iris：フィッシャーのアヤメのデータ

❑3種のアヤメについて、がく片・花びらの長さ・幅を計測したデータ

・setosa・versicolor・virginica 各50個体ずつ（計150個体）

	がく辺の長さ	がく片の幅	花びらの長さ	花びらの幅	種
1	5.1	3.5	1.4	0.2	setosa
2	4.9	3.0	1.4	0.2	setosa
3	4.7	3.2	1.3	0.2	setosa
4	4.6	3.1	1.5	0.2	setosa
5	5.0	3.6	1.4	0.2	setosa
⋮	⋮	⋮	⋮	⋮	⋮
149	6.2	3.4	5.4	2.3	virginica
150	5.9	3.0	5.1	1.8	virginica
	量的変数	量的変数	量的変数	量的変数	質的変数

データフレームの先頭6行を表示する

❑head(df)

```
head(iris)
```

```
##   Sepal.Length Sepal.Width Petal.Length Petal.Width Species
## 1          5.1         3.5          1.4         0.2  setosa
## 2          4.9         3.0          1.4         0.2  setosa
## 3          4.7         3.2          1.3         0.2  setosa
## 4          4.6         3.1          1.5         0.2  setosa
## 5          5.0         3.6          1.4         0.2  setosa
## 6          5.4         3.9          1.7         0.4  setosa
```

データフレームの基礎情報を表示する

❑summary(df)

```
summary(iris)
```

```
##   Sepal.Length    Sepal.Width     Petal.Length    Petal.Width
##  Min.   :4.300   Min.   :2.000   Min.   :1.000   Min.   :0.100
##  1st Qu.:5.100   1st Qu.:2.800   1st Qu.:1.600   1st Qu.:0.300
##  Median :5.800   Median :3.000   Median :4.350   Median :1.300
##  Mean   :5.843   Mean   :3.057   Mean   :3.758   Mean   :1.199
##  3rd Qu.:6.400   3rd Qu.:3.300   3rd Qu.:5.100   3rd Qu.:1.800
##  Max.   :7.900   Max.   :4.400   Max.   :6.900   Max.   :2.500
##        Species
##  setosa    :50
##  versicolor:50
##  virginica :50
##
##  ※数値の列では最小値・平均値・最大値・四分位数などの要約統計量が、
##    文字列の列では、格納されている各文字列の観測値の個数が表示される
```

全データを表示する

❑View(df)

・エディタに
データー覧が表示される。

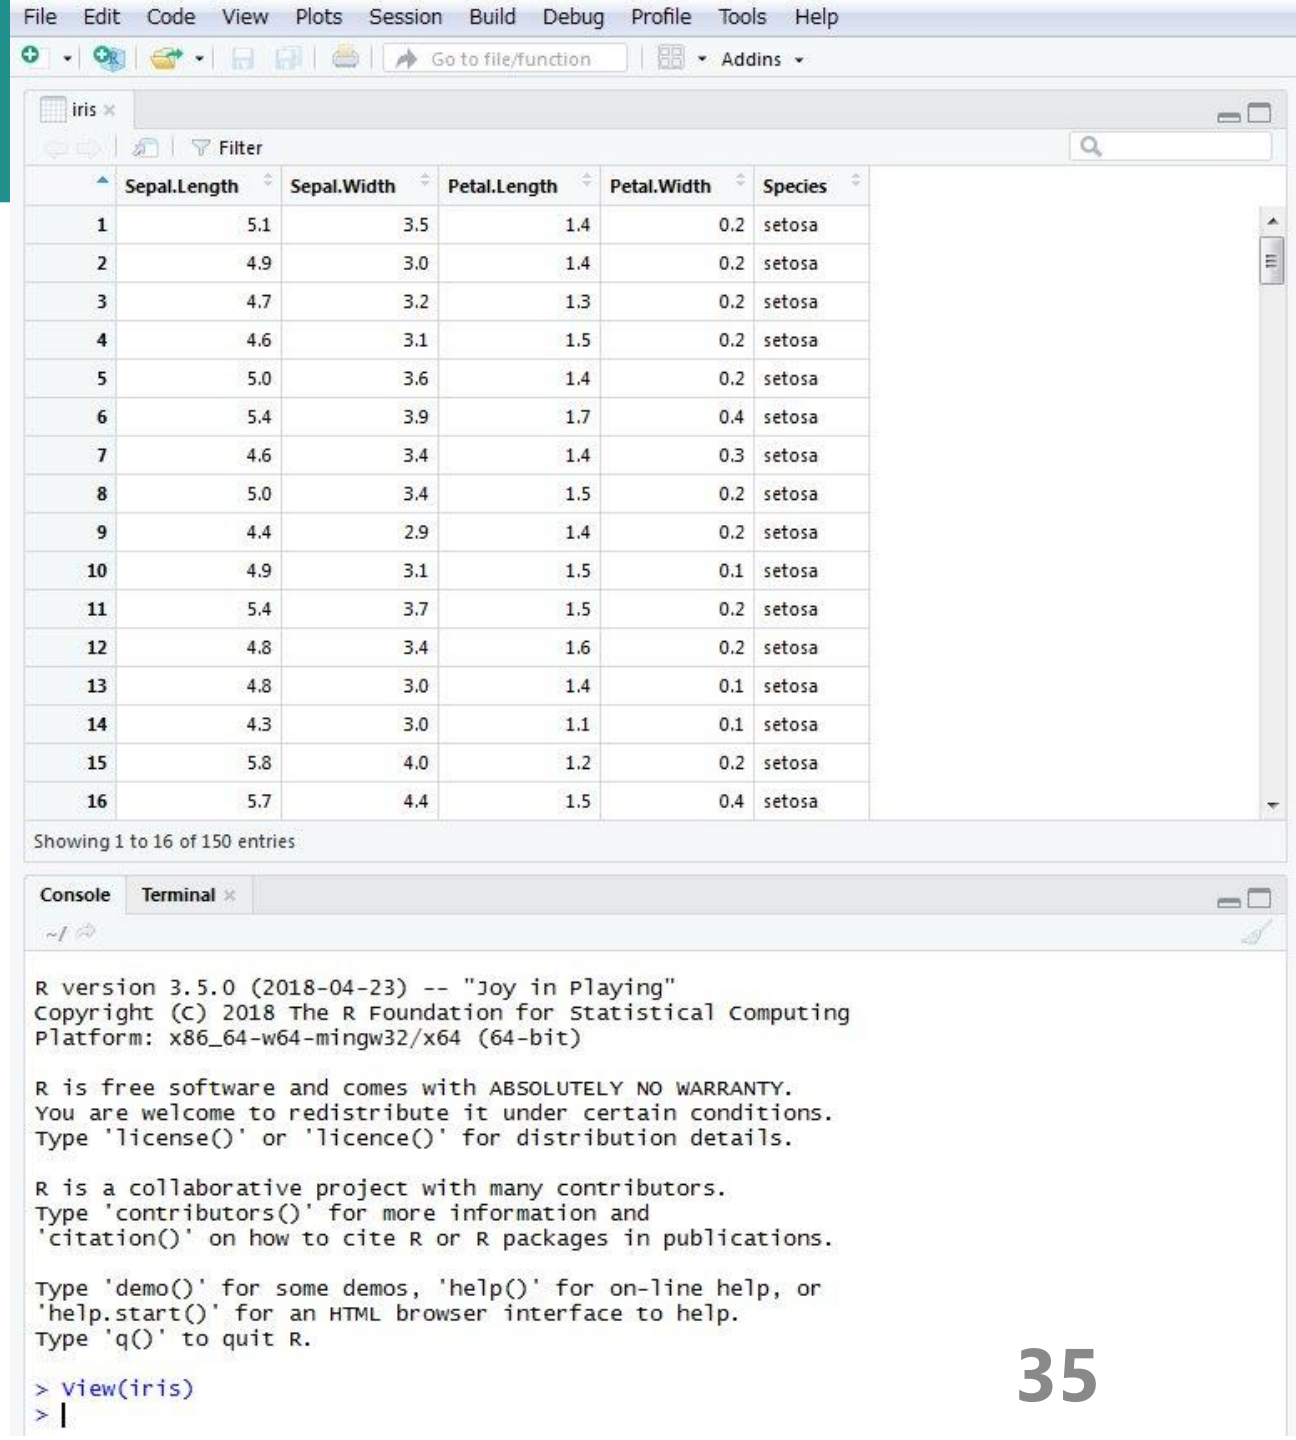

分析レポートの生成

RmarkdownをKnitしよう

❑Windows上部のKnitボタンをクリック

Knitボタン

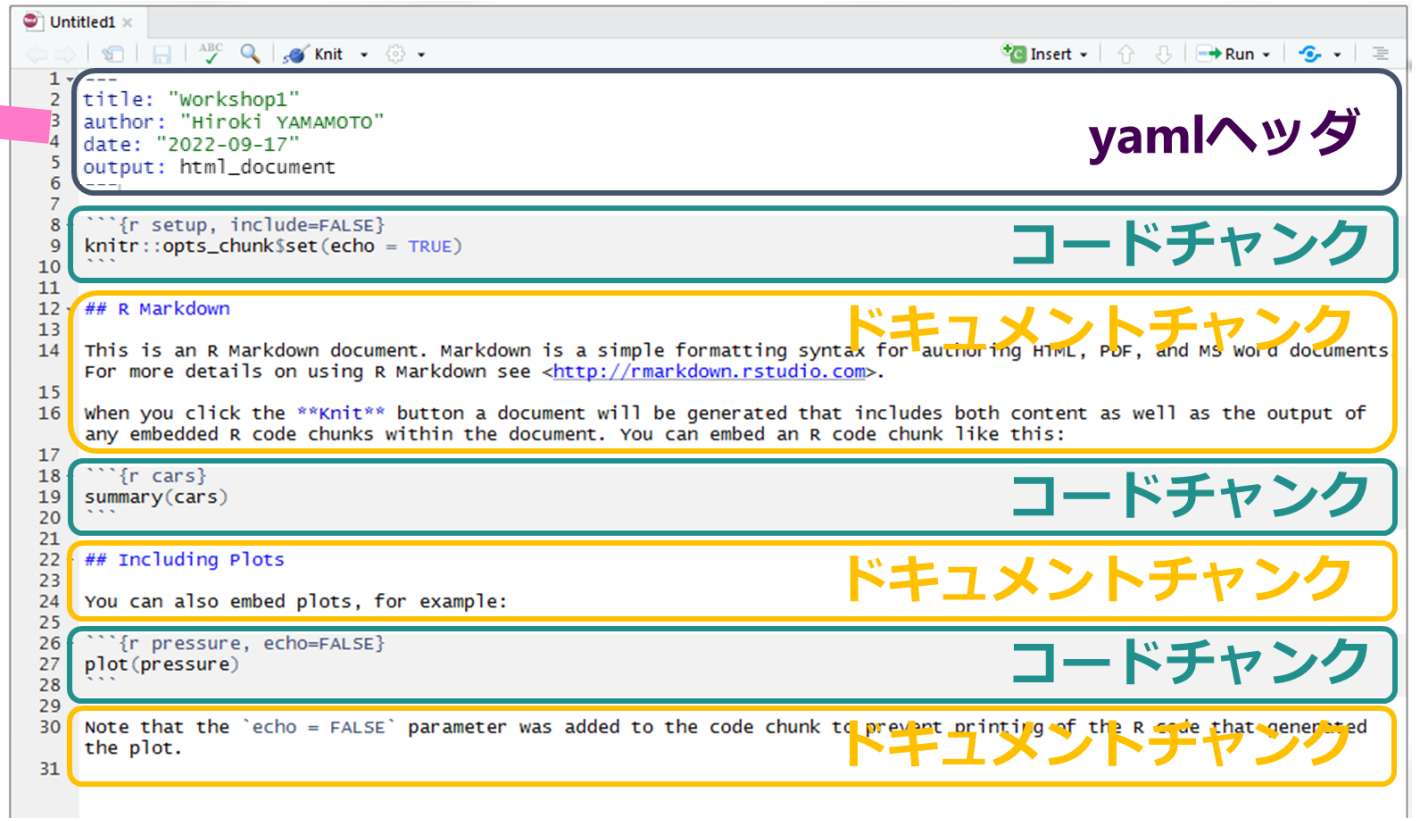

RmarkdownをKnitしよう

❑Choose Encogingウィンドウがでてくる

- Windowsの場合
  - CP932を選択

- Mac OSの場合
  - UTF-8を選択

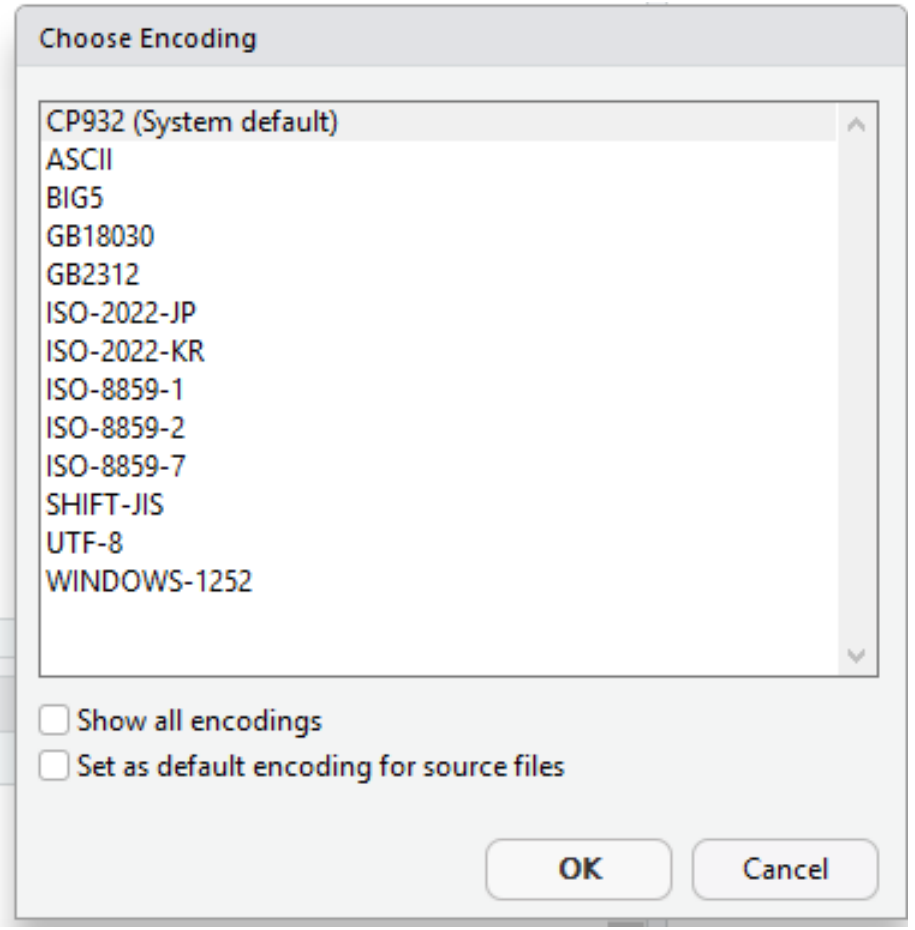

RmarkdownをKnitしよう

❑**“Save File”というウィンドウがでてくる**

・好きな名前をつけて”Save”ボタン

– 今回は”workshop1”
という名前をつけましょう。

RmarkdownをKnitしよう

❑htmlファイルが出力され、Viewerに表示される

workshop1.Rmd

Knit on Save　Knit

~/workshop1.Rmd

Source　Visual

```
1  ---
2  title: "Workshop1"
3  author: "Hiroki YAMAMOTO"
4  date: "2022-09-17"
5  output: html_document
6  ---
7  ```{r}
8  a <- 1 + 1
9  b <- 3
10 a * b
11 ```
12
13 aとbの積は6
14
```

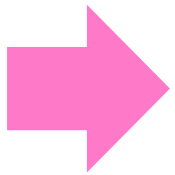

~/workshop1.html

workshop1.html　Open in Browser　Find

Workshop1

Hiroki YAMAMOTO

2022-09-17

```
a <- 1 + 1
b <- 3
a * b
```

```
## [1] 6
```

aとbの積は6

RmarkdownをKnitしよう

❑Rmarkdownに書いたコードとViewerのhtml出力は対応している

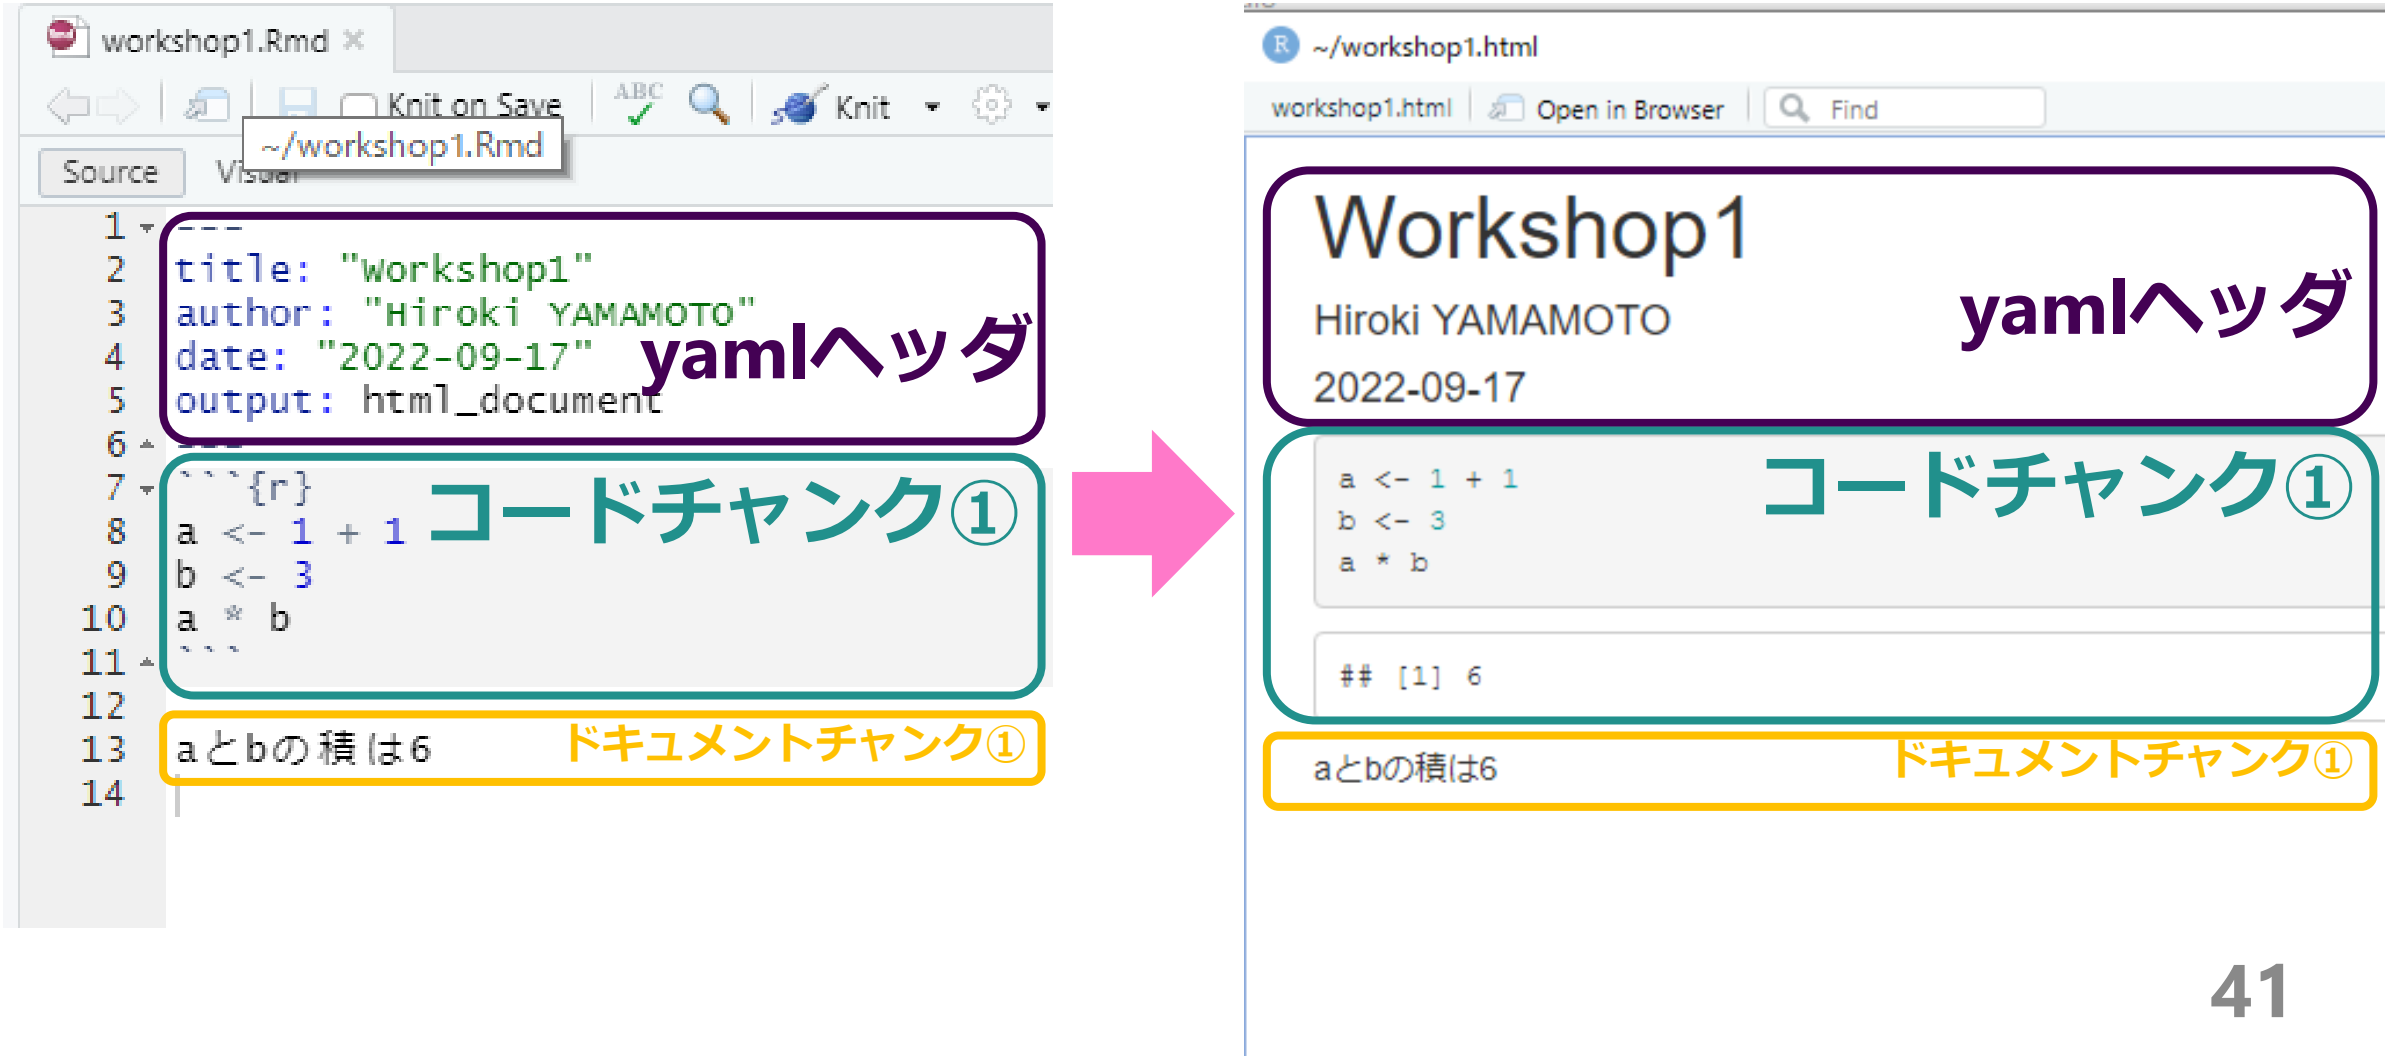

RmarkdownをKnitしよう

❑My documentsにhtmlファイルが出力される

- クリックするとWebブラウザに
  さきほどのhtmlファイルが表示される
  ー”workshop1.html”

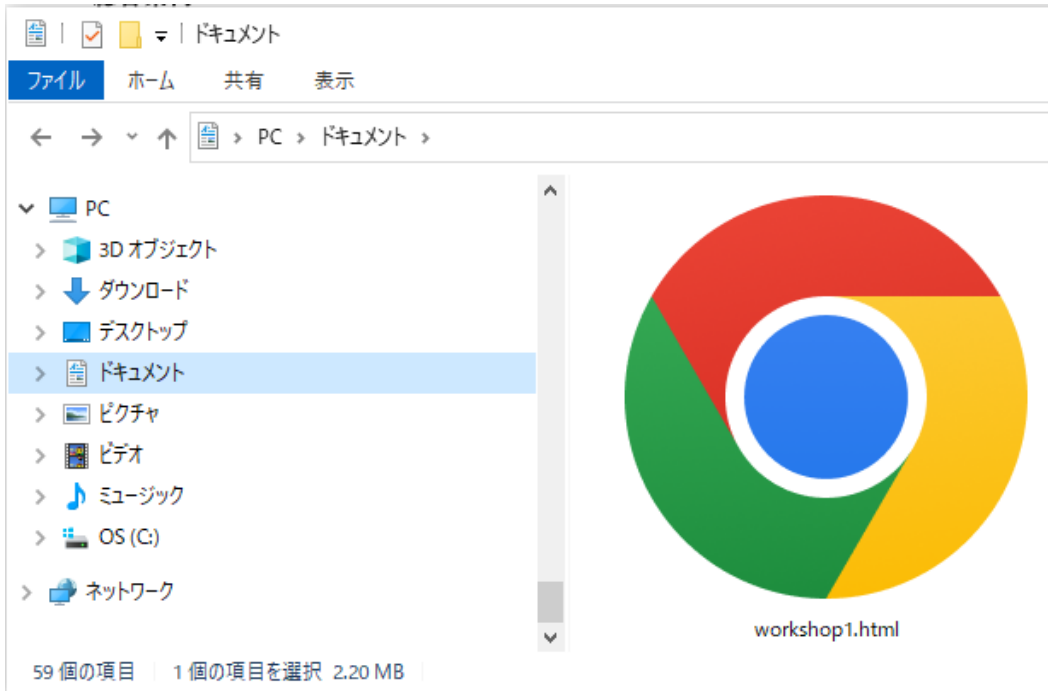

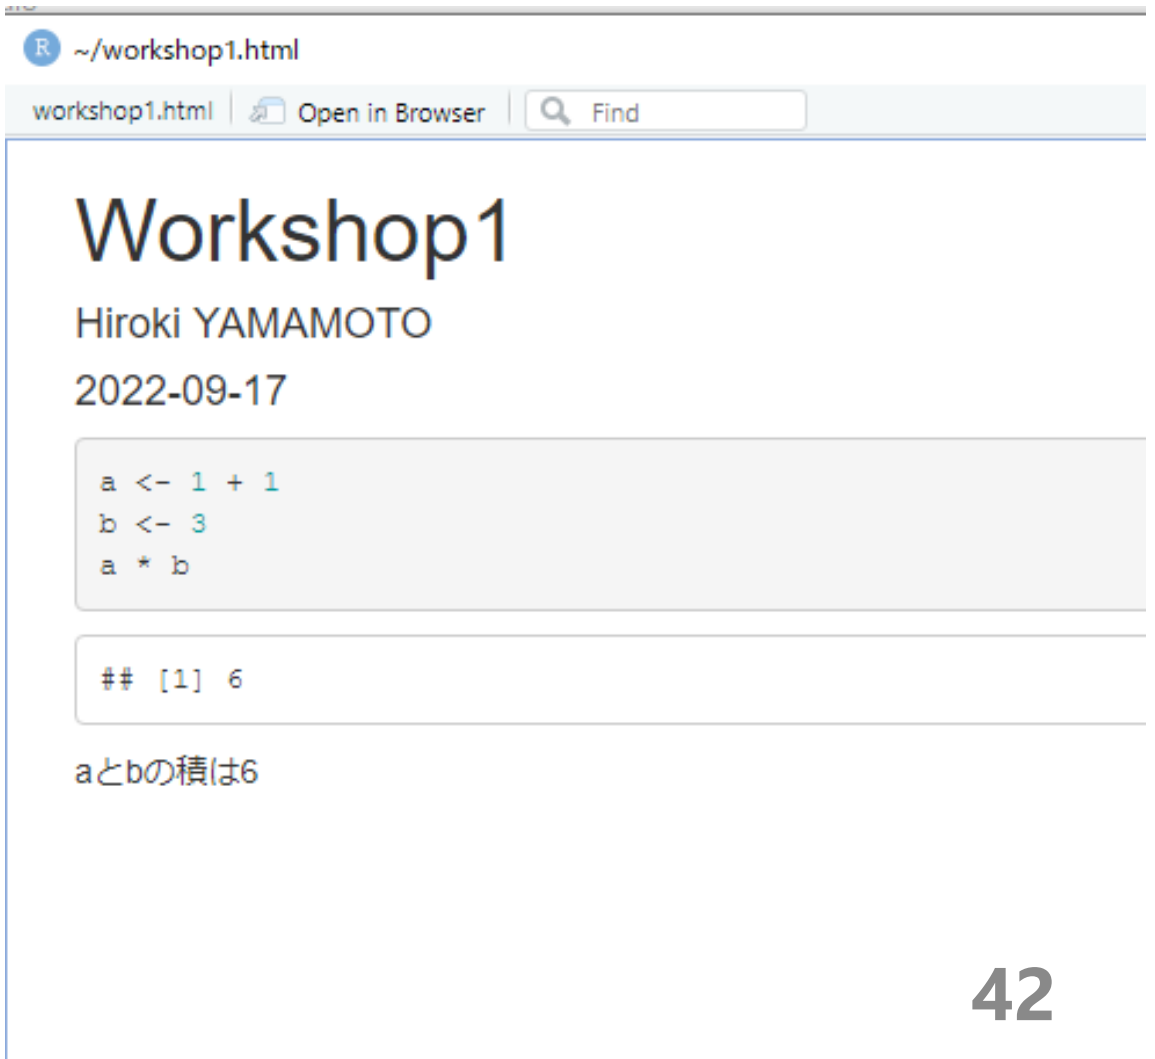

作業ディレクトリ

❑作業ディレクトリ

・PCは多くのフォルダが階層構造をつくる

・Rが、ファイルを入出力することができる
フォルダを**作業ディレクトリ**という。
－作業ディレクトリと
その深層のフォルダにあるデータは
簡単にファイルの入出力ができる。
－作業ディレクトリの外部で
ファイルを入出力したいときは
ディレクトリを変更するなど、一手間必要。

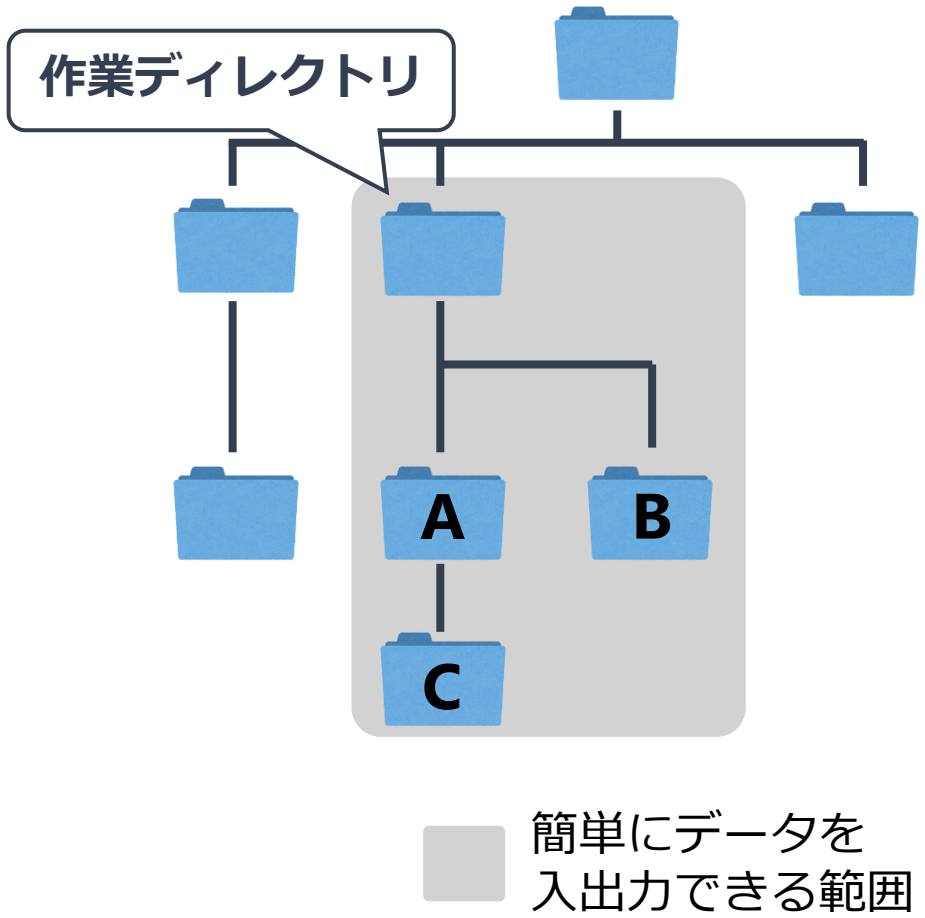

getwd()関数で作業ディレクトリを確認

❑RStudioを起動してコンソールでgetwd()を実行

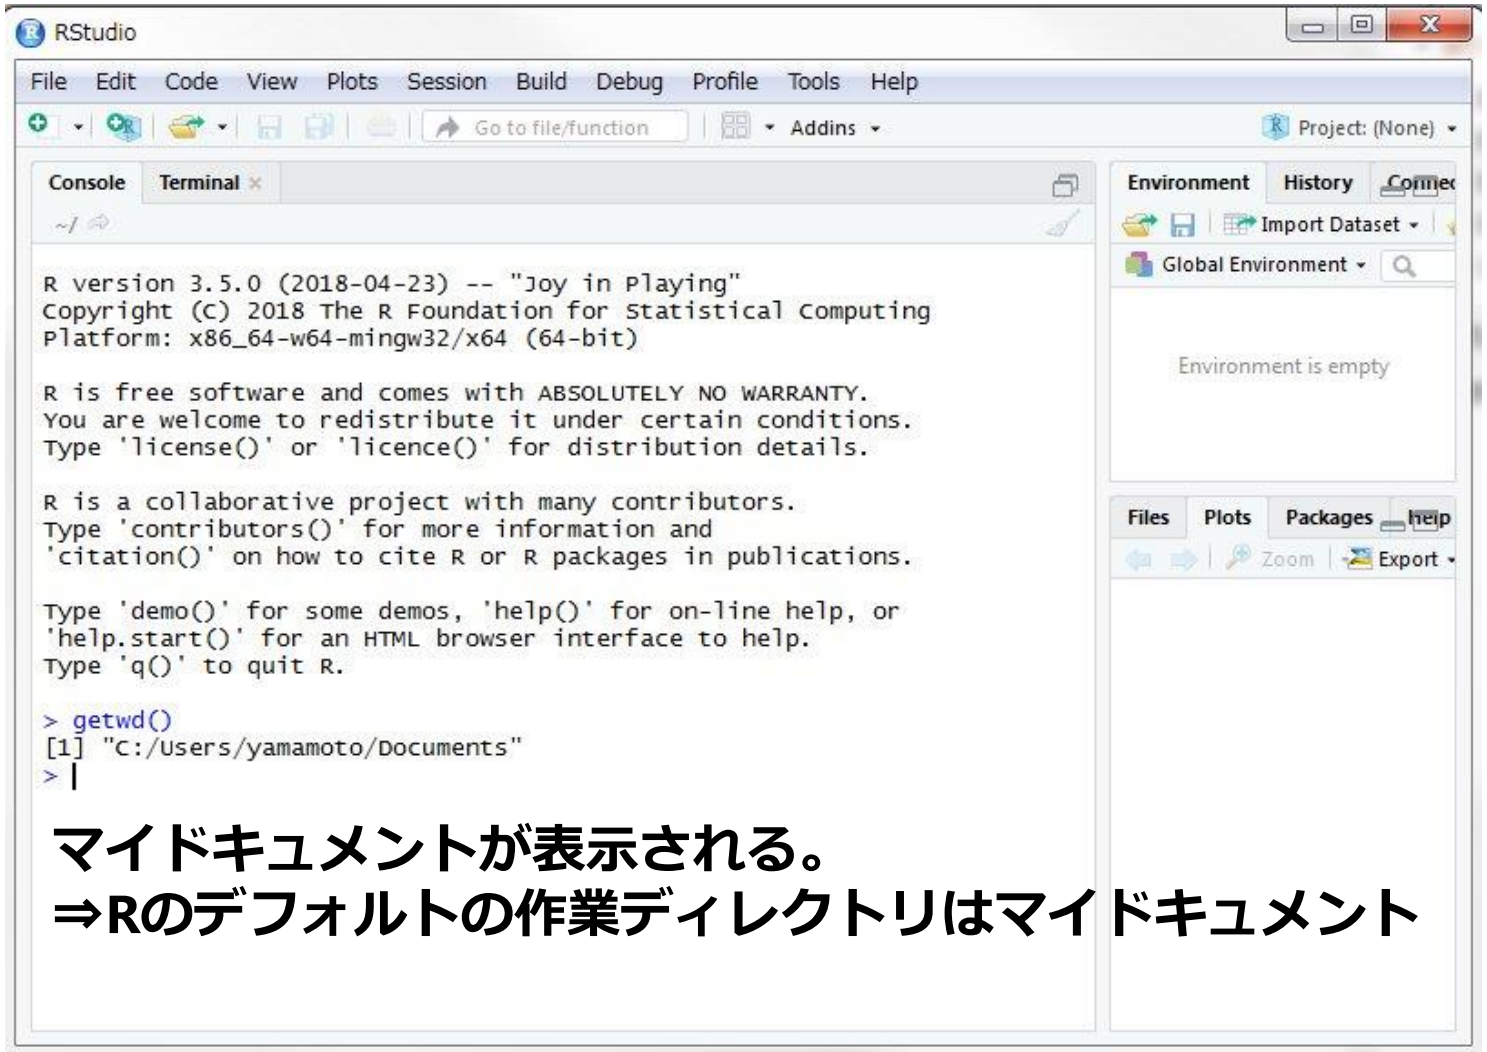

マイドキュメントが表示される。
⇒Rのデフォルトの作業ディレクトリはマイドキュメント

作業ディレクトリ

❑Rのデフォルトの作業ディレクトリは「マイドキュメント」

・マイドキュメント内のファイルに関しては
入出力は簡単。
– それ以外のフォルダに
アクセスしようとすると一手間必要。

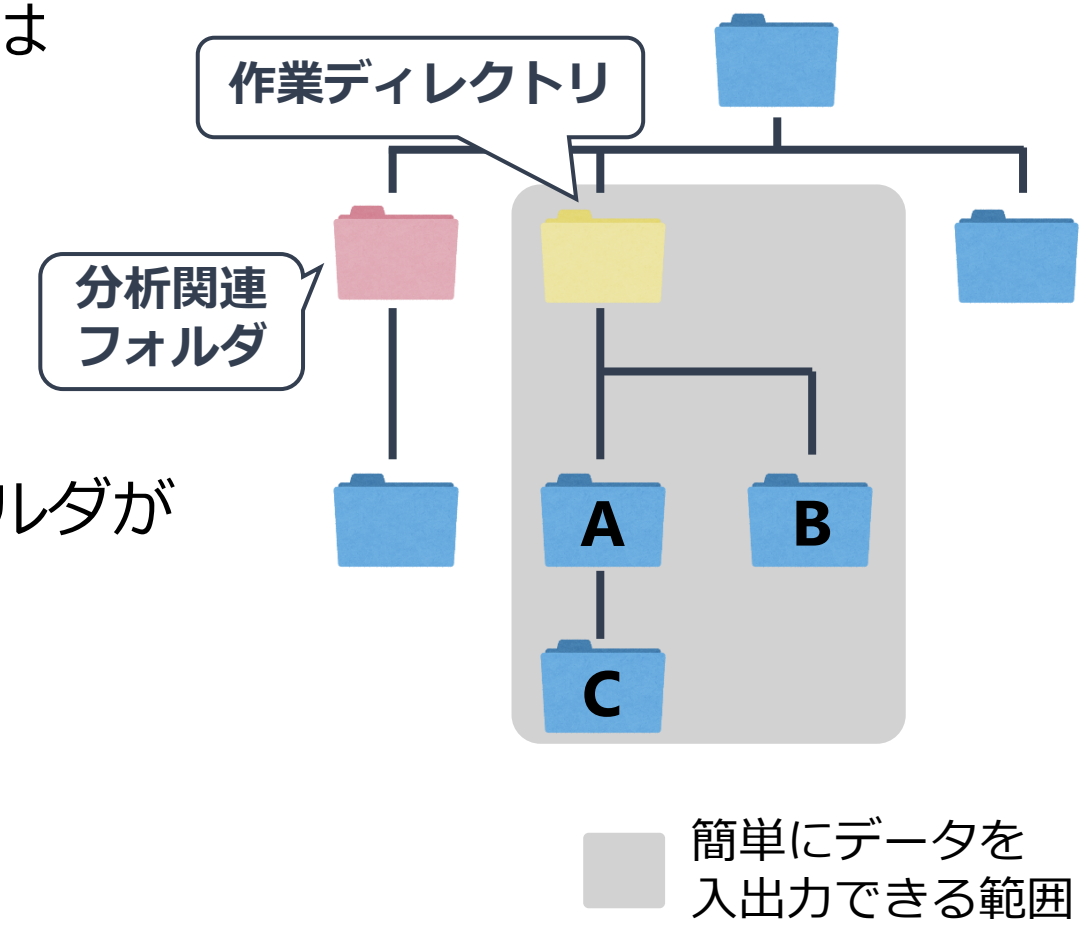

・分析関連ファイルをまとめておいたフォルダが
作業ディレクトリになると便利。

⇩

作業ディレクトリを変更しましょう。

作業ディレクトリの変更

❑ディレクトリを変更する

- **”Session”**

  ⇒”Set Working Directory”

  ⇒”Choose Directory…”

  で、ファイルを入出力する
  フォルダを指定

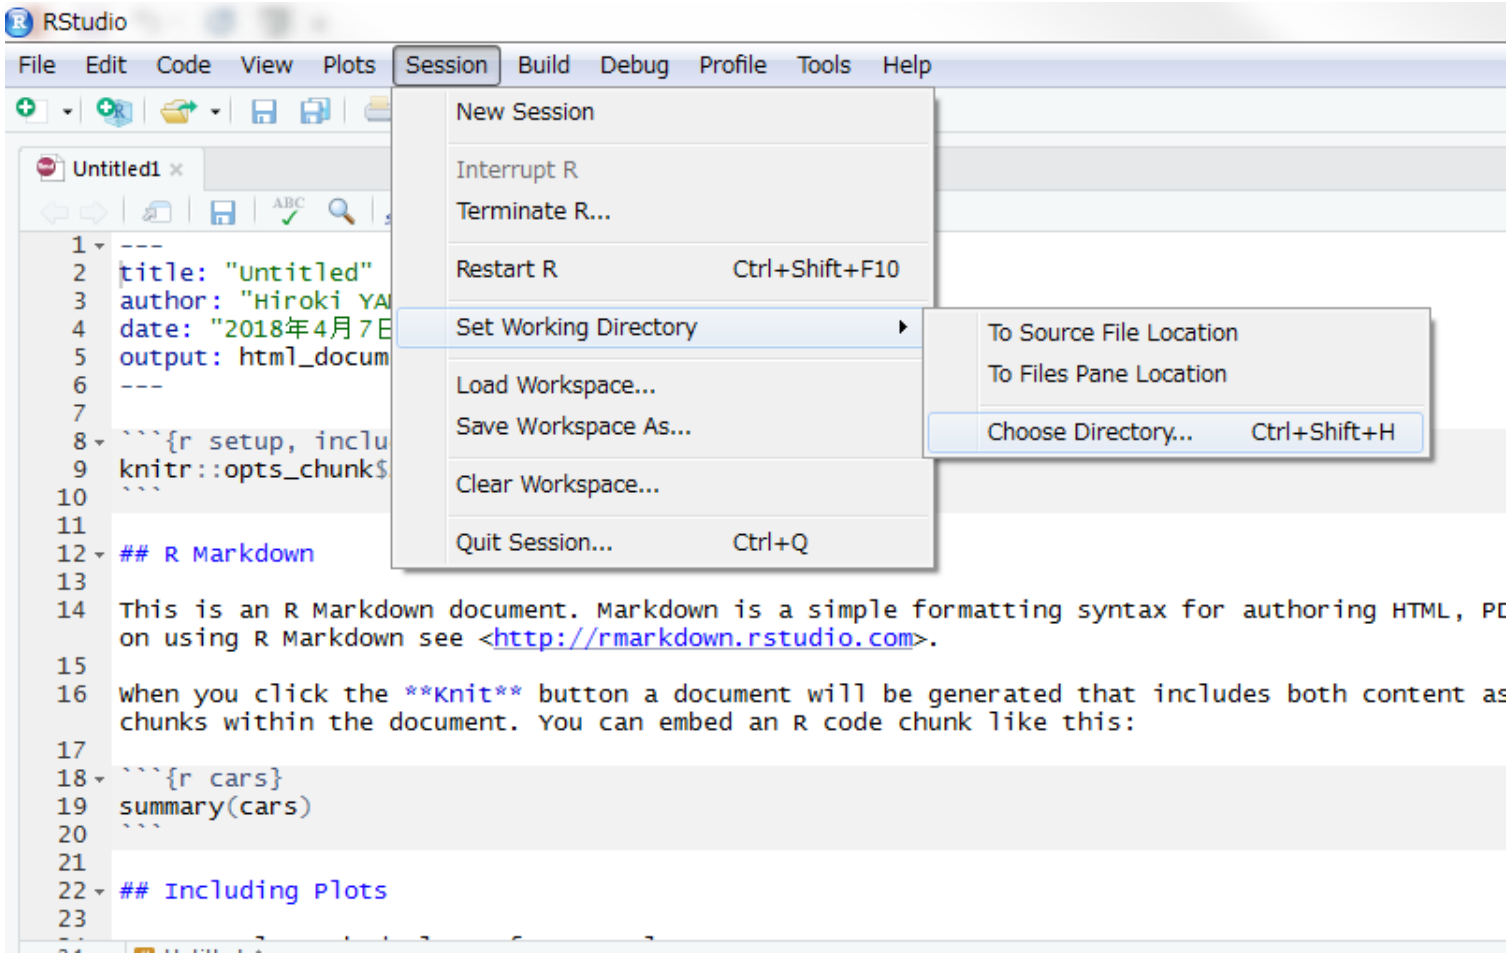

Rmarkdown+Knitで分析レポート作成

❑分析レポート作成のワークフロー

- **前準備**
  (a) エディタにRmarkdown画面を生成
  (b) yamlヘッダを残して下部をDelete

- コードをかく（以下の①～⑤を繰り返す）
  ①コードチャンクを挿入(Ctrl+Alt+I)
  ②コードチャンクにコードをかく
  ③カーソルの行のコードを実行(Ctrl+Enter)
  ④コンソール・ワークスペースで出力を確認
  (⑤メモをドキュメントチャンクに記述)

- **Knit**
  (1) Knitボタンを押す
  (2) ファイル名をつけて保存
  (3) htmlファイルが出力される

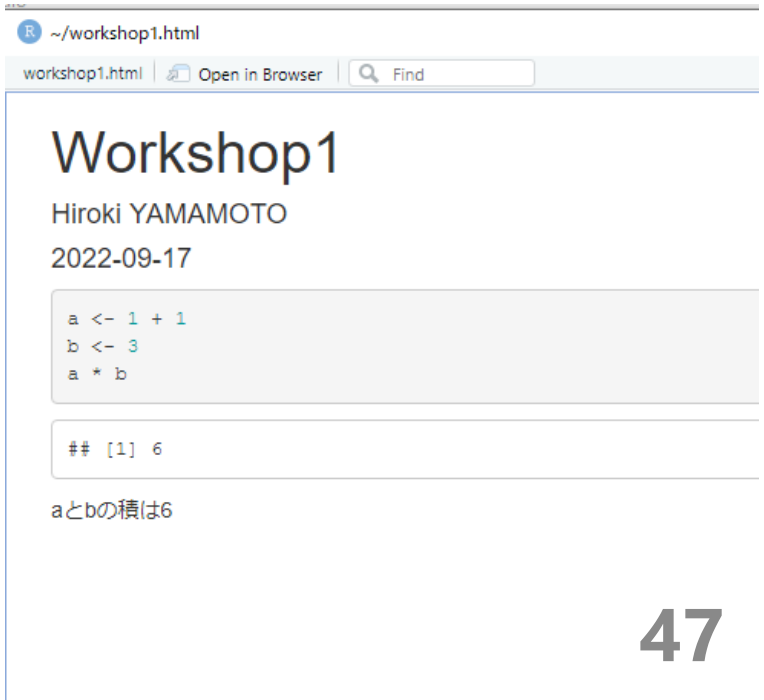

パッケージのインストール

48

パッケージをインストールしよう

❑パッケージ

- ●R用の関数のセット
  - Rのインストール時から備わっているもの
  - ウェブ上からダウンロードして使うもの
  - 分析の目的にあわせて，必要なパッケージを用いる

- ●**install.packages()関数**を使用して、パッケージをインストール
  - パッケージ名をダブルクォーテーション(“”)でくくって指定

- ●tidyverseパッケージをインストールしてみよう
  - **install.packages(“tidyverse”)**

関数とは？

❑関数 (function)

- 「入力」に対して「出力」を返すもの
  - 入力する値のことを「**引数**（ひきすう）」と呼ぶ
  - 引数が複数あることもあり、
    左から「第１引数・第2引数・第3引数…」と呼ばれる

- Rの関数は全て、関数の名前の後にカッコ（）がついた形式
  - 例：install.packages()関数

Tidyverseパッケージとは...

❑データ解析のためのRパッケージ群

Components

パッケージの読み込み

❑library()関数でパッケージを読み込む

- ●パッケージはRを起動するたびに読み込む必要があるので注意。
  - コードの先頭で読み込むことをオススメします。

- **●library(tidyverse)**　　...tidyverseパッケージを読み込む

```
library(tidyverse)
```

```
## -- Attaching packages ---------------------------------------------------------------------------
---------------------------------- tidyverse 1.2.1 --
```

```
## √ ggplot2 2.2.1     √ purrr   0.2.4
## √ tibble  1.4.2     √ dplyr   0.7.4
## √ tidyr   0.8.0     √ stringr 1.3.0
## √ readr   1.1.1     √ forcats 0.3.0
```

tidyverseパッケージに含まれるパッケージ群

```
## -- Conflicts ------------------------------------------------------------------------------------
--------------------------- tidyverse_conflicts() --
## x dplyr::filter() masks stats::filter()
## x dplyr::lag()    masks stats::lag()
```

データフレームの型：ワイド型とロング型

ワイド型データフレーム

地点	6時	12時	18時
札幌			
東京			
福岡			

ロング型データフレーム

地点	時刻	天気
札幌	6時	
札幌	12時	
札幌	18時	
東京	6時	
東京	12時	
東京	18時	
福岡	6時	
福岡	12時	
福岡	18時	

データフレームの型：ワイド型とロング型

ワイド型データフレーム

地点	6時	12時	18時
札幌			
東京			
福岡			

1つの観測

ロング型データフレーム

地点	時刻	天気
札幌	6時	
札幌	12時	
札幌	18時	
東京	6時	
東京	12時	
東京	18時	
福岡	6時	
福岡	12時	
福岡	18時	

1つの観測

Rではロング型が扱いやすい

- ggplot2やdplyrの関数はロング型に対応
  - 第１引数にデータフレームを入れ，列名で変数を指定

    > ggplot(**iris**, aes(x = Sepal.Length, y = Sepal.Width)) +…

  - 列名を指定してデータを抽出する

    > select(iris, **Sepal.Length**, **Species**)

    > filter(iris, **Sepal.Length > 7**)

Rにデフォルトで用意されている
データフレーム「iris」

```
> head(iris)
  Sepal.Length Sepal.Width Petal.Length Petal.Width Species
1          5.1         3.5          1.4         0.2  setosa
2          4.9         3.0          1.4         0.2  setosa
3          4.7         3.2          1.3         0.2  setosa
4          4.6         3.1          1.5         0.2  setosa
5          5.0         3.6          1.4         0.2  setosa
6          5.4         3.9          1.7         0.4  setosa
```

dplyr

データフレームを操作・加工する関数が詰まったパッケージ

①行の一部を取り出す	filter()関数
②列の一部を取り出す	select()関数
③新しい列を追加する	mutate()関数
④データをグループ化する	group_by()関数
⑤データを要約する	summarise()関数

	Sepal.Length	Sepal.Width	Petal.Length	Petal.Width	Species
1	5.1	3.5	1.4	0.2	setosa
2	4.9	3.0	1.4	0.2	setosa
3	4.7	3.2	1.3	0.2	setosa
4	4.6	3.1	1.5	0.2	setosa
5	5.0	3.6	1.4	0.2	setosa
6	5.4	3.9	1.7	0.4	setosa

dplyrの関数を使って
データフレームirisを
加工してみよう

①行の一部を抽出する： filter()関数

- filter()関数
  - 第１引数：データフレームの名前
  - 第２引数以降：抽出したい行を表す条件式

データフレームirisからsetosaのアヤメのデータだけ抽出しよう

```r
filter(iris, Species == "setosa")
```

※文字列の指定には “” ダブルクォーテーションが必要

Rの比較演算子

❑条件式を書く際に使用する記号

記号	意味
==	等しい　※「=」は代入
!=	等しくない
>=	以上
>	より大きい
<=	以下
<	より小さい
%in%	グループメンバシップ

記号	意味
is.na	NA(欠損値)である
!is.na	NA(欠損値)でない
&	かつ
|	または

①行の一部を抽出する： filter()関数

irisからSepal.Lengthが7より大きいデータだけ抽出しよう

```
filter(iris, Sepal.Length > 7) # Sepal.Lengthが7より大きい行を抽出
```

```
##     Sepal.Length Sepal.Width Petal.Length Petal.Width   Species
## 1            7.1         3.0          5.9         2.1 virginica
## 2            7.6         3.0          6.6         2.1 virginica
## 3            7.3         2.9          6.3         1.8 virginica
## 4            7.2         3.6          6.1         2.5 virginica
## 5            7.7         3.8          6.7         2.2 virginica
## 6            7.7         2.6          6.9         2.3 virginica
## 7            7.7         2.8          6.7         2.0 virginica
```

①行の一部を抽出する： filter()関数

filter()関数で複数の条件を指定しよう
「Sepal.Lengthが6.5以上 かつ Speciesがversicolor」の行を抽出

※条件式を ＆ または コンマ で区切る　⇒「かつ」を表す

```
 # Sepal.Lengthが6.5以上かつSpeciesが"versicolor"である行を抽出
filter(iris, Sepal.Length >= 6.5, Species == "versicolor")
```

```
##    Sepal.Length Sepal.Width Petal.Length Petal.Width    Species
## 1           7.0         3.2          4.7         1.4 versicolor
## 2           6.9         3.1          4.9         1.5 versicolor
## 3           6.5         2.8          4.6         1.5 versicolor
## 4           6.6         2.9          4.6         1.3 versicolor
## 5           6.7         3.1          4.4         1.4 versicolor
```

①行の一部を抽出する： filter()関数

filter()関数で複数の条件を指定しよう
「Sepal.Lengthが7以上 または Sepal.Lengthが4以上 」の行を抽出

※条件式を｜（縦線）で区切る　⇒「または」を表す

```
 # Sepal.Lengthが7以上 またはSepal.Lengthが4以上である行を抽出
filter(iris, Sepal.Length >= 7| Sepal.Width >= 4)
```

```
##    Sepal.Length Sepal.Width Petal.Length Petal.Width    Species
## 1           5.8         4.0          1.2         0.2     setosa
## 2           5.7         4.4          1.5         0.4     setosa
## 3           5.2         4.1          1.5         0.1     setosa
## 4           5.5         4.2          1.4         0.2     setosa
## 5           7.0         3.2          4.7         1.4 versicolor
```

②列の一部を抽出する： select()関数

- select()関数
  - 第１引数：データフレームの名前
  - 第２引数以降：抽出したい列名

irisからSpeciesという名前の列だけ抽出しよう

```
select(iris, Species)
```

irisからSpecies，Sepal.Length，Sepal.Widthの列を抽出しよう

```
select(iris, Species, Sepal.Length, Sepal.Width)
```

②列の一部を抽出する： select()関数

指定した列を除外しよう

```
select(iris, -Species)
```

	Sepal.Length	Sepal.Width	Petal.Length	Petal.Width
1	5.1	3.5	1.4	0.2
2	4.9	3.0	1.4	0.2
3	4.7	3.2	1.3	0.2
4	4.6	3.1	1.5	0.2
5	5.0	3.6	1.4	0.2
6	5.4	3.9	1.7	0.4

Sで始まる列名だけ抽出しよう

```
select(iris, starts_with("S"))
```

	Sepal.Length	Sepal.Width	Species
1	5.1	3.5	setosa
2	4.9	3.0	setosa
3	4.7	3.2	setosa
4	4.6	3.1	setosa
5	5.0	3.6	setosa
6	5.4	3.9	setosa

③新しい列を追加する：mutate()関数

❑mutate()関数

・第１引数：データフレーム

第２引数以降：新しい列の名前と追加する内容を指定

各アヤメのがく・花びらの面積を計算し，新規な列に追加しよう

```
mutate(iris,
       Area_Sepal = Sepal.Length * Sepal.Width,
       Area_Petal = Petal.Length * Petal.Width)
```

新規な列名を指定

それぞれの列に，各行の計算結果を代入

Sepal.Length	Sepal.Width	Petal.Length	Petal.Width	Species	Area_Sepal	Area_Petal
5.1	3.5	1.4	0.2	setosa	17.85	0.28
4.9	3.0	1.4	0.2	setosa	14.70	0.28
4.7	3.2	1.3	0.2	setosa	15.04	0.26
4.6	3.1	1.5	0.2	setosa	14.26	0.30
5.0	3.6	1.4	0.2	setosa	18.00	0.28
5.4	3.9	1.7	0.4	setosa	21.06	0.68

③条件ごとに異なる値を追加する

- mutate()関数 + if_else()関数
  - if_else(条件式, TRUEのとき, FALSEのとき)

- Speciesがvirginicaならば"virginica"，それ以外は"NOT virginica"を入れる列Species2を追加しよう

```
mutate(iris,
       Species2 = if_else(Species == "virginica", "virginica", "NOT virginica"))
```

```
##     Sepal.Length Sepal.Width Petal.Length Petal.Width    Species         Species2
## 1            5.1         3.5          1.4         0.2     setosa    NOT virginica
## 2            4.9         3.0          1.4         0.2     setosa    NOT virginica
## 3            4.7         3.2          1.3         0.2     setosa    NOT virginica
## 4            4.6         3.1          1.5         0.2     setosa    NOT virginica
## 5            5.0         3.6          1.4         0.2     setosa    NOT virginica
## 6            5.4         3.9          1.7         0.4     setosa    NOT virginica
## 7            4.6         3.4          1.4         0.3     setosa    NOT virginica
```

④データを一行に要約： summarise()関数

❑summarise()関数

・第１引数：データフレーム

第２引数以降：要約して出力するデータフレームの列の情報

irisのSepal.Lengthの平均と不偏標準偏差を計算し，その結果を新たなデータフレームに要約しよう

```
summarise(iris,
          Mean = mean(Sepal.Length),
          SD = sd(Sepal.Length))
```

```
##       Mean        SD
## 1 5.843333 0.8280661
```

新規な列名 = 関数名(計算したい元の列名)

⑤データをグループ化する：group_by()関数

❑group_by()関数

・第１引数：データフレーム

第２引数以降：グループ化する変数名

irisのデータをSpeciesごとにグループ化しよう

```
group_by(iris, Species)
```

- Speciesでグループ化したirisを，**iris_g**というオブジェクトに代入
- iris_gの頭6行だけを表示

```
iris_g <- group_by(iris, Species)
head(iris_g)
```

変数Speciesでグループ化されていることを表す

```
## # A tibble: 6 × 5
## # Groups:   Species [1]
##   Sepal.Length Sepal.Width Petal.Length Petal.Width Species
##          <dbl>       <dbl>        <dbl>       <dbl> <fct>
## 1          5.1         3.5          1.4         0.2 setosa
## 2          4.9         3            1.4         0.2 setosa
## 3          4.7         3.2          1.3         0.2 setosa
## 4          4.6         3.1          1.5         0.2 setosa
## 5          5           3.6          1.4         0.2 setosa
## 6          5.4         3.9          1.7         0.4 setosa
```

group_by()関数+summarise()関数

グループごとにデータを要約しよう

- group_by()関数でグループ化したデータフレームiris_gを，summarise()関数の第１引数に渡す

```
iris_g <- group_by(iris, Species)

summarise(iris_g,
          Mean = mean(Sepal.Length),
          SD = sd(Sepal.Length))
```

SpeciesごとにMeanとSDが計算されている

```
# A tibble: 3 × 3
  Species      Mean    SD
  <fct>       <dbl> <dbl>
1 setosa       5.01 0.352
2 versicolor   5.94 0.516
3 virginica    6.59 0.636
```

データフレームToothGrowth

モルモットにビタミンCかジュースを投与し，歯の長さ(**len**)を記録

- ❑投与物(**supp**)：ビタミンC（VC） / オレンジジュース（OJ）の2水準
- ❑投与量(**dose**)：0.5 / 1.0 / 2.0 mgの3水準

```
> head(ToothGrowth)
   len supp dose
1  4.2   VC  0.5
2 11.5   VC  0.5
3  7.3   VC  0.5
4  5.8   VC  0.5
5  6.4   VC  0.5
6 10.0   VC  0.5
```

ToothGrowthをdoseとsuppの2変数でグループ化しよう

- group_by()関数
  - 第１引数：データフレーム
  - 第２引数以降：グループ化する変数名

```
TG_g <- group_by(ToothGrowth, dose, supp)
head(TG_g)
```

一旦別のデータフレームに格納

頭6行だけを表示

```
# A tibble: 6 × 3
# Groups:   dose, supp [1]
    len supp   dose
  <dbl> <fct> <dbl>
1   4.2 VC      0.5
2  11.5 VC      0.5
3   7.3 VC      0.5
4   5.8 VC      0.5
5   6.4 VC      0.5
6  10   VC      0.5
```

変数doseと変数suppの2変数でグループ化された

group_by()関数+summarise()関数

❑2変数でグループ化したデータフレームTG_gをsummarise()関数に渡し，条件ごとに要約統計量を計算する

```
TG_g <- group_by(ToothGrowth, dose, supp)

summarise(TG_g,
          Mean = mean(len),
          Median = median(len),
          Variance = var(len),
          SD = sd(len))
```

```
# A tibble: 6 × 6
# Groups:   dose [3]
   dose supp   Mean Median Variance    SD
  <dbl> <fct> <dbl>  <dbl>    <dbl> <dbl>
1   0.5 OJ     13.2   12.2     19.9  4.46
2   0.5 VC      7.98   7.15     7.54 2.75
3   1   OJ     22.7   23.5     15.3  3.91
4   1   VC     16.8   16.5      6.33 2.52
5   2   OJ     26.1   26.0      7.05 2.66
6   2   VC     26.1   26.0     23.0  4.80
```

dose（3水準）×supp（2水準）ごとに平均値，中央値，不偏分散，不偏標準偏差が計算されている

group_by()関数+mutate()関数

- グループごとに新しい列の値を追加する
  - group_by()関数で出力したデータフレームをmutate()関数の第１引数へ

```
iris_g <- group_by(iris, Species)
mutate(iris_g,
       Mean = mean(Sepal.Length)) # 平均値
```

```
## # A tibble: 150 x 6
## # Groups:   Species [3]
##    Sepal.Length Sepal.Width Petal.Length Petal.Width Species  Mean
##           <dbl>       <dbl>        <dbl>       <dbl> <fct>   <dbl>
##  1          5.10        3.50         1.40       0.200 setosa   5.01
##  2          4.90        3.00         1.40       0.200 setosa   5.01
##  3          4.70        3.20         1.30       0.200 setosa   5.01
##  4          4.60        3.10         1.50       0.200 setosa   5.01
##  5          5.00        3.60         1.40       0.200 setosa   5.01
##  6          5.40        3.90         1.70       0.400 setosa   5.01
```

ungroup()関数：グループ化を解除

❑ungroup()関数

・第１引数：グループ化されたデータフレーム

```
iris_g <- group_by(iris, Species)
ungroup(iris_g)
```

グループ化されていない

```
## # A tibble: 150 x 5
##    Sepal.Length Sepal.Width Petal.Length Petal.Width Species
##           <dbl>       <dbl>        <dbl>       <dbl> <fct>
##  1          5.10        3.50         1.40       0.200 setosa
##  2          4.90        3.00         1.40       0.200 setosa
##  3          4.70        3.20         1.30       0.200 setosa
##  4          4.60        3.10         1.50       0.200 setosa
##  5          5.00        3.60         1.40       0.200 setosa
##  6          5.40        3.90         1.70       0.400 setosa
```

パイプ演算子を使ったパイプ処理

パイプ演算子（Win: Ctrl+Shift+**M**，Mac: ⌘+Shift+**M**）

- tidyverse内のmagrittrパッケージで扱える
- 前の値を，後ろの関数の第一引数として渡す


```
%>%
```

- 上下のコマンドはそれぞれ同じ意味になる

```
head(iris)

iris %>% head()
```

```
filter(iris, Species == "setosa")

iris %>% filter(Species == "setosa")
```

パイプ演算子を使ったパイプ処理

パイプ演算子

- tidyverseの関数は第1引数がデータフレーム
- 関数間のデータフレームの受け渡しがスムーズ
- いちいちデータフレームを作る必要がない
- 複数の処理をパイプライン化してひと繋がりにできる

以下のコマンドをパイプ演算子を使って書いてみよう

① irisのうちSepal.Lengthが5より大きい行を抽出する
② Speciesごとにグループ化する
③ グループごとにSepal.LengthのMeanとSDを計算する

```
iris_2 <- filter(iris, Sepal.Length > 5)

iris_g <- group_by(iris_2, Species)

summarise(iris_g,
          Mean = mean(Sepal.Length),
          SD = sd(Sepal.Length))
```

```
iris %>%
  filter(Sepal.Length > 5) %>%
  group_by(Species) %>%
  summarise(Mean = mean(Sepal.Length),
            SD = sd(Sepal.Length))
```

dplyrでデータフレームを操作

紹介したdplyrの関数

- ❑行の一部を取り出す　filter()関数
- ❑列の一部を取り出す　select()関数
- ❑新しい列を追加する　mutate()関数
- ❑データをグループ化　group_by()関数
- ❑データを要約する　summarise()関数

関数の合わせ技

- group_by() + summarise()
- group_by() + mutate()
- mutate() + if_else()

その他Tips

- 行を並び替える　arrange()関数
- 列名を変える　rename()関数
- 欠損値を除外　filter(df, !is.na(列名))
- パイプ演算子　%>%

R Markdownをknitして
htmlを出力しましょう