文系のための R セミナー

第 1 回　R をはじめてみよう：ベクトル操作まで(7/15(火)，18(金))

R 概説

環境構築

簡単な計算

ベクトル作成と簡単な操作

スクリプトファイルの保存 5 分

第 2 回　データの可視化をしてみよう(7/22(火), 25(金))

環境構築 5 分?

- Posit Cloud の登録

クラスと関数　5 分

- R で扱うデータはすべてクラスに分類される
- 関数のネスト

データフレームの操作 15 分

- データフレームとは
- データフレームを概観する基本的な関数
- 列の操作
- 行の操作

データのビジュアライゼーション 20 分

- 散布図の基本的な書き方
- パッケージの導入
- ggplot2 を使った散布図の描き方

R 概要

そもそも R とは、**統計解析**や**データ可視化**に特化したプログラミング言語で、**無償**で利用できます。現在人気のある Python などの汎用プログラミング言語と比べると、アプリ開発などには向いていませんが、回帰分析や時系列分析、仮説検定など統計の基礎から高度な手法まで幅広く対応しています。

エクセルでも基本的な回帰分析はできますが、R を使うことで、テキストデータや空間データの分析も扱うことができます。またエクセルは表計算ソフトですので、直感的に使うことができますが、自分が行った作業の過程が少し分かりにくいところがあります。他方、R はコードを書くという行為が挟まる分、手間はかかりますが、**分析の過程が記録され作業の工程をあとから確認することができます。**さらに**同じ作業を別のデータ分析に再利用**することができます。

	R	Excel	Python
使用タイミング	統計分析、学術研究	幅広い業務、教育統計	データ分析、Web・AI開発
費用	無料	有料	無料
特徴	・統計分析に特化 ・グラフや図の可視化が簡単 ・文章で残しやすい	・直感的な操作 ・マクロが使える	・ライブラリが豊富 ・機械学習やAI分野で主流
習得難易度	慣れるのに少し時間がかかる	簡単	直感的
汎用性	○ 統計分析のみ	△ 統計や機械学習は苦手	◎ 統計・機械学習・Web開発など幅広く対応
グラフ作成	◎ 簡単・キレイに作成可能	△ 簡単に作図可能。ただし微調整が難しい	○ Rに比べるとやや難しい

Posit Cloud の登録

R はインストールすれば単体でもすぐに分析することができます。しかし、コードが書きにくかったり、R で一番やりたい統計分析のためのデータの読み込みが少し大変だったりします。なので、一般的には **RStudio** と呼ばれるソフトウェアをダウンロードして利用します。このようなソフトを **IDE**(Integrated Development Environment、統合開発環境)と呼びます。RStudio は R をより便利に使うためのソフトで、これから行う分析をより簡単に便利に行うことができます。プログラミング言語を学習することはまさしく言語を学ぶことに近く、IDE は言語の学習と実践的な利用をサポートしてくれる環境であり、これを活用すればより効率的に R を学べます。RStudio を用意するなど、R を始めとしたプロ

グラミング言語を自分のパソコンで利用できるようにすることを**環境構築**といいますが、人によってとても時間がかかる場合があります。ですので、今回は **Posit Cloud** (https://posit.cloud) というサービスを利用します。Posit Cloud とは、RStudio をブラウザ上で利用することができるサービスで、RStudio を管理している団体が運営しています。サービスに多少制限はありますが、無料でも利用できるので、今回はこちらを利用します。まず、Posit Cloud のサイトにアクセスし、画面右上の「Log in」を選択します。

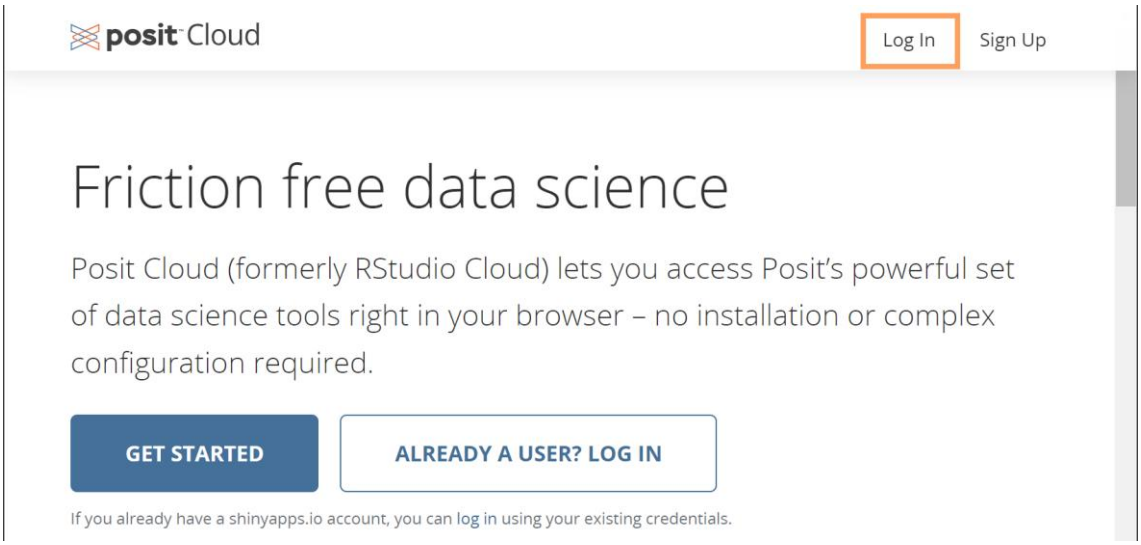

図 1. Posit Cloud のトップページ

次に「Sign Up」を選択し、画面上部に必要情報を入力するか、Google アカウントを持っている方は下の「Sign Up with Google」から手続きを進めてください。 Google アカウント以外で登録(Sign up)を行った場合は、差出人”noreply@posit.cloud”から件名”Please verify your email address”というメールが届きます。メール本文中の”Verify your email”と書かれたリンクをクリックすると、承認完了です。

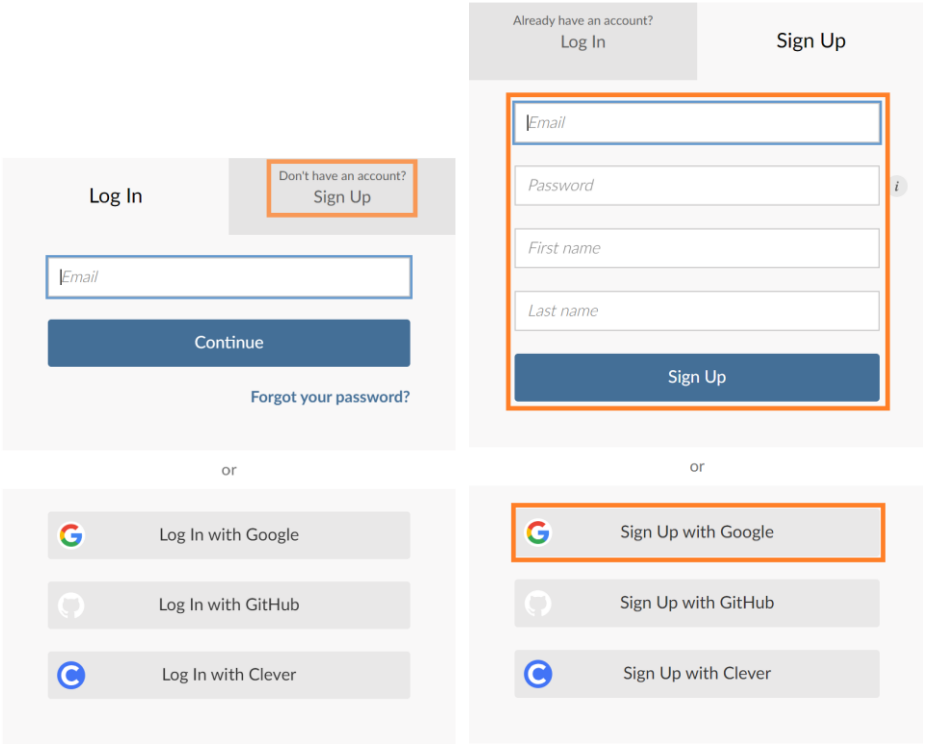

図 2．利用登録(サインアップ)画面

登録が完了し、ログインができれば、図 3 のような画面が表示されるはずです。

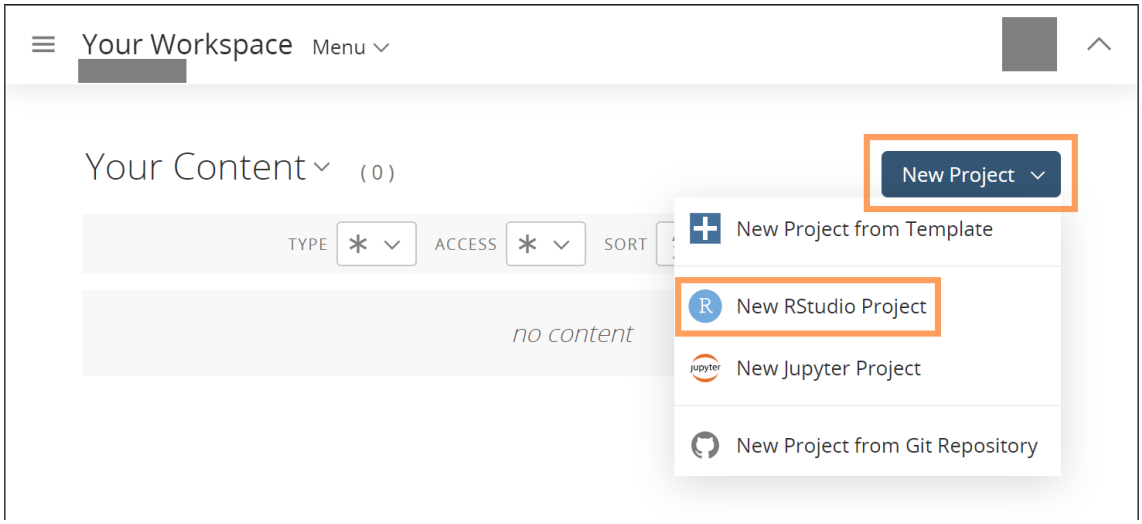

図 3．プロジェクト選択

画面右上の「New Project」を選択し、表示されたリストから「New RStudio Project」を選択してください。(次の画面の立ち上げまで多少時間がかかります)
その後、次のような画面が表示されるはずです。

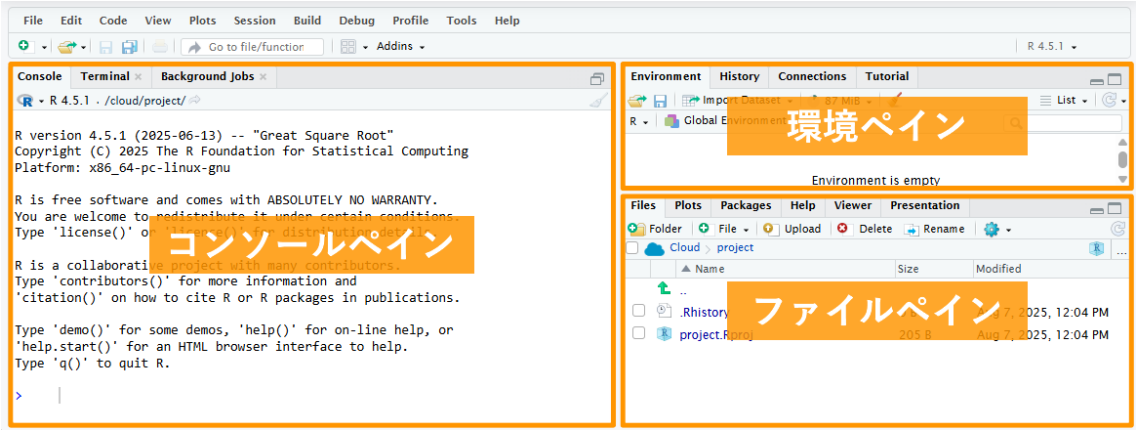

図 4．RStudio の基本画面

RStudio のウィンドウは、**ペイン(pane)**と呼ばれるいくつかの領域から成り立っています。それぞれの役割については都度、解説していきます。

これで今回の環境構築は完了です！

クラスと関数

R で扱う、「1000」という数値や「大阪」という文字列のような値(value)は、それぞれ**クラス(class)**に分類されています。クラスごとに扱える関数が異なっており、クラスには主に以下のような種類があります。

R の主なクラス

クラス名	説明
character	文字列型（テキストデータ）
numeric	数値型（小数を含む数値データ）
logical	論理型（TRUE または FALSE）
factor	カテゴリデータ型
data.frame	表形式のデータ型

クラスは**class()関数**を用いることで確認することができます。

```
class("The Uniersity of Osaka")
## [1] "character"
class(122)
## [1] "numeric"
a <- "renshu"
class(a) # 変数の場合は中身のクラスが参照される。
## [1] "character"
```

関数(function)とは、入力を受け取り、それに対して何らかの処理を加え、その結果として出力を**返す(return)**仕組みのことです。関数の括弧内に入力する値を**引数(ひきすう、argument)**といいます。例えば、class()関数であれば、丸括弧内で受け取った値のクラスを返しますし、**c()関数**であれば、数値や文字列などの 1 つ以上の値を引数として受け取り、ベクトルという 1 つのオブジェクトとしてまとめて返します。このように、関数はさまざまな入力を受け取り、特定の処理を行って結果を返す便利なツールです。関数があらかじめよく使う作業をまとめてくれているおかげで、簡単にデータ分析できます。

それでは、データの要約を見るのに使用する基本的な関数をいくつか紹介します。

```
vec1 <- c(1, 2, 3, 4, 5)
length(vec1) # ベクトルの長さ、すなわちベクトル内の要素の数を返す。
## [1] 5
range(vec1)  # ベクトル内の値の範囲(range)を返す。
## [1] 1 5
mean(vec1)   # 平均値(mean)を返す。
## [1] 3
```

これらの関数に引数を渡す場合、関数側では引数に名前を割り当てており、この**引数名を明示**して引数を渡すことができます。

```
mean(x = vec1) #左側が引数名。関数側であらかじめ名前が決まっている。
## [1] 3
length(x = vec1)
## [1] 5
```

引数が 1 つだけのときは省略しても問題ありませんが、後で出てくる関数では引数が複数あるものもあり、明示して書くと読みやすくなります。

また、関数は**ネスト(入れ子)**して使うことができます。関数の処理は内側から進んでいきます。

```
length(c(1, 3, 5, 7, 9)) # 始めに、(1, 3, 5, 7, 9)のベクトルを作成(c()関数)し、次にそのベクトルの長さを出力(length()関数)する。
## [1] 5
sqrt(length(c(1, 3, 5, 7, 9))) # 上記処理に加えて、最後にベクトルの長さの平方根を取っている(sqrt()関数)。
## [1] 2.236068
```

データフレームの操作

それでは、エクセルで扱うようなデータフレームの簡単な操作とグラフ化を行いましょう。今回は、mtcars という、1974 年に発行されたアメリカの「Motor Trend」誌に記載された、自動車の性能に関する情報をまとめたものを扱ってみましょう。

```
##                   mpg cyl  disp  hp drat    wt  qsec vs am gear carb
## Mazda RX4         21.0   6 160.0 110 3.90 2.620 16.46  0  1    4    4
## Mazda RX4 Wag     21.0   6 160.0 110 3.90 2.875 17.02  0  1    4    4
## Datsun 710        22.8   4 108.0  93 3.85 2.320 18.61  1  1    4    1
## Hornet 4 Drive    21.4   6 258.0 110 3.08 3.215 19.44  1  0    3    1
## Hornet Sportabout 18.7   8 360.0 175 3.15 3.440 17.02  0  0    3    2
## Valiant           18.1   6 225.0 105 2.76 3.460 20.22  1  0    3    1
## Duster 360        14.3   8 360.0 245 3.21 3.570 15.84  0  0    3    4
## Merc 240D         24.4   4 146.7  62 3.69 3.190 20.00  1  0    4    2
## Merc 230          22.8   4 140.8  95 3.92 3.150 22.90  1  0    4    2
## Merc 280          19.2   6 167.6 123 3.92 3.440 18.30  1  0    4    4
```

mtcars の変数

変数名	内容
mpg	1 ガロンあたりの走行距離（マイル）
cyl	シリンダー数
disp	排気量（立方インチ）
hp	馬力
drat	リアアクスル比
wt	車体重量（1000 ポンド単位）
qsec	1/4 マイルの加速時間（秒）
vs	エンジン形状（0 = V 型, 1 = 直列）
am	トランスミッション（0 = 自動, 1 = 手動）
gear	ギア数
carb	キャブレター数

R は統計分析を目的としたプログラミング言語ですので、実は最初から統計分析を学習するためのデータフレームが組み込まれています。プログラミング「言語」に、データセットが入っているのは奇妙な感じがしますが、言語のような規則は存在しつつも、あくまで R は統計分析をするための機能を提供するものですので、それを学習するためのデータ

も同梱されています。ではデータフレームを変数に入れてクラスを確かめてみましょう。変数名は何でもいいですが、ここでは df(data frame の略)としましょう。

```
df <- mtcars # 変数 df に mtcars データセットを入れる。
class(df)
## [1] "data.frame"
```

クラスを確認すると「data.frame(**データフレーム**)」と表示されました。データフレームとは、「**同じ長さ**の複数のベクトルを**列**として一つにまとめた**２次元データ構造**」です。要するに、エクセルやスプレッドシートで作った表みたいなものです。分析に移る前に、まず読み込んだデータフレームがどのようなものか、関数を使って概観しましょう。

dim()関数 :データフレームの行数と列数をベクトル形式で返す。(行は横のまとまり、列は縦のまとまり)

```
dim(df)
## [1] 32 11
```

head()関数 :データフレームの冒頭 6 行を返す。

```
head(df)
##                   mpg cyl disp  hp drat    wt  qsec vs am gear carb
## Mazda RX4         21.0   6  160 110 3.90 2.620 16.46  0  1    4    4
## Mazda RX4 Wag     21.0   6  160 110 3.90 2.875 17.02  0  1    4    4
## Datsun 710        22.8   4  108  93 3.85 2.320 18.61  1  1    4    1
## Hornet 4 Drive    21.4   6  258 110 3.08 3.215 19.44  1  0    3    1
## Hornet Sportabout 18.7   8  360 175 3.15 3.440 17.02  0  0    3    2
## Valiant           18.1   6  225 105 2.76 3.460 20.22  1  0    3    1
```

summary()関数:各列の最小値、第 1 四分位数、中央値、第 3 四分位数、最大値を返す。

```
summary(df)
##       mpg             cyl             disp             hp
##  Min.   :10.40   Min.   :4.000   Min.   : 71.1   Min.   : 52.0
##  1st Qu.:15.43   1st Qu.:4.000   1st Qu.:120.8   1st Qu.: 96.5
##  Median :19.20   Median :6.000   Median :196.3   Median :123.0
##  Mean   :20.09   Mean   :6.188   Mean   :230.7   Mean   :146.7
##  3rd Qu.:22.80   3rd Qu.:8.000   3rd Qu.:326.0   3rd Qu.:180.0
##  Max.   :33.90   Max.   :8.000   Max.   :472.0   Max.   :335.0
```

```
##       drat             wt             qsec             vs
##  Min.   :2.760   Min.   :1.513   Min.   :14.50   Min.   :0.0000
##  1st Qu.:3.080   1st Qu.:2.581   1st Qu.:16.89   1st Qu.:0.0000
##  Median :3.695   Median :3.325   Median :17.71   Median :0.0000
##  Mean   :3.597   Mean   :3.217   Mean   :17.85   Mean   :0.4375
##  3rd Qu.:3.920   3rd Qu.:3.610   3rd Qu.:18.90   3rd Qu.:1.0000
##  Max.   :4.930   Max.   :5.424   Max.   :22.90   Max.   :1.0000
##        am              gear            carb
##  Min.   :0.0000   Min.   :3.000   Min.   :1.000
##  1st Qu.:0.0000   1st Qu.:3.000   1st Qu.:2.000
##  Median :0.0000   Median :4.000   Median :2.000
##  Mean   :0.4062   Mean   :3.688   Mean   :2.812
##  3rd Qu.:1.0000   3rd Qu.:4.000   3rd Qu.:4.000
##  Max.   :1.0000   Max.   :5.000   Max.   :8.000
```

str()関数：データフレームの行数、列数、列ごとのクラスと含まれるデータの冒頭 10 行を示す。

```
str(df)
## 'data.frame':    32 obs. of  11 variables:
##  $ mpg : num  21 21 22.8 21.4 18.7 18.1 14.3 24.4 22.8 19.2 ...
##  $ cyl : num  6 6 4 6 8 6 8 4 4 6 ...
##  $ disp: num  160 160 108 258 360 ...
##  $ hp  : num  110 110 93 110 175 105 245 62 95 123 ...
##  $ drat: num  3.9 3.9 3.85 3.08 3.15 2.76 3.21 3.69 3.92 3.92 ...
##  $ wt  : num  2.62 2.88 2.32 3.21 3.44 ...
##  $ qsec: num  16.5 17 18.6 19.4 17 ...
##  $ vs  : num  0 0 1 1 0 1 0 1 1 1 ...
##  $ am  : num  1 1 1 0 0 0 0 0 0 0 ...
##  $ gear: num  4 4 4 3 3 3 3 4 4 4 ...
##  $ carb: num  4 4 1 1 2 1 4 2 2 4 ...
```

obs.(observations):「観測値」という意味でここではデータフレームの行数を示します。

variables:「変数」という意味で、データフレームの列数を指します。

実際にデータ分析をするときにも、以上のような関数を用いて、分析したいデータフレームが本当に読み込めているか、数値クラスが文字列クラスとして読み込まれていないかなどを確かめます。関数を使う以外に、エクセルやスプレッドシートのようにデータフレーム全体を確認する方法もあります。

```
View(df) #「V」は大文字! 画面右上の environment ペインから直接見ることもできる。
```

先述したように、データフレームはベクトルを列としてまとめた集合であり、今回読み込んだデータフレームは 11 個のベクトルが 1 つの表形式にまとめられたものです。ここで、**$演算子**を使うことで、データフレーム内の個別の変数(列)を抜き出し、ベクトルとして扱うことができます。それでは、データフレームから mpg 列(mile per gallon, 1 ガロン当たり何マイル進めるか = 燃費)を抜き出し、1 リットル当たり何キロメートル進めるかという値に変換しましょう。

データフレーム名$変数名

```
df$mpg
##  [1] 21.0 21.0 22.8 21.4 18.7 18.1 14.3 24.4 22.8 19.2 17.8 16.4 17.3 15.2 1
0.4
## [16] 10.4 14.7 32.4 30.4 33.9 21.5 15.5 15.2 13.3 19.2 27.3 26.0 30.4 15.8 1
9.7
## [31] 15.0 21.4
mpg <- df$mpg
kmpl <- (mpg * 1.60934) / 3.78541 # kilometers per liter
kmpl
##  [1]  8.928000  8.928000  9.693257  9.098057  7.950171  7.695086  6.079543
##  [8] 10.373486  9.693257  8.162743  7.567543  6.972343  7.354971  6.462171
## [15]  4.421486  4.421486  6.249600 13.774628 12.924343 14.412343  9.140571
## [22]  6.589714  6.462171  5.654400  8.162743 11.606400 11.053714 12.924343
## [29]  6.717257  8.375314  6.377143  9.098057
```

それでは作成した kmpl ベクトルを df に追加してみましょう。列を抜き出した際と同じように、新たに列を追加するには、ベクトル名を指定し、そこに代入します。コードではベクトル名と同じ「kmpl」としていますが、他のベクトル名でも構いません。ただし、既存の列名にすると上書きしてしまうので、気を付けてください。

```
df$kmpl <- kmpl
str(df)
## 'data.frame':    32 obs. of  12 variables:
##  $ mpg : num  21 21 22.8 21.4 18.7 18.1 14.3 24.4 22.8 19.2 ...
##  $ cyl : num  6 6 4 6 8 6 8 4 4 6 ...
##  $ disp: num  160 160 108 258 360 ...
##  $ hp  : num  110 110 93 110 175 105 245 62 95 123 ...
##  $ drat: num  3.9 3.9 3.85 3.08 3.15 2.76 3.21 3.69 3.92 3.92 ...
##  $ wt  : num  2.62 2.88 2.32 3.21 3.44 ...
##  $ qsec: num  16.5 17 18.6 19.4 17 ...
##  $ vs  : num  0 0 1 1 0 1 0 1 1 1 ...
##  $ am  : num  1 1 1 0 0 0 0 0 0 0 ...
##  $ gear: num  4 4 4 3 3 3 3 4 4 4 ...
##  $ carb: num  4 4 1 1 2 1 4 2 2 4 ...
##  $ kmpl: num  8.93 8.93 9.69 9.1 7.95 ...
```

また行を抜き出す場合、df[抜き出したい行,]のように指定します。

```
df[1, ] #1 行目を抜き出す。
##           mpg cyl disp  hp drat   wt  qsec vs am gear carb  kmpl
## Mazda RX4  21   6  160 110  3.9 2.62 16.46  0  1    4    4 8.928
df[1] # コンマを入れ忘れると列の抜き出しになってしまいます。
##                     mpg
## Mazda RX4          21.0
## Mazda RX4 Wag      21.0
## Datsun 710         22.8
## Hornet 4 Drive     21.4
## Hornet Sportabout  18.7
## （以下略）
```

```r
df[2:4, ] # 連続した行を抜き出す場合は「:(コロン)」で範囲指定します。
```

```
##                 mpg cyl disp  hp drat    wt  qsec vs am gear carb     kmpl
## Mazda RX4 Wag  21.0   6  160 110 3.90 2.875 17.02  0  1    4    4 8.928000
## Datsun 710     22.8   4  108  93 3.85 2.320 18.61  1  1    4    1 9.693257
## Hornet 4 Drive 21.4   6  258 110 3.08 3.215 19.44  1  0    3    1 9.098057
```

```r
df[df$cyl == 6, ] # 今回の講習内では扱いませんが、条件を指定して抜き出すことも可能です。これは cyl の値が 6 のみの行を抜き出しています。
```

```
##                 mpg cyl  disp  hp drat    wt  qsec vs am gear carb     kmpl
## Mazda RX4      21.0   6 160.0 110 3.90 2.620 16.46  0  1    4    4 8.928000
## Mazda RX4 Wag  21.0   6 160.0 110 3.90 2.875 17.02  0  1    4    4 8.928000
## Hornet 4 Drive 21.4   6 258.0 110 3.08 3.215 19.44  1  0    3    1 9.098057
## Valiant        18.1   6 225.0 105 2.76 3.460 20.22  1  0    3    1 7.695086
## Merc 280       19.2   6 167.6 123 3.92 3.440 18.30  1  0    4    4 8.162743
## Merc 280C      17.8   6 167.6 123 3.92 3.440 18.90  1  0    4    4 7.567543
## Ferrari Dino   19.7   6 145.0 175 3.62 2.770 15.50  0  1    5    6 8.375314
```

データのビジュアライゼーション

では最後に、このデータフレームを使って散布図を作成してみましょう！下のコードを入力してみてください。

```
plot(x = df$mpg, y = df$wt) # コンマで区切るよう注意してください。
```

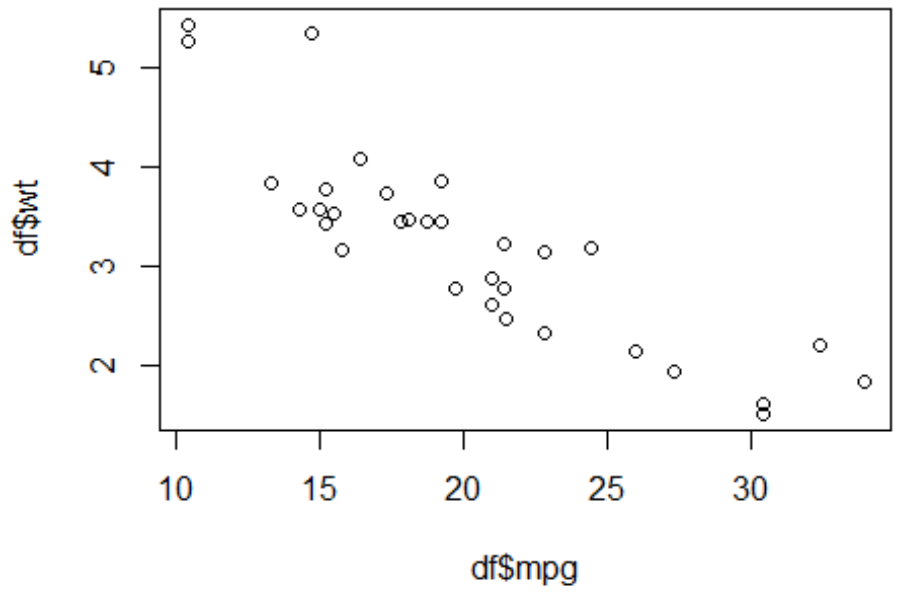

これは**散布図(scatter plot)**で、x 軸に燃費(1 ガロンあたりの距離(マイル))、y 軸に車体重量(単位：1000 ポンド)の値が入っています。ここまで関数に入れる引数は基本的に 1 種類だけでしたが、plot()関数のように複数種類の引数を受け取ることができるものがあります1。引数が複数ある場合、上記コードのように書くことで、「x(軸)には mpg ベクトル、y(軸)には wt ベクトル」と、渡した引数がどこに代入したいものかを明示して渡すことができます。引数を明示するのは面倒かもしれませんが、結果的にコード作成しているときや後から読むときに混乱せずに済みます。

---

1 c()関数は複数の要素を受け取りましたが、いずれも「ベクトルの要素」という意味では 1 種類です。対して、plot()関数は x 軸のデータ、y 軸のデータ、グラフのタイトルのように複数種類の引数を受け取ることができます。

同じように散布図を書くにしても、より便利に、より柔軟に書く方法が R には備わっています。R では、これまでに使ってきた基本機能以外は**パッケージ**という形で**CRAN**(Comprehensive R Archive Network)というサイトに置いてあります。**install.packages()関数**を使うことで、引数に入力したパッケージをそのサイトから取ってきてインストールすることができます。そして **library()関数**でパッケージを使えるように読み込むことができます。

ここでは、**ggplot2** という、グラフを書くためのパッケージを使ってみます。

```
# パッケージのインストール。パッケージ名は引用符で囲む。
# 「Warning～」となにやら不穏当な表示が出ますが、単なる注意喚起ですので、気にしないで大丈夫です。
install.packages('ggplot2')
library(ggplot2) # パッケージの読み込み。クォーテーションで囲まなくて良い
##
## Attaching package: 'ggplot2'
## The following object is masked _by_ '.GlobalEnv':
##
##     mpg
```

ggplot2 を使って、もう一度散布図を書いてみましょう。

```
# ggplot()関数内の引数や関数のネストが複雑になっているので、注意して入力してください。
# 見やすさのために「+」で改行しています。「+」まで入力した後、Enter を押すことで、
# 自動的に少し字下げ(インデント)した状態でコードのつづき　が入力できるはずです。
ggplot(data = df, mapping = aes(x = mpg, y = wt)) +
  geom_point()
```

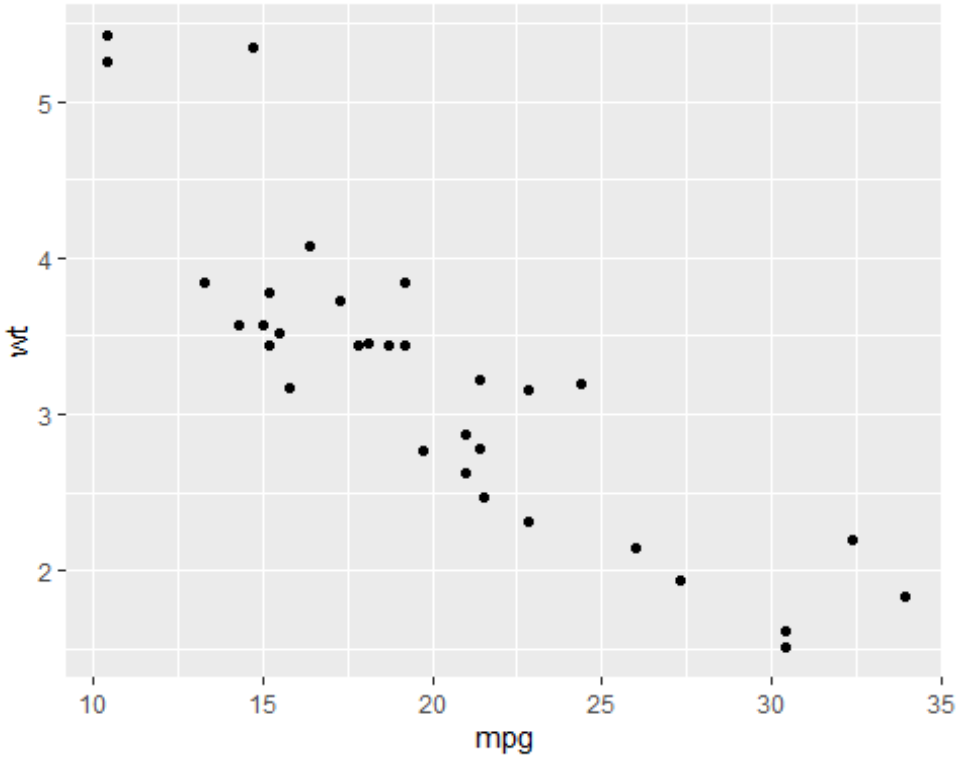

先ほどの散布図のコードよりも長くなりましたが、これが ggplot2 で散布図を書くための最低限のコードです。一つずつ解説します。まず、**ggplot()関数**はグラフを書くためのベースを用意する関数です。絵のキャンバスを用意するようなイメージです。data 引数はグラフ描画対象のデータセットを指定します。mapping 引数では指定したデータセット内の引数で x 軸と y 軸に割り当てる列を選びます。その際、**aes()関数(aesthetic、美的の意)**を用いて指定します。ggplot()関数でグラフの基本情報が設定出来たら、次にどのように描画するかを決めます。今回は散布図を描きたいので、**geom_point()関数**を用いました。このとき、両関数を + でつなぎます。これ以外にもヒストグラムを描く**geom_histogram()**関数や、折れ線グラフを描くための、**geom_bar()関数**といった関数など様々用意されています。

このグラフをもう少し分析チックにするために、次に車のシリンダー数(cyl)毎に点を塗り分けてみましょう。次のコードのように、aes()関数に color 引数を追加し、塗分けの基準とする cyl 変数を追加します。ただし、このままだと cyl 変数は連続的に変化する変数とみなされてしまい、データセットに存在しないシリンダー数 7 まで凡例に表示されてしまいます(左図)。ですので、**factor()関数**を使い、変数を離散的な値(カテゴリー型)に変換しましょう(右図)。

```
# 左図
ggplot(data = mtcars, mapping = aes(x = wt, y = mpg, color = cyl)) +
  geom_point()

# 右図
# 左図のコードの color 引数が cyl→factor(cyl)となっています。
# コードのネストが深くなっているので入力ミスが無いか注意しましょう。
ggplot(data = mtcars, mapping = aes(x = wt, y = mpg, color = factor(cyl))) +
  geom_point()
```

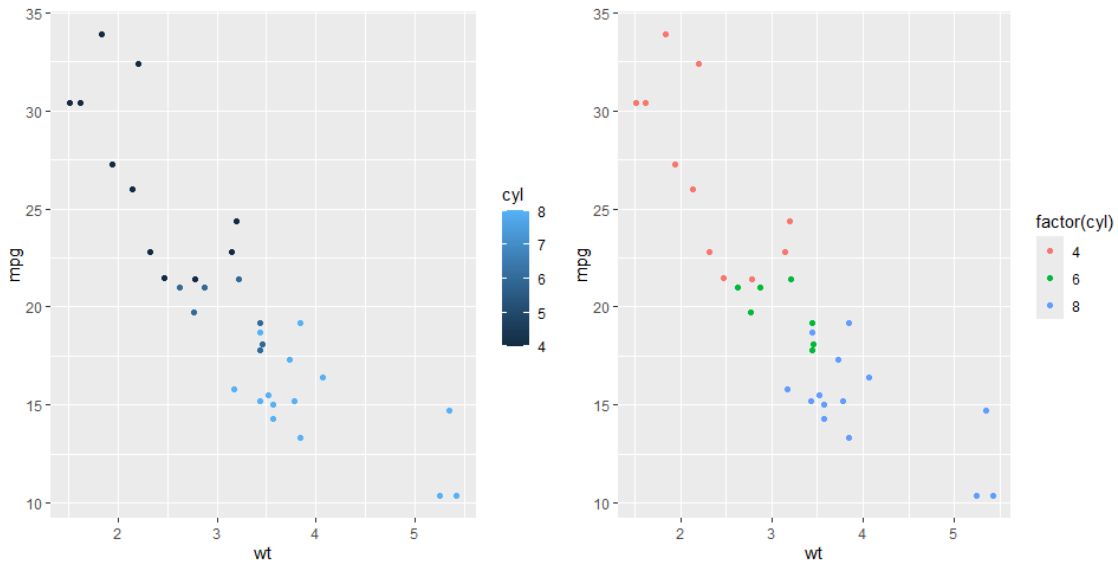

ここに更に手を加えて、グラフを分析結果として見やすくまとめましょう。まず、散布図の点が少し小さくて見づらいので、geom_point()関数で size 引数を指定して、点を少し大きくします。次に、散布図自体のタイトルと、x 軸と y 軸のラベルを付けて、グラフの内容がすぐ分かるようにします。また、凡例部分の名称も分かりやすいものにしましょう。これらの作業は、**labs()関数**を用いることで実行できます。

```
ggplot(data = mtcars, mapping = aes(x = wt, y = mpg, color = factor(cyl))) +
  geom_point(size = 2) +
  labs(title = "Fuel Efficiency by Car Weight", # グラフのタイトル
       x = "Weight(1000 lbs)",                  # x 軸のラベル
       y = "Fuel Efficiency(miles per gallon)", # y 軸のラベル
       color = "Number of Cylinders")           # 凡例のラベル
```

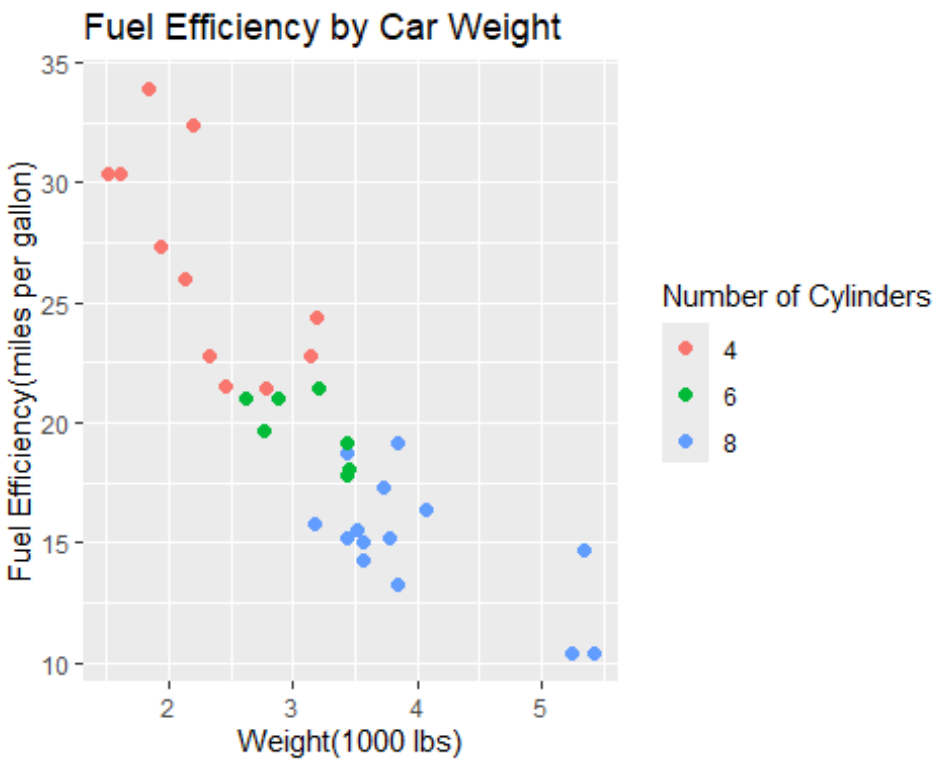

このように、ggplot2 パッケージにはグラフをキレイに描くための多くの機能が備わっています。ちなみに、同じようなものを先ほど散布図を作ったデフォルトの R の機能でやろうとすると、次のようなやや煩雑なコードになってしまいます。

```
df <- mtcars
colors <- c("red", "green", "blue")  # シリンダー数ごとの色を指定
```

```r
cyl_factors <- as.factor(df$cyl)    # シリンダー数を因子型に変換
color_mapping <- colors[cyl_factors]

# 散布図の作成
plot(x = df$wt, y = df$mpg,
     col = color_mapping,                    # 色をシリンダー数に基づいて設定
     pch = 16,                               # 点の形状を設定
     cex = 1.5,                              # 点のサイズ
     main = "Fuel Efficiency by Car Weight", # タイトル
     xlab = "Weight(1000 lbs)",                 # X軸ラベル
     ylab = "Fuel Efficiency(miles per gallon)" # Y軸ラベル
)

# 凡例を追加
legend("topright",
       legend = levels(cyl_factors),  # シリンダー数のラベル
       col = colors,                  # 色を対応付け
       pch = 16,                      # 点の形状
       title = "Number of Cylinders"
)
```

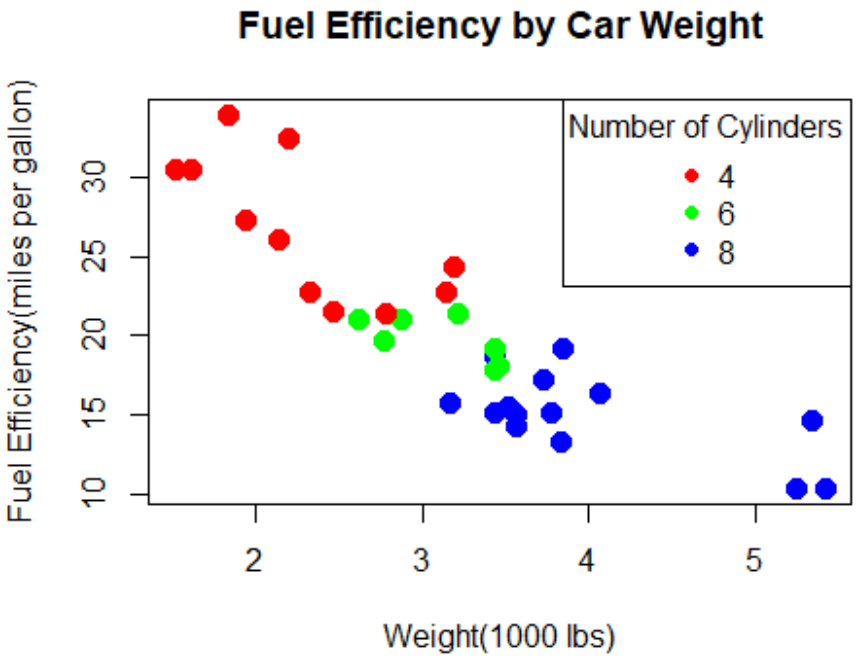

参考資料

書籍

- **浅野正彦・矢内勇生**（2018）『R による計量政治学』オーム社
- **今井耕助**（2018）『社会科学のためのデータ分析入門 上：Quantitative Social Science: An Introduction』（粕谷祐子・原田勝孝・久保浩樹 訳）岩波書店
- **Wilke, Claus O.**（2022）『データビジュアライゼーションの基礎：明確で、魅力的で、説得力のあるデータの見せ方・伝え方』（小林儀匡・瀬戸山雅人 訳）オライリー・ジャパン
- **掌田津耶乃**（2023）『R／RStudio でやさしく学ぶプログラミングとデータ分析』マイナビ出版
- **松村優哉・湯谷啓明・紀ノ定保礼・前田和寛**（2021）『R ユーザのための RStudio〈実践〉入門：tidyverse によるモダンな分析フローの世界』改訂 2 版、技術評論社

Web リソース

- **宋財泫・矢内勇生**「私たちの R」https://www.jaysong.net/RBook/（2025 年 7 月 14 日確認）
- **野村俊一**「RStudio 入門」https://shunichinomura.github.io（2025 年 7 月 14 日確認）

演習問題

問 1

df の wt 列は 1000 ポンド単位です。これをキログラム（1 ポンド ≒ 0.453592kg）に変換した列(wt_kg)を作成しましょう。

```
df$wt_kg <- df$wt * 1000 * 0.453592
```

問 2

問 1 で作成した wt_kg 列と講習内で作成した kmpl 列を使って散布図を作成してみましょう。その際、下記コードのようにデータフレームや列の指定が ggplot()関数でなくてもできることを確認しましょう。

```
# 先ほど data の指定などを ggplot()関数で行いましたが、
# 下記のように、geom_point()関数で行うこともできます。
# グラフを重ねて描画する時にこういった指定が活きてきます
ggplot() +
  geom_point(data = df, aes(x = wt_kg, y = kmpl)) +
  labs(title = "重量と燃費の関係", # 全角と半角の切り替えに注意
       x = "重量（kg）",
       y = "燃費（km/l）")
```

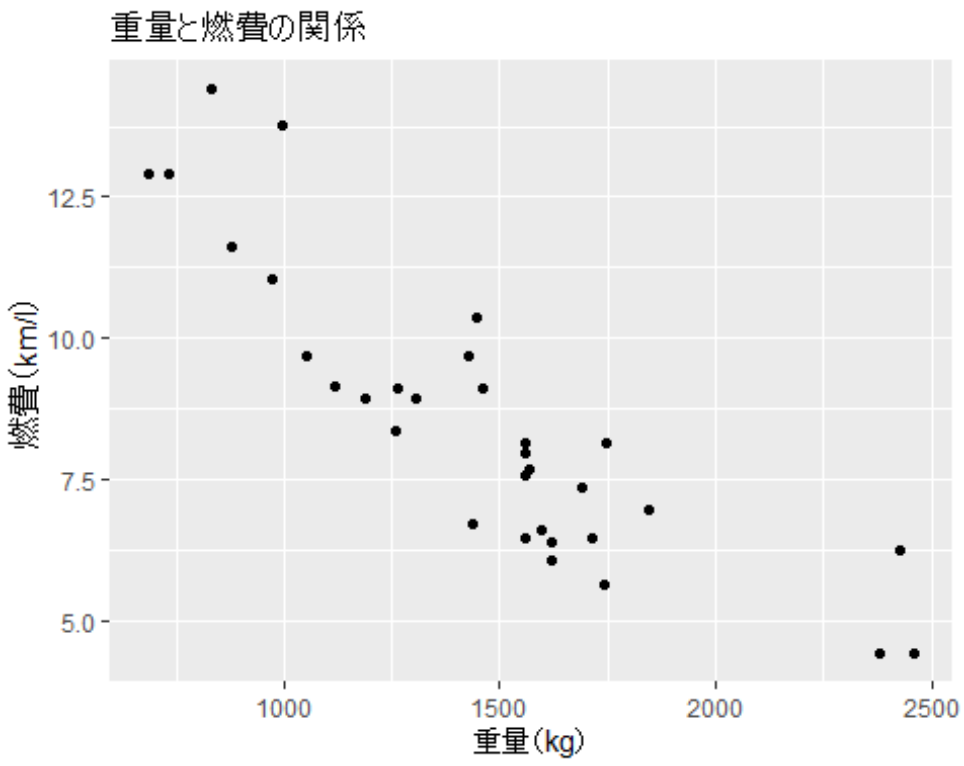

問 3

次のコードを書いて、ヒストグラムを描いてみましょう。ヒストグラムとはデータをいくつかの区間(bin)に分けて、その区間に含まれるデータの個数を棒グラフで表したものです。

```
ggplot() +
  geom_histogram(data = df, mapping = aes(x = mpg))
## `stat_bin()` using `bins = 30`. Pick better value with `binwidth`.
```