2024/11/12 Tue.

問題解決技法入門

3. Data Analysis
2. Data Visualization using R

堀田 敬介

R と R commander について

- R（アール）
  - データ解析・統計処理ソフト
  - The R Project for Statistical Computing
    - https://www.r-project.org/
      - R is a free software environment for statistical computing and graphics.
    - ※CUI（Character User Interface）で使用するため，初心者・初級者には敷居が高い
- R commander（アール・コマンダー）
  - 初心者・初級者でもRを使用し易くするためのGUI（Graphical User Interface）パッケージ．Rから呼び出して使う library(Rcmdr)
  - The R Commander: A Basic-Statistics GUI for R
    - https://socialsciences.mcmaster.ca/jfox/Misc/Rcmdr/
      - The R Commander is a graphical user interface (GUI) to the free, open-source R statistical software.

Outline

1. データの準備
   - ① データの準備（csvファイル）
   - ② R/R commander の起動
   - ③ データの読み込み（csv-fileをR/R commanderで開く）
   - ④ データの整備：ケース名の設定
2. R commander によるデータの視覚化
   - ⑤ 箱ひげ図 box plot, box-and-whisker plot
   - ⑥ 幹葉図 stem-and-leaf plot
   - ⑦ 散布図 scatter plot
   - ⑧ 散布図行列 scatter plot matrix
3. R によるデータの視覚化
   - ⑨ 多次元尺度法 multi-dimensional scaling

R commanderでデータの視覚化

① データの準備：csv ファイル

2024年プロ野球 セ・パ成績
（出典：スポーツナビ - Yahoo! JAPAN）

bb2024utf8.csv

※文字コードがutf8でないと読込エラーが起きる
（文字コードがsjisだと「不正なマルチバイト文字エラー」が出て読込みに失敗する）

チーム	リーグ	試合	勝利	敗戦	引分	勝率	得点	失点	本塁打	盗塁	打率	防御率	失策
巨人	セ	143	77	59	7	0.566	462	381	81	59	0.247	2.490	58
阪神	セ	143	74	63	6	0.540	485	420	67	41	0.242	2.500	85
DeNA	セ	143	71	69	3	0.507	522	503	101	69	0.256	3.070	96
広島	セ	143	68	70	5	0.493	415	419	52	66	0.238	2.620	66
ヤクルト	セ	143	62	77	4	0.446	506	556	103	67	0.243	3.640	69
中日	セ	143	60	75	8	0.444	373	478	68	40	0.243	2.990	68
ソフトバンク	パ	143	91	49	3	0.650	607	390	114	89	0.259	2.530	53
日本ハム	パ	143	75	60	8	0.556	532	485	111	91	0.245	2.940	75
ロッテ	パ	143	71	66	6	0.518	493	495	75	64	0.248	3.170	71
楽天	パ	143	67	72	4	0.482	492	579	72	90	0.242	3.730	64
オリックス	パ	143	63	77	3	0.450	402	448	71	61	0.238	2.820	78
西武	パ	143	49	91	3	0.350	350	485	60	83	0.212	3.020	72

② Rの起動：「R x64 X.X.X」を選択

- 注）x64 = 64bit用のプログラム（アプリ），X.X.X = Rのバージョン
- 注）32bit PCの場合は，「R i386 X.X.X」を選択
- 注）起動すると「R Console」が開く．コマンドプロンプト（>）で「library(Rcmdr)」と打ち[Enter] → R commander が起動

R commanderでデータの視覚化

③ データの読込

- 「データ」ー「データのインポート」ー「テキストファイル…」を選択

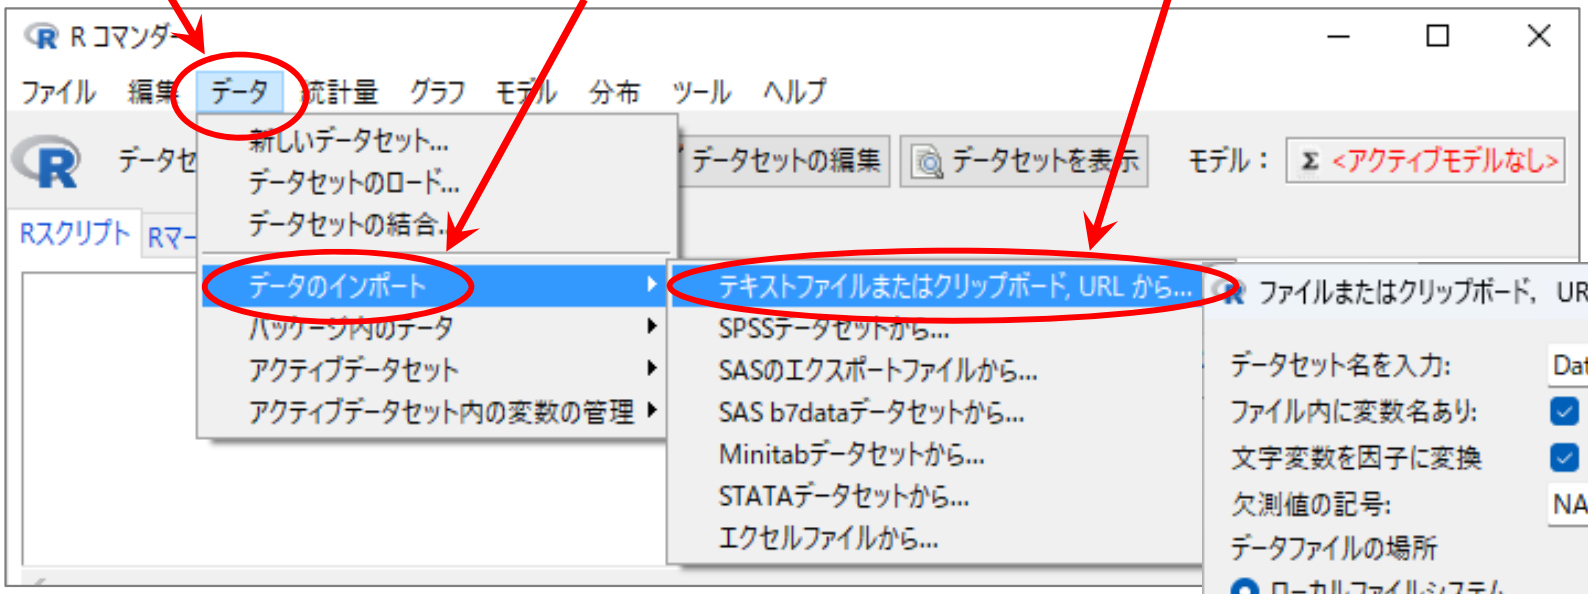

- [フィールドの区切り記号]で[カンマ[,]]を選び，[OK]クリック

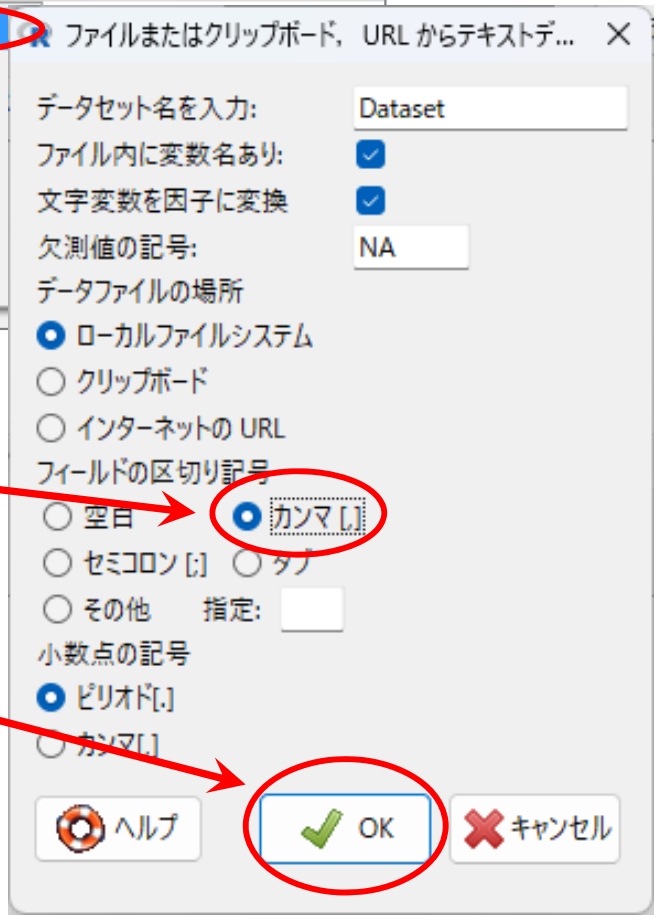

- ①で準備したファイル「*.csv」を選び[開く]

注)「データセットDatasetがすでに存在…上書き…」→[Yes]

R commanderでデータの視覚化

③ データの読込（読み込んだファイルの確認）

- [データセットを表示]ボタンをクリックし，内容を確認

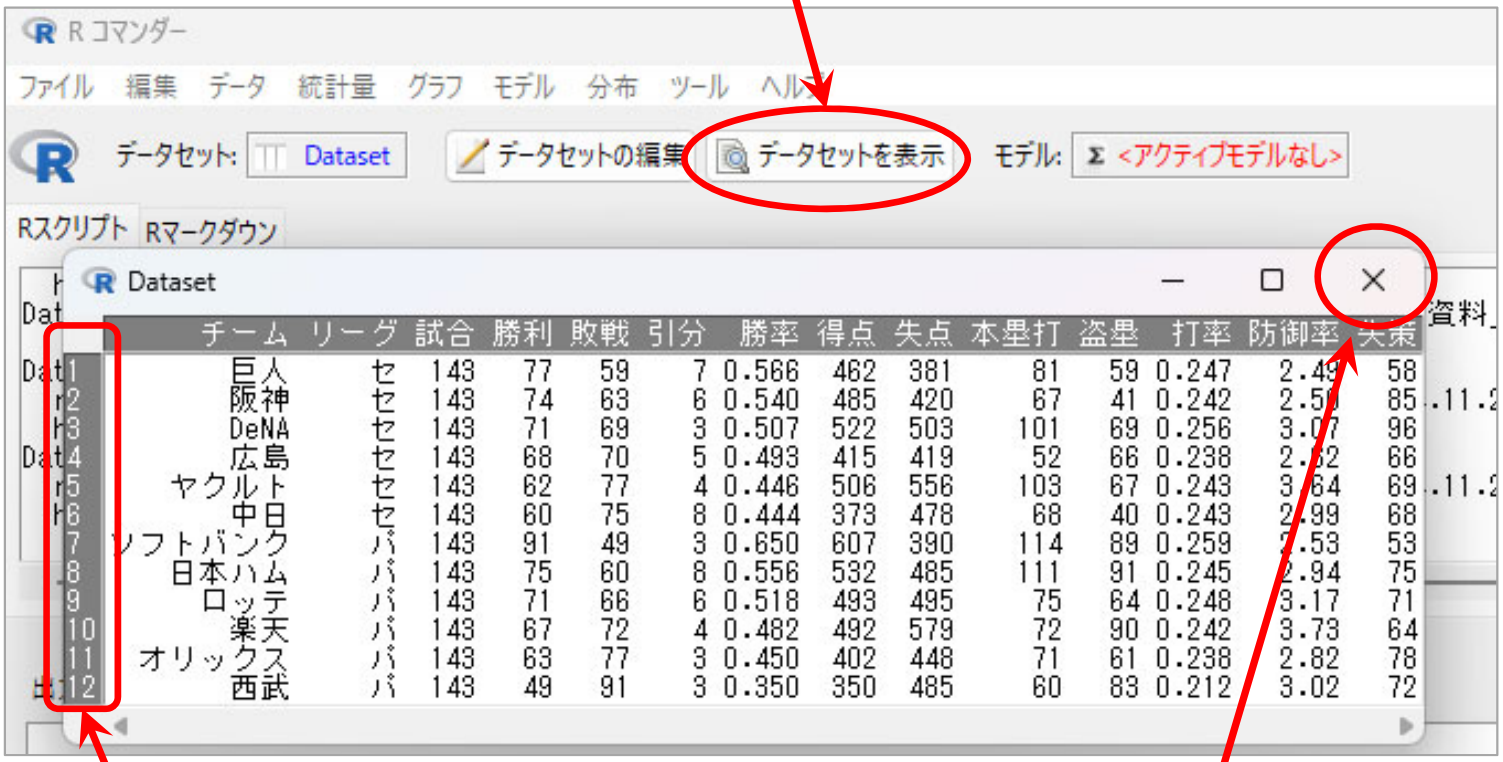

- ケース名（左端）が通し番号（1,2,…,12）であることを確認
- 確認できたら，「Dataset」の「×」をクリックして「閉じる」

R commanderでデータの視覚化

④ データにケース名を設定する

- 「データ」ー「アクティブデータセット」ー「ケース名の設定」選択

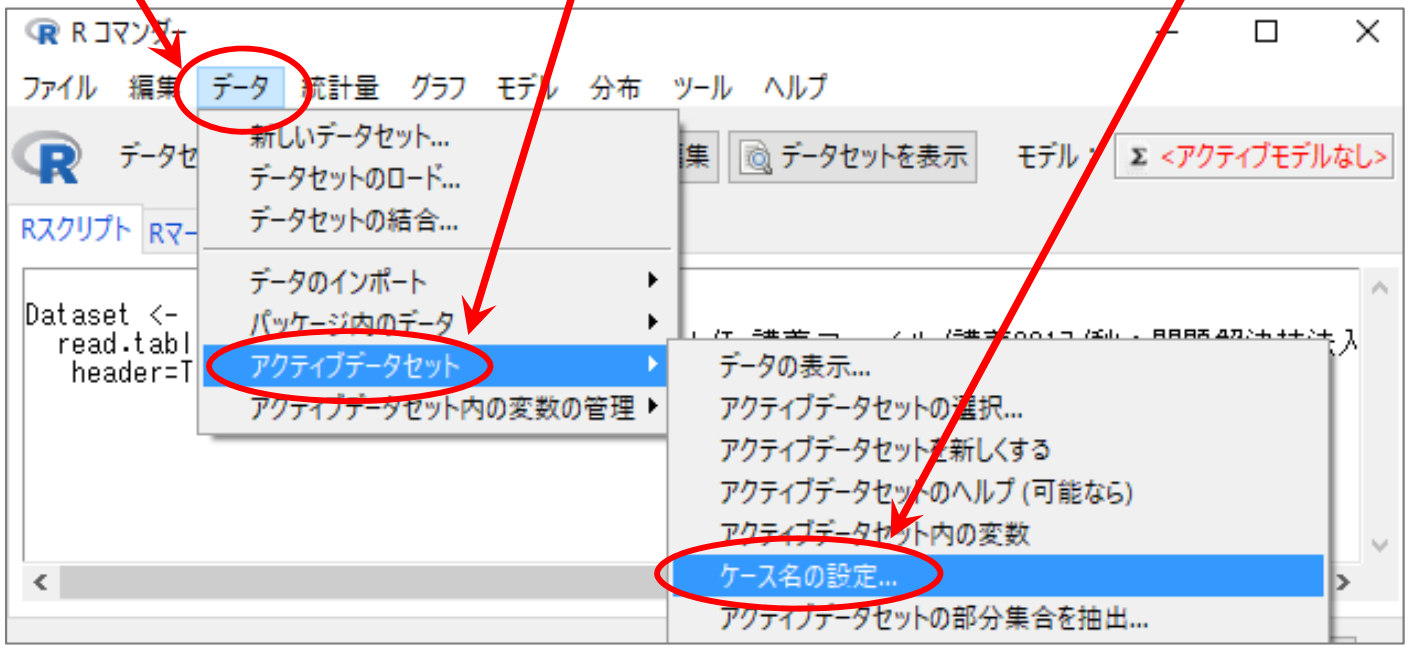

- [行名を含む変数を選択]で
  [チーム]を選び[OK]

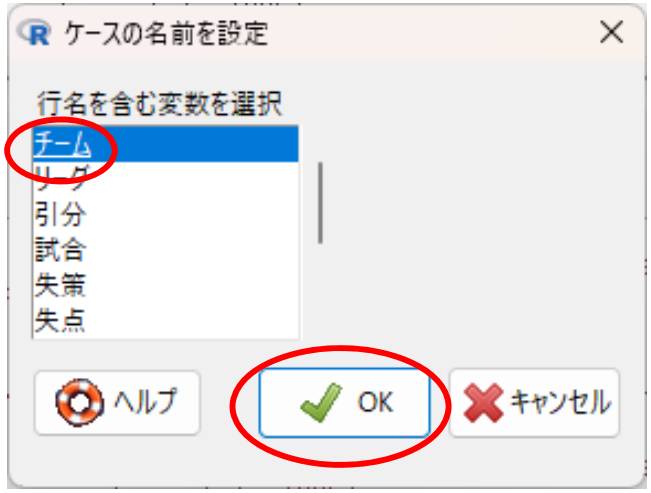

R commanderでデータの視覚化

④ データにケース名を設定する（設定確認）

- [データセットを表示]ボタンをクリックし内容を確認

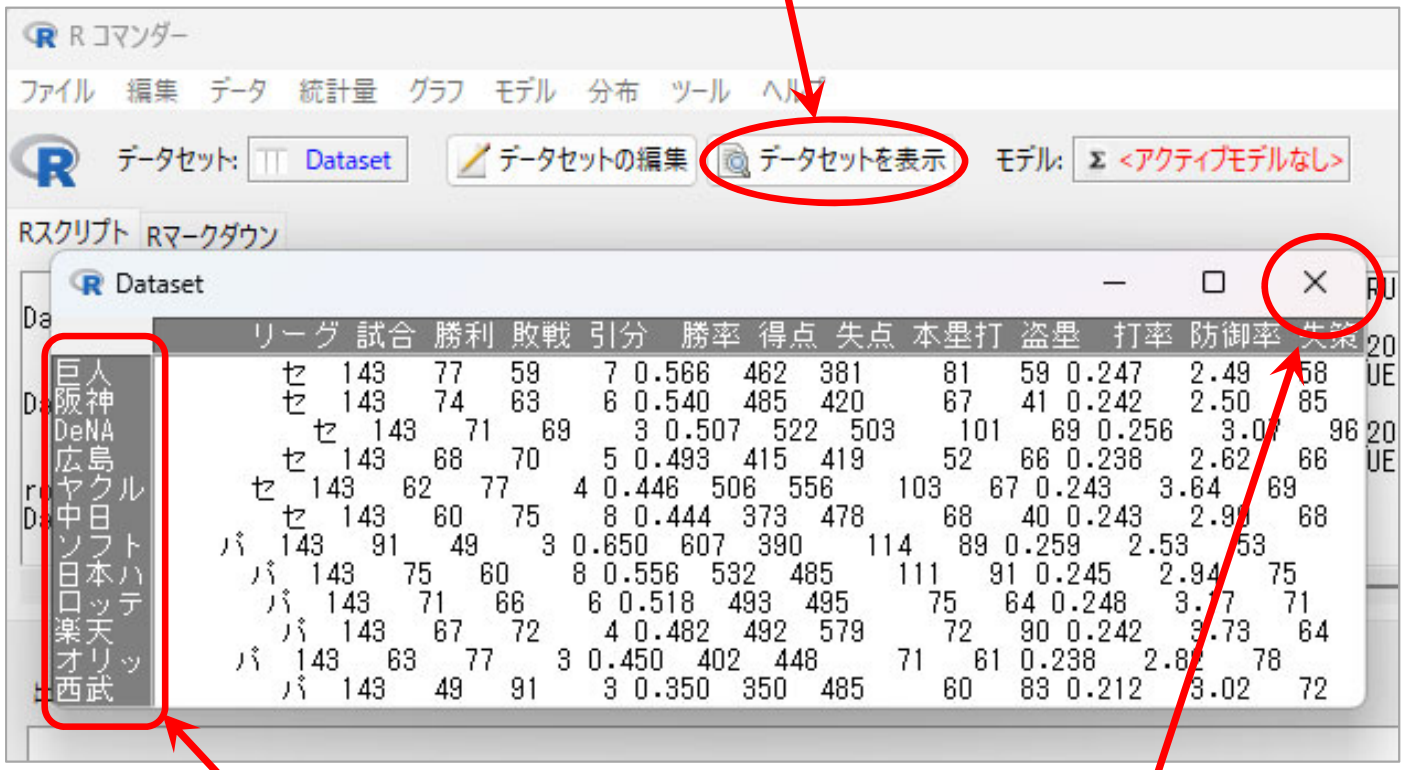

- 指定した変数がケース名になっていることを確認
- 確認できたら，「Dataset」の「×」をクリックして「閉じる」

R commanderでデータの視覚化

⑤ 箱ひげ図を描く

- 「グラフ」ー「箱ひげ図」を選択

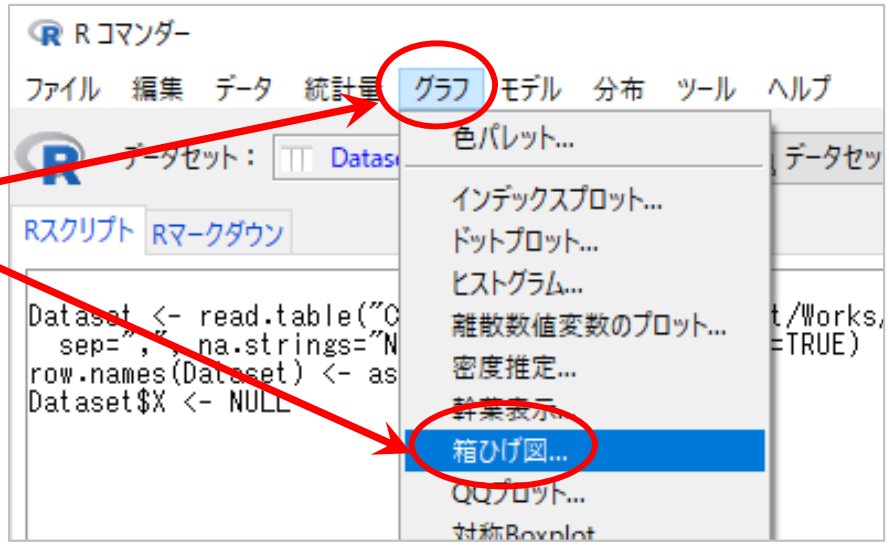

- 『箱ひげ図』で以下を設定
  - [変数（1つ選択）]で [本塁打] を選択
  - [層別のプロット]クリック
  - [層別変数（1つ選択）]で [リーグ] を選択し [OK]

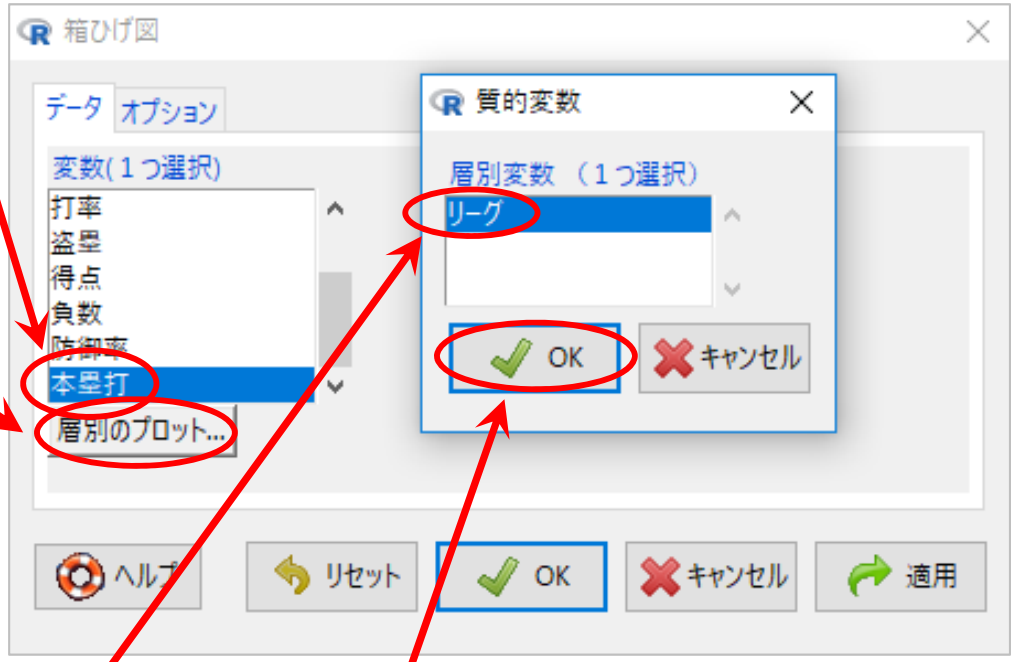

R commanderでデータの視覚化

⑤ 箱ひげ図を描く【完成】

- 『箱ひげ図』の [オプション]タブで以下を設定
  - [ラベルを表示]に，ラベルをそれぞれ適切に設定
    - [X軸のラベル] = リーグ
    - [Y軸のラベル] = 本数
    - [グラフのタイトル] = セ・パ 本塁打比較

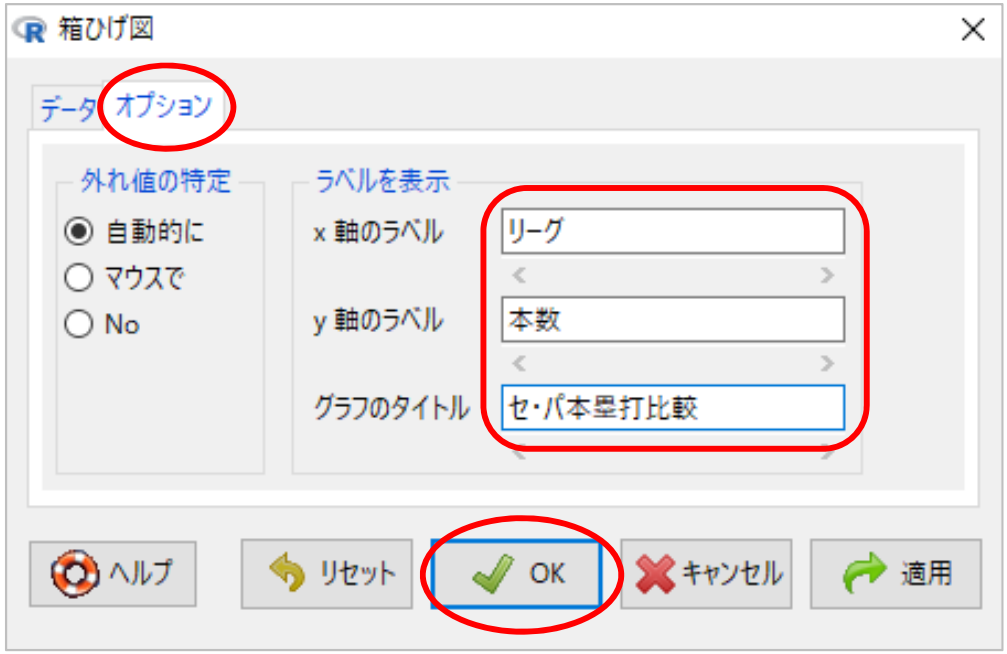

- 全て設定後，[OK]

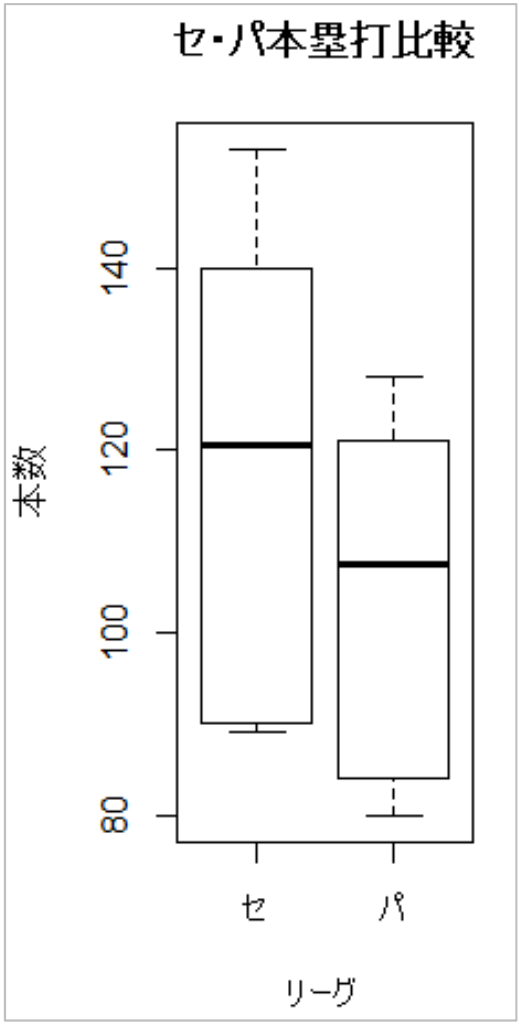

R commanderでデータの視覚化

⑥ 幹葉図を描く

- 「グラフ」ー「幹葉表示」を選択

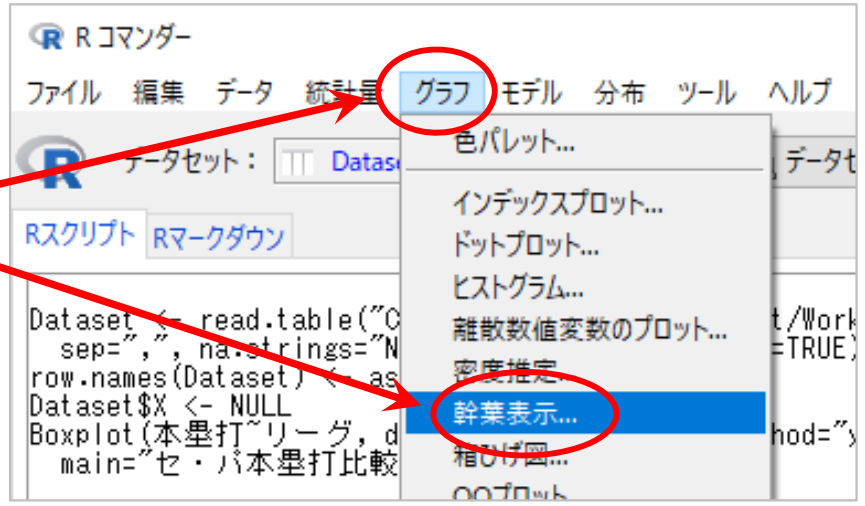

- 『幹葉表示』で以下を設定
  - [変数（1つ選択）]で [盗塁] 選択
  - [Plot back-to-back by..]クリック
  - [層別変数（1つ選択）]で
    [リーグ] を選択し [OK]
- 全て設定後，[OK]

R commanderでデータの視覚化

⑥ 幹葉図を描く【完成】

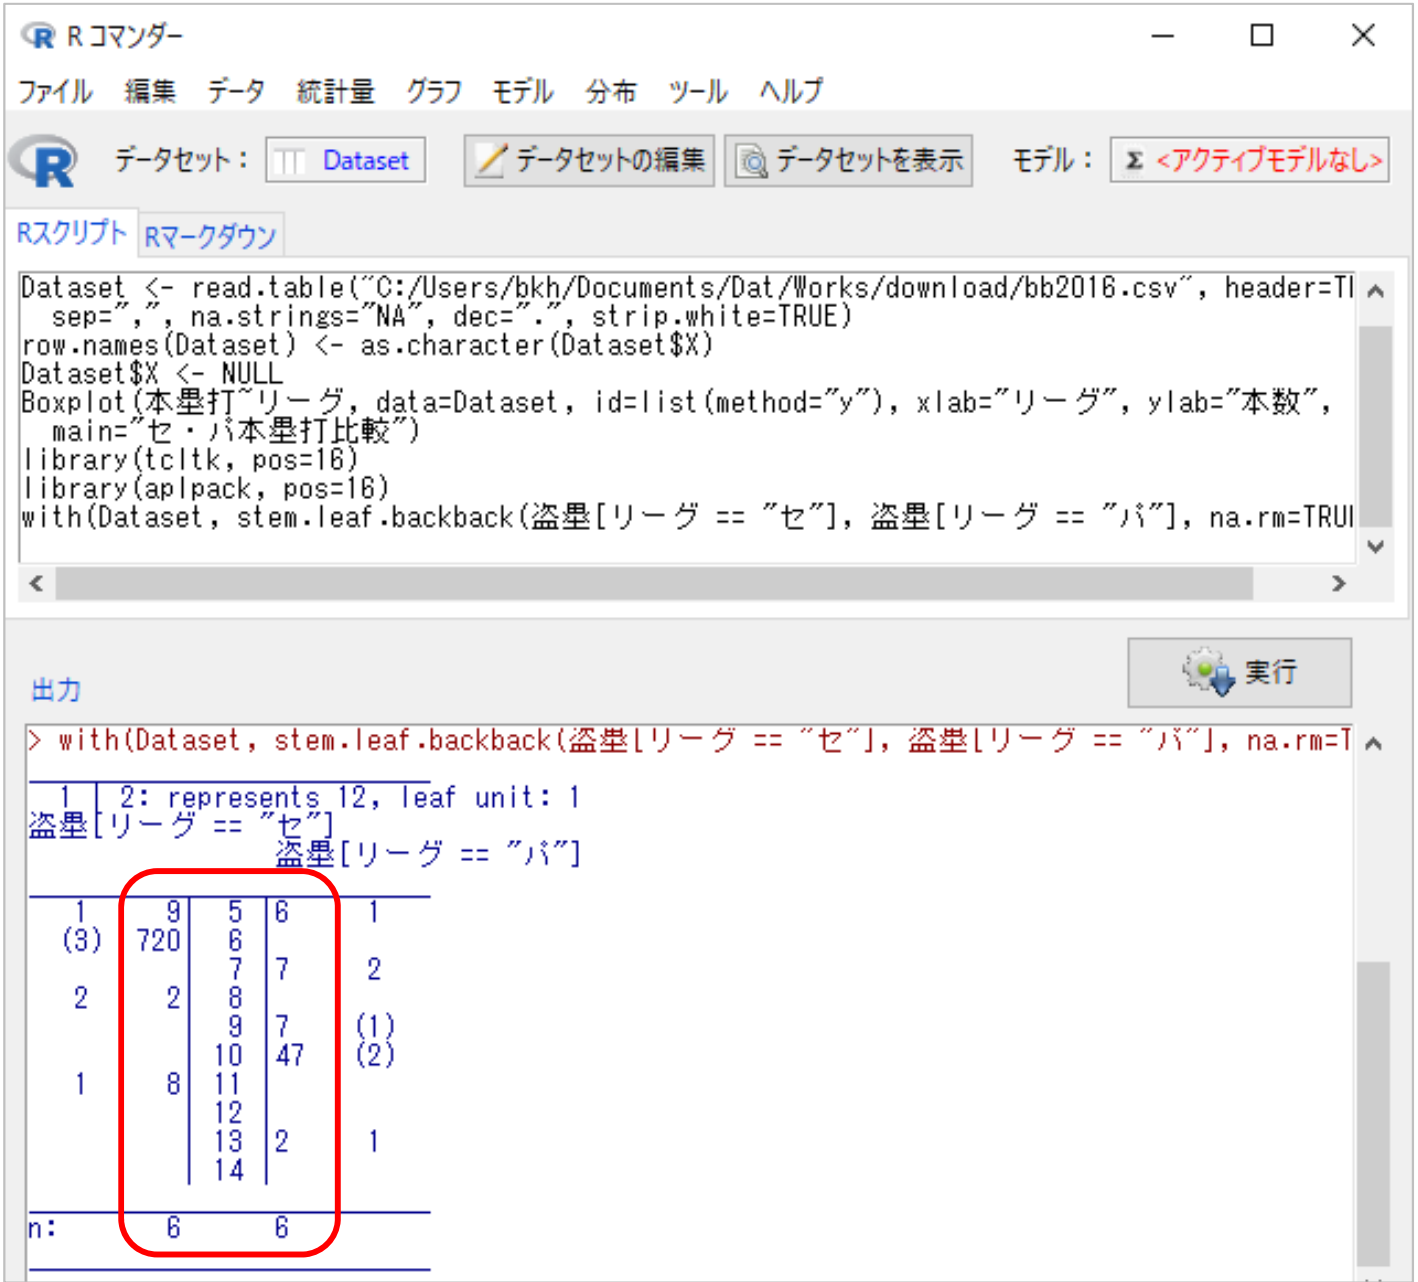

R commanderでデータの視覚化

⑦ 散布図を描く

- 「グラフ」ー「散布図」を選択
- 『散布図』で以下設定
  - [x変数] = 打率
  - [y変数] = 勝率
- [層別のプロット]クリック
- [層別変数（1つ選択）]で
  [リーグ] を選択し [OK]

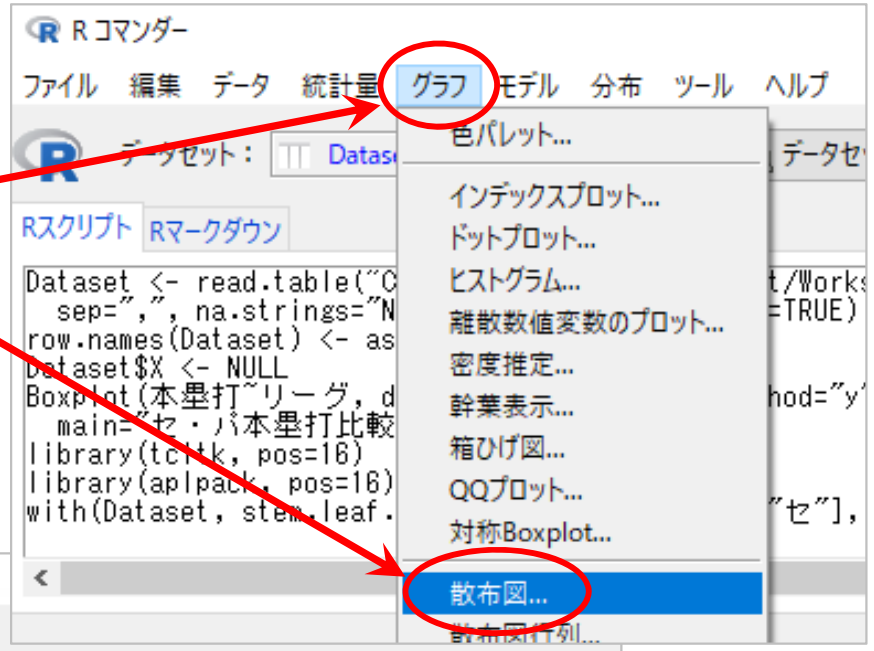

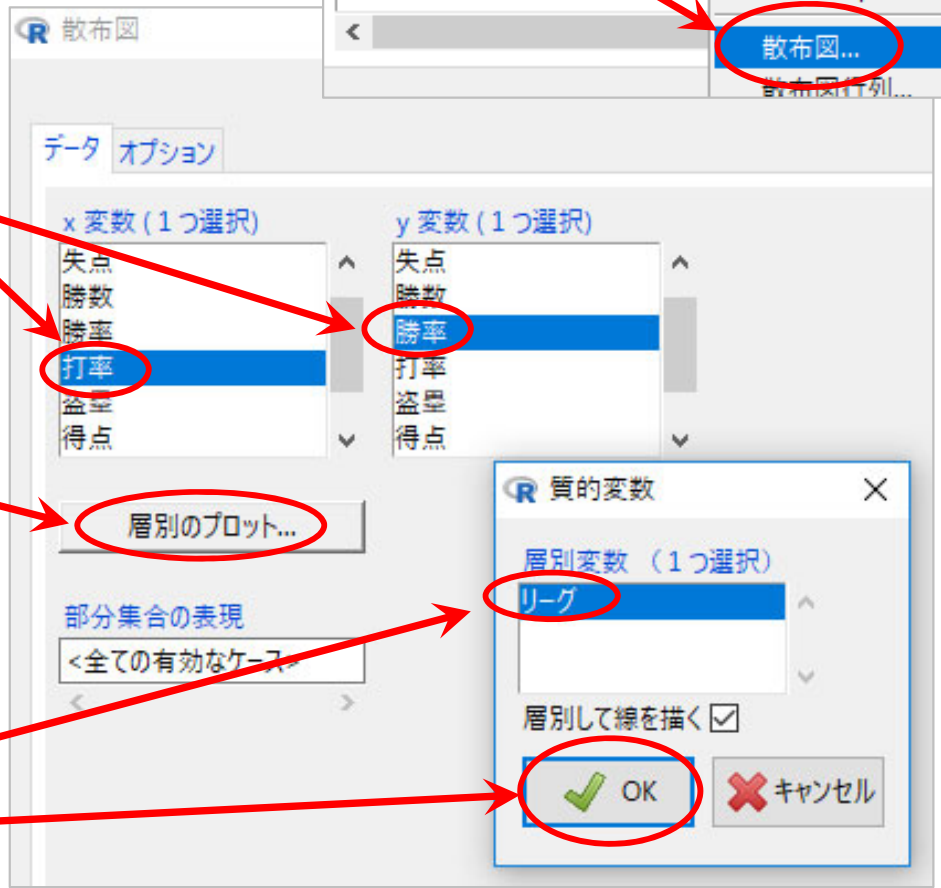

R commanderでデータの視覚化

⑦ 散布図を描く【完成】

- 『散布図』の[オプション]タブで以下を設定後，[OK]

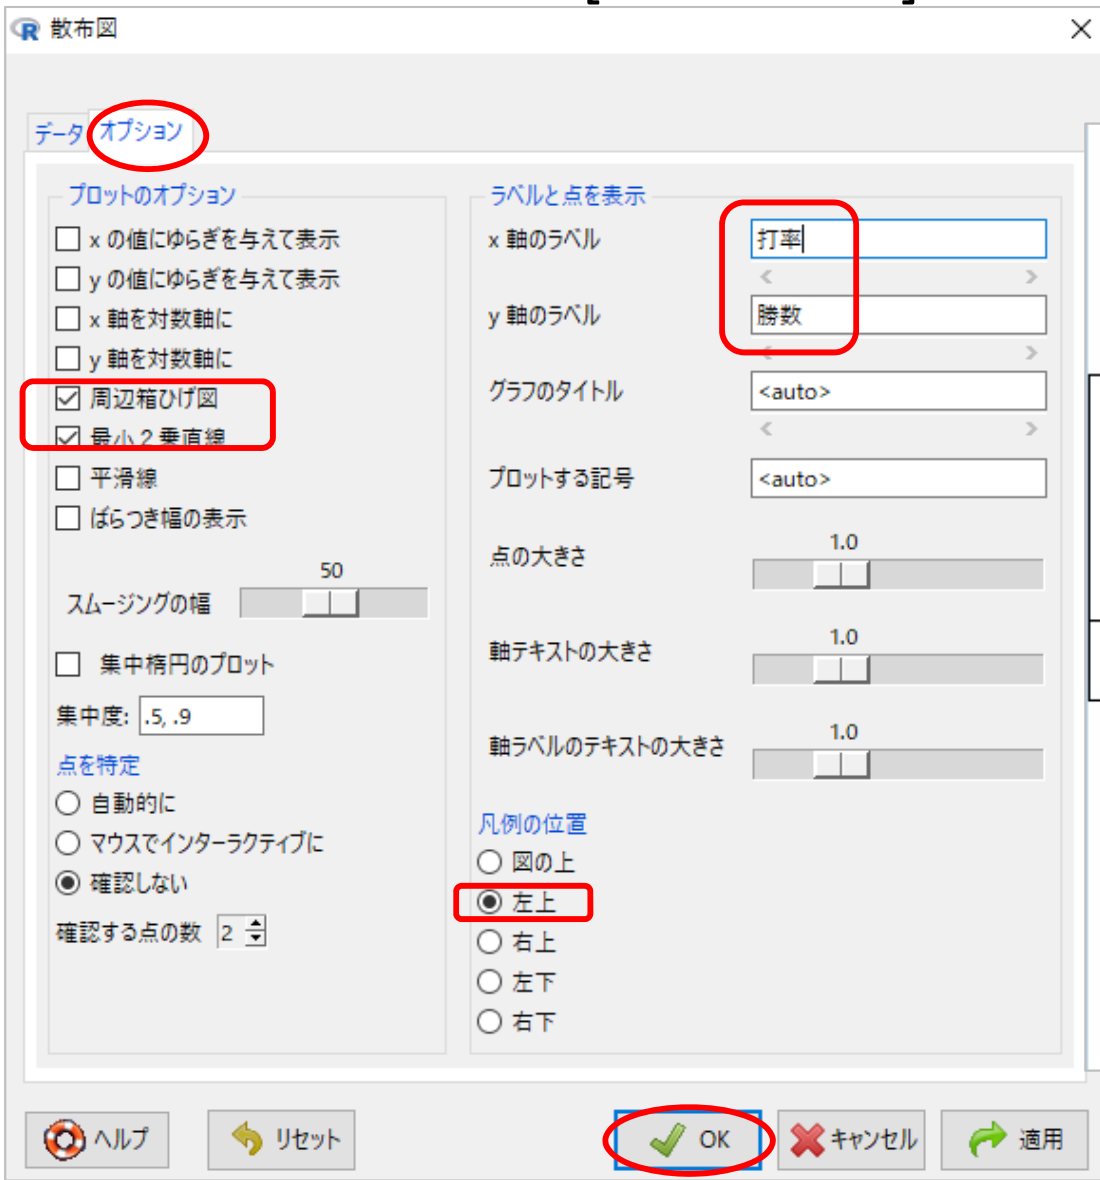

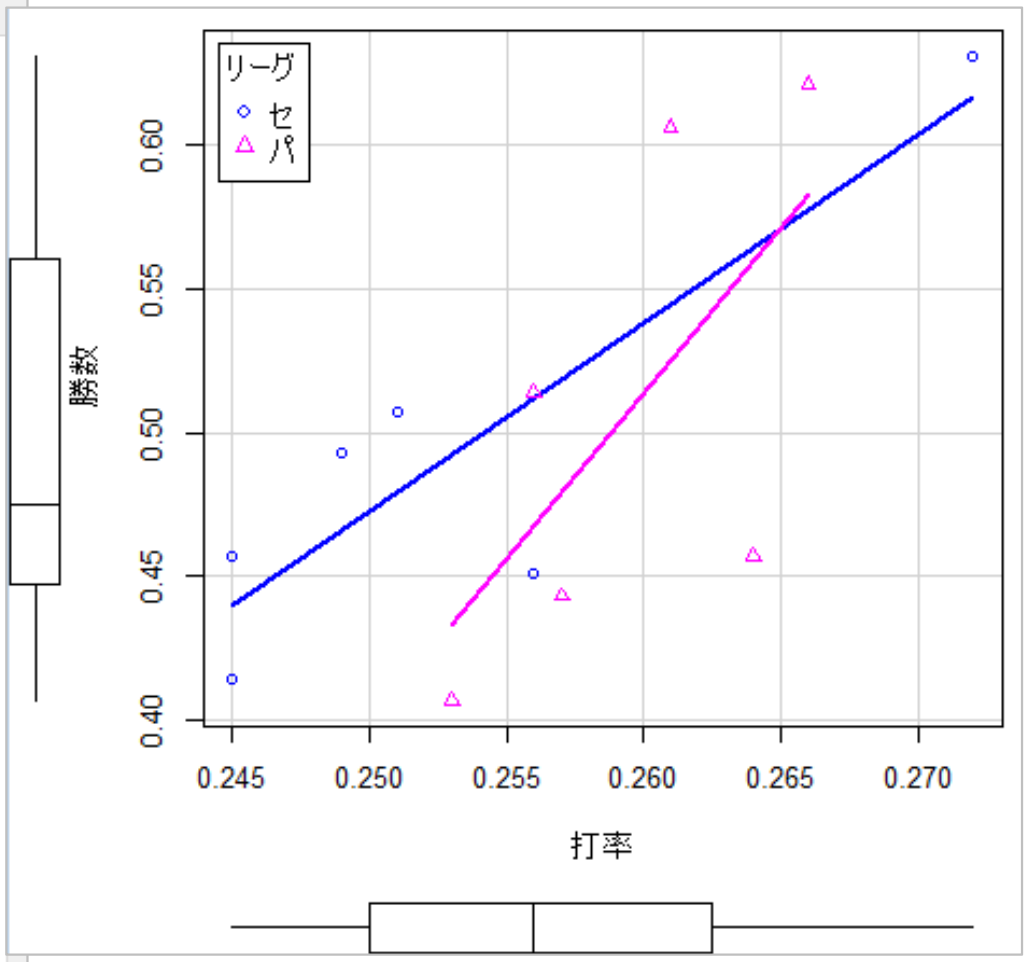

R commanderで散布図行列描画

⑧ 散布図行列を描く

- 「グラフ」ー「散布図行列」を選択
- 『散布図行列』で以下を設定
  - [変数（3つ以上）]で [失点][勝利数][打率][本塁打] 4つを選択

（※複数選択は[Ctrl]キーを押しながら選択）

- [層別のプロット]クリック
- [層別変数（1つ選択）]で [リーグ] 選択し [OK]
- [散布図行列]に戻ったら [OK]

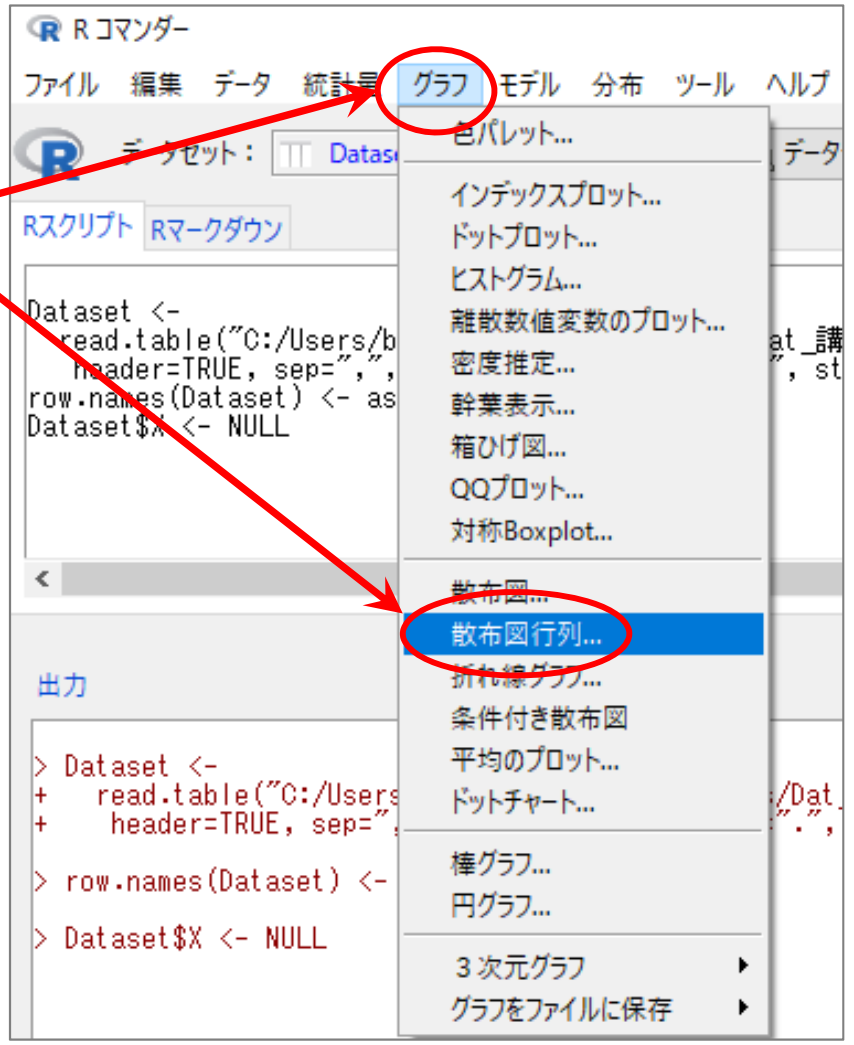

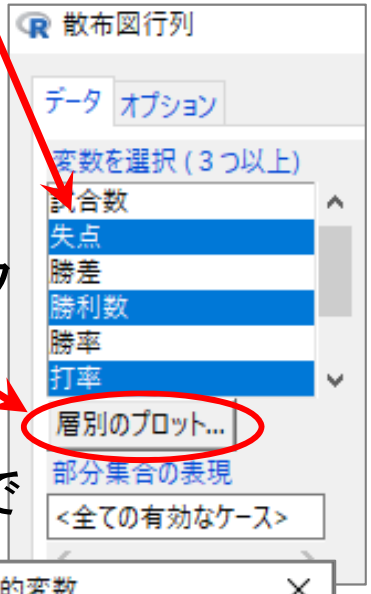

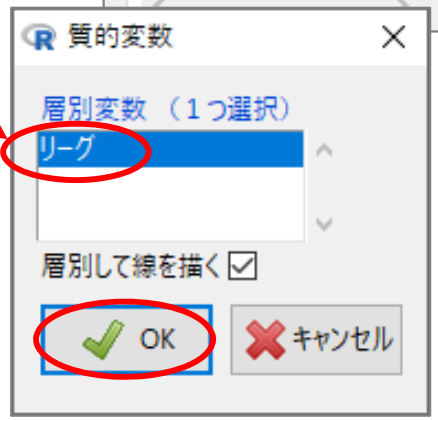

R commanderで散布図行列描画

⑧ 散布図行列を描く1 【完成1】

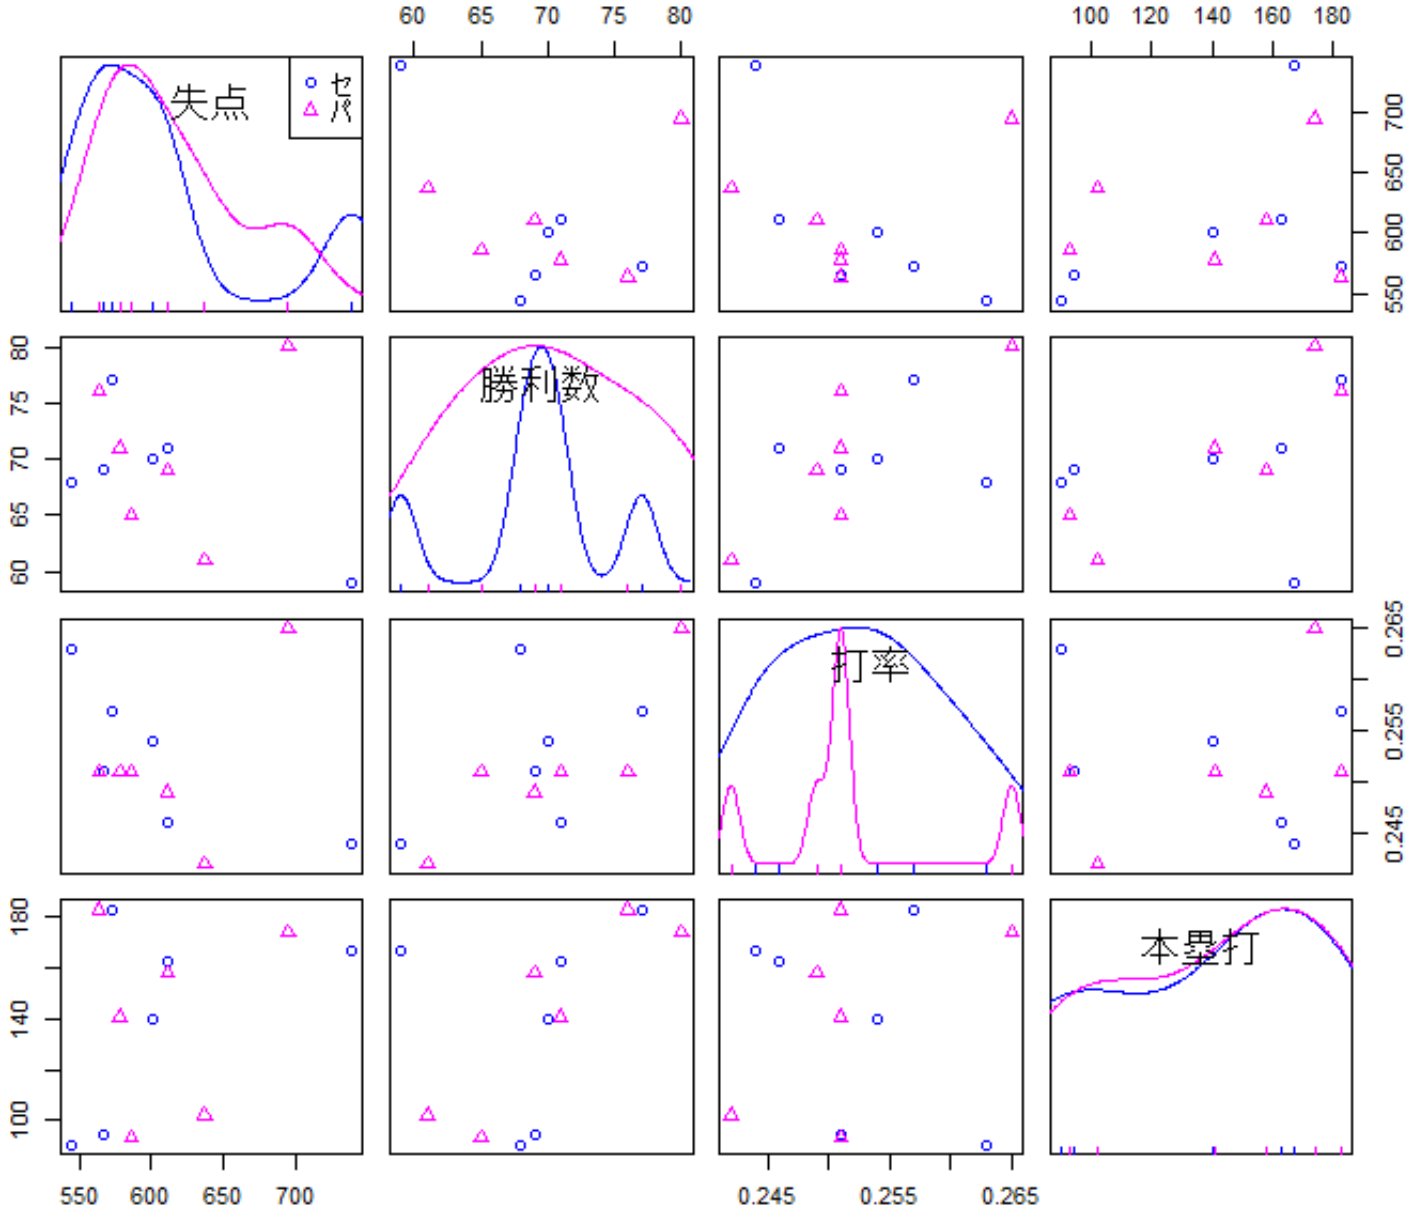

R commanderで散布図行列描画

⑧ 散布図行列を描く2 【完成2】

- 再度「グラフ」ー「散布図行列」選択し，[オプション]タブで設定
  - [対角位置に]=ヒストグラム
  - [他のオプション]=最小2乗直線

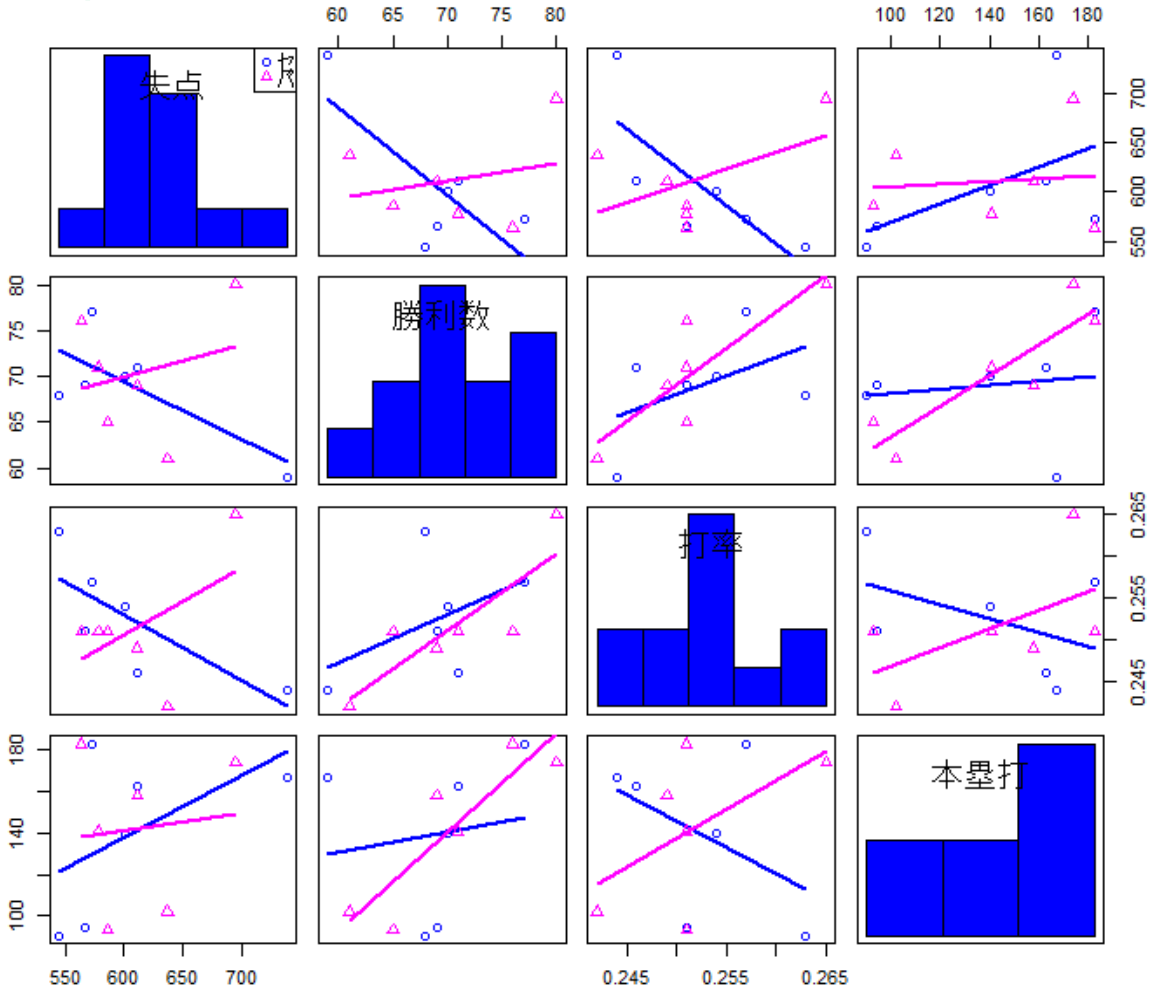

R commanderで散布図行列描画

⑧ 散布図行列を描く3 【完成3】

- 再度「グラフ」ー「散布図行列」選択し，[オプション]タブで設定
  - [対角位置に]=箱ひげ図
  - [他のオプション]=最小2乗直線, 集中楕円のプロット

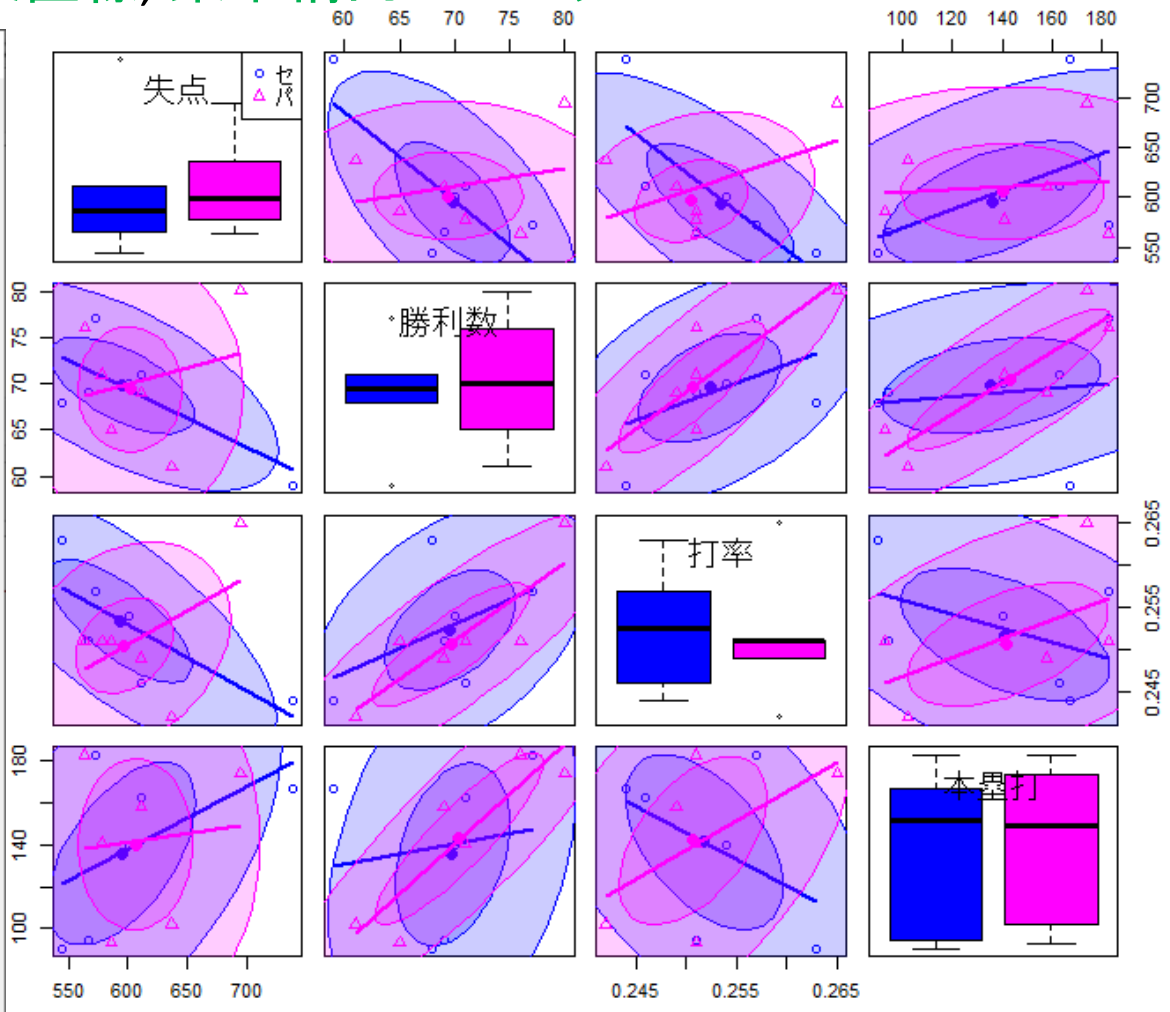

Rでデータの視覚化

- 多次元尺度法 multi-dimensional scaling
  - 類似度データから類似性が高いもの同士を近くに，低いもの同士を遠くに配置して描画する手法の1つ
- 描画用データファイルの準備
  - 類似度を表した行列形式のデータを csv ファイルにし，「マイドキュメント（"K:/"）」に保存

「yamaote.csv」… JR山手線30駅の駅間所要時間（分）データ

	東京駅	神田駅	秋葉原駅	御徒町駅	上野駅	鶯谷駅	日暮里駅	西日暮里駅	田端駅	駒込駅	巣鴨駅	大塚駅	池袋駅
東京駅	0	1	3	5	7	9	11	12	14	16	18	20	22
神田駅	1	0	2	4	6	8	10	11	13	15	17	19	21
秋葉原駅	3	2	0	2	4	6	8	9	11	13	15	17	19
御徒町駅	5	4	2	0	2	4	6	7	9	11	13	15	17
上野駅	7	6	4	2	0	2	4	5	7	9	11	13	15
鶯谷駅	9	8	6	4	2	0	2	3	5	7	9	11	13
日暮里駅	11	10	8	6	4	2	0	1	3	5	7	9	11
西日暮里駅	12	11	9	7	5	3	1	0	2	4	6	8	10
田端駅	14	13	11	9	7	5	3	2	0	2	4	6	8
駒込駅	16	15	13	11	9	7	5	4	2	0	2	4	6
巣鴨駅	18	17	15	13	11	9	7	6	4	2	0	2	4
大塚駅	20	19	17	15	13	11	9	8	6	4	2	0	2
池袋駅	22	21	19	17	15	13	11	10	8	6	4	2	0

…

⋮

Rでデータの視覚化

- 多次元尺度法 multi-dimensional scaling で描画
  - 作業フォルダの設定（マイドキュメント（”K:/”）へ移動）

```
> setwd(“K:/”)
```

  - 作業フォルダの確認/位置取得 get working directory

```
> getwd()
```

  - 保存してある csvファイル（yamanote.csv）の読み込み

```
> y0 <- read.csv(“K:/yamanote.csv", header=T, row.names=1)
```

  - （古典的）多次元尺度法で計算

```
> y1 <- cmdscale(y0)
```

  - 描画

```
> plot(y1, type=“b”)
> text(y1, names(y0), col=“blue”)
```

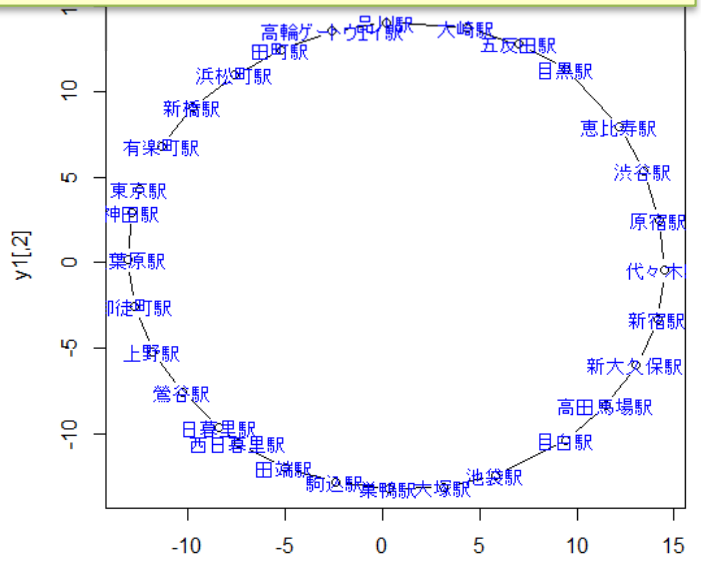

参考文献

- 山本他『Rで学ぶデータサイエンス12統計データの視覚化』共立出版（2013）
- 奥村晴彦『Rで楽しむ統計』共立出版（2016）
- J. P. Lander『みんなのR』マイナビ（2015）
- W. Chang『Rグラフィックス クックブック』オライリー（2013）
- 青木繁伸『Rによる統計解析』オーム社（2009）
- 荒木孝治『RとRコマンダーではじめる多変量解析』日科技連（2007）
- 金明哲『Rによるデータサイエンス』森北出版（2007）
- 新納浩幸『Rで学ぶクラスタ解析』オーム社（2007）

もっと知りたい人へ

- 関連する経営学科の授業
  - 「**基礎統計**」（1/2セメ）
  - 「**基礎統計演習**」（3/4セメ）
  - 「**データ処理応用**」（2/3セメ）
  - 「**統計モデル分析**」（5セメ）
  - 「**ビッグデータ・AI演習**」（6セメ）

Rでデータの視覚化

- csvファイルをデータとして利用
  - 「マイドキュメント(Y:)」に「R」フォルダをつくり中に保存

bb2018.csv

※）2018年プロ野球セ・パ成績（Yahoo Japan! Sports naviより）

	リーグ	試合数	勝利数	敗戦数	引分数	勝率	得点	失点	本塁打	盗塁	打率	防御率
広島	セ	143	82	59	2	0.582	721	651	175	95	0.262	4.12
ヤクルト	セ	143	75	66	2	0.532	658	665	135	68	0.266	4.13
巨人	セ	143	67	71	5	0.486	625	575	152	61	0.257	3.79
ＤｅＮＡ	セ	143	67	74	2	0.475	572	642	181	71	0.25	4.18
中日	セ	143	63	78	2	0.447	598	654	97	61	0.265	4.36
阪神	セ	143	62	79	2	0.44	577	628	85	77	0.253	4.03
西武	パ	143	88	53	2	0.624	792	653	196	132	0.273	4.24
ソフトバンク	パ	143	82	60	1	0.577	685	579	202	80	0.266	3.9
日本ハム	パ	143	74	66	3	0.529	589	586	140	98	0.251	3.77
オリックス	パ	143	65	73	5	0.471	538	565	108	97	0.244	3.69
ロッテ	パ	143	59	81	3	0.421	534	628	78	124	0.247	4.04
楽天	パ	143	58	82	3	0.414	520	583	132	69	0.241	3.78

- ファイルの読込み

※1行目にheaderあり　※各行の名称は列1に

```
> dfbb <- read.csv("Y:/R/bb2018.csv", header=T, row.names=1)
```

※ファイルのフルパス
例）Yドライブの Rフォルダ内にあるbb2018.csvという名前のファイル

Rでデータの視覚化

- 読込データの確認
  - dfbbに代入したdata frame の中身を全て表示

```
> dfbb
```

  - dfbbに代入したdata frame の中身を一部（先頭）表示

```
> head(dfbb)
```

  - dfbbに代入したdata frame の中身を一部（後尾）表示

```
> tail(dfbb)
```

  - dfbbの項目名表示（header=Tで読んだデータ）

```
> names(dfbb)
```

  - dfbbのレコード名表示（row.names=1で指定した）

```
> row.names(dfbb)
```

Rでデータの視覚化

- 箱ひげ図を描画

※dfbb$本塁打 … data.frameである dfbbの項目”本塁打”を箱ひげ図のデータとして使用

```
> boxplot(dfbb$本塁打)
```
… ①

- オプションを指定し箱ひげ図を描画

```
> boxplot(dfbb$本塁打, col="tomato", xlab="本塁打", ylab="本数",
main="12チーム本塁打数の箱ひげ図")
```
… ②

＜オプション＞
col … 色の指定(colour)
xlab … x軸のラベル(label)
ylab … y軸のラベル(label)
main … タイトル

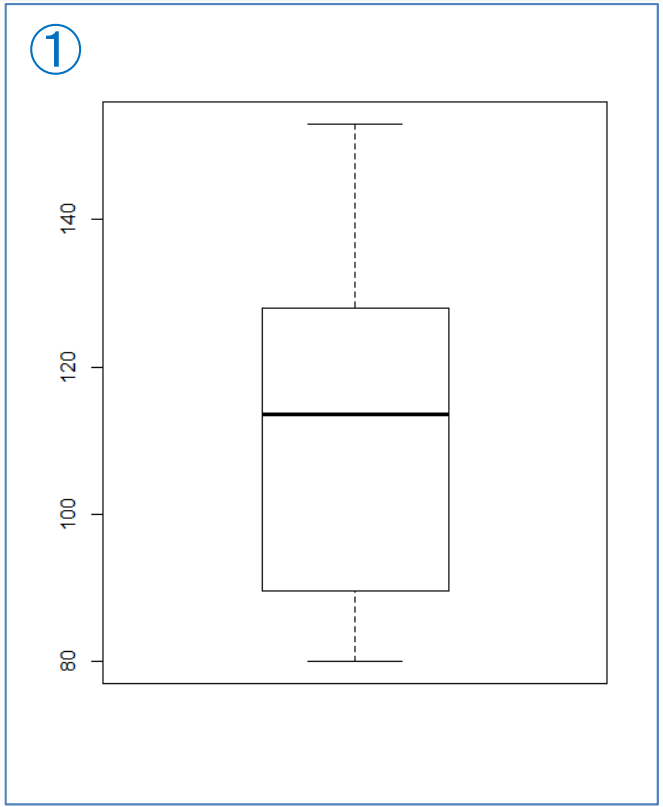

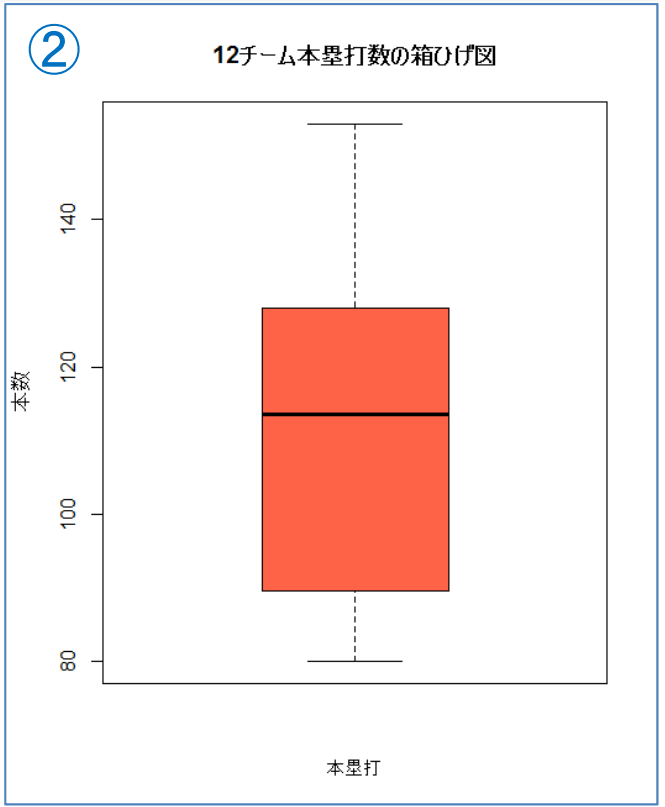

Rでデータの視覚化

- グループ毎に箱ひげ図を描画

```
> boxplot(dfbb$本塁打~dfbb$リーグ)
```

※項目「リーグ（セ・パ）」毎に描画するよう指定
（チルド記号 tilde（~）で層別にしたい項目を指定）

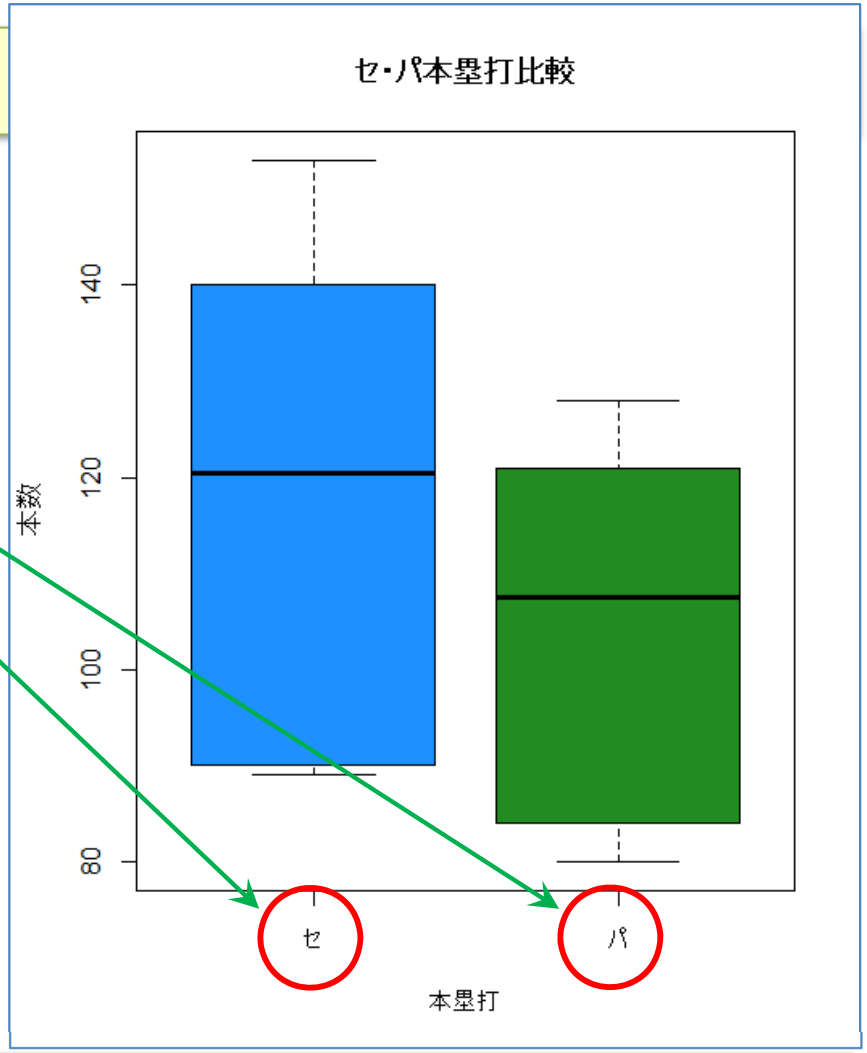

＜オプション＞
col … 色の指定(colour)
c(“blue”, ”red”, “green”) … 色名のベクトルをつくる
xlab … x軸のラベル(label)
ylab … y軸のラベル(label)
main … タイトル

```
> boxplot(dfbb$本塁打~dfbb$リーグ, xlab="本塁打", ylab="本数",
col=c("dodgerblue","forestgreen"), main="セ・パ本塁打比較")
```

Rでデータの視覚化

- 幹葉図（stem-and-leaf plot）を描画

```
> stem(dfbb$本塁打)
```

```
The decimal point is 1 digit(s) to the right of the |
 8 | 0490
10 | 134
12 | 188
14 | 03
```

- 幹葉図を描画（オプション scale=2）

```
> stem(dfbb$本塁打, 2)
```

```
The decimal point is 1 digit(s) to the right of the |
 8 | 049
 9 | 0
10 | 1
11 | 34
12 | 188
13 |
14 | 0
15 | 3
```

※scale数を大きくするとより詳細な幹葉図に
（default=1）

Rでデータの視覚化

- csv ファイルをデータとして利用
  - 「マイドキュメント（Y:）」に「R」フォルダをつくり中に保存

bi2016.csv

氏名	チーム	リーグ	打率	試合数	打席数	打数	安打	二塁打	三塁打	本塁打	塁打数	打点	得点	三振	四球	死球	犠打	犠飛	盗塁	出塁率	長打率	得点圏	併殺	失策
坂本　勇人	巨	セ	0.344	137	576	488	168	28	3	23	271	75	96	67	81	0	1	6	13	0.433	0.555	0.339	6	16
鈴木　誠也	広	セ	0.335	129	528	466	156	26	8	29	285	95	76	79	53	3	3	3	16	0.404	0.612	0.346	10	2
筒香　嘉智	D	セ	0.322	133	561	469	151	28	4	44	319	110	89	105	87	3	0	2	0	0.43	0.68	0.393	6	2
菊池　涼介	広	セ	0.315	141	640	574	181	22	3	13	248	56	92	106	40	0	23	3	13	0.358	0.432	0.343	3	4
福留　孝介	神	セ	0.311	131	523	453	141	25	3	11	205	59	52	78	61	3	0	6	0	0.392	0.453	0.31	6	1
山田　哲人	ヤ	セ	0.304	133	590	481	146	26	3	38	292	102	102	101	97	8	0	4	30	0.425	0.607	0.299	16	5
村田　修一	巨	セ	0.3024	143	576	529	160	32	0	25	267	81	58	83	38	5	2	2	1	0.354	0.505	0.305	21	15
川端　慎吾	ヤ	セ	0.3023	103	458	420	127	22	1	1	154	32	48	31	34	1	1	2	3	0.354	0.367	0.301	13	5
新井　貴浩	広	セ	0.3	132	513	454	136	23	2	19	220	101	66	101	54	1	0	4	0	0.372	0.485	0.323	12	5

※）2016年プロ野球個人成績（Yahoo Japan! Sports naviより）

- ファイル読込み

```
> dfbi <- read.csv("Y:/R/bi2016.csv", header=T, row.names=1)
```

【演習】

箱ひげ図で表示したい項目を1つ選び（例：打率，安打，本塁打，打点，得点，etc.），12チーム毎の箱ひげ図を描画せよ．

さらに，可能なら，色，x軸ラベル，y軸ラベル，タイトルを適切に設定してみよう

Rでデータの視覚化

その他のグラフ作成例

棒グラフ

散布図

※これらのグラフを作成したい時は，Excelを使った方が良い

Rでデータの視覚化

- 棒グラフを作成

※色指定用のベクトル生成．“royalblue”を6回 repeat し，
”violetred”を6回repeat したベクトルをつくり cc に代入

```
> cc <- c(rep("royalblue",6), rep("violetred",6))
> barplot(dfbb$勝数, names.arg=row.names(dfbb), col=cc, xlab="
チーム名", ylab="勝数")
```

dfbb$勝数 … data.frameである dfbb の項目”勝数”を棒グラフのデータとして使用
names.arg … それぞれの棒に対応する名称
col … 棒の色指定
xlab … x軸のラベル
ylab … y軸のラベル

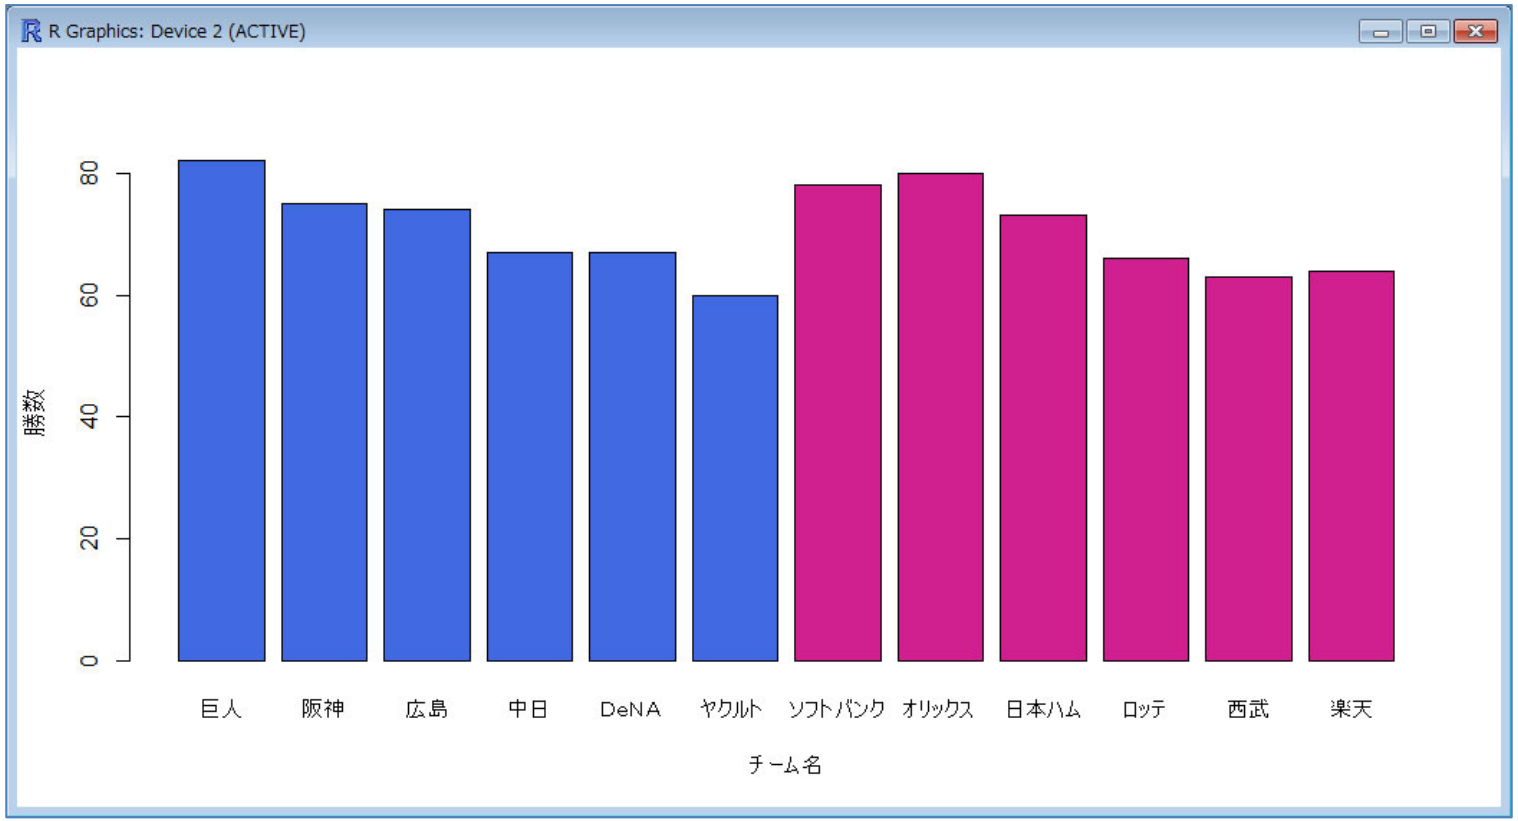

- Tips！

```
> colors()
```

※Rで使える657色の名称リスト表示

Rでデータの視覚化

- 散布図を作成（1）

```
> plot(dfbb$勝率, dfbb$防御率, xlab="勝率", ylab="防御率",
col="purple")
```

x軸を dfbb$勝率
y軸を dfbb$防御率
のデータを用い散布図を作成

xlab … x軸ラベルの指定
ylab … y軸ラベルの指定
col … プロットする点の色指定

dfbb$勝率 は dfbb[,6] でもよい
dfbb$防御率 は dfbb[,12] でもよい

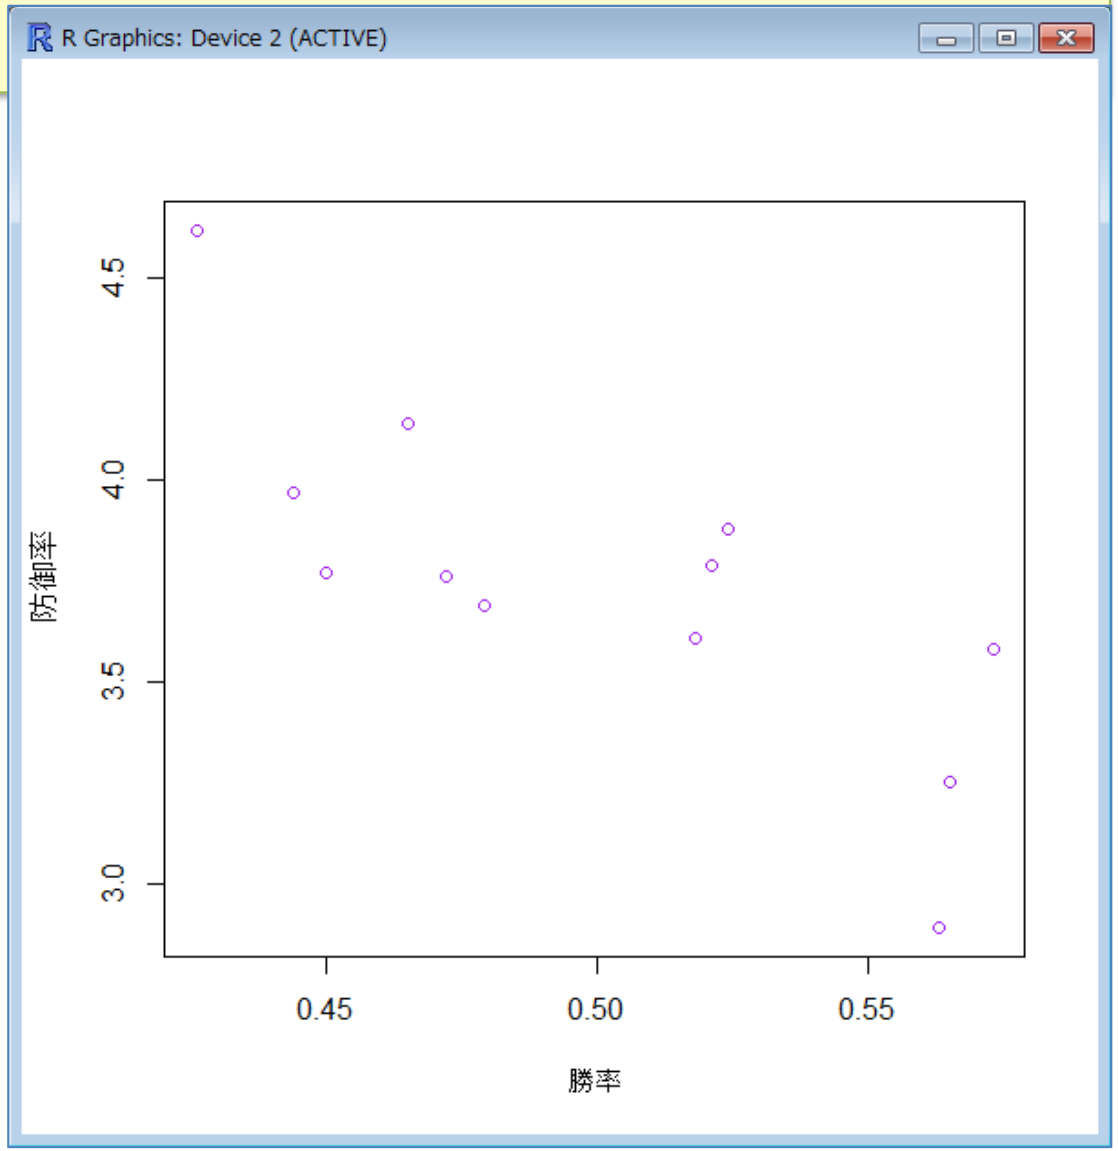

Rでデータの視覚化

- 散布図を作成（2）

```
> plot(dfbb[,6], dfbb[,12], xlab="勝率", ylab="防御率", type="b")
```

x軸を dfbb[,6]=“勝率”
y軸を dfbb[,12]=“防御率”
のデータを用い散布図を作成

xlab … x軸ラベルの指定
ylab … y軸ラベルの指定

type … 描画点の種類
- “p” … points 点（default）
- “l” … lines 線分
- “b” … both点と線分　両方
- “c” … “b” から点を抜いたもの
- “o” … overplotted
- “h” … histogram
- “s” … stair steps
- “n” … no plotting 点をかかない

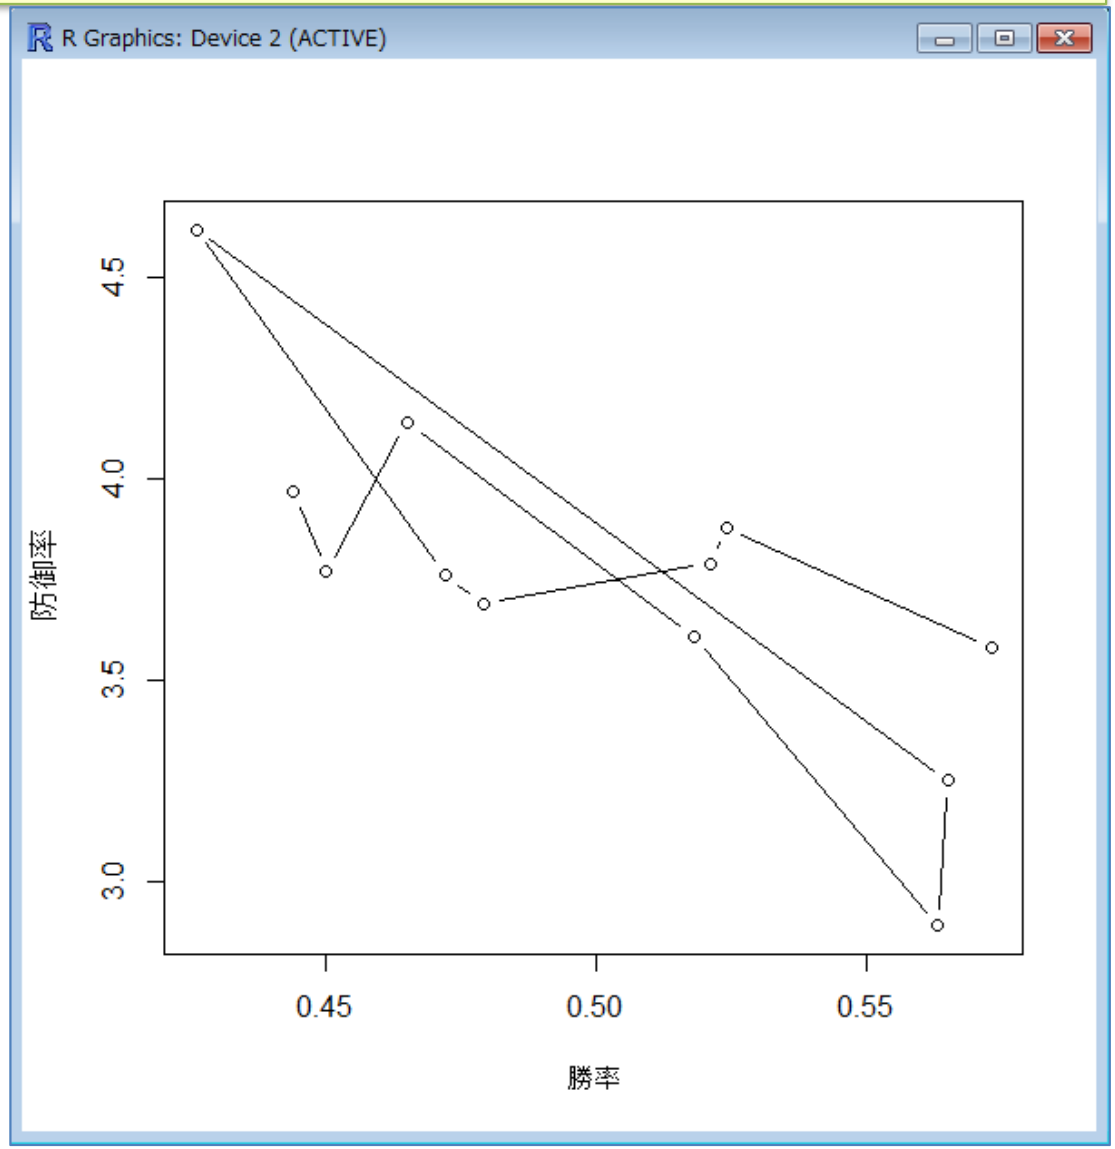

Rでデータの視覚化

- 散布図を作成（3）

※プロットはせずに，枠・軸だけを描画

```
> plot(dfbb[,6], dfbb[,12], xlab="勝率", ylab="防御率", type="n")
> text(dfbb[,6], dfbb[,12], dfbb[,1], col=cc)
```

※リーグ名称をプロット点として描く
（data.frame である dfbb の1列目に
リーグ名を入れたことを思いだそう！）

※col=cc は色設定を ccにするということ
（cc はリーグ毎の色設定用ベクトル
として作ったことを思いだそう！）

dfbb[,1] は dfbb$リーグ でもよい
dfbb[,6] は dfbb$勝率 でもよい
dfbb[,12] は dfbb$防御率 でもよい

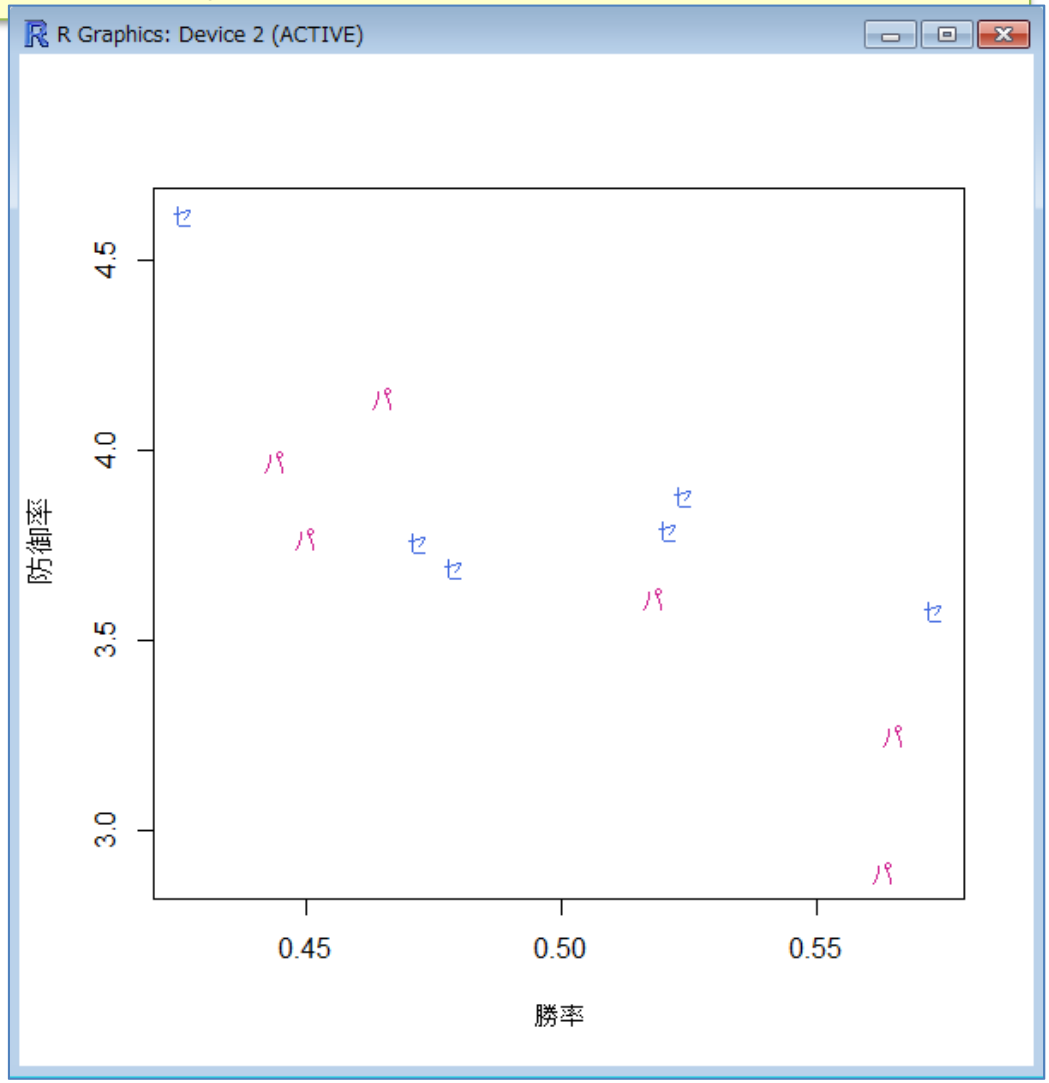

Rでデータの視覚化

- 散布図を作成（4）

※プロットはせずに，枠・軸だけを描画

```
> plot(dfbb[,6], dfbb[,12], xlab="勝率", ylab="防御率", type="n")
> text(dfbb[,6], dfbb[,12], row.names(dfbb))
```

※チーム名称をプロット点としてかく
（read.csvでcsvファイルを読み込んだ時に，row.namesとして1列目のチーム名称を指定したことを思いだそう！）

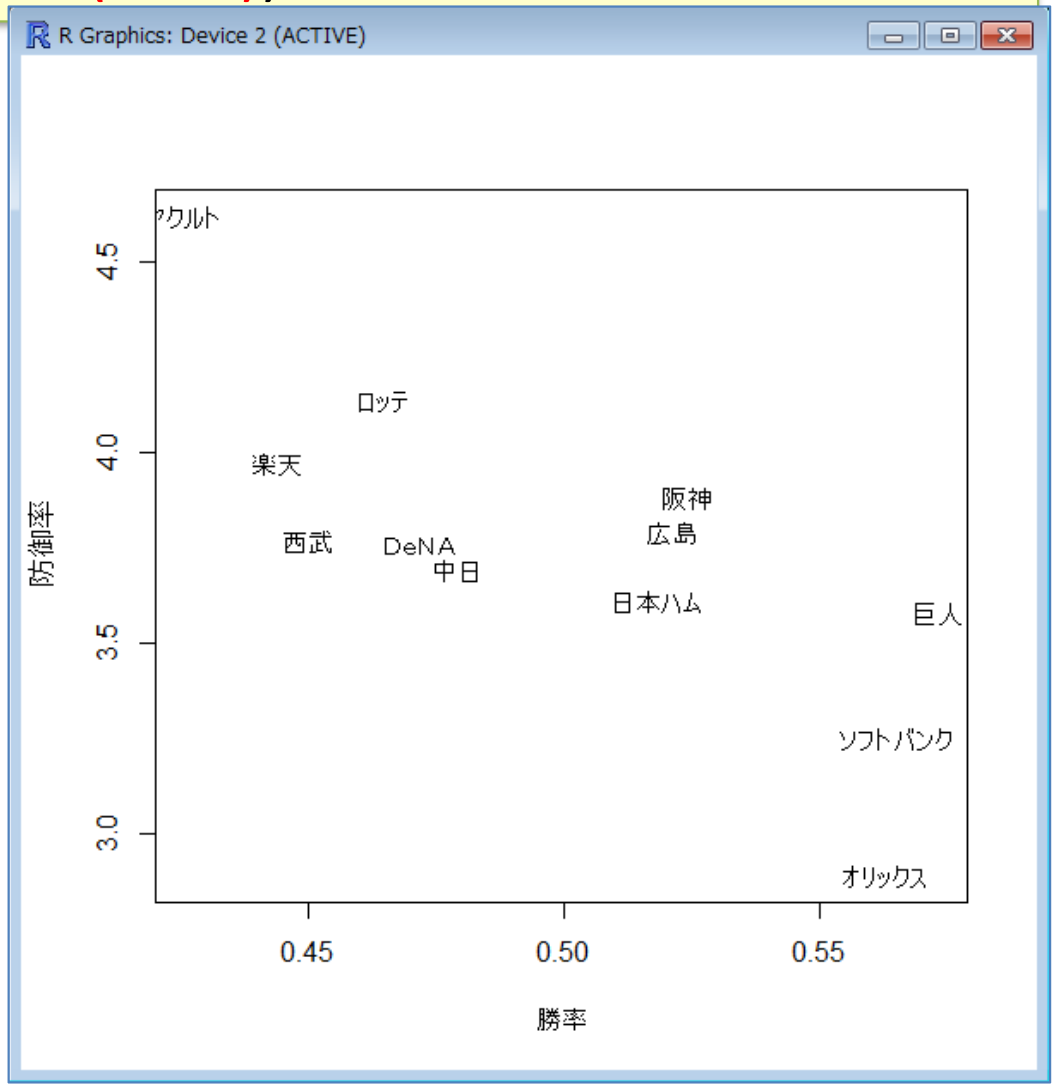

dfbb[,6] は dfbb$勝率 でもよい
dfbb[,12] は dfbb$防御率 でもよい

【参考】

Rでデータの視覚化

- 箱ひげ図と散布図を作成（1）-scatterplot()-

```
> install.packages("car")
> library(car)
```

※scatterplot() の使用準備
package “car”のインストール
package “car”の読込み

```
> scatterplot(dfbb[,4], dfbb[,8], xlab="負数", ylab="失点")
```

x軸を dfbb[,4]=“負数”
y軸を dfbb[,8]=“失点”
のデータを用い散布図を作成

xlab … x軸ラベルの指定
ylab … y軸ラベルの指定

※それぞれの軸に，それぞれのデータの箱ひげ図が描かれる

※緑線は回帰直線 regression line

※赤線・赤点線は平滑化線とspan

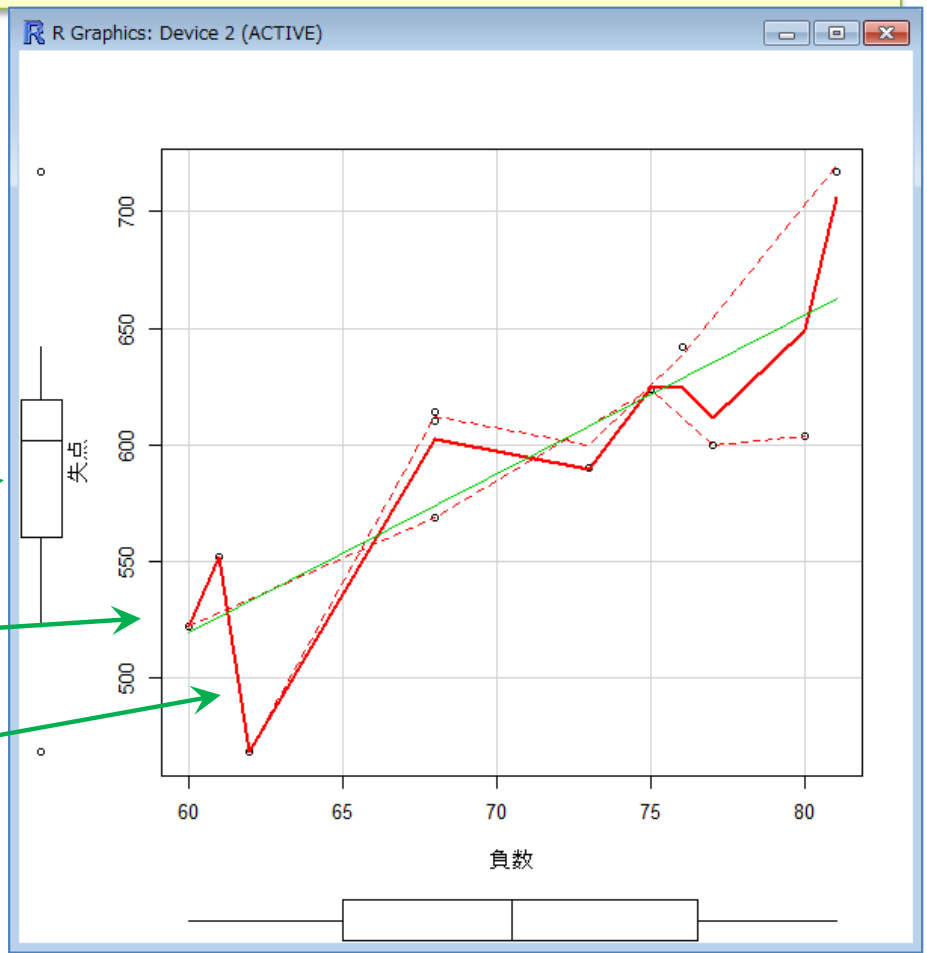

【参考】

Rでデータの視覚化

- 箱ひげ図と散布図を作成（2）-scatterplot()-

```
> install.packages(“sp”)
> install.packages(“maptools”)
> library(sp)
> library(maptools)
```

※pointLabel() の使用準備
packages “sp”,“maptools”のインストール

packages “sp”, “maptools”の読込み
（注：必ず sp → maptools の順！）

– 点とチーム名を両方プロットする

```
> scatterplot(dfbb[,4], dfbb[,8], xlab="負数", ylab="失点", reg.line=F, smooth=F)
> pointLabel(x=dfbb[,4], y=dfbb[,8], labels=row.names(dfbb))
```

※平滑化線は描かない

※散布図の点のラベルを
row.names(dfbb)として書く

※回帰直線 regression line
は描かない（FはFalseの意）

【参考】

Rでデータの視覚化