

# 問題解決技法入門

## 4. Data Analysis

### 2. Data Visualization using R

堀田 敬介

# R commanderでデータの視覚化

## ① データの準備: csv ファイル

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

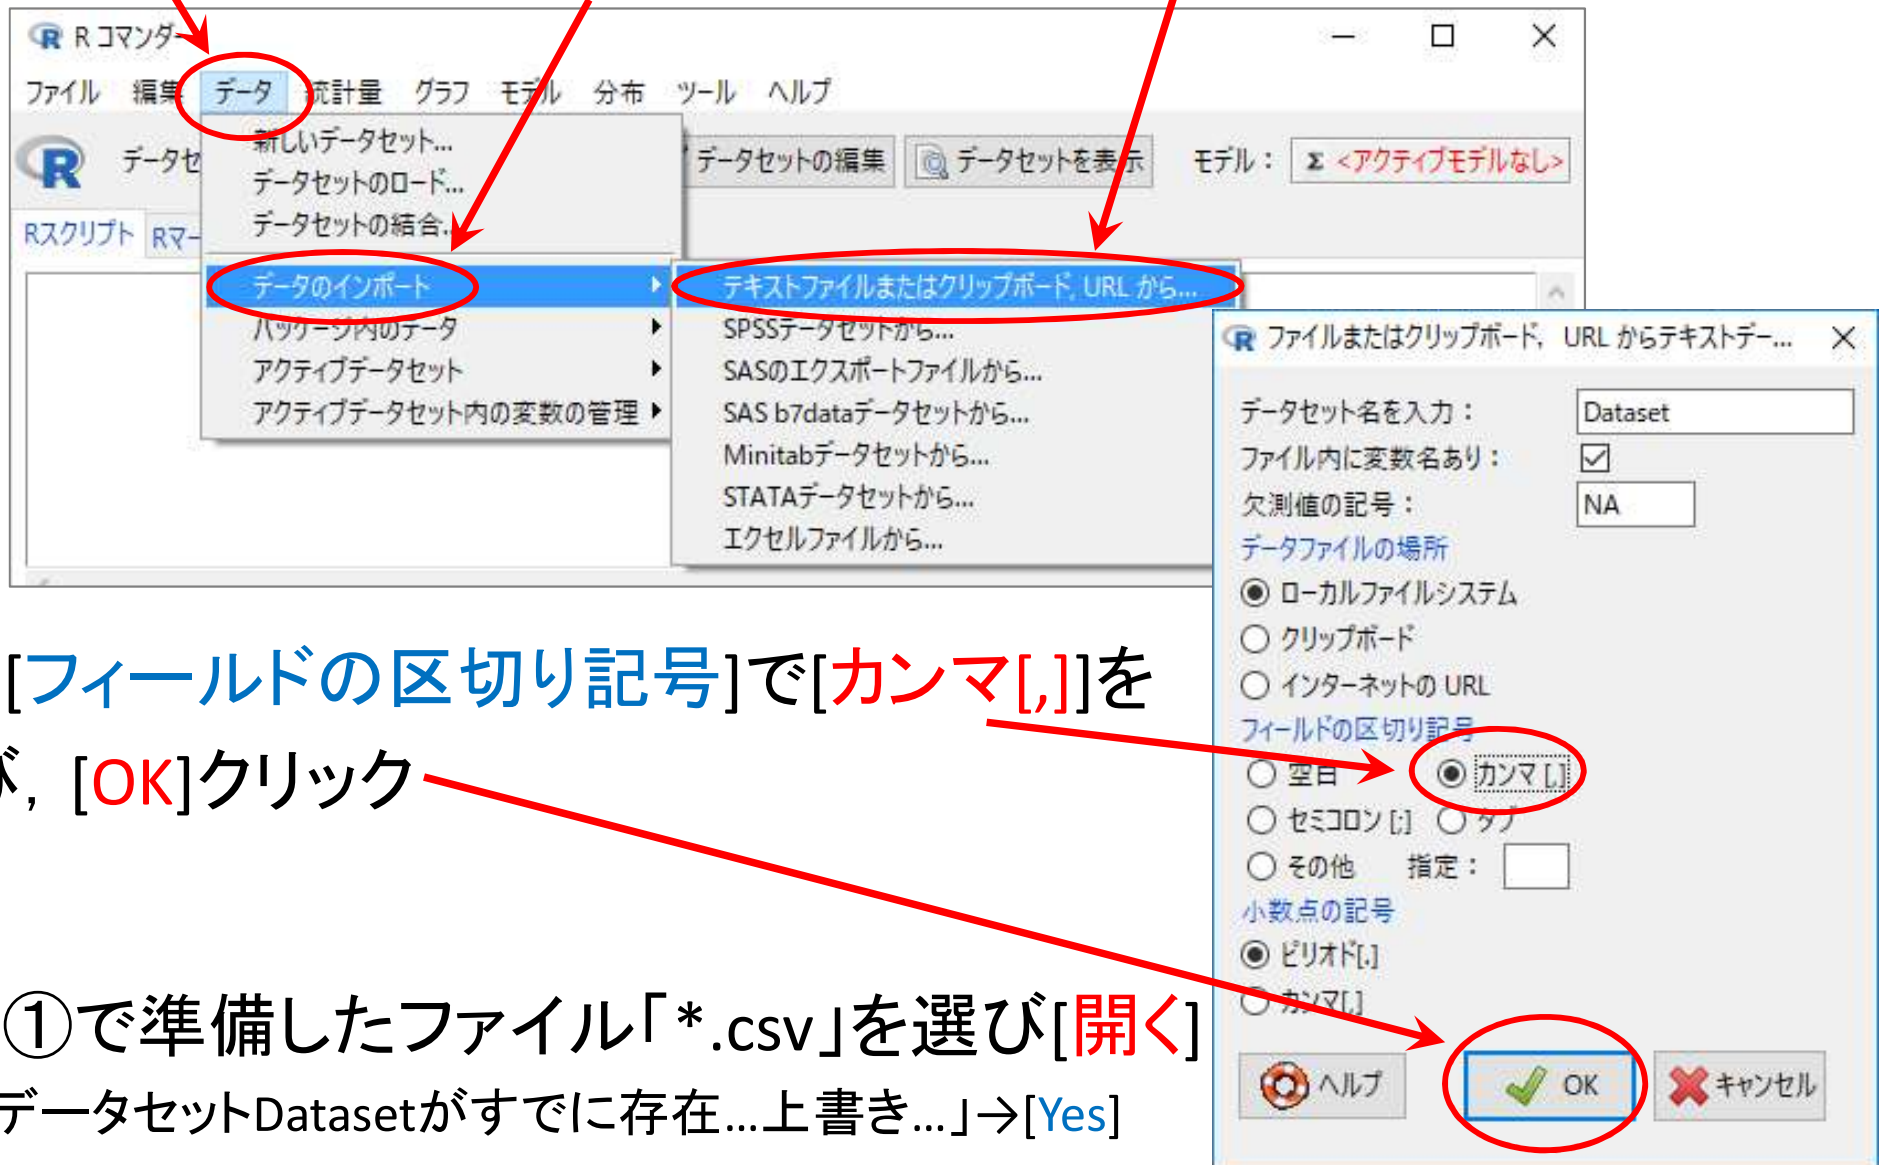
## ② Rの起動: 「プログラム」で「R x64 3.x.x」を選択

- 注) x64 = 64bit用のプログラム(アプリ)
- 注) 3.x.x = Rのバージョン
- 注) 起動すると「R Console(64-bit)」と「Rコマンドー」の2つのウィンドウが開く。「Rコマンドー」を使う

# R commanderでデータの視覚化

## ③ データの読込

- 「データ」-「データのインポート」-「テキストファイル...」を選択



The screenshot shows the R Commander interface. The 'Data' menu is open, and the 'Import Data' sub-menu is selected. The 'Text File or Clipboard, URL...' option is highlighted. A dialog box titled 'File or Clipboard, URL from Text Data...' is open, showing the 'Field Separator' section with 'Comma' selected. The 'OK' button is also highlighted.

- [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
  - 注1) 氏名の項目名が「X」であることを確認（もとのファイルに項目名がないデータは自動的に「X」となる）
  - 注2) ケース名（左端）が通し番号（1,2,...,12）となっていることを確認

R Commander window showing the 'Dataset' window. The 'データセットを表示' button is circled in red. The dataset table is also circled in red.

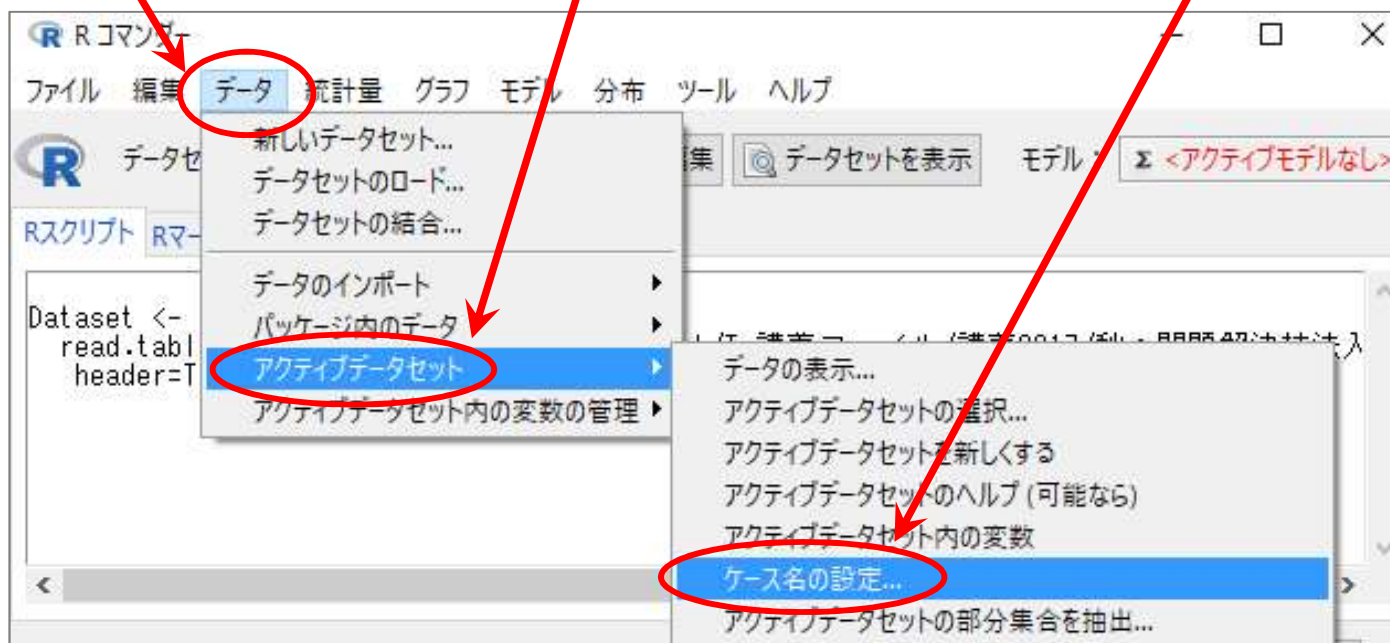
	X	リーグ	試合数	勝数	負数	引分数	勝率	得点	失点	本塁打	盗塁	打率	防
1	広島	セ	143	89	52	2	0.631	684	497	153	118	0.272	
2	巨人	セ	143	71	69	3	0.507	519	543	128	62	0.251	
3	DeNA	セ	143	69	71	3	0.493	572	588	140	67	0.249	
4	阪神	セ	143	64	76	3	0.457	506	546	90	59	0.245	
5	ヤクルト	セ	143	64	78	1	0.451	594	694	113	82	0.256	
6	中日	セ	143	58	82	3	0.414	500	573	89	60	0.245	
7	日本ハム	パ	143	87	53	3	0.621	619	467	121	132	0.266	
8	ソフトバンク	パ	143	83	54	6	0.606	637	479	114	107	0.261	
9	ロッテ	パ	143	72	68	3	0.514	583	582	80	77	0.256	
10	西武	パ	143	64	76	3	0.457	619	618	128	97	0.264	
11	楽天	パ	143	62	78	3	0.443	544	654	101	56	0.257	
12	オリックス	パ	143	57	83	3	0.407	499	635	84	104	0.253	

- 注3) 確認後は、必ず「Dataset」の「×」をクリックして「閉じる」こと

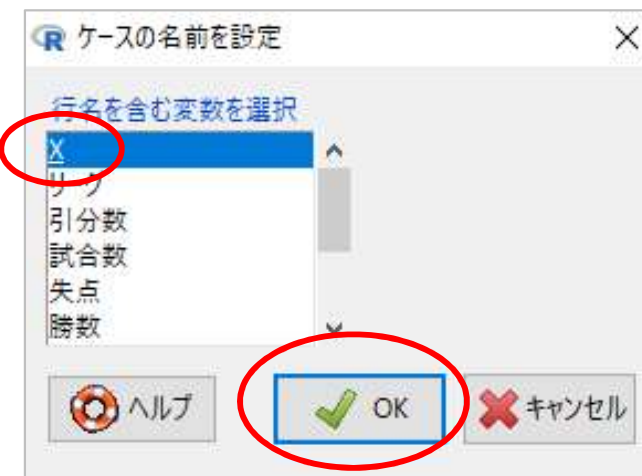
# R commanderでデータの視覚化

## ④ データにケース名を設定する

- 「データ」-「アクティブデータセット」-「ケース名の設定」選択



- [行名を含む変数を選択]で[X]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
  - 注1) 指定した変数がケース名になっていることを確認

Rコマンドー

ファイル 編集 データ 統計量 グラフ モデル 分布 ツール ヘルプ

データセット: Dataset データセットの編集 データセットを表示 モデル: <アクティブモデルなし>

Rスクリプト Dataset

リーグ	試合数	勝数	負数	引分数	勝率	得点	失点	本塁打	盗塁	打率	防御
広島	143	89	52	2	0.631	684	497	153	118	0.272	3.20
巨人	143	71	69	3	0.507	519	543	128	62	0.251	3.45
DeN	143	69	71	3	0.493	572	588	140	67	0.249	3.76
阪神	143	64	76	3	0.457	506	546	90	59	0.245	3.38
ヤクル	143	64	78	1	0.451	594	694	113	82	0.256	4.73
中日	143	58	82	3	0.414	500	573	89	60	0.245	3.65
日本ハ	143	87	53	3	0.621	619	467	121	132	0.266	3.06
ソフト	143	83	54	6	0.606	637	479	114	107	0.261	3.09
ロッテ	143	72	68	3	0.514	583	582	80	77	0.256	3.66
西武	143	64	76	3	0.457	619	618	128	97	0.264	3.85
楽天	143	62	78	3	0.443	544	654	101	56	0.257	4.11
オリッ	143	57	83	3	0.407	499	635	84	104	0.253	4.18

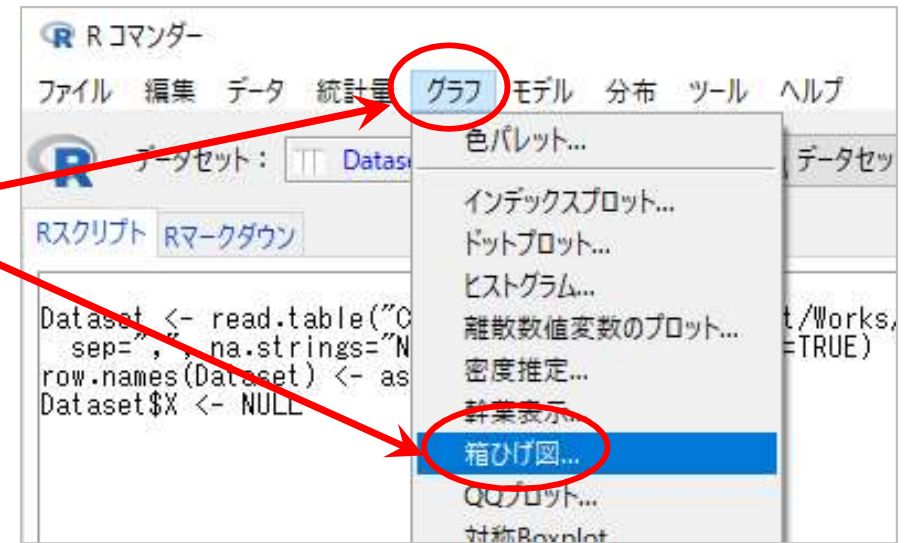
出力 実行

- 注2) 確認後は、必ず「Dataset」の「×」をクリックして「閉じる」こと

# R commanderでデータの視覚化

## ⑤ 箱ひげ図を描く

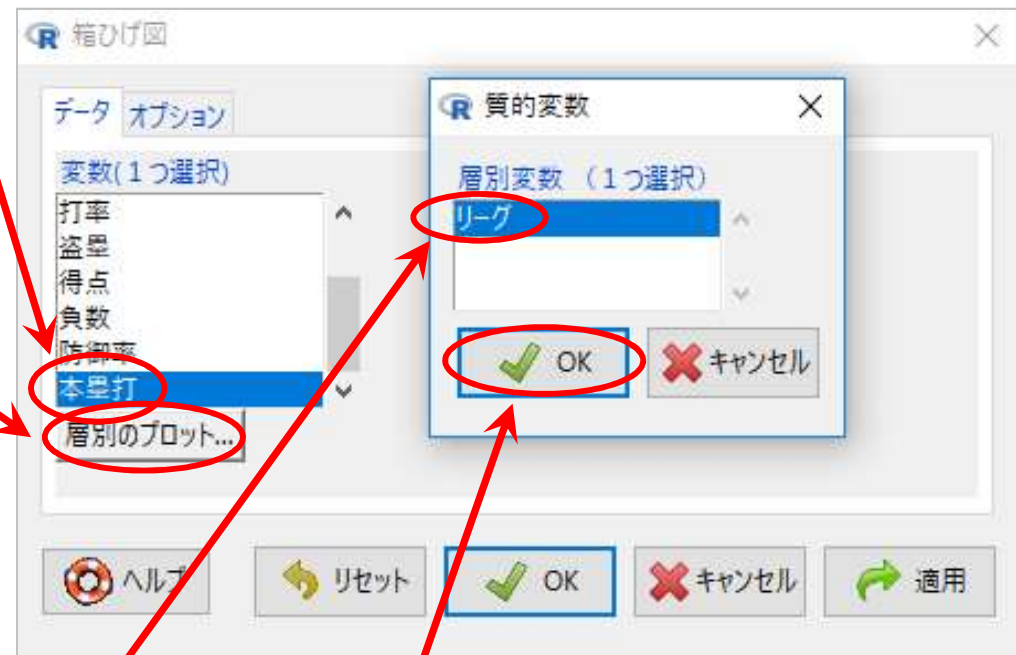
➤ 「グラフ」-「箱ひげ図」を選択



➤ 『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

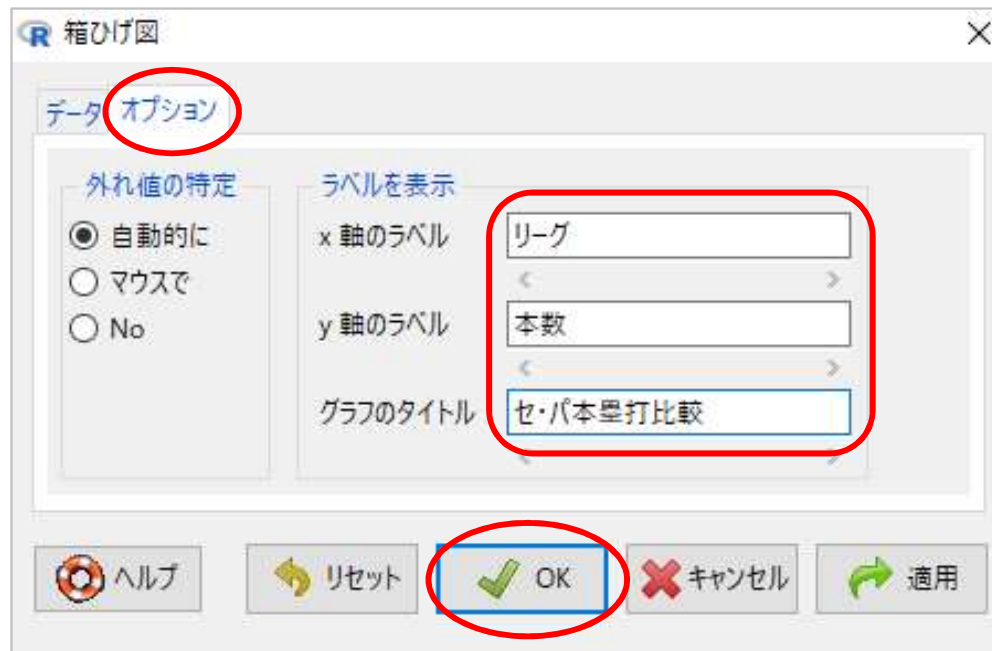


➤ [層別変数(1つ選択)]で[リーグ]を選択し[OK]


# 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」-「幹葉表示」を選択

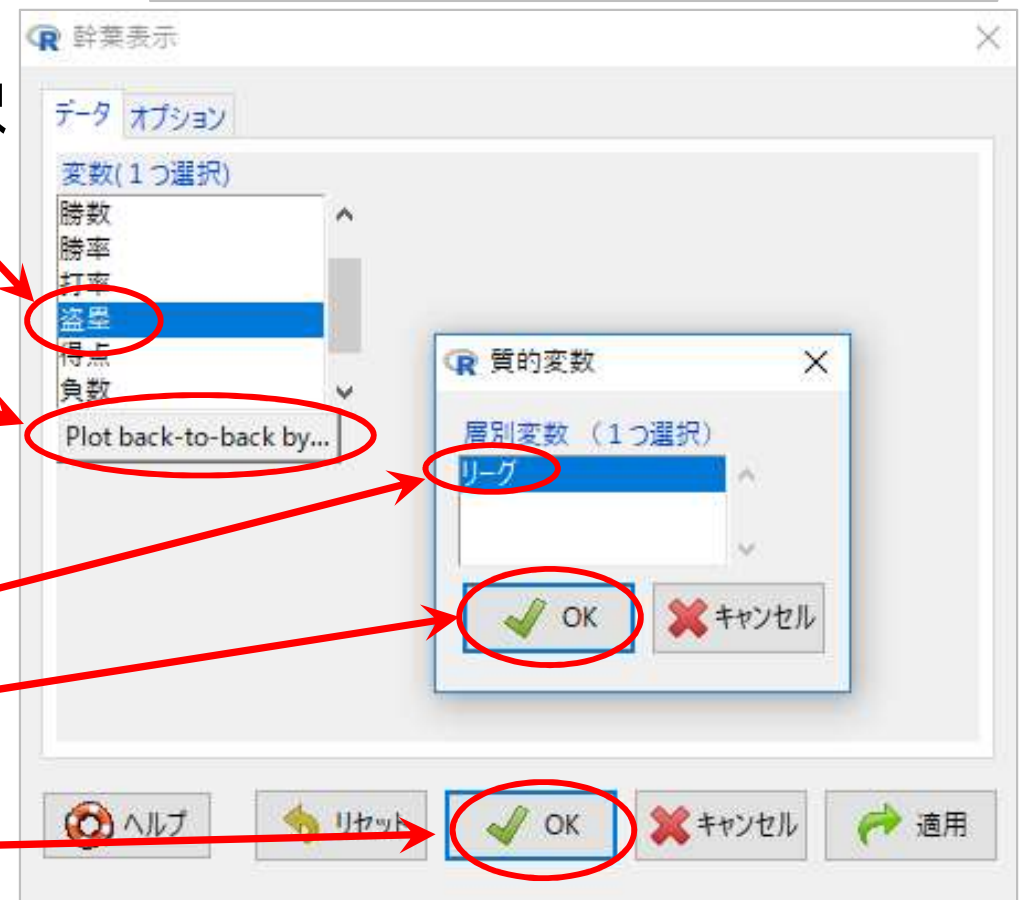
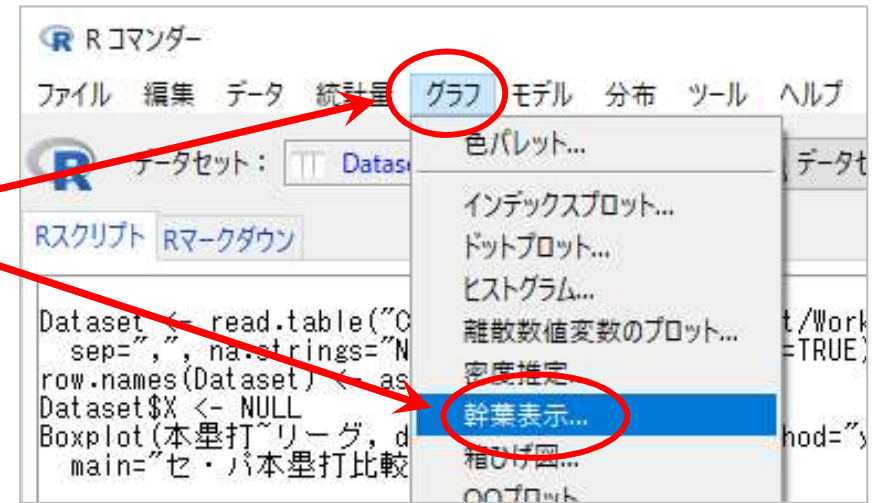
➤ 『幹葉表示』で以下を設定

➤ [変数(1つ選択)]で[盗塁]選択

➤ [Plot back-to-back by..]クリック

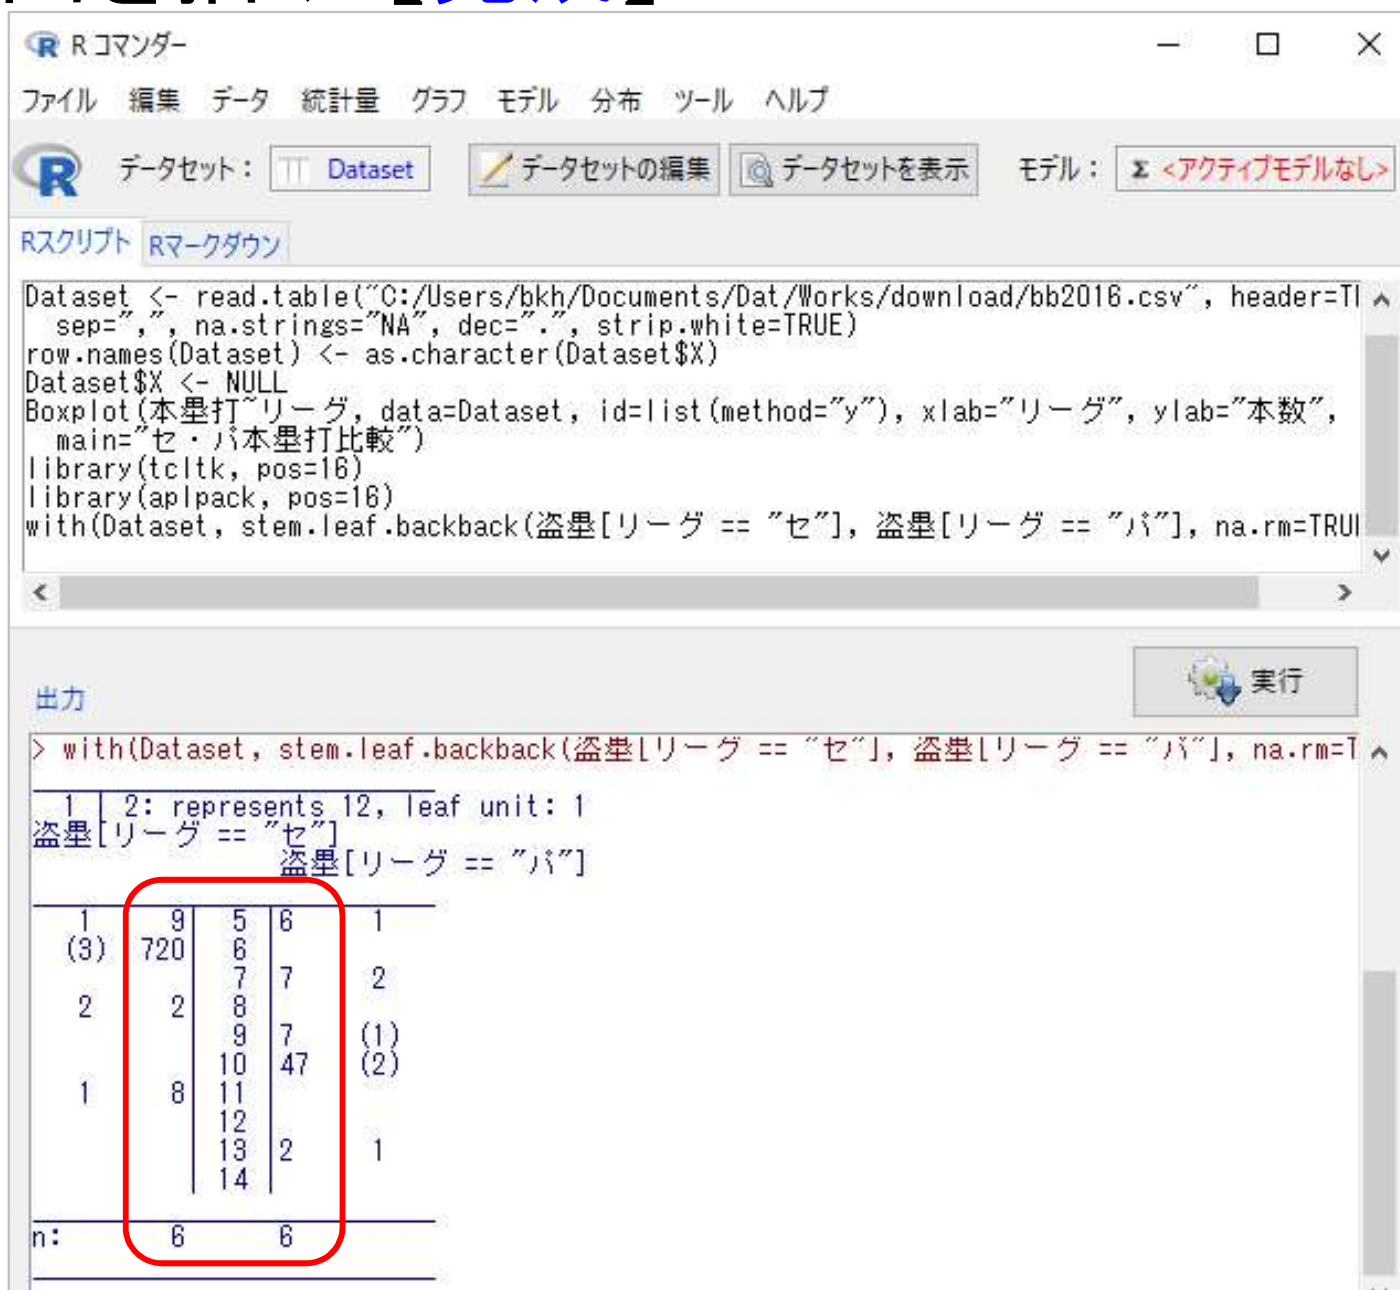
➤ [層別変数(1つ選択)]で  
[リーグ]を選択し[OK]

➤ 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】



The screenshot shows the R Commander interface. The R script pane contains the following code:

```
Dataset <- read.table("C:/Users/bkh/Documents/Dat/Works/download/bb2018.csv", header=TI ^
  sep=",", na.strings="NA", dec=".", strip.white=TRUE)
row.names(Dataset) <- as.character(Dataset$X)
Dataset$X <- NULL
Boxplot(本塁打~リーグ, data=Dataset, id=list(method="y"), xlab="リーグ", ylab="本数",
  main="セ・パ本塁打比較")
library(tcltk, pos=16)
library(aplpack, pos=16)
with(Dataset, stem.leaf.backback(盗塁[リーグ == "セ"], 盗塁[リーグ == "パ"], na.rm=TRUE))
```

The output pane shows the execution of the `with(Dataset, stem.leaf.backback(...))` command, resulting in a stem-and-leaf plot. A red box highlights the plot area.

```
> with(Dataset, stem.leaf.backback(盗塁[リーグ == "セ"], 盗塁[リーグ == "パ"], na.rm=TRUE))
1 | 2: represents 12, leaf unit: 1
盗塁[リーグ == "セ"]      盗塁[リーグ == "パ"]
-----
1 | 9 | 5 | 6 | 1
(3) | 720 | 6 | 7 | 2
2 | 2 | 8 | 7 | (1)
| 9 | 7 | 47 | (2)
1 | 8 | 10 | 11 |
| 11 | 12 |
| 13 | 2 | 1
| 14 |
n: | 6 | 6
```

# R commanderでデータの視覚化

## ⑦ 散布図を描く

➤ 「グラフ」-「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

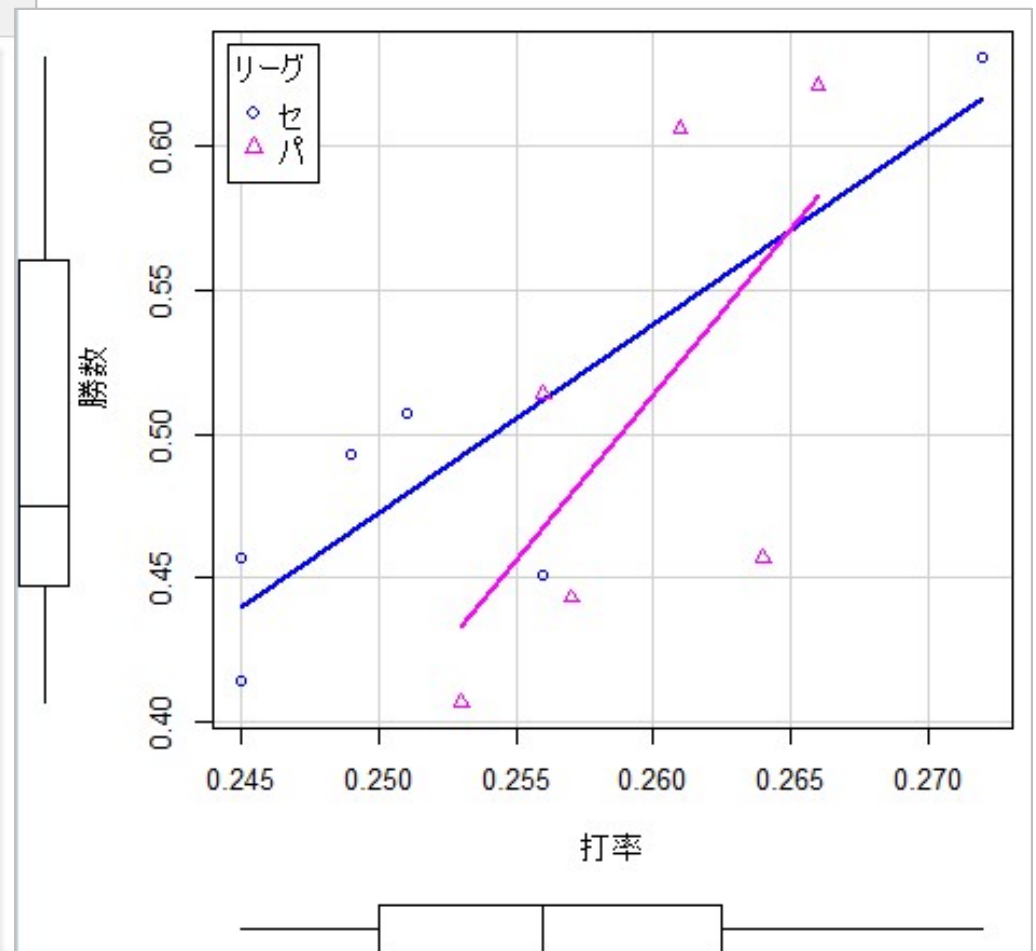
➤ [層別変数(1つ選択)]で  
[リーグ]を選択し [OK]

The image shows a sequence of screenshots from the R Commander application. The top screenshot shows the 'Graph' menu with 'Scatter Plot...' selected. The middle screenshot shows the 'Scatter Plot' dialog box with 'Rate' selected for the x-axis and 'Win Rate' for the y-axis. The bottom screenshot shows the 'Layered Plot' dialog box with 'League' selected for the faceting variable and the 'OK' button highlighted.

# 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]



# 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
  - 「**統計の見方**」(1/2セメ)
  - 「**統計の分析と利用**」(2セメ)
  - 「**データ処理Ⅱ**」(2/3セメ)
  - 「**統計データの扱い方**」(3/4セメ)
  - 「**多変量の統計データ解析**」(4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

- ファイルの読み込み

※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)

- ファイル読み込み

```
> 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

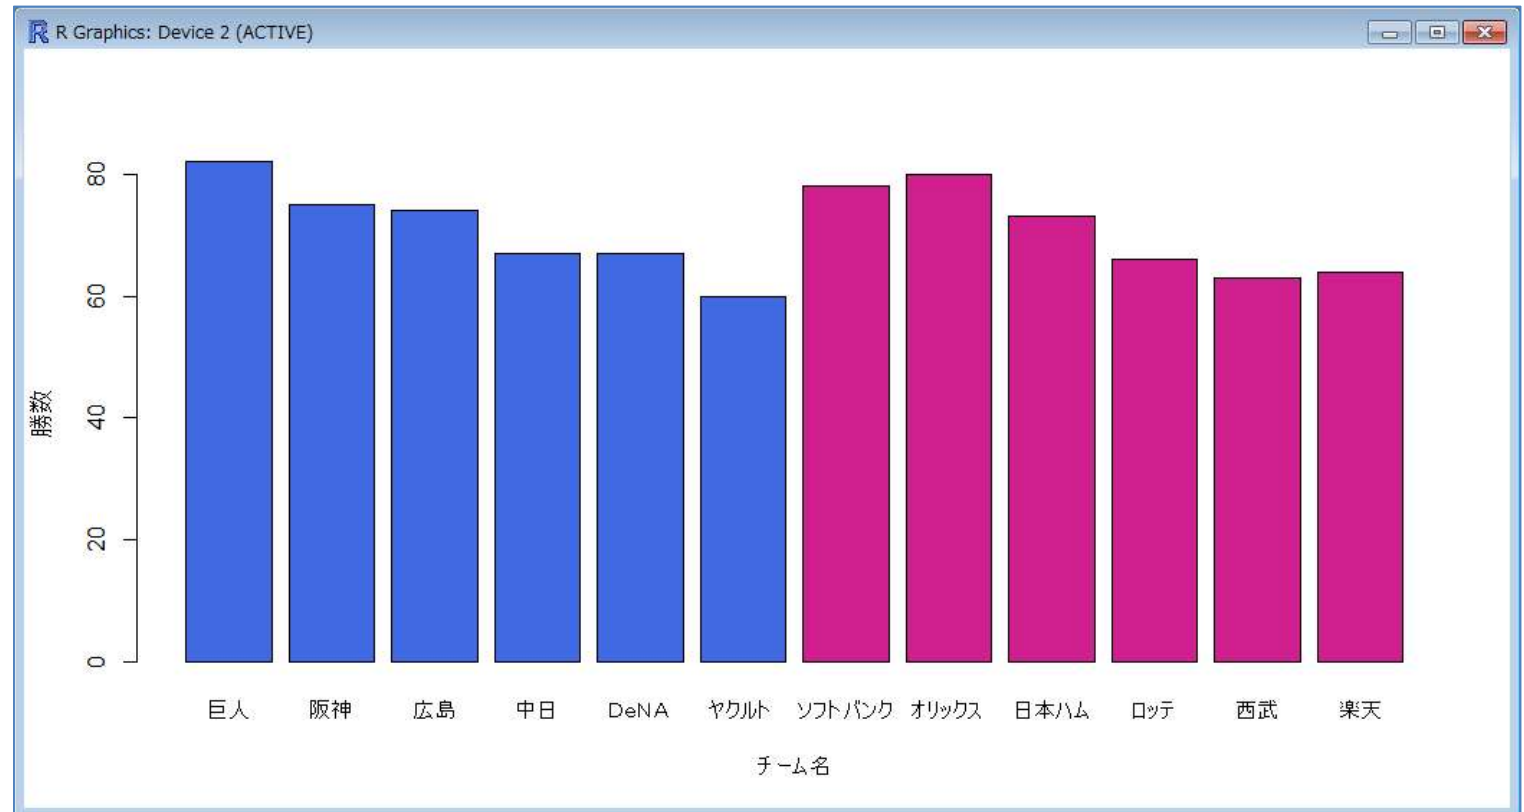
xlab ... x軸のラベル

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)

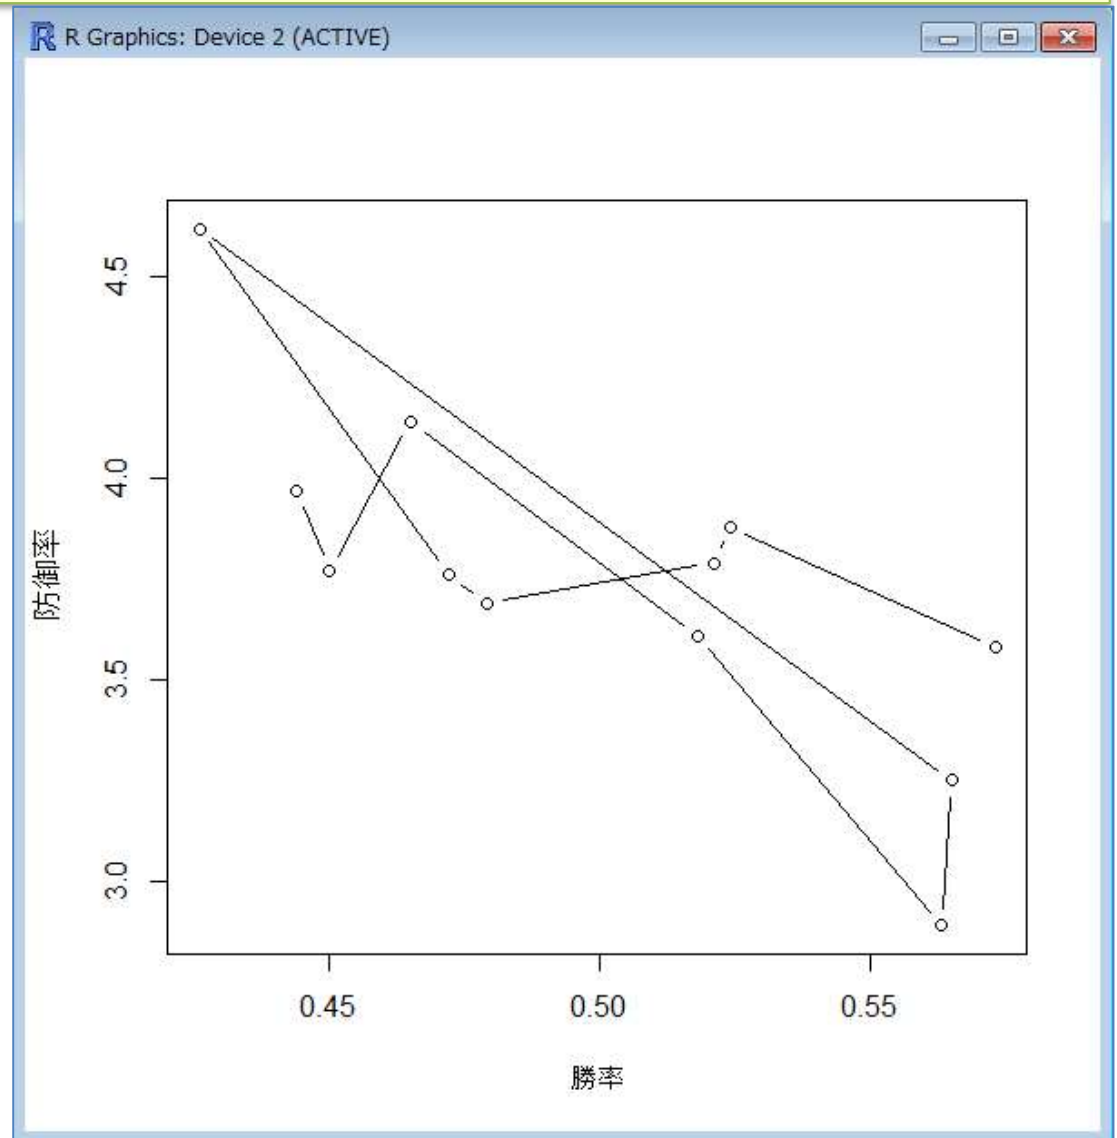
```
> plot(dfbb[,6], dfbb[,12], xlab="勝率", ylab="防御率", type="b")
```

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)

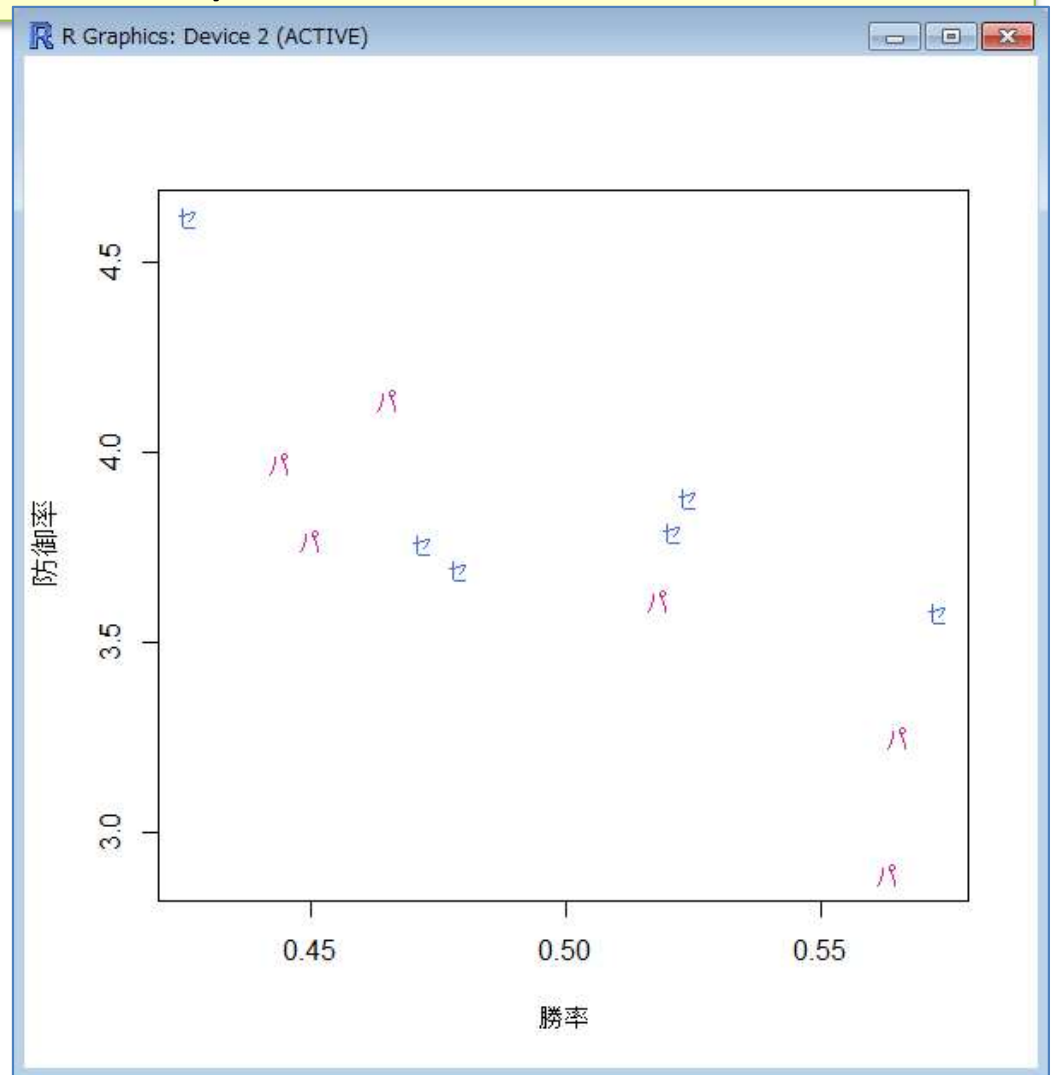
※プロットはせずに、枠・軸だけを描画

```
> 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" の読み込み

```
> 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"の読み込み  
(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

