

# データサイエンス 基礎

*Fundamental Data Science*

## 第4回 データの要約



私たちがナビゲートします!



## 今日の内容

### ▶ データの要約 (続き)



## 前回の復習

### ▶ ヒストグラム

**分布**を視覚的に表す

### ▶ 要約統計量

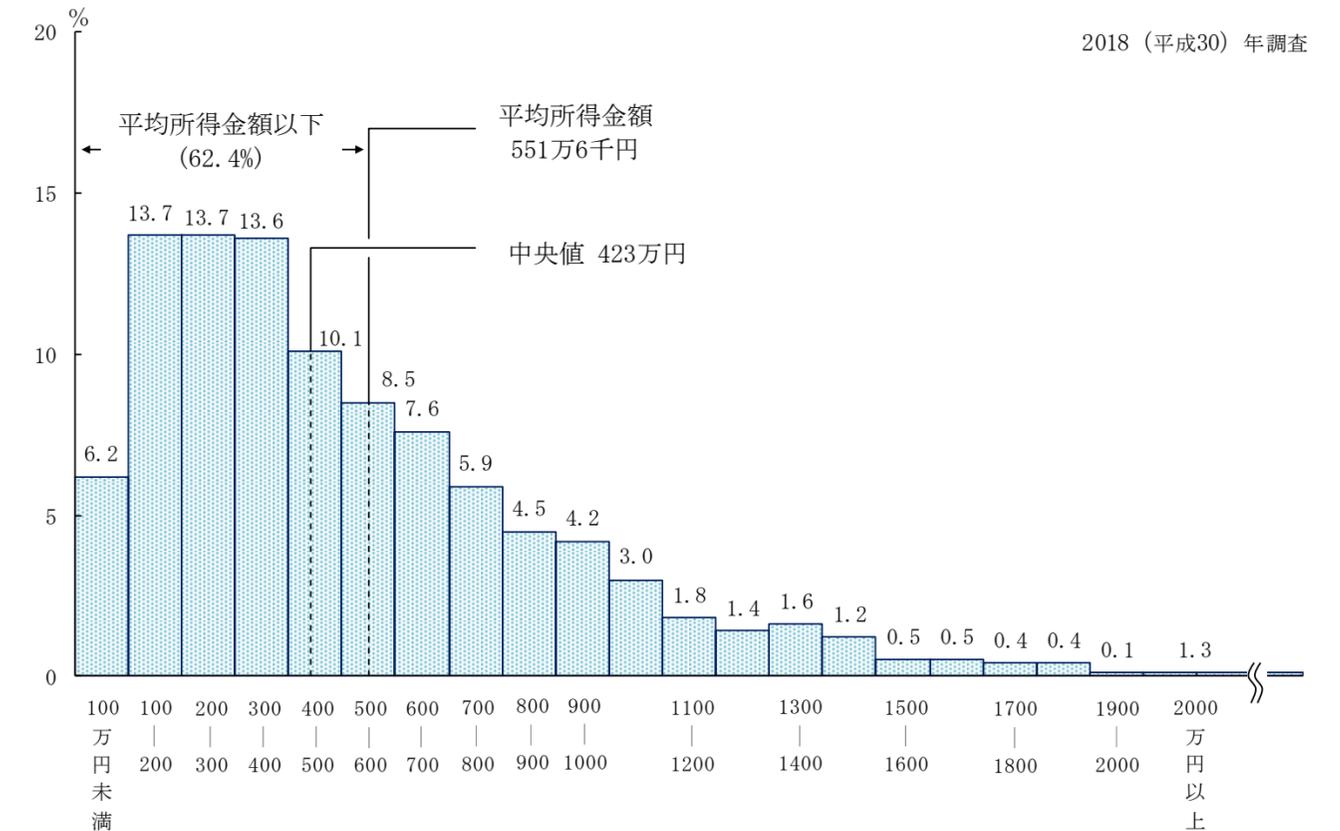
**分布**の位置を数値で知る

平均値, 中央値

普通の世帯の所得を知りたい ⇒ **中央値**

世帯全体の所得の中心を知りたい ⇒ **平均値**

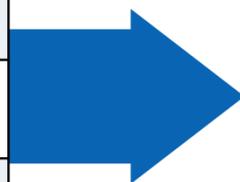
図. 2018年所得金額階級別世帯数のヒストグラム



# 練習問題 (1)

表. 10人の小テストA, B, C の成績 (10点満点)

生徒/小テスト	A	B	C
生徒1	0	0	3
生徒2	3	1	4
生徒3	3	2	4
生徒4	5	3	5
生徒5	5	5	5
生徒6	5	5	5
生徒7	5	7	5
生徒8	7	8	6
生徒9	7	9	6
生徒10	10	10	7



	A	B	C
平均値			
中央値			

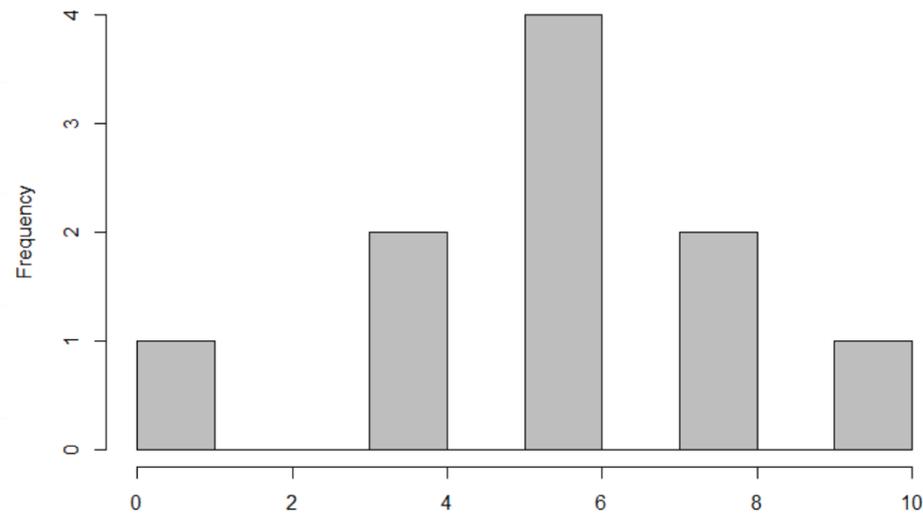
Q 上の表を埋めよ

Q どの小テストも  
分布の特徴は同じ?

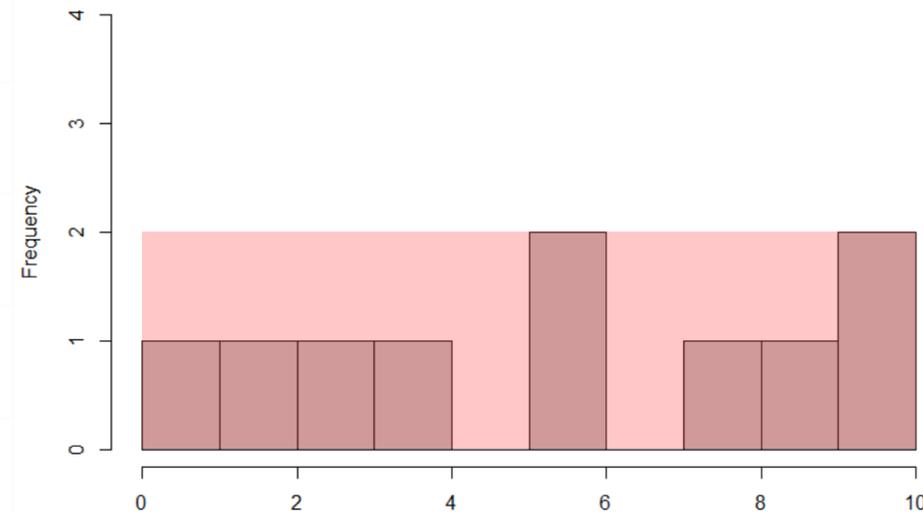
# 分布の散らばり

分布の位置は同じでも散らばり具合が違う

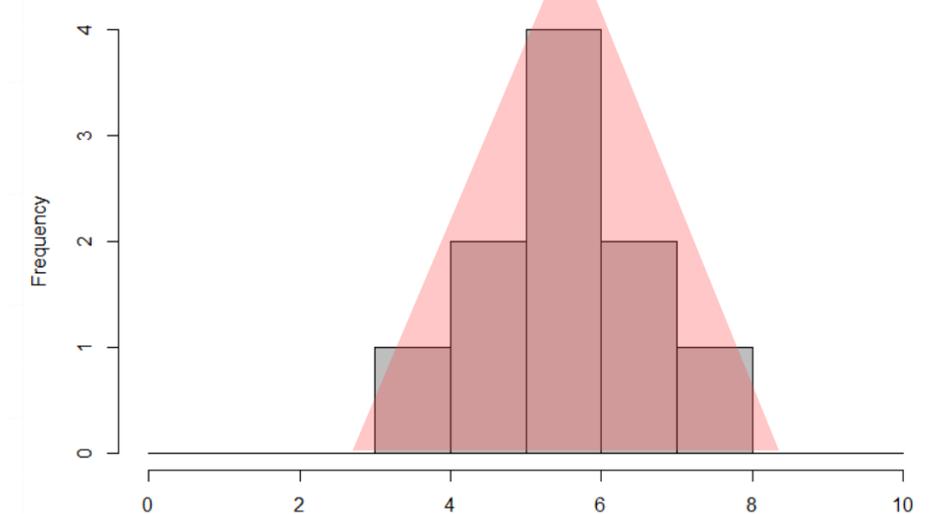
小テストA



小テストB



小テストC



Q 散らばりを表す要約統計量は?

# 分布の散らばり 分散, 標準偏差

# 分散

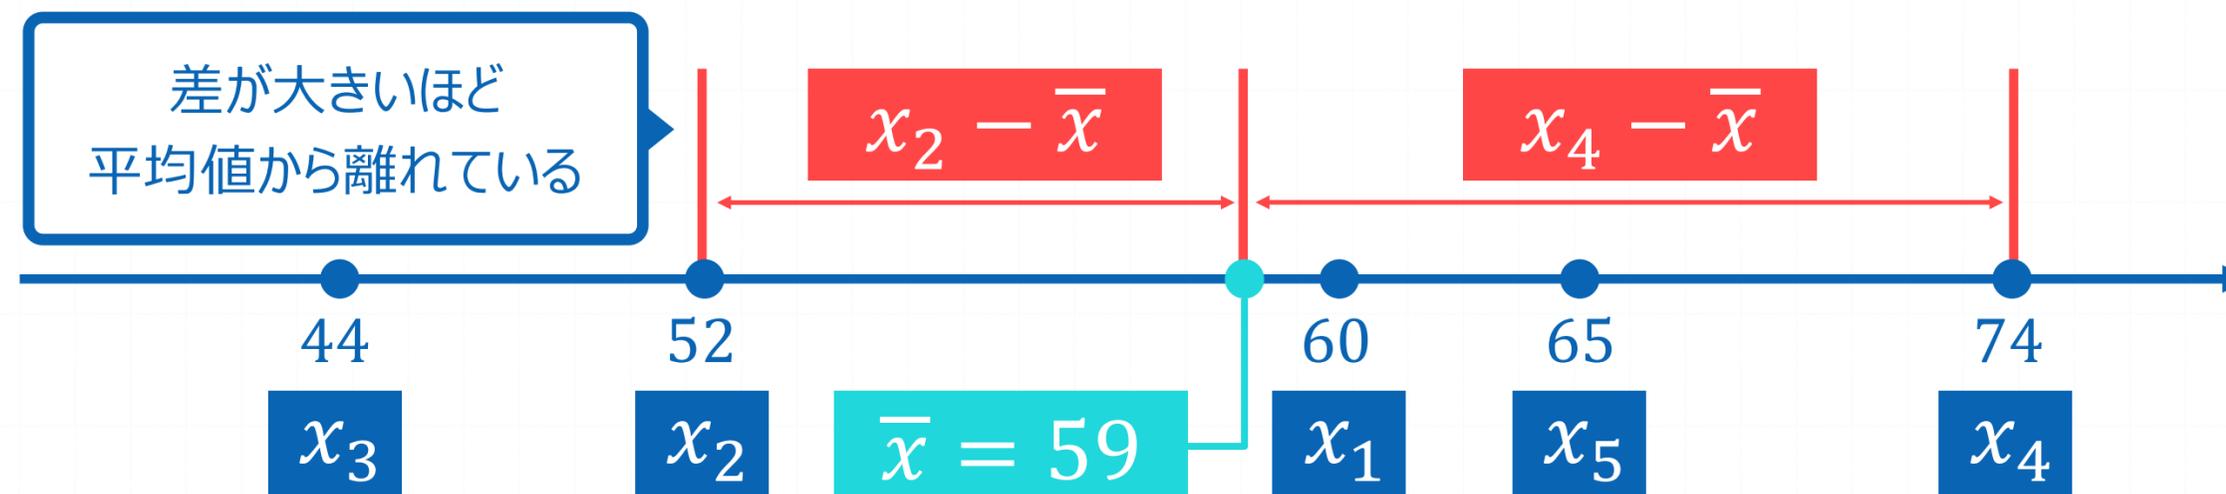
## ✓ 分散 (variance)

変数  $x$  の  $n$  個のデータ  $x_1, \dots, x_n$  に対する分散:

$$\text{分散 } s_x^2 = \frac{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n} \quad \bar{x} = \frac{x_1 + \dots + x_n}{n}: \text{平均値}$$

個体	変数 $x$
1	$x_1$
2	$x_2$
⋮	⋮
$n-1$	$x_{n-1}$
$n$	$x_n$

平均値周りの散らばり (バラつき) 具合を表す



人	体重 (kg)
1	60
2	52
3	44
4	74
5	65

# 分散

## 分散の解釈

分散が大きい

⇔ データ全体が平均値から離れている傾向

⇔ 散らばりが大きい

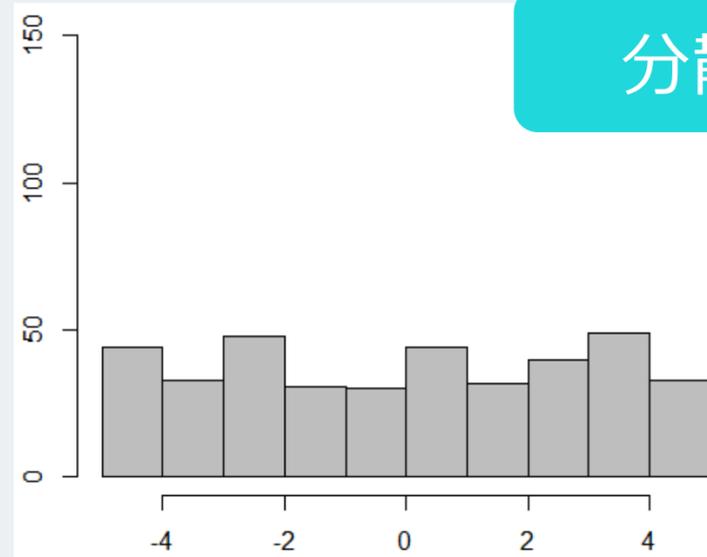
分散が小さい

⇔ データ全体が平均値に近い傾向

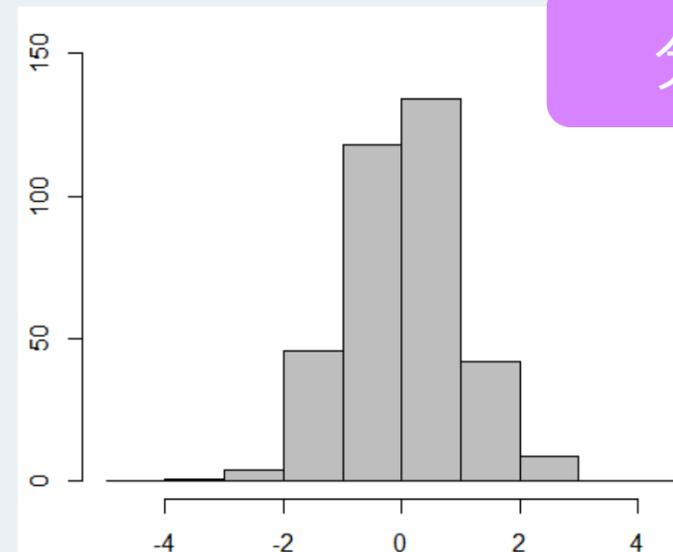
⇔ 散らばりが小さい

$$s_x^2 = \frac{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n}$$

ヒストグラムによるイメージ図



分散大



分散小

# 分散

$$s_x^2 = \frac{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n}$$

小テストA, B, C の分散:

小テストA: 分散 = 6.6

小テストB: 分散 = 10.8

散らばり具合  
**C < A < B**

数値 (要約統計量) で  
わかる!!

小テストC: 分散 = 1.2

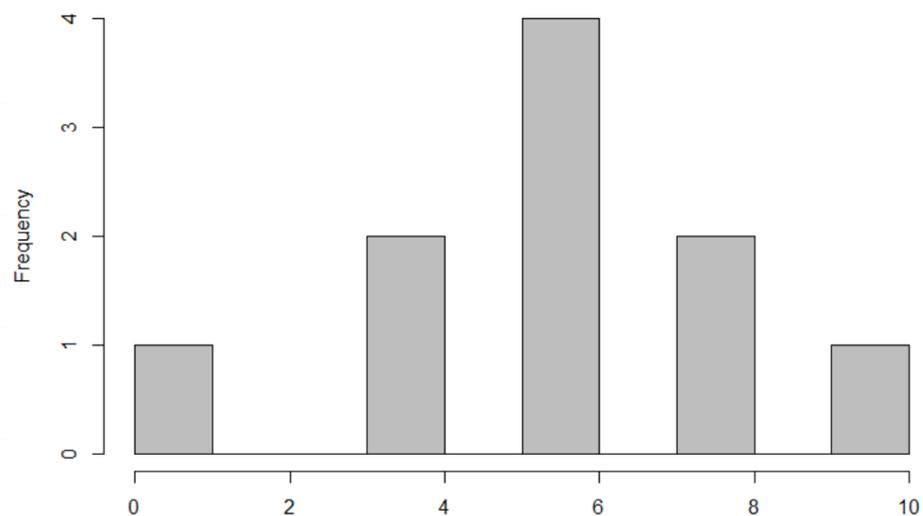
先ほどの  
小テストの例で  
考えてみましょう



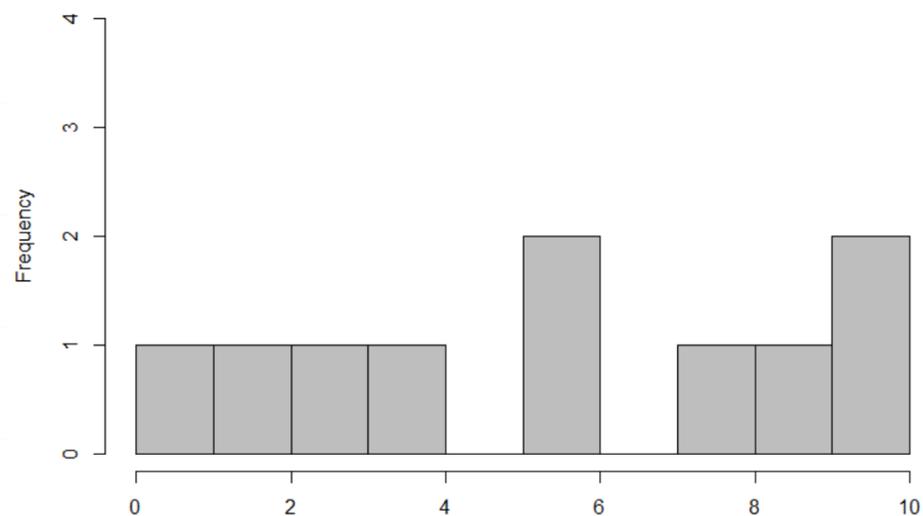
# 分散

小テストA, B, C の分散:

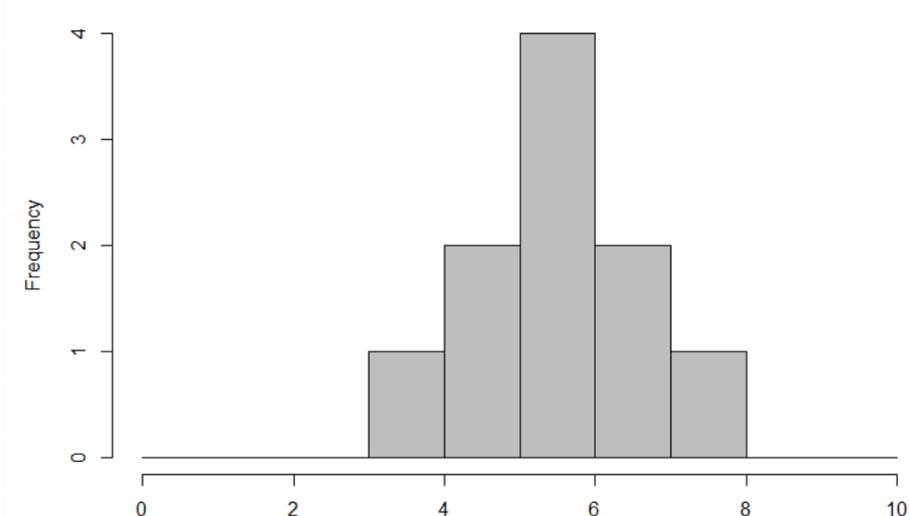
小テストA: 分散 = 6.6



小テストB: 分散 = 10.8



小テストC: 分散 = 1.2



散らばり具合:  $C < A < B$


# 分散のコメント1

## 平均値と分散はセットで用いる

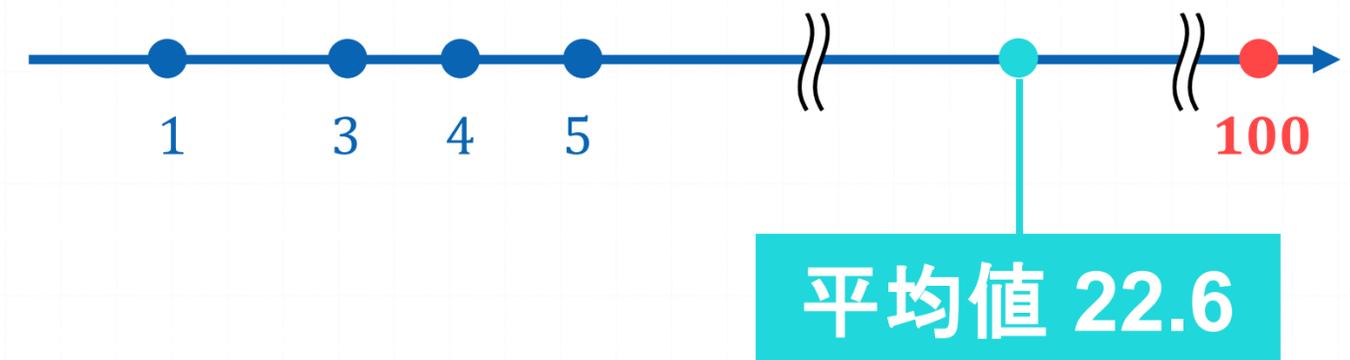
! データが全て同じ値なら, 分散 = 0

! 分散は**外れ値**の影響を受けやすい

例 1,3,4,5,9 の分散: 7.04



1,3,4,5,100 の分散: 1499.44



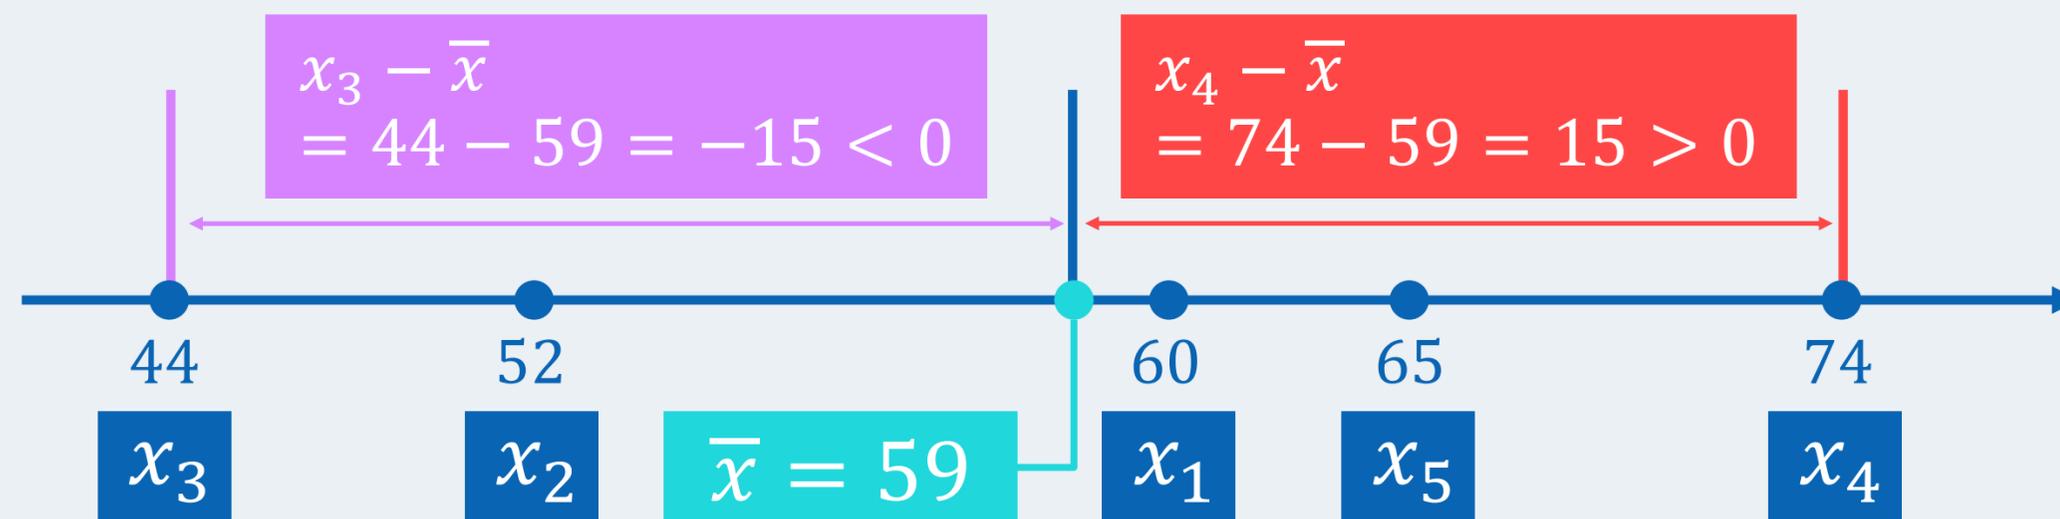
# 分散のコメント2

分散の式で2乗している理由

$$s_x^2 = \frac{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n}$$

- $x_i - \bar{x}$  は負の値をとるかも?? (正と負の足し算で相殺される)

➡ 相殺されないように**正の数**で表すため



人	体重 (kg)
1	60
2	52
3	44
4	74
5	65

- 絶対値で正にすると, 数学的に扱いにくい

# 標準偏差

## ✓ 標準偏差 (Standard Deviation; SD)

変数  $x$  の  $n$  個のデータ  $x_1, \dots, x_n$  に対する標準偏差:

$$\text{標準偏差 } s_x = \sqrt{s_x^2}$$

標準偏差 = 分散の正の平方根

分散の単位を元の単位に戻したもの

正の平方根とは  
2乗してルートの中身のもの  
になる正の値のことです



例 5cm, 10cm, 12cm, 13cm

分散 9.5 (cm<sup>2</sup>)

標準偏差 約 3.08 (cm)

## 練習問題 (2)

Q 以下のデータの平均値, 分散, 標準偏差を求めよ

- 1,4,5,3,7

- 4,4,4,4,4

## 解答: 練習問題 (2)

- 1,4,5,3,7

$x_1 = 1, x_2 = 4, x_3 = 5,$   
 $x_4 = 3, x_5 = 7$  と思うと

平均値

分散

標準偏差

## 解答: 練習問題 (2)

- 4,4,4,4,4

$x_1 = 4, x_2 = 4, x_3 = 4, x_4 = 4, x_5 = 4$  と思うと

平均値

分散

標準偏差

実際に計算してみると  
記憶に定着しやすいですね



# 分布の散らばり 範囲, 四分位範囲

# 範囲

## ✓ 範囲 (range)

変数  $x$  の  $n$  個のデータ  $x_1, \dots, x_n$  の範囲:

**範囲**  $R = (\text{データの最大値}) - (\text{データの最小値})$

範囲 = **全てのデータ100%**が含まれる区間の大きさ

範囲が大きい → 散らばり大

範囲が小さい → 散らばり小

**外れ値**の影響を受けやすい

例

1,4,5,3,7 の範囲  $R = 7 - 1 = 6$

1,4,5,3,100 の範囲  $R = 100 - 1 = 99$

# 四分位点

## ✓ 四分位点 (quartile)

変数  $x$  の  $n$  個のデータ  $x_1, \dots, x_n$  の四分位点:

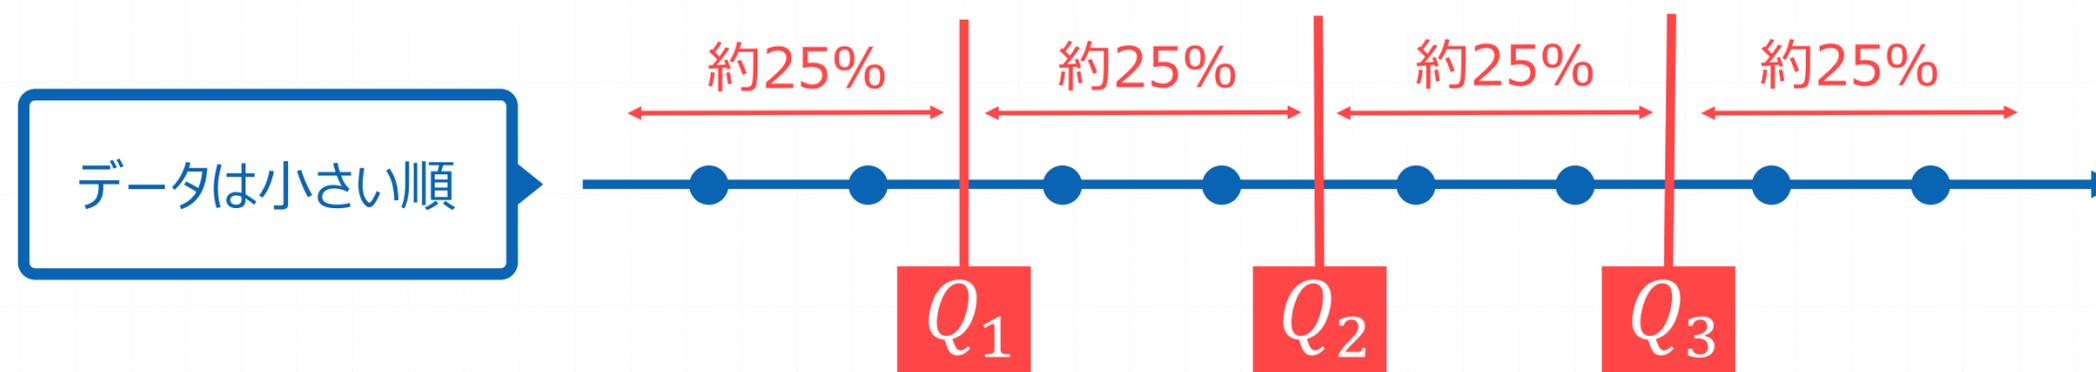
データを小さい順に並べたとき,

**第1四分位点  $Q_1$** : 真ん中より値が小さいデータの中央値

**第2四分位点  $Q_2$** : 中央値

**第3四分位点  $Q_3$** : 真ん中より値が大きいデータの中央値

データを4分割したときの境界が四分位点 (だいたい)

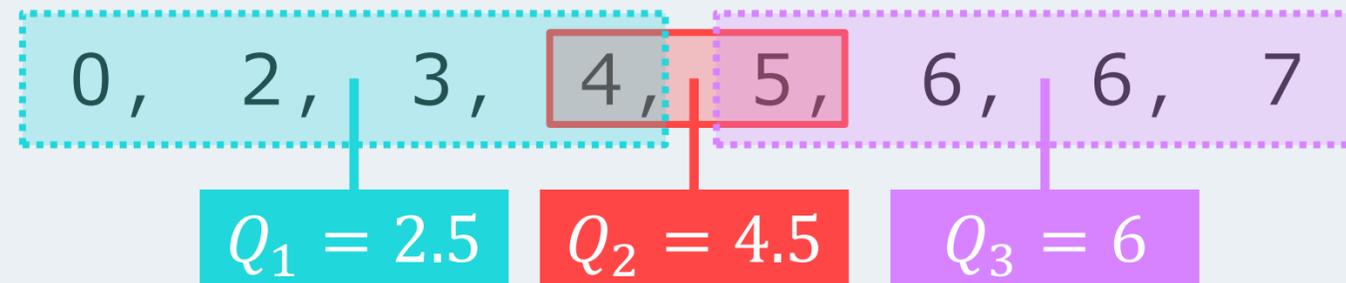


さっそく、計算例を見て  
理解を深めていきましょう



# 四分位点

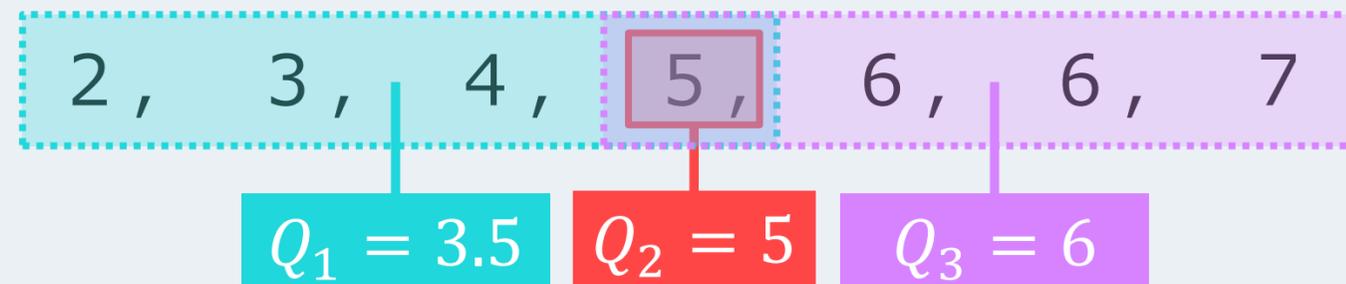
## 例 データが偶数個のとき



$Q_1$  は 0, 2, 3, 4 の中央値  
 $Q_3$  は 5, 6, 6, 7 の中央値

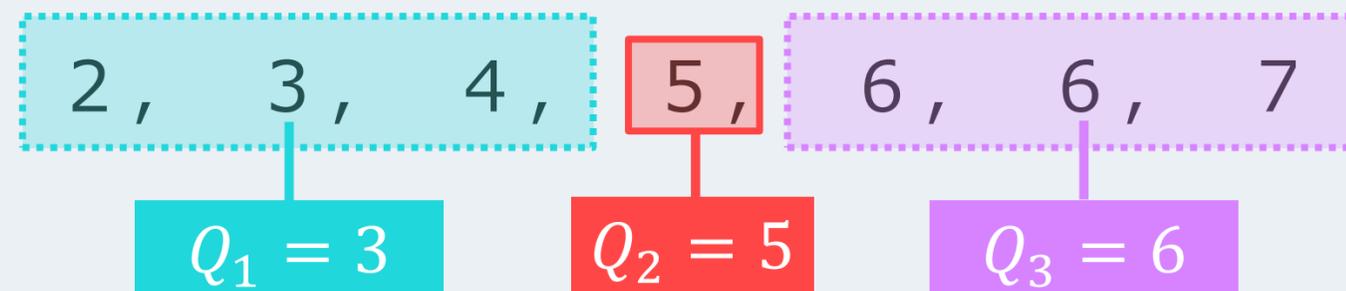
## 例 データが奇数個のとき

計算方法1  
(ヒンジ法)



$Q_1$  は 2, 3, 4, 5 の中央値  
 $Q_3$  は 5, 6, 6, 7 の中央値  
( $Q_2$  を含める場合)

計算方法2



$Q_1$  は 3, 4, 5 の中央値  
 $Q_3$  は 6, 6, 7 の中央値  
( $Q_2$  を含めない場合)

# 四分位範囲

## ✓ 四分位範囲 (InterQuartile Range; IQR)

変数  $x$  の  $n$  個のデータ  $x_1, \dots, x_n$  の四分位範囲:

$$\text{四分位範囲} = (\text{第3四分位点 } Q_3) - (\text{第1四分位点 } Q_1)$$

四分位範囲 = **真ん中のデータ (全データの約50%)**  
が含まれる区間の大きさ

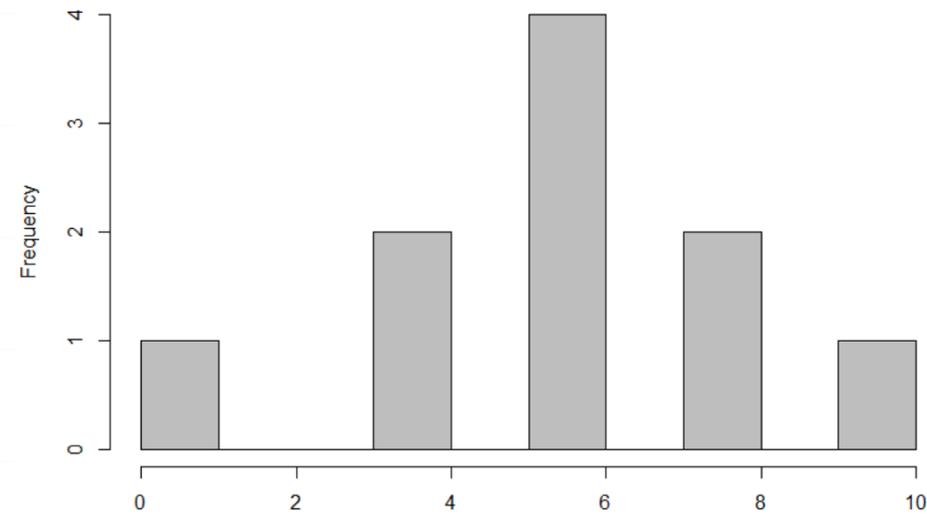
中央値周りの散らばり具合を表す

範囲よりも外れ値の影響を受けにくい

中央値と四分位範囲の計算はセットで

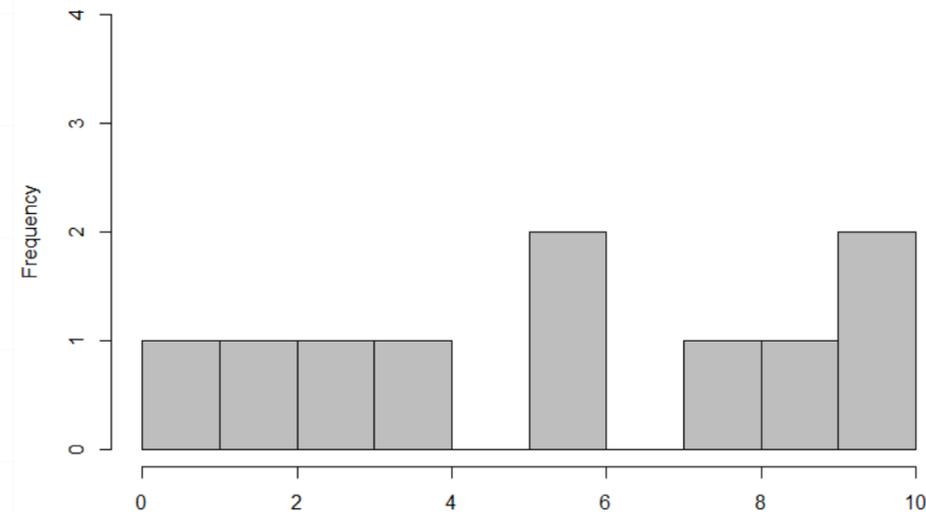
# 分布の散らばり

小テストA



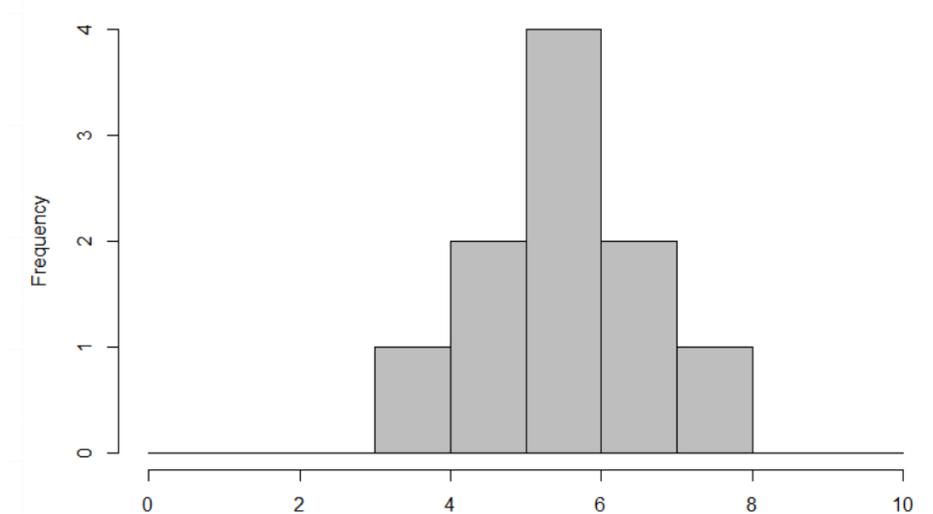
範囲: 10  
IQR: 4

小テストB



範囲: 10  
IQR: 6

小テストC



範囲: 4  
IQR: 2

# 例題

## 表. サービス満足度のアンケート

(1:とても不満, 2:少し不満, 3:ふつう, 4:少し満足, 5:とても満足)

	サービスA	サービスB
顧客1	3	5
顧客2	4	2
顧客3	4	3
顧客4	5	4
顧客5	5	4
顧客6	1	5
顧客7	1	4
顧客8	5	3
顧客9	4	4
顧客10	4	3

Q どちらのサービスが安定して満足度が高い?

平均値… A: 3.6, B: 3.7

分散…… A: 2.04, B: 0.81

~~だからサービスBのほう!!~~



! 順序変数だから平均値, 分散は適さない

# 練習問題 (3)

## 表. サービス満足度のアンケート

(1:とても不満, 2:少し不満, 3:ふつう, 4:少し満足, 5:とても満足)

	サービスA	サービスB
顧客1	3	5
顧客2	4	2
顧客3	4	3
顧客4	5	4
顧客5	5	4
顧客6	1	5
顧客7	1	4
顧客8	5	3
顧客9	4	4
顧客10	4	3

**Q** 中央値, IQR を計算してどっちのサービスが安定して満足度が高いか調べよ

この講義で紹介した方法で計算してみてください



# 解答: 練習問題 (3)

## サービスA

1, 1, 3, 4, 4, 4, 4, 5, 5, 5

中央値

四分位点

IQR

A

## サービスB

2, 3, 3, 3, 4, 4, 4, 4, 5, 5

中央値

四分位点

IQR

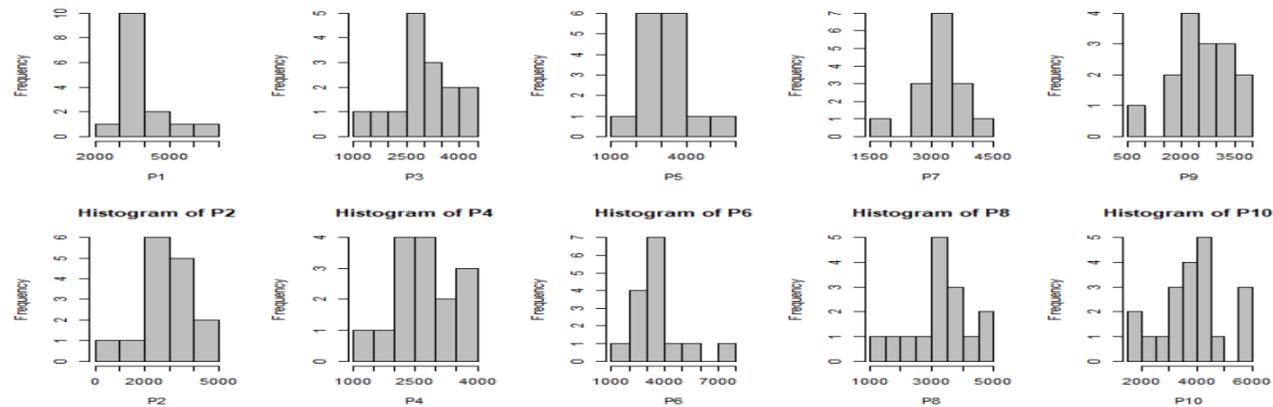
# 箱ひげ図

# グラフ + 要約統計量

10地区の住宅価格の特徴を教えてください

10地区のヒストグラムはこんな感じで、  
地区Aの平均値は~~~~、分散は~~~~、  
中央値は~~~~、四分位範囲は~~~~、地区Bの…

部下



不動産会社の上司



グラフが小さいたくさんあって見にくい。  
数値もいけどもっとわかりやすく教えて

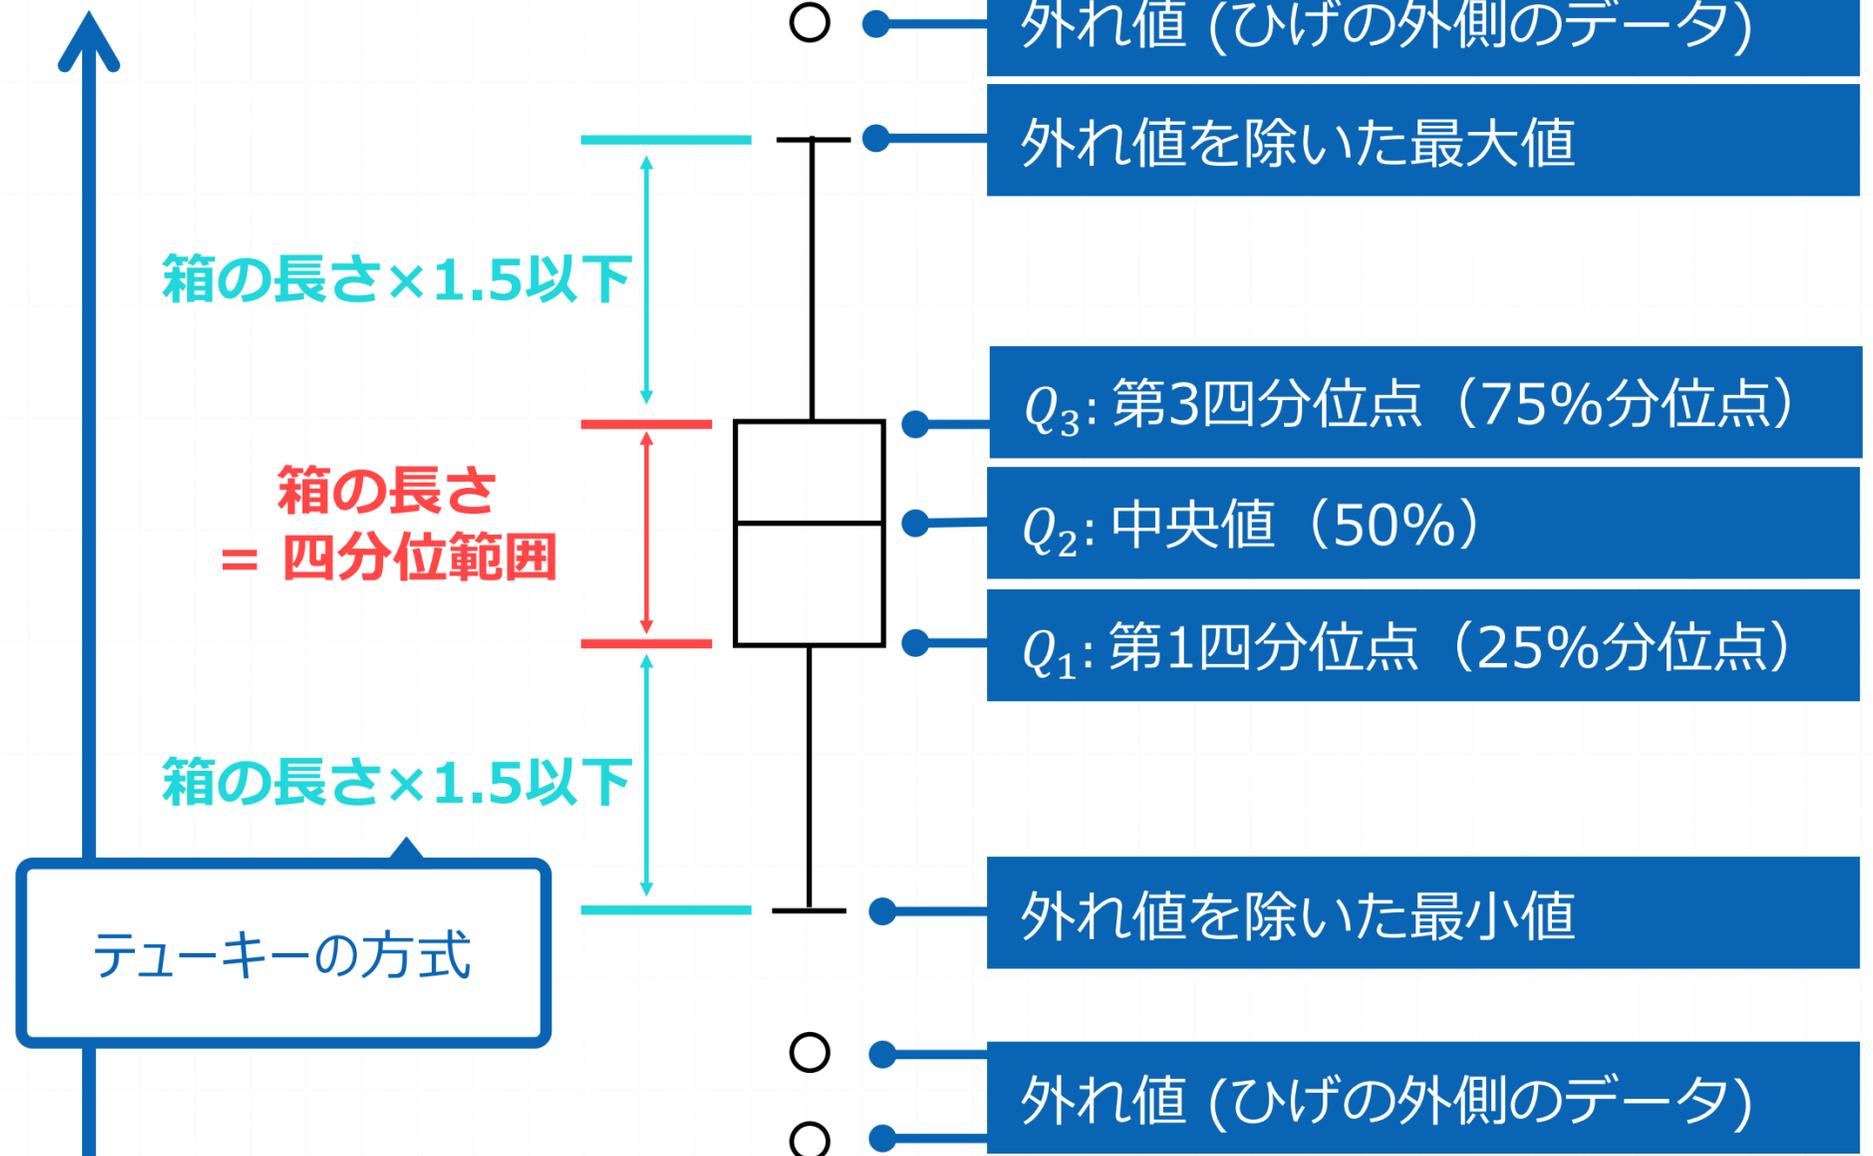
# 箱ひげ図

## ✓ 箱ひげ図

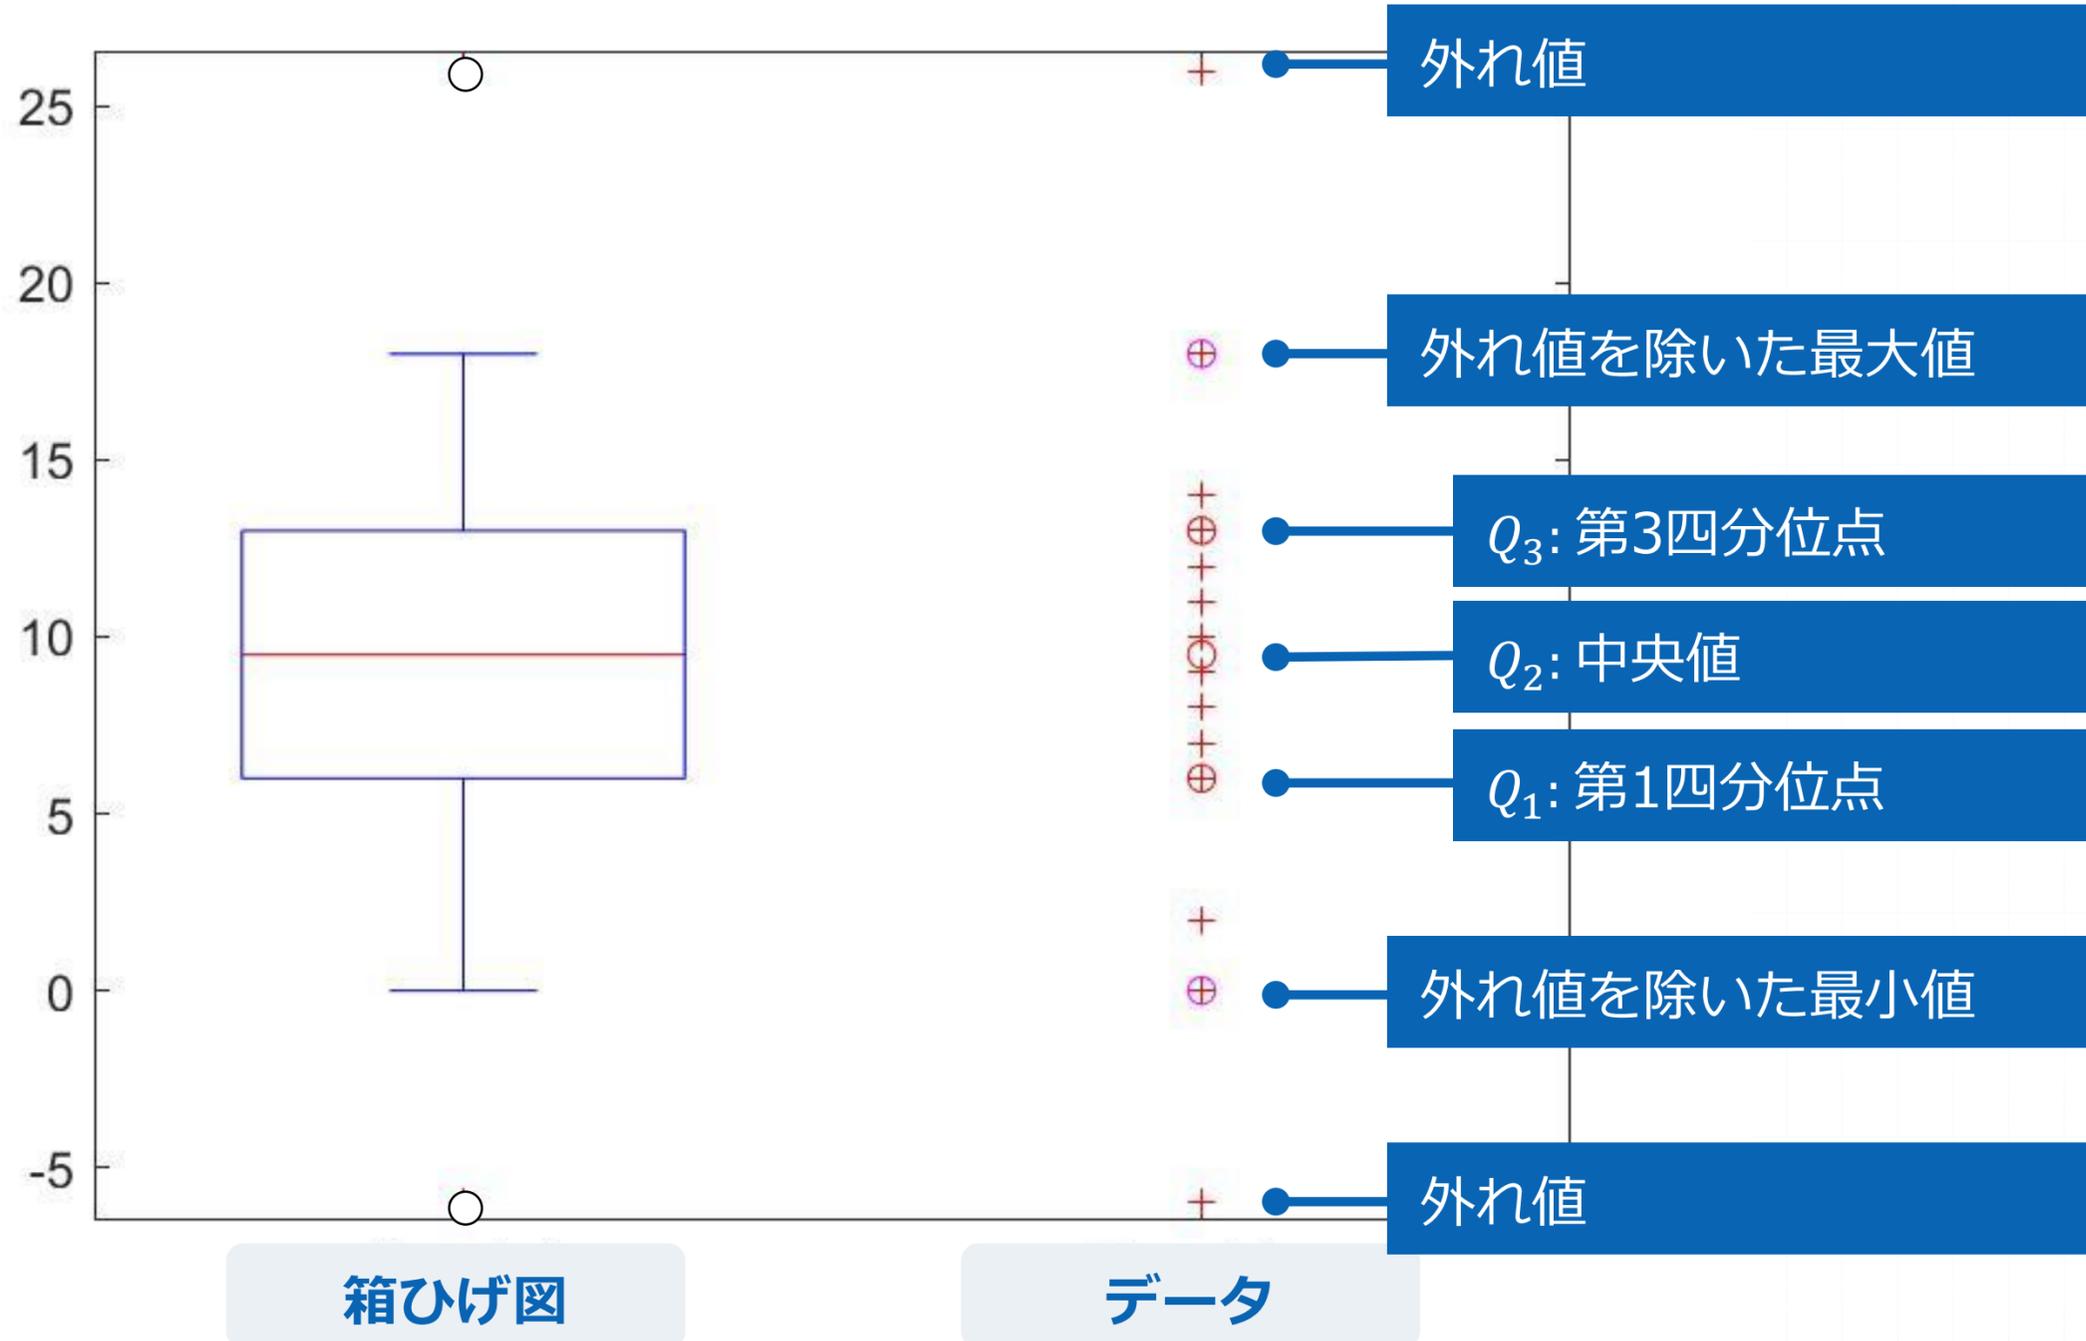
データの要点を  
簡潔に表したグラフ

箱の長さ  
= 散らばり具合

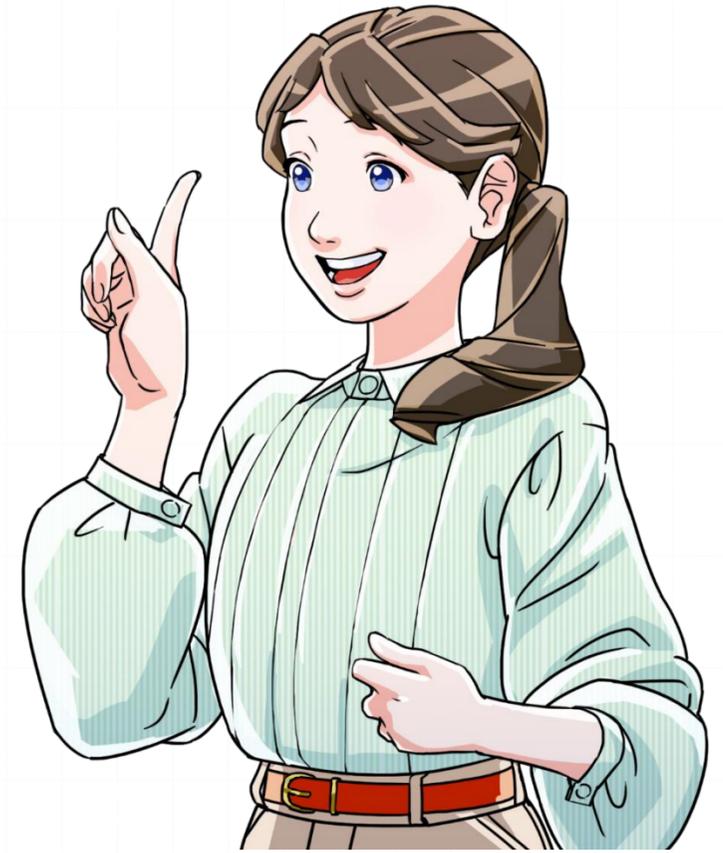
縦軸: データの値



# 箱ひげ図

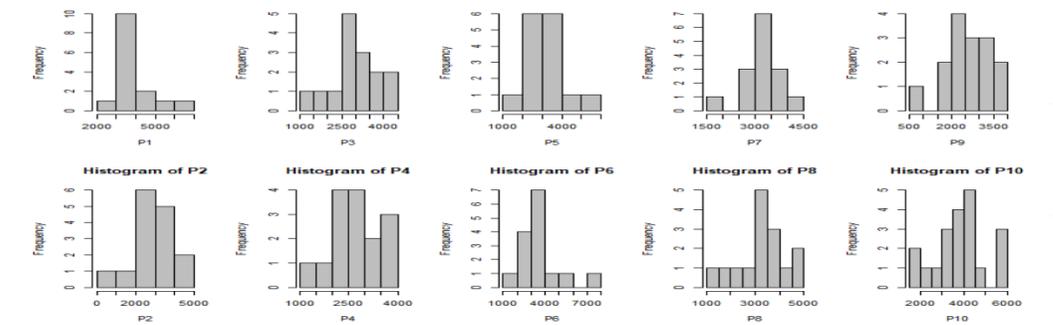
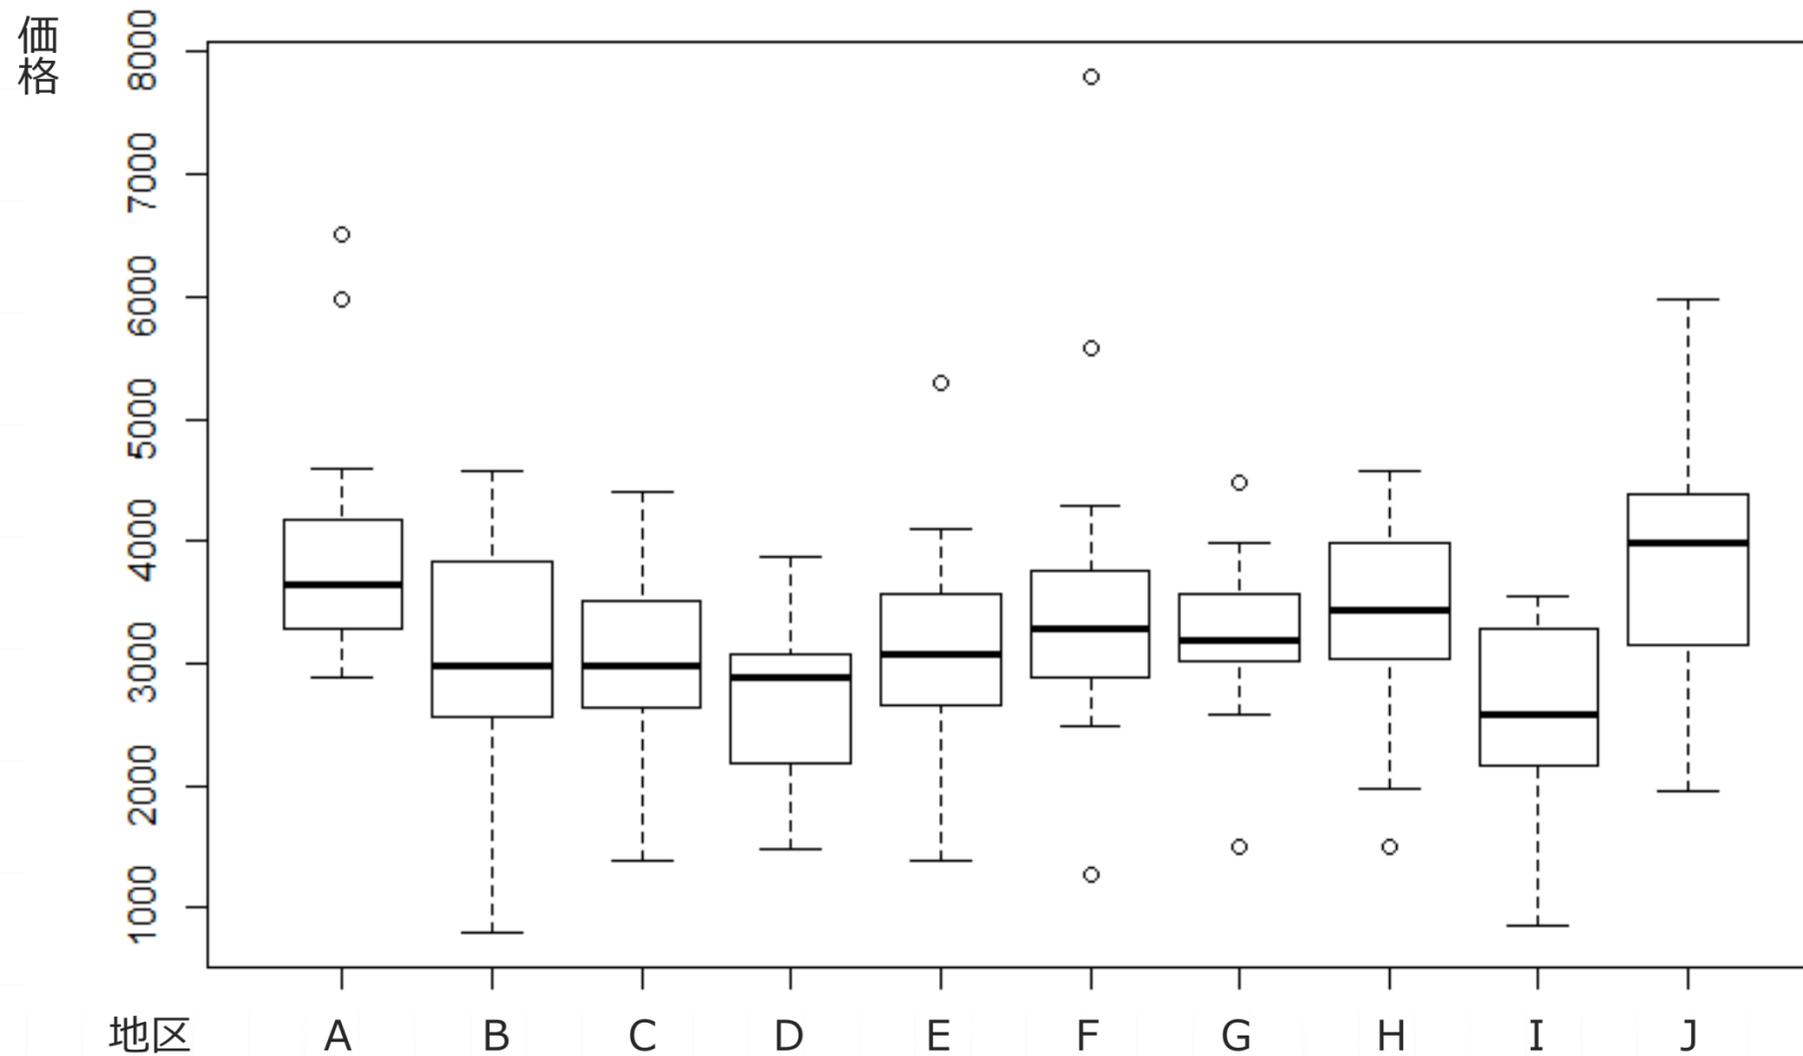


+マークが  
データを表していますね



# 箱ひげ図

複数グループを比較するとき箱ひげ図が便利



# 散布図

# データの次元

## ✓ 1次元データ

**1つの変数**についてのデータ

例 学生の身長 (変数  $x$ )

グラフ: ヒストグラム, 箱ひげ図など

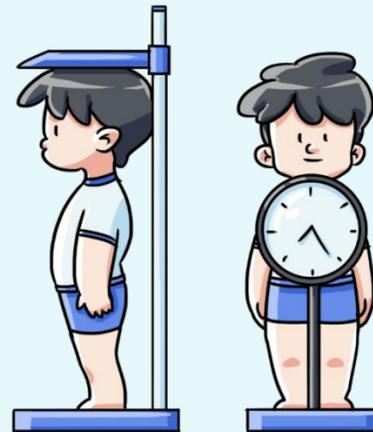


個体	変数 $x$
1	$x_1$
$\vdots$	$\vdots$
$n$	$x_n$

## ✓ 2次元データ

**2つの変数**についてのデータ

例 学生の身長 (変数  $x$ ) と体重 (変数  $y$ )



個体	変数 $x$	変数 $y$
1	$x_1$	$y_1$
$\vdots$	$\vdots$	$\vdots$
$n$	$x_n$	$y_n$

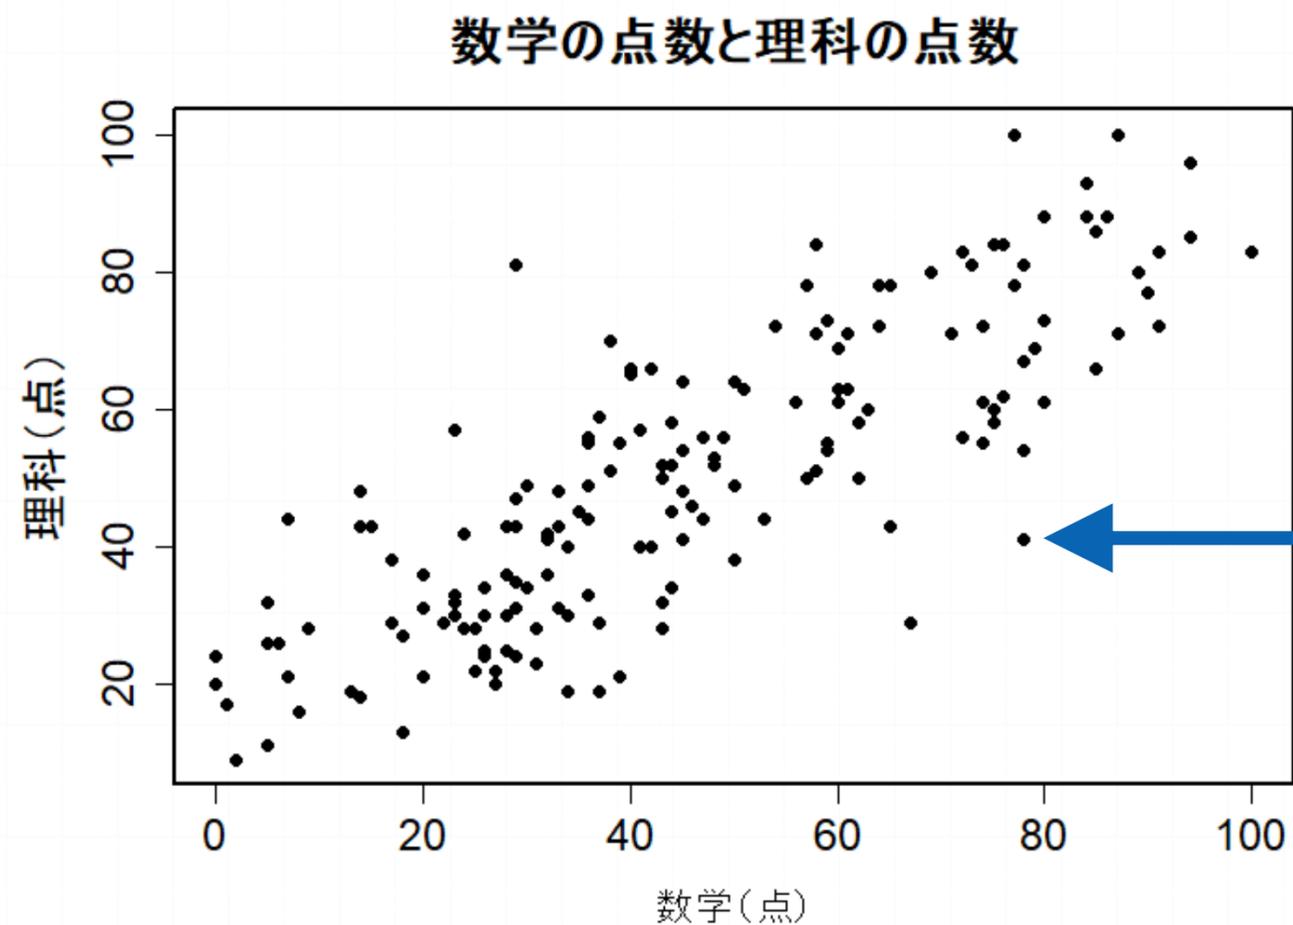
データの組:  $(x_1, y_1), \dots, (x_n, y_n)$

# 散布図

## ✓ 散布図

2つの変数の関係性を可視化したグラフ

例 数学の点数を横軸, 理科の点数を縦軸にとってデータを平面上の点として表す

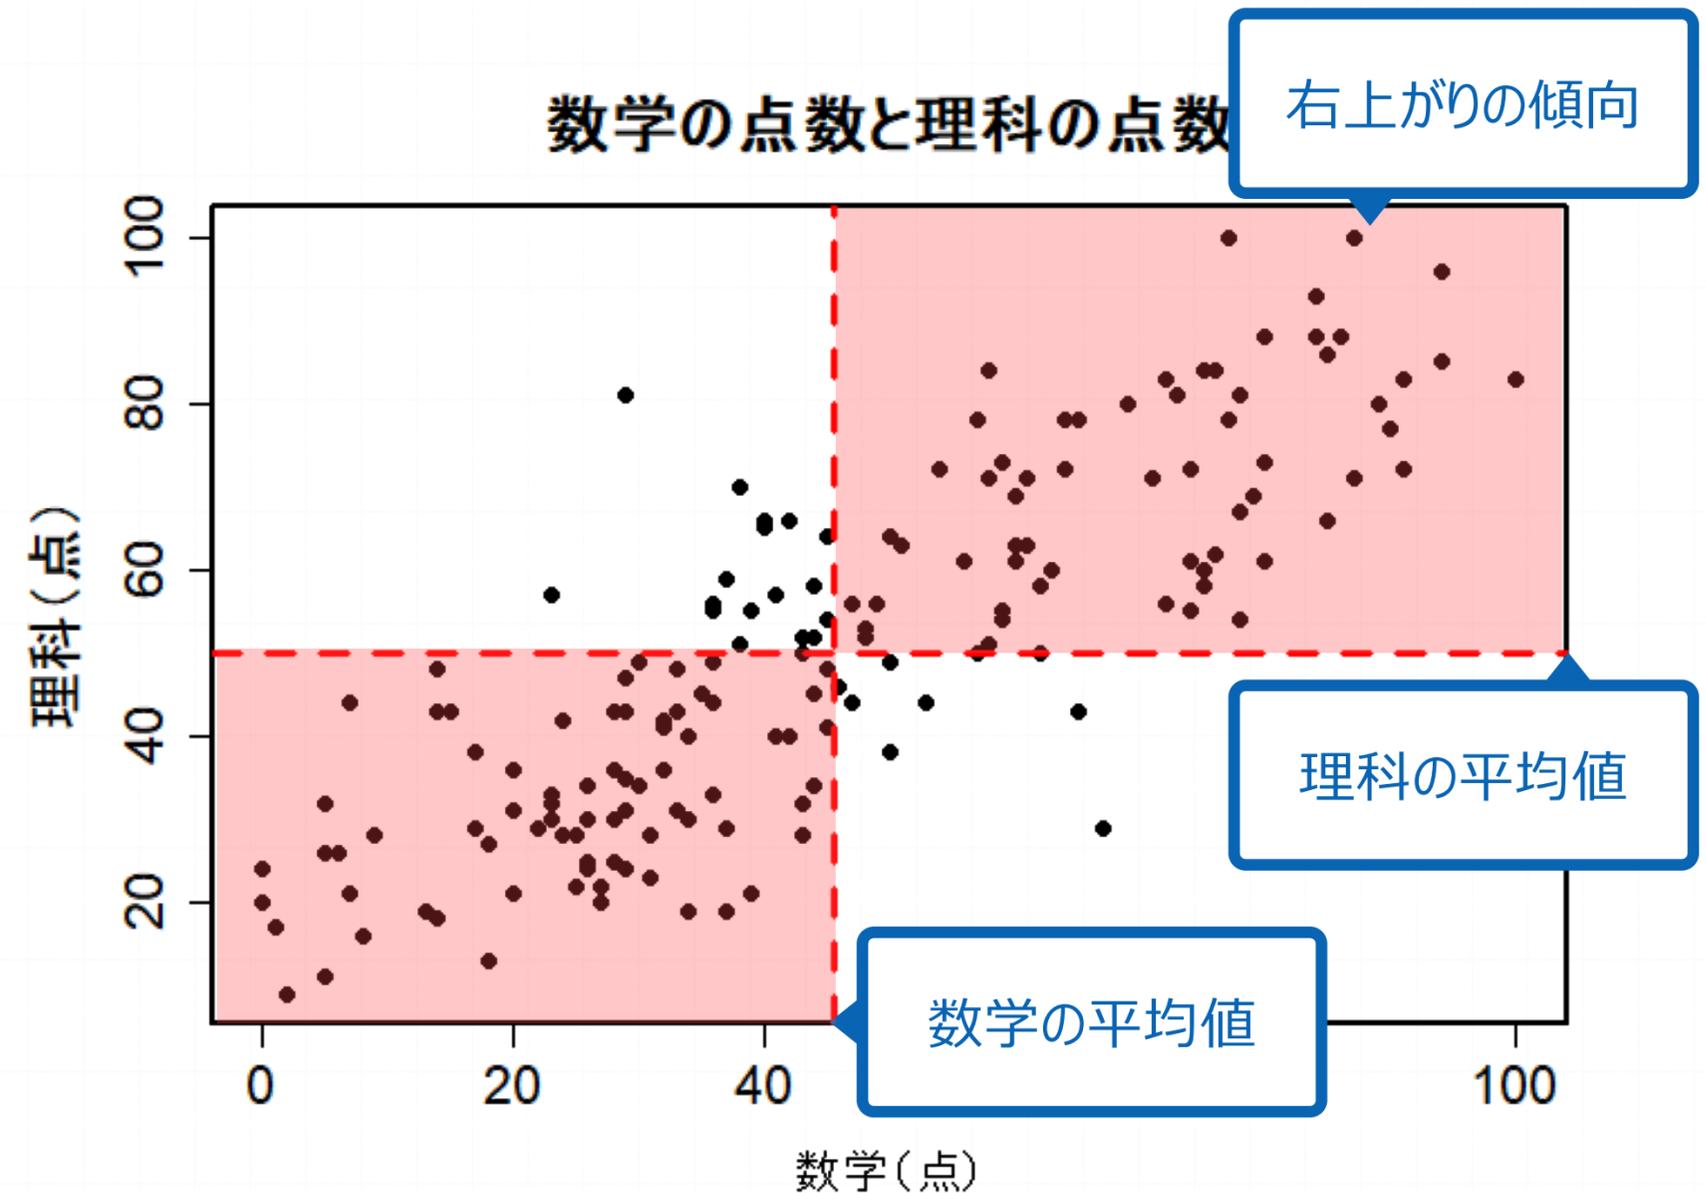


数学80点くらい,  
理科40点くらいの人

# 散布図の見方

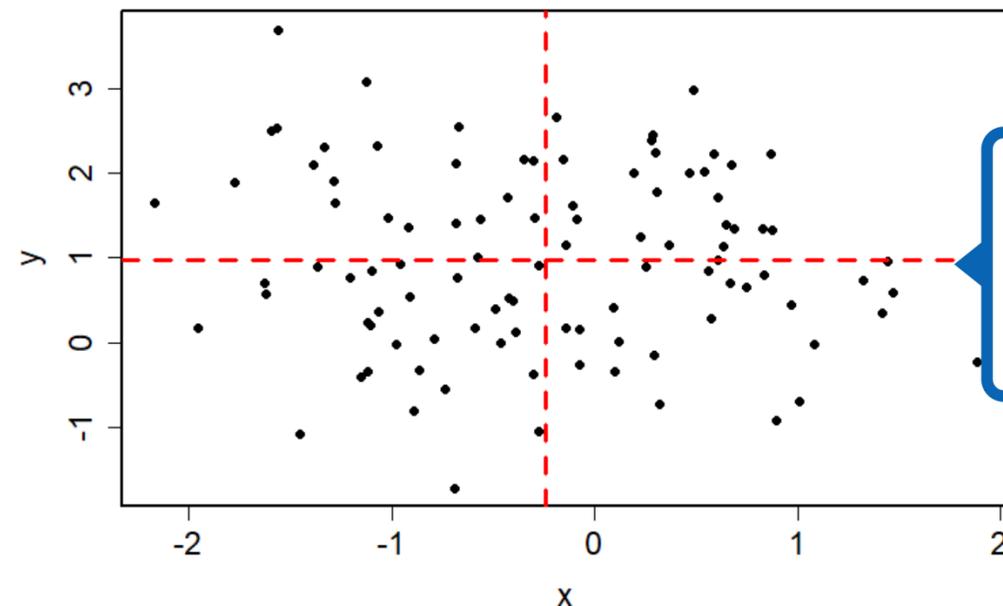
## 直線的な関係性をみる方法

- 1 2つの変数の平均値の直線を引いて4つの区画に分ける
- 2 データ点が**右上, 左下**に多い  
→ **右上がりの(直線)傾向**  
**右下, 左上**に多い  
→ **右下がりの(直線)傾向**

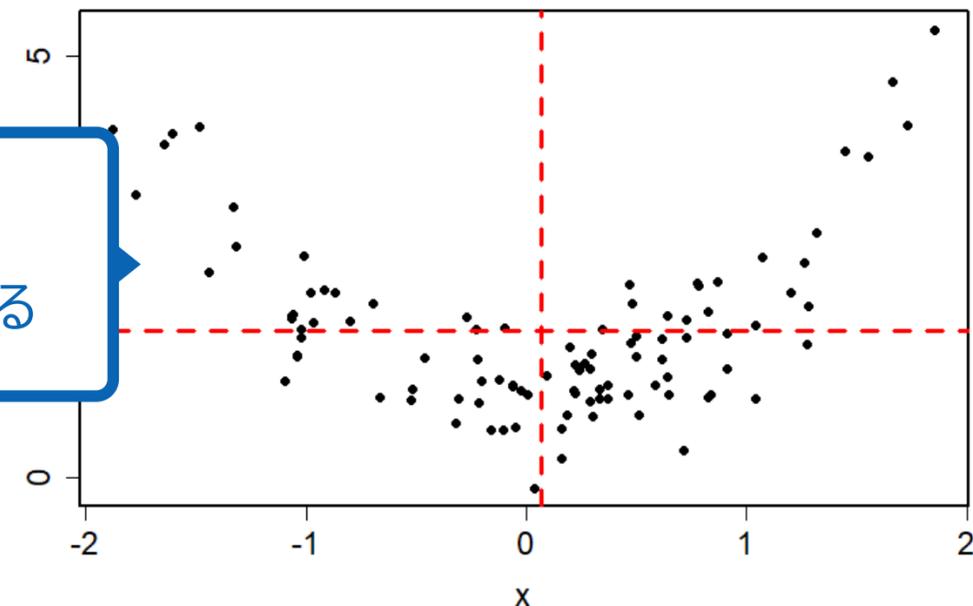


# 散布図の見方

直線的でない関係性も目でみて判断できる



- 4つの区画に散らばっている
- 右上がりでも右下がりでもない
- **直線的な関係はなさそう**



- 4つの区画に散らばっている
- 右上がりでも右下がりでもない
- **そもそも曲線??**

**2つの変数の関係性をみるにはまずは散布図を描こう!!**

## 今日のまとめ

### ▶ 要約統計量

分布の位置: 平均値, 中央値, 最頻値, 四分位点

**分布の散らばり**: 分散, 標準偏差, 範囲, 四分位範囲

### ▶ グラフ

ヒストグラム, **箱ひげ図** (1次元データ)

**散布図** (2次元データ)

次回も一緒に  
頑張りましょう!



要約統計量とグラフで分布の特徴を知る・伝える・比較する