

Fusion 補遺—データ解析環境 R 入門

関西大学商学部 荒木孝治

2019/10/30

- ・データ解析環境 R : 統計学・機械学習
- ・Python : ディープラーニング・機械学習

1. R 入門

(1) 電卓的使い方—演算子（足し算+、引き算-、かけ算*、割り算/）

```
> 1 + 2  
[1] 3
```

(2) 変数の利用—x、y

```
> x <- 10  
> y <- 20
```

(3) 変数の足し算

```
> z = x + y
```

(4) 結果の表示

```
> z  
[1] 30  
> (z = x * y)
```

(5) 計算と同時に結果を表示—()で囲む

```
[1] 200
```

(6) ベクトルの定義

```
> v1 <- c(1, 2, 3, 2, 1)  
> v2 <- c(10, 20, 30, 40, 50)
```

(7) ベクトルの足し算—対応する位置の数字同士の足し算

```
> (plus_v1v2 = v1 + v2)
```

```
[1] 11 22 33 42 51
```

(8) ベクトルの結合 (column : 列)。他に rbind()がある (row : 行)

```
> (set_v1v2 = cbind(v1, v2))
```

```
v1 v2
[1,] 1 10
[2,] 2 20
[3,] 3 30
[4,] 2 40
[5,] 1 50
```

(9) 平均の計算—関数 mean()

```
> mean(plus_v1v2)
```

```
[1] 31.8
```

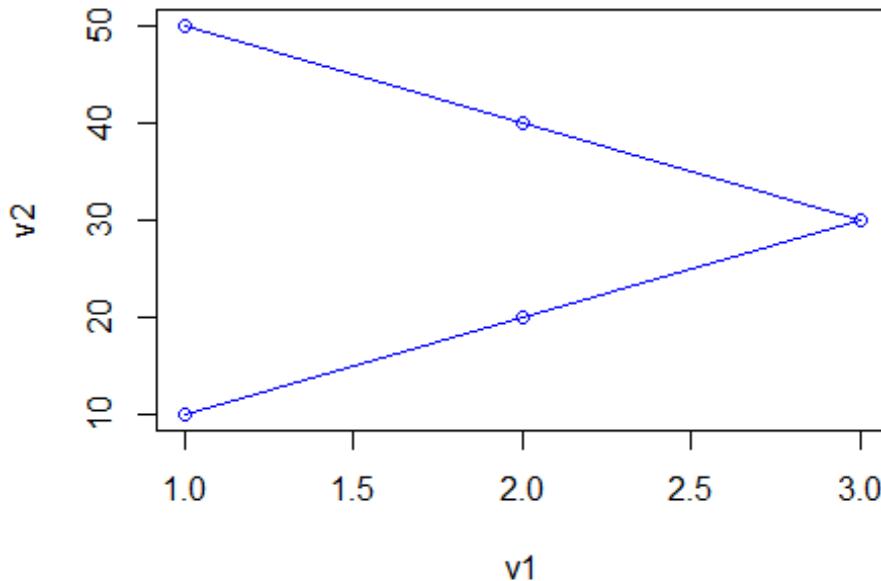
(10) データの要約情報 (最小値、第1四分位数、メディアン、第3四分位数、最大値)

```
> summary(plus_v1v2)
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
11.0	22.0	33.0	31.8	42.0	51.0

(11) 行列のプロット (第1列を横軸、第2列を縦軸)

```
> plot(set_v1v2, type = "o", col = "blue")
```



(12) エクセルファイルの読み込み。関数 `library()`を用いてパッケージ `readxl` を起動

```
> library(readxl)
```

(13) 関数 `read_excel()`の利用。パス・ファイル名を指定

```
> tokyo_drink <- read_excel("C:/data/tokyo_drink.xlsx")
```

(14) 読み込まれたデータセット `tokyo_drink` をコピー (`td`)

```
> td <- tokyo_drink
```

(15) 関数 `lm()`を用いて回帰分析の実行

モデルの書式 : 目的変数～説明変数 1+説明変数 2+……

```
> lm_result <- lm(td$飲料販売量 ~ td$気温 + td$湿度 + td$土日祝ダミー)
```

結果の表示 : 関数 `summary()`の利用

```
> summary(lm_result)
```

Call:

```
lm(formula = td$飲料販売量 ~ td$気温 + td$湿度 + td$土日祝ダミー)
```

Residuals:

```

      Min       1Q     Median      3Q      Max
-142.718 -49.742      5.141   46.590  127.925

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 374.9633   14.5686  25.738 <2e-16 ***
td$気温      5.8803    0.4914  11.965 <2e-16 ***
td$湿度      0.4903    0.2318   2.115  0.0351 *
td$土日祝ダミー -86.7386   6.9676 -12.449 <2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 62.69 on 362 degrees of freedom
Multiple R-squared:  0.5183,    Adjusted R-squared:  0.5143
F-statistic: 129.8 on 3 and 362 DF,  p-value: < 2.2e-16

```

(16) 別の回帰モデルの作成 lm_res2、lm_res3

```

> lm_res2 <- lm(td$飲料販売量 ~ td$気温 + td$土日祝ダミー)
> lm_res3 <- lm(td$飲料販売量 ~ td$湿度 + td$土日祝ダミー)

```

(17) パッケージ memisc の起動

```

> library(memisc)

Loading required package: lattice

Loading required package: MASS

Attaching package: 'memisc'

The following object is masked from 'package:car':
  recode

The following objects are masked from 'package:stats':
  contr.sum, contr.treatment, contrasts

The following object is masked from 'package:base':
  as.array

```

(18) 関数 mtable()を利用して、複数の回帰分析の結果の比較

```

> mtable(lm_result, lm_res2, lm_res3)

```

```

Calls:
lm_result: lm(formula = td$飲料販売量 ~ td$気温 + td$湿度 + td$土日祝ダミー)

```

```
lm_res2: lm(formula = td$飲料販売量 ~ td$気温 + td$土日祝日)
lm_res3: lm(formula = td$飲料販売量 ~ td$湿度 + td$土日祝日)
```

	lm_result	lm_res2	lm_res3
(Intercept)	374.963*** (14.569)	400.563*** (8.151)	376.813*** (17.185)
td\$気温	5.880*** (0.491)	6.394*** (0.429)	
td\$湿度	0.490* (0.232)		1.860*** (0.238)
td\$土日祝日	-86.739*** (6.968)	-87.746*** (6.984)	-84.283*** (8.216)
R-squared	0.518	0.512	0.328
N	366	366	366

Significance: *** = p < 0.001; ** = p < 0.01;
* = p < 0.05

2. 電力消費データの分析

```
> library(readxl)
```

(19) エクセルデータの読み込み

```
> elec_weather <- read_excel("C:/data/elec_weather.xlsx")
```

(20) 切り出す変数の指定

```
> lm_name <- c("年月日", "月", "平日 or 土日祝", "時", "東京電力 (1 時間単位)",  
+ "東京_気温 (1 時間単位)",  
+ "東京_降水量 (1 日合計値)")
```

(21) 必要なデータの切り出し

```
> elwe <- elec_weather[, lm_name]
```

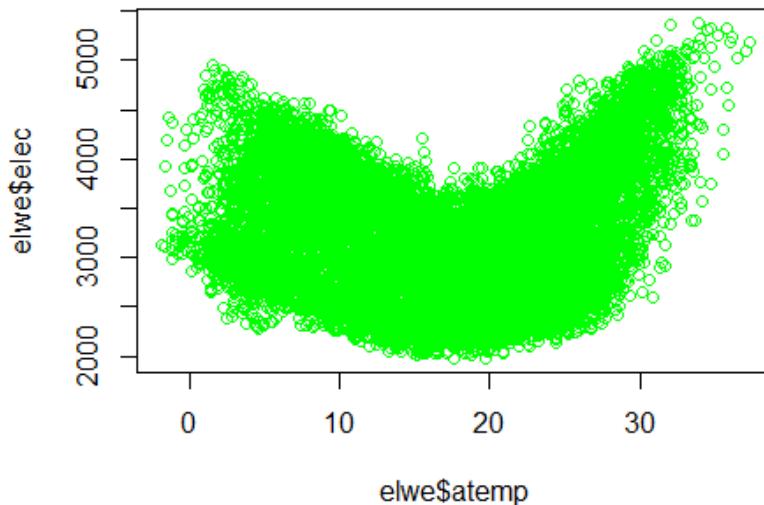
(22) 変数名の変更

```
> names(elwe) <- c("ymd", "month", "hei_dns", "hour", "elec", "atemp",  
"wdrop")
```

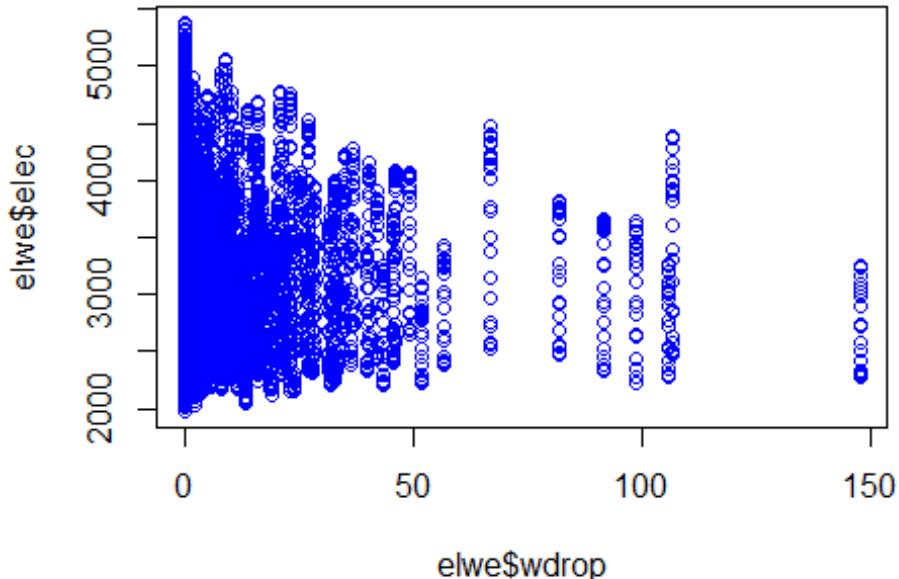
(23) 散布図の作成 (plot(横軸に取る変数, 縦軸に取る変数))

Col (color: 色の指定)

```
> plot(elwe$atemp, elwe$elec, col = "green")
```



```
> plot(elwe$wdrop, elwe$elec, col = "blue")
```



(24) 変数 atemp の 2 乗の変数 atemp2 の追加

```
> elwe$atemp2 <- elwe$atemp^2
```

(25) 変数 atemp の 3 乗の変数 atemp3 の追加

```
> elwe$atemp3 <- elwe$atemp^3
```

(26) ダミー変数 wadr_dummy の作成 (雨量 wdrop が正(>0)のとき、1、他のとき、0)

```
> elwe$wadr_dummy <- ifelse(elwe$wdrop > 0, 1, 0)
```

(27) 回帰分析 (2 乗、3 乗の項、ダミー変数の利用)

```
> lm_re1 <- lm(elwe$elec ~ elwe$atemp + elwe$atemp2 + elwe$atemp3 + elwe$wadr_dummy)
```

(28) モデル lm_re1 の回帰係数の表示 (関数 coef() の利用)

```
> coef(lm_re1)
```

	(Intercept)	elwe\$atemp	elwe\$atemp2	elwe\$atemp3
	3453.6410544	35.4280133	-8.5273962	0.2650495

```
elwe$wadr_dummy  
68.5061220
```

(29) 回帰係数をファイルに書き込み（関数 `write.table()`）

```
sep (separator : sep = "," カンマ区切り)  
> write.table(coef(lm_re1), "C:/data/lm_coef1.csv", sep = ",")
```