rd-2. ヒストグラム，散布図，折れ線グラフ，要約統計量

データサイエンス演習

（R システムを使用）

https://www.kkaneko.jp/de/rd/index.html

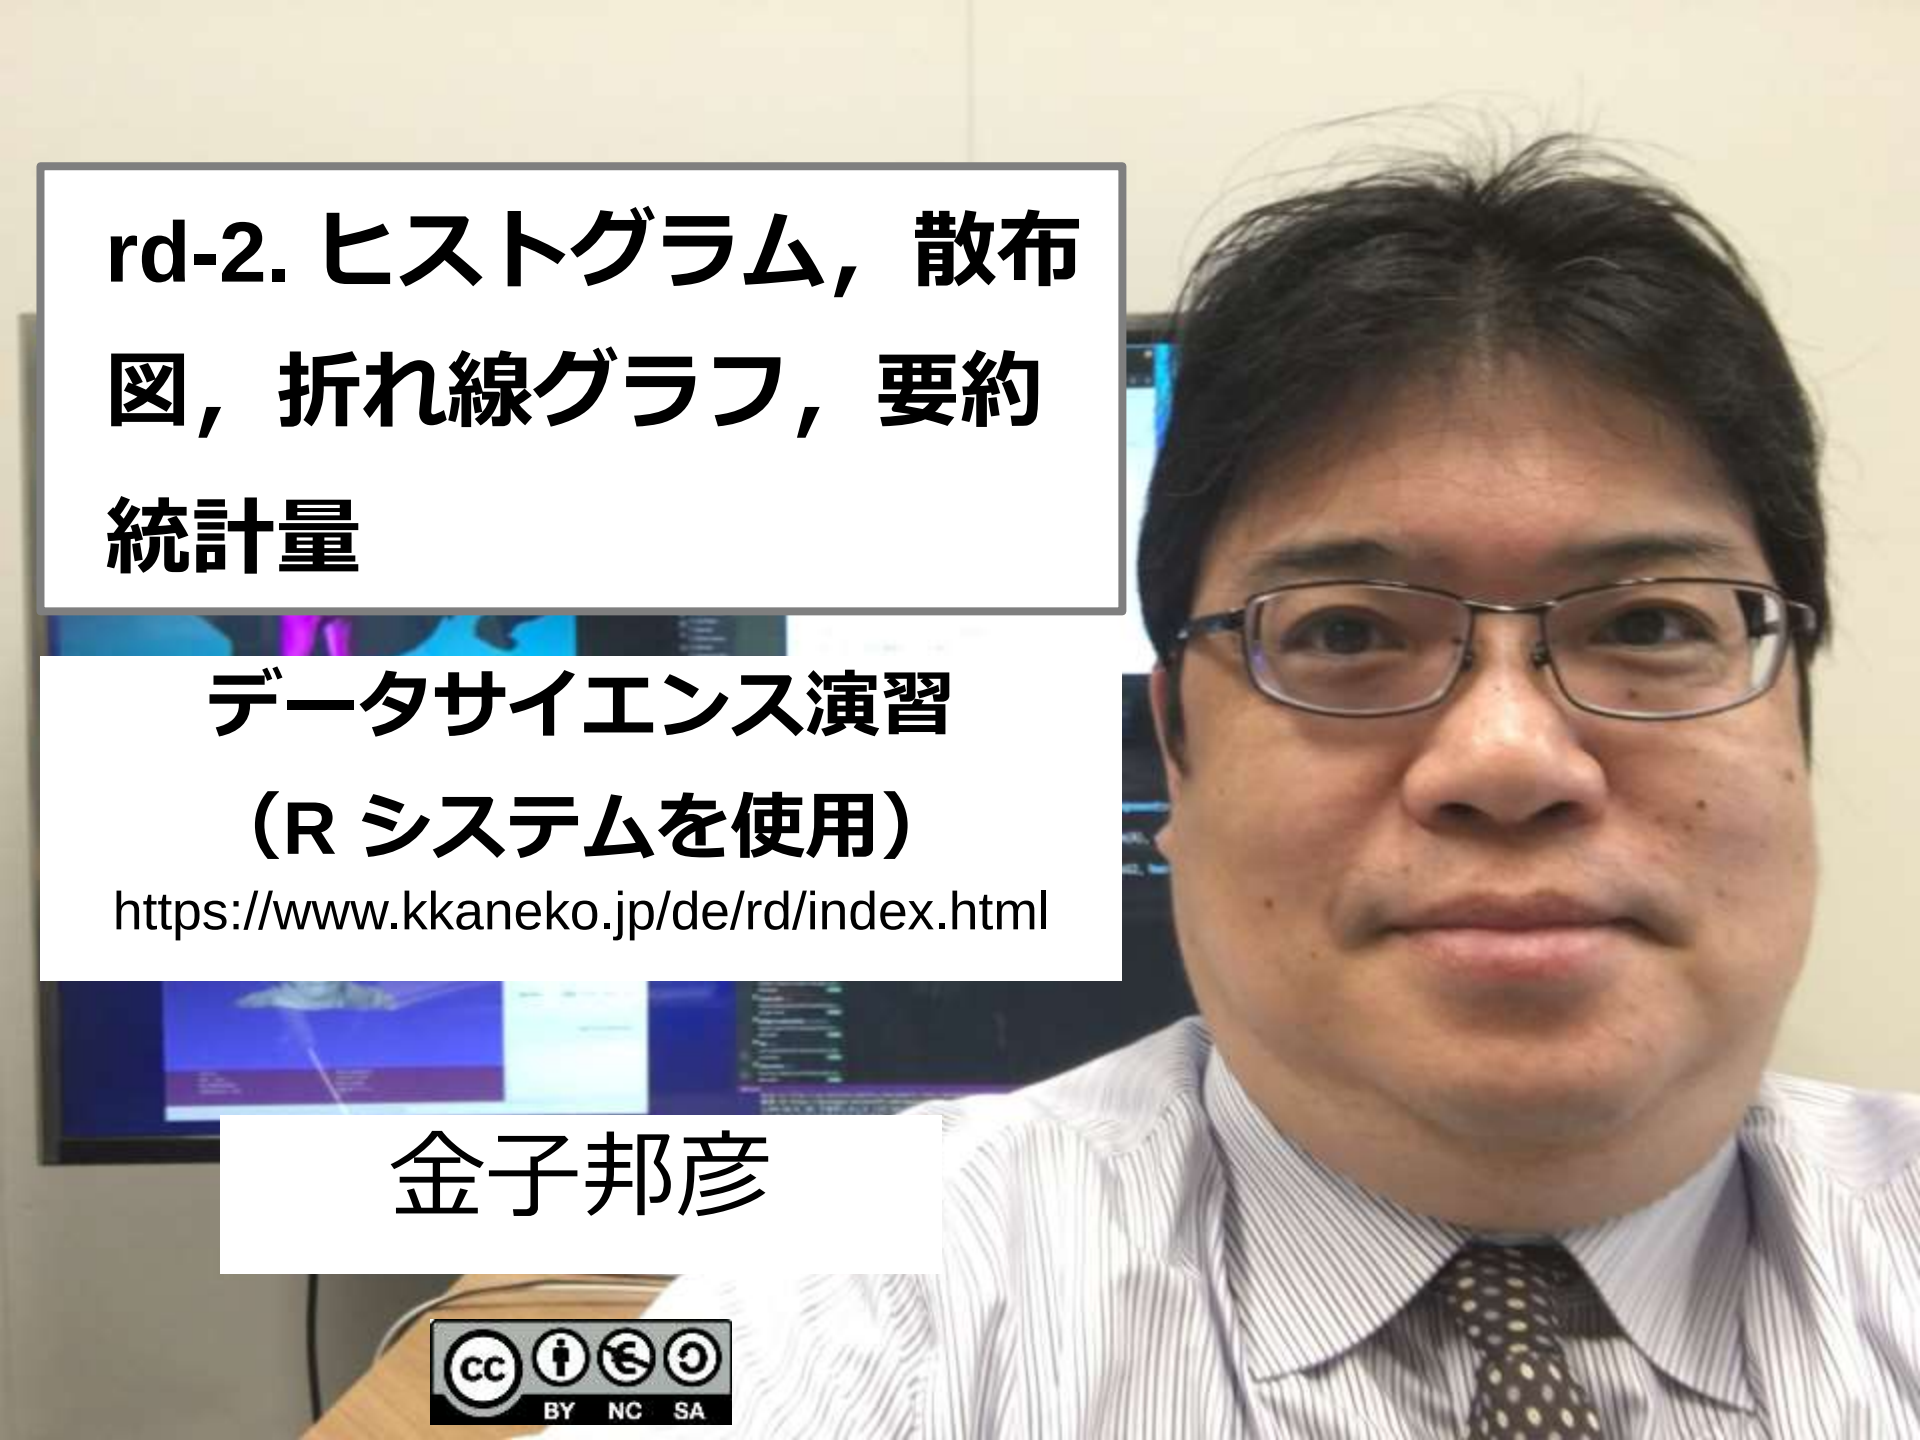

金子邦彦

2-1 パッケージの追加インストール

パッケージの設定 (1/2)

- 次の手順で，必要なパッケージをインストール
- パッケージをインストールするのにインターネット接続が必要
- install.packages("ggplot2")　を実行

```
> install.packages("ggplot2")
Installing package into ‘D:/Users/user/Doc
(as ‘lib’ is unspecified)
trying URL 'https://mran.revolutionanalyti
/contrib/3.2/ggplot2_2.0.0.zip'
```

- install.packages("dplyr") を実行

```
> install.packages("dplyr")
Installing package into ‘D:/Users/user/Do
(as ‘lib’ is unspecified)
trying URL 'https://mran.revolutionanalyt
ws/contrib/3.2/dplyr_0.4.3.zip'
```

パッケージの設定 (2/2)

- install.packages("tidyr")　を実行

```
> install.packages("tidyr")
Installing package into 'D:/Users/user
(as 'lib' is unspecified)
trying URL 'https://mran.revolutionana
ws/contrib/3.2/tidyr_0.3.1.zip'
```

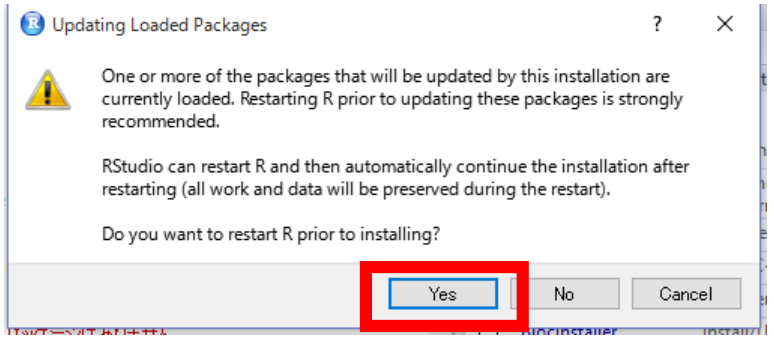

こんな表示がでたら **Yes**

- install.packages("magrittr") を実行

```
> install.packages("magrittr")
Error in install.packages : Updating loade

Restarting R session...

Microsoft R Open 3.2.3
Default CRAN mirror snapshot taken on 2016
```

- install.packages("KernSmooth") を実行

```
> install.packages("KernSmooth")
Installing package into 'D:/Users/user/Doc
(as 'lib' is unspecified)
trying URL 'https://mran.revolutionanalyti
ws/contrib/3.2/KernSmooth_2.23-15.zip'
Content type 'application/zip' length 105(
```

※「K」と「S」が大文字

2-2 R オブジェクトのコンストラクタ

コンストラクタの例

年次	出生数	死亡数
1985	1432	752
1990	1222	820
1995	1187	922
2000	1191	962
2005	1063	1084
2010	1071	1197

テーブルの例

```
x1 <- data.frame( 年次=c(1985, 1990, 1995, 2000, 2005, 2010),
                  出生数=c(1432, 1222, 1187, 1191, 1063, 1071),
                  死亡数=c(752, 820, 922, 962, 1084, 1197) )
```

上記のテーブルを生成するコンストラクタ

```
> x1 <- data.frame( 年次=c(1985, 1990, 1995, 2000, 2005, 2010),
+                   出生数=c(1432, 1222, 1187, 1191, 1063, 1071),
+                   死亡数=c(752, 820, 922, 962, 1084, 1197) )
> |
```

コンストラクタの動作画面

2-3 iris データセット

アヤメ属 (Iris)

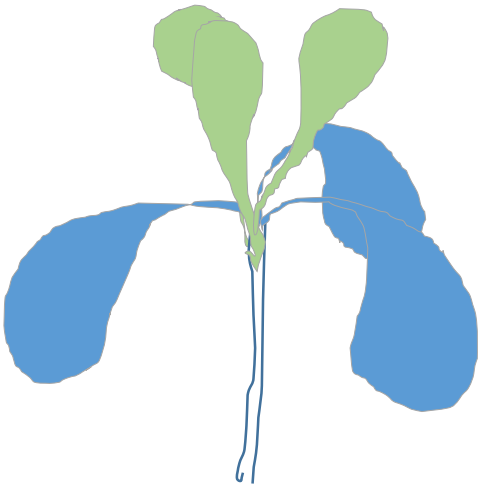

- 多年草
- 世界に 150種. 日本に 9種.
- 花被片は 6個
- 外花被片（がいかひへん） Sepal
  3個（大型で下に垂れる）
- 内花被片（ないかひへん） Petal
  3個（直立する）

Iris データセット

```
> 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
```

Iris データセットは，Rシステムの中に組み込み済み

- 3種のアヤメの外花被辺、内花被片の幅と長さを計測したデータセット
  - Iris setosa
  - Iris versicolor
  - Iris virginica
- データ数は 50 × 3
- 作成者：Ronald Fisher
- 作成年：1936

2-4 ヒストグラムの例

iris の 4属性それぞれのヒストグラム

属性： Sepal.Length, Sepal.Width, Petal.Length, Petal.Width

```
> 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

各属性のヒストグラム

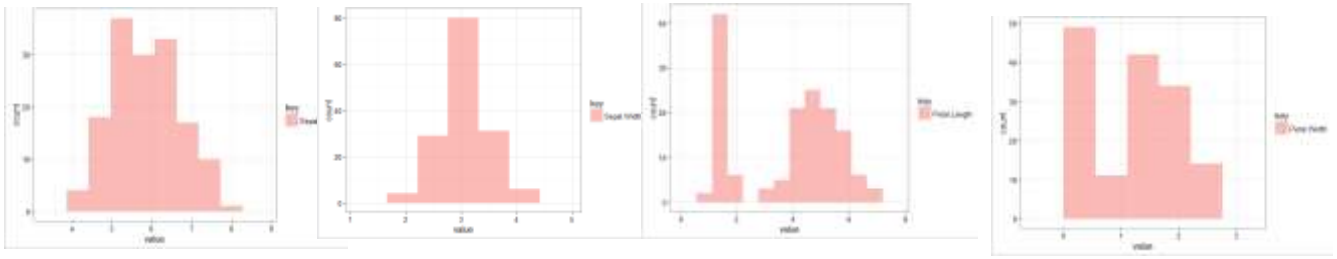

複数ヒストグラムの重ね合わせ表示

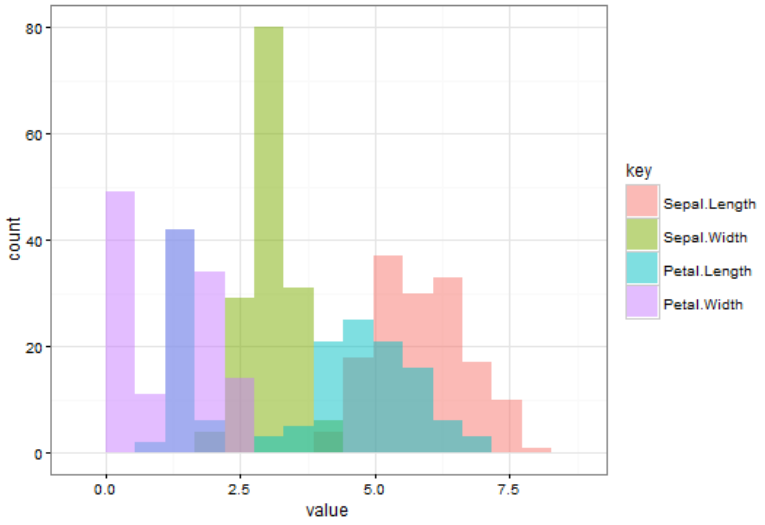


```
library(dplyr)

d2 <- tbl_df( iris )

library(tidyr)

library(magrittr)

library(KernSmooth)

library(ggplot2)

d2 %>% select( Sepal.Length, Sepal.Width, Petal.Length,
Petal.Width ) %>% gather() %>% ggplot( aes(x=value, fill=key) ) +

  geom_histogram( binwidth=dpih( use_series(d2, Sepal.Length) ),
alpha=0.5, position="identity") +

  theme_bw()
```

ヒストグラムでの区間幅の調整

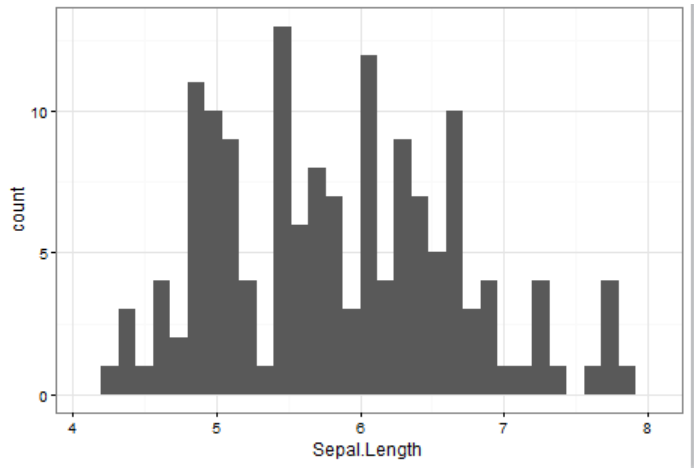

区間幅 = **0.1**

```
library(ggplot2)
ggplot(iris, aes(x = Sepal.Length)) +
  geom_histogram(binwidth=0.1) +
  theme_bw()
```

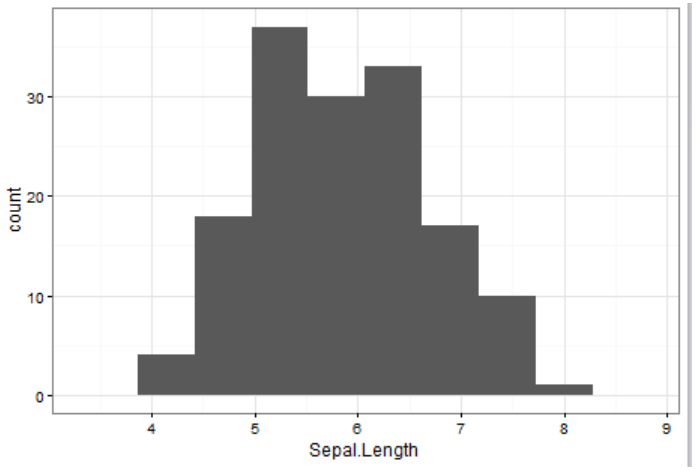

区間幅を、**dpih 関数を用いて調整**

```
library(magrittr)
library(KernSmooth)
library(ggplot2)
ggplot(iris, aes(x = Sepal.Length)) +
  geom_histogram(
    binwidth=dpih( iris$Sepal.Length ) ) +
  theme_bw()
```

2-5 散布図，折れ線グラフ

散布図、折れ線グラフのバリエーション

年次	出生数（千人）	死亡数（千人）
1985	1432	752
1990	1222	820
1995	1187	922
2000	1191	962
2005	1063	1084
2010	1071	1197

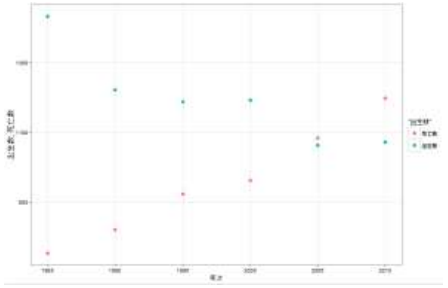

散布図

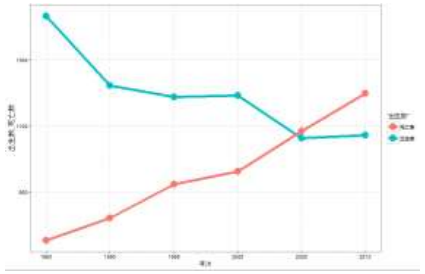

散布図
＋折れ線

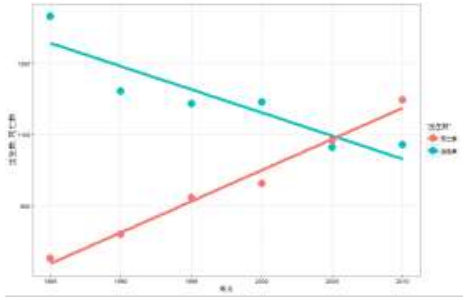

散布図
＋線形近似

出生数、死亡数の推移
出典：総務省「第63回 日本統計年鑑 平成26年」

散布図

年次	出生数	死亡数
1985	1432	752
1990	1222	820
1995	1187	922
2000	1191	962
2005	1063	1084
2010	1071	1197

x 軸 (フィールド名)	年次
y 軸 (フィールド名)	出生数, 死亡数
点の大きさ (数値)	3
x 軸の名前 (文字列)	年次
y 軸の名前 (文字列)	出生数, 死亡数

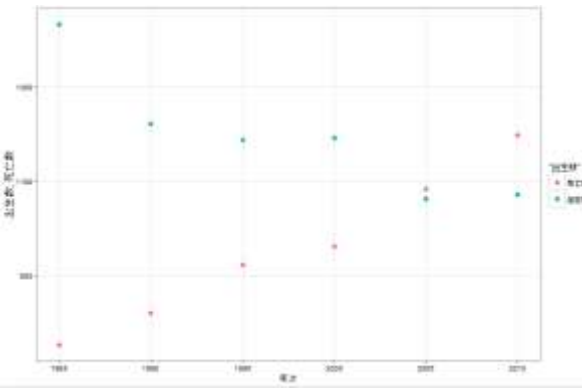

```
x1 <- data.frame( 年次=c(1985, 1990, 1995, 2000, 2005, 2010),
                  出生数=c(1432, 1222, 1187, 1191, 1063, 1071),
                  死亡数=c(752, 820, 922, 962, 1084, 1197) )
library(ggplot2)
ggplot(x1, aes(x=年次)) +
  geom_point( aes(y=出生数, colour="出生数"), size=3 ) +
  geom_point( aes(y=死亡数, colour="死亡数"), size=3 ) +
  labs(x="年次", y="出生数, 死亡数") +
  theme_bw()
```

散布図＋折れ線

年次	出生数	死亡数
1985	1432	752
1990	1222	820
1995	1187	922
2000	1191	962
2005	1063	1084
2010	1071	1197

x 軸 (フィールド名)	年次
y 軸 (フィールド名)	出生数, 死亡数
点の大きさ (数値)	3
x 軸の名前 (文字列)	年次
y 軸の名前 (文字列)	出生数, 死亡数

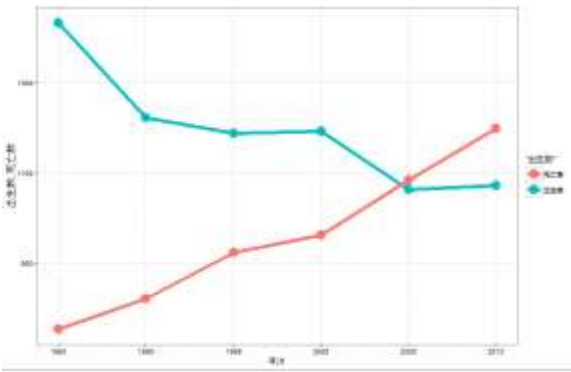

```
x1 <- data.frame( 年次=c(1985, 1990, 1995, 2000, 2005, 2010),
                  出生数=c(1432, 1222, 1187, 1191, 1063, 1071),
                  死亡数=c(752, 820, 922, 962, 1084, 1197) )
library(ggplot2)
ggplot(x1, aes(x=年次)) +
  geom_point( aes(y=出生数, colour="出生数"), size=6 ) +
  geom_point( aes(y=死亡数, colour="死亡数"), size=6 ) +
  geom_line( aes(y=出生数, colour="出生数"), size=2 ) +
  geom_line( aes(y=死亡数, colour="死亡数"), size=2 ) +
  labs(x="年次", y="出生数, 死亡数") +
  theme_bw()
```

散布図＋線形近似

年次	出生数	死亡数
1985	1432	752
1990	1222	820
1995	1187	922
2000	1191	962
2005	1063	1084
2010	1071	1197

x 軸 (フィールド名)	年次
y 軸 (フィールド名)	出生数, 死亡数
点の大きさ (数値)	3
x 軸の名前 (文字列)	年次
y 軸の名前 (文字列)	出生数, 死亡数

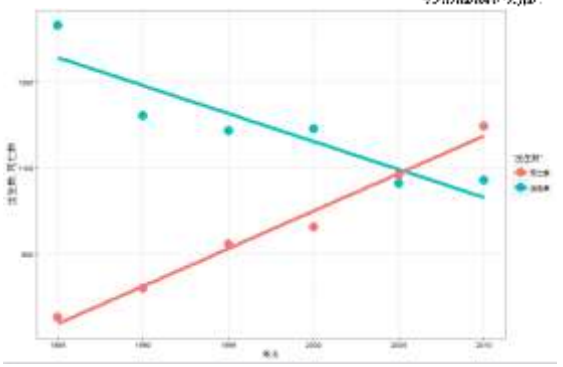

```
x1 <- data.frame( 年次=c(1985, 1990, 1995, 2000, 2005, 2010),
                  出生数=c(1432, 1222, 1187, 1191, 1063, 1071),
                  死亡数=c(752, 820, 922, 962, 1084, 1197) )
library(ggplot2)
ggplot(x1, aes(x=年次)) +
  geom_point( aes(y=出生数, colour="出生数"), size=6 ) +
  geom_point( aes(y=死亡数, colour="死亡数"), size=6 ) +
  stat_smooth( method="lm", se=FALSE, aes(y=出生数, colour="出生数"), size=2 ) +
  stat_smooth( method="lm", se=FALSE, aes(y=死亡数, colour="死亡数"), size=2 ) +
  labs(x="年次", y="出生数, 死亡数") +
  theme_bw()
```

2-6 グラフのファイルへの保存

png ファイルの作成

ファイル f:/1.png に保存

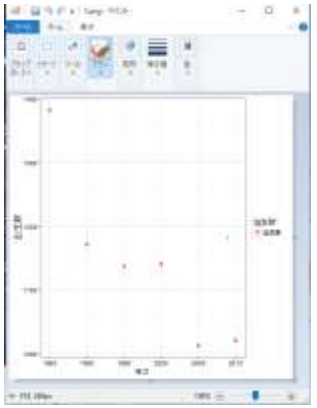

```
x1 <- data.frame( 年次=c(1985, 1990, 1995, 2000, 2005, 2010),
                  出生数=c(1432, 1222, 1187, 1191, 1063, 1071),
                  死亡数=c(752, 820, 922, 962, 1084, 1197) )
library(ggplot2)
png("f:/1.png")
ggplot(x1, aes(x=年次)) +
  geom_point( aes(y=出生数, colour="出生数"), size=3 ) +
  labs(x="年次", y="出生数") +
  theme_bw()
dev.off()
```

2-7 要約統計量，頻度，ヒストグラム

ここで行うこと

各フィールドの頻度（数え上げ）

種類ごとの数え上げ

各フィールドの要約統計量の算出

平均 (mean)、標準偏差 (sd)、分散 (var)

中央値 (median)、四分位点 (quantile)、

最大値 (max)、最小値 (min)

科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

元データ

```
     科目                受講者                得点
Length:5           Length:5           Min.   :80
Class :character   Class :character   1st Qu.:80
Mode  :character   Mode  :character   Median :90
                                      Mean   :87
                                      3rd Qu.:90
                                      Max.   :95
```

要約統計量の例

ここでの説明で使用するデータ

成績データ

科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

```
d1 <- data.frame(
    科目=c("国語", "国語", "算数", "算数", "理科"),
    受講者=c("A", "B", "A", "B", "A"),
    得点=c(90, 80, 95, 90, 80) )
```

コンストラクタ

```
> 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
```

iris データセット

※ **iris データセット**は
R システムに組み込み済み

要約統計量（summary を使用）①

成績

科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

```
> summary(d1)
   科目     受講者       得点
 国語:2   A:3     Min.   :80
 算数:2   B:2     1st Qu.:80
 理科:1           Median :90
                  Mean   :87
                  3rd Qu.:90
                  Max.   :95
>
```

◆ **数値属性**に対しては
最小、最大、平均、
中央値、四分位点

```
d1 <- data.frame(
    科目=c("国語", "国語", "算数", "算数", "理科"),
    受講者=c("A", "B", "A", "B", "A"),
    得点=c(90, 80, 95, 90, 80) )
summary(d1)
```

頻度のグラフ化 ①

科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

集約を行うテーブルの変数名	d1
集約したいフィールド名	科目
x 軸の名前 (文字列)	科目
y 軸の名前 (文字列)	総数

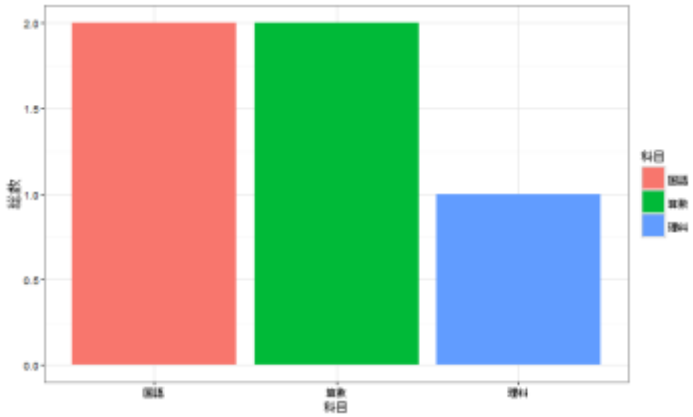

```
d1 <- data.frame(
    科目=c("国語", "国語", "算数", "算数", "理科"),
    受講者=c("A", "B", "A", "B", "A"),
    得点=c(90, 80, 95, 90, 80) )
library(ggplot2)
ggplot(d1, aes( x=科目, fill=科目 )) +
  geom_bar(stat="count") +
  labs(x="科目", y="総数") +
  theme_bw()
```

頻度のグラフ化 ②

科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

集約を行うテーブルの変数名	d1
集約したいフィールド名	得点
x 軸の名前 (文字列)	得点
y 軸の名前 (文字列)	総数

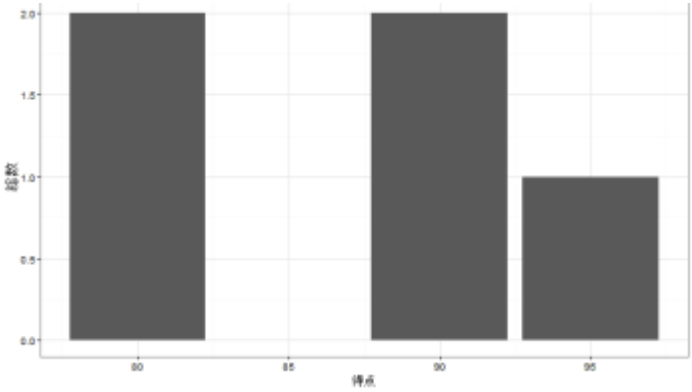


```
d1 <- data.frame(
    科目=c("国語", "国語", "算数", "算数", "理科"),
    受講者=c("A", "B", "A", "B", "A"),
    得点=c(90, 80, 95, 90, 80) )
library(ggplot2)
ggplot(d1, aes( x=得点 )) +
  geom_bar(stat="count") +
  labs(x="得点", y="総数") +
  theme_bw()
```

要約統計量（summary を使用）②

```
> 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
```

iris データセット

```
  Sepal.Length    Sepal.Width     Petal.Length
Min.   :4.300   Min.   :2.000   Min.   :1.000
1st Qu.:5.100   1st Qu.:2.800   1st Qu.:1.600
Median :5.800   Median :3.000   Median :4.350
Mean   :5.843   Mean   :3.057   Mean   :3.758
3rd Qu.:6.400   3rd Qu.:3.300   3rd Qu.:5.100
Max.   :7.900   Max.   :4.400   Max.   :6.900
  Petal.Width          Species
Min.   :0.100   setosa     :50
1st Qu.:0.300   versicolor:50
Median :1.300   virginica :50
Mean   :1.199
3rd Qu.:1.800
Max.   :2.500
```

summary(iris)