

データの代表値と散布度

樋口さぶろお <https://hig3.net>

龍谷大学工学部数理情報学科

確率統計☆演習 I L02(2019-09-30 Mon)

最終更新: Time-stamp: "2019-10-01 Tue 08:33 JST hig"

今日の目標

- 代表値:中央値, 四分位数, 平均値, 最頻値を求められる [岩薩林 確率・統計 §1.2](#) [高校 数学 I](#)
- 散布度:レンジ, 四分位範囲, 分散, 標準偏差を求められる [岩薩林 確率・統計 §1.2](#) [高校 数学 I](#)

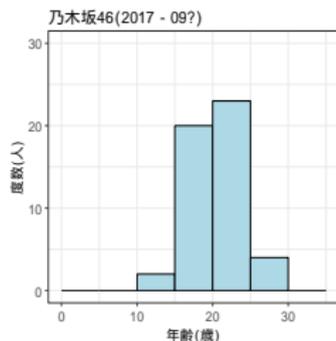
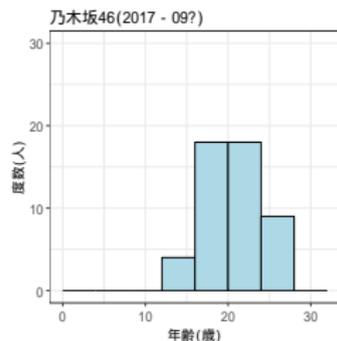


L01-Q1

Quiz 解答:度数分布表とヒストグラムを作ろう

度数分布表略.

例



ここまで来たよ

1 データの分布

2 データの代表値と散布度

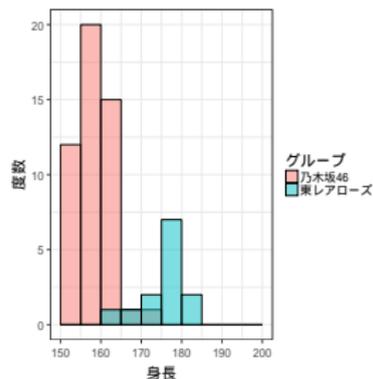
- 中央値と四分位数
- 平均値
- レンジ (範囲, range) ・ 四分位範囲 (IQR) ・ 箱ひげ図
- 分散 ・ 標準偏差

代表値:データを1個の値で代表させたい!

縮約値=代表値 集団の身長はだいたい 150cm? 170cm?

01 171cm
02 166cm
03 165cm
⋮
49 151cm

01 179cm
02 183cm
03 182cm
⋮
13 171cm



今日やる様々な表現方法

	分位数タイプ 岩薩林 確率・統計 (少)	平均タイプ 岩薩林 確率・統計 §1.2	岩薩林 確率・統計 (少)
代表値	中央値, 四分位数	平均値	最頻値 (離散データの, ヒストグラムの)
散布度	範囲=レンジ, 四分位範囲=IQR	分散, 標準偏差	

これらをデータ, 度数分布表, ヒストグラム (, 箱ひげ図) から読み取る

代表値・散布度 \lesssim 箱ひげ図 \gtrsim ヒストグラム \approx 度数分布表 $<$ ストリップチャート $<$ (生) データ
 情報が少ない, アバウト \leftrightarrow 情報が多い, 詳しい
 見やすい・直観的 \leftrightarrow 見にくい・直観に訴えない

中央値 (median) と四分位数/値/点 (quartile)

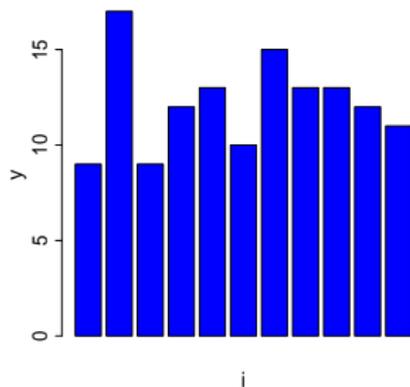
身長 y_i のデータ (n 個) を小さい順に並び替えたものを,
 $x_0 \leq x_1 \leq \dots \leq x_{n-1}$ とする.

例 $n = 11$

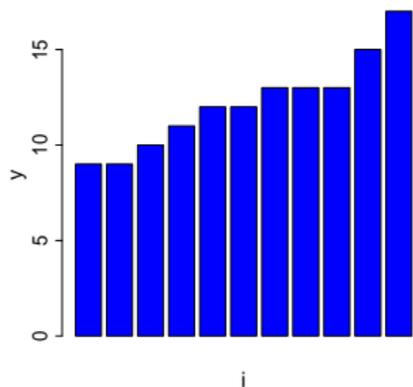
i	0	1	2	3	4	5	6	7	8	9	10
y_i	9	17	9	12	13	10	15	13	13	12	11

→

i	0	1	2	3	4	5	6	7	8	9	10
x_i	9	9	10	11	12	12	13	13	13	15	17



→ 順にならべる



中央値 (median) と四分位数/値/点 (quartile)

分位数, 四分位数のアバウトな定義

- q -分位数 $= x_{q \cdot (n-1)}$. ($0 \leq q \leq 1$).

- 最小値 $Q_0 = x_0 = x_{\frac{0}{4} \cdot (n-1)} = (0.0\text{-分位数})$.

- 第1四分位数 $Q_1 = x_{\frac{1}{4} \cdot (n-1)} = (0.25\text{-分位数})$.

- 第2四分位数 $Q_2 = x_{\frac{2}{4} \cdot (n-1)} = \text{中央値} = \text{メディアン} = (0.5\text{-分位数})$.

岩薩林 確率・統計練習問題 1-1

- 第3四分位数 $Q_3 = x_{\frac{3}{4} \cdot (n-1)} = (0.75\text{-分位数})$.

- 最大値 $Q_4 = x_{\frac{4}{4} \cdot (n-1)} = (1.0\text{-分位数})$.

高校数学における四分位数の定義 高校 数学 I

- Q_0, Q_4 さっきのまま.
-

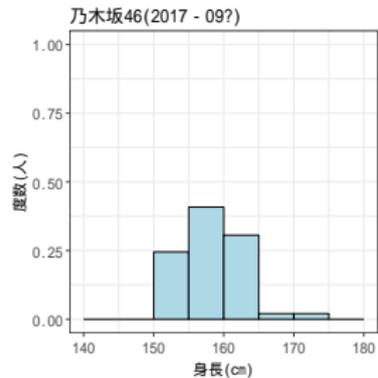
$$Q_2 = \begin{cases} x_{\frac{n-1}{2}} = \boxed{} & (n \text{ が奇}) \\ \frac{1}{2} \left(x_{\frac{n}{2}-1} + x_{\frac{n}{2}} \right) = \boxed{} & (n \text{ が偶}) \end{cases}$$

- Q_1 は, Q_2 の位置より前にあるデータ (Q_2 自身は除く) の中央値
- Q_3 は, Q_2 の位置より後にあるデータ (Q_2 自身は除く) の中央値

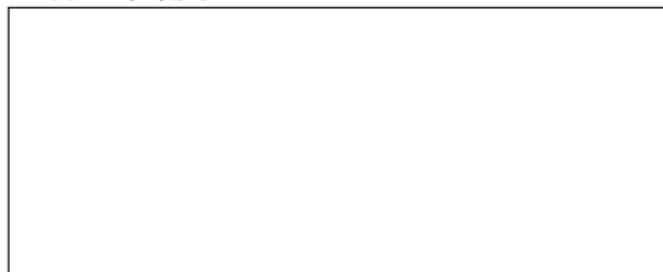
Q_2 と同じ値のデータが複数あるときも 1 個だけ除く

例: 9 9 10 11 12 12 13 13 13 15 17

ちょっと変えた例: 10 11 12 12 13 13 13 15 17

相対度数のヒストグラムからの q -分位数の求め方

全体の面積は 1



ここまで来たよ

1 データの分布

2 データの代表値と散布度

- 中央値と四分位数
- **平均値**
- レンジ (範囲, range) ・ 四分位範囲 (IQR) ・ 箱ひげ図
- 分散 ・ 標準偏差

平均 (値) = mean

平均 (値) の定義 岩薩林 確率・統計 (1.1)p.5

n 個のデータ x_1, x_2, \dots, x_n に対して,

$$\text{平均値 } \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

\bar{x} のかわりに m, m_x などという記号もある。

岩薩林 確率・統計例題 1.2(p.5)

中央値より平均値のいい点

平均値より中央値のいい点

度数分布表からの平均値の求め方

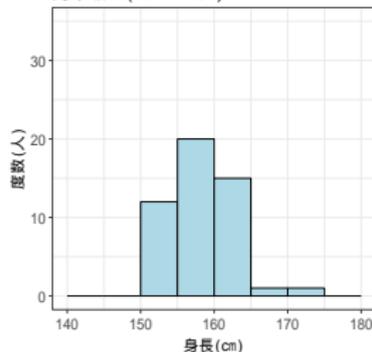
岩薩林 確率・統計 §1.2.3, (1.14)p.17

j 番目の階級の階級値 x_j , 度数 f_j . 近似的に,

$$\bar{x} \approx \frac{1}{n} \sum_{j=1}^k x_j f_j = \frac{\sum_{j=1}^k x_j f_j}{\sum_{j=1}^k f_j}$$

ヒストグラムからの平均値の求め方

乃木坂46(2017 - 09?)



力学のりで

k 個の質点の重心の座標 $x_G = \frac{\sum_{j=1}^k x_j m_j}{\sum_j m_j}$ 力学

j 番目の質点の位置 $x_j =$ 階級値, 質量 $m_j = f_j$

最頻値=mode

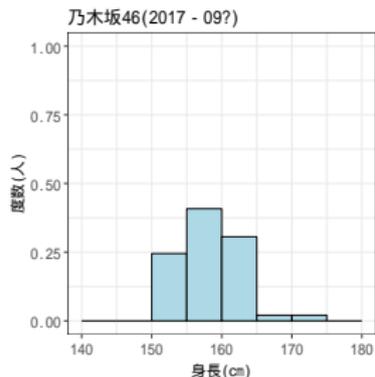
岩薩林 確率・統計練習問題 1-2

最頻値の定義

- 離散データの最頻値: '離散的な' データのとき いちばん多く繰り返し現れる値
- ヒストグラムの最頻値: '連続的または離散的な' データのとき 度数分布表/ヒストグラムで, 度数最大の階級の階級値

離散データの最頻値 (30 50 55 55 60 70 70 70 75 100) だと

ヒストグラムの最頻値

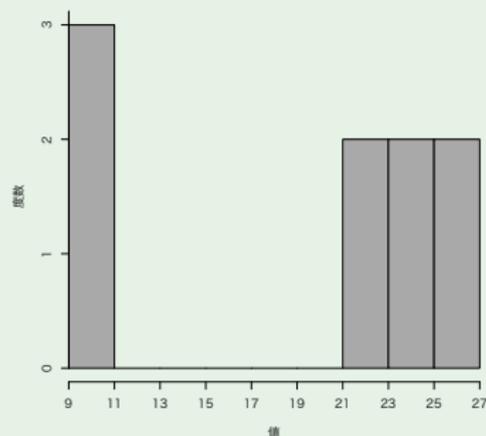


L02-Q1

Quiz(平均値中央値最頻値)

次の代表値を、下のヒストグラムから求めよう。

- ① 中央値
- ② (ヒストグラムの) 最頻値
- ③ 平均値



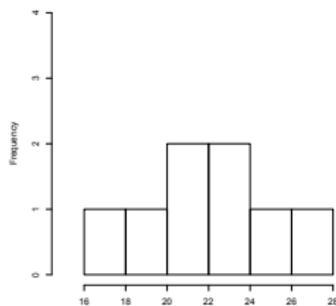
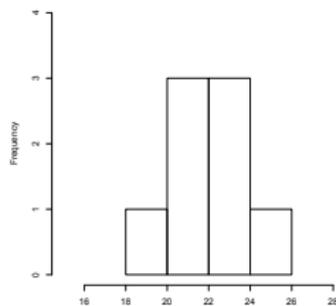
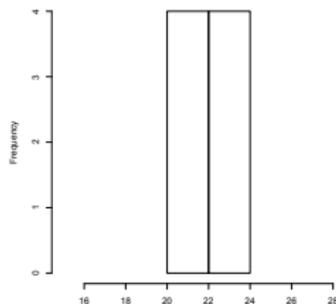
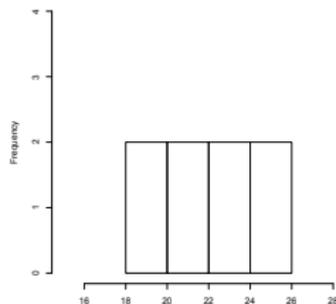
ここまで来たよ

1 データの分布

2 データの代表値と散布度

- 中央値と四分位数
- 平均値
- レンジ (範囲,range) ・ 四分位範囲 (IQR) ・ 箱ひげ図
- 分散 ・ 標準偏差

平均値が同じでも分布はいろいろ



第 1,3 四分位数は?

樋口さぶるお (数理情報学科)

散布度:散らばりの尺度が必要

レンジ・四分位範囲の定義 I

範囲タイプの量の定義 高校 数学 I 岩薩林 確率・統計なし

● 範囲 (レンジ) =

● 四分位範囲 (interquartile range) IQR =

L02-Q2

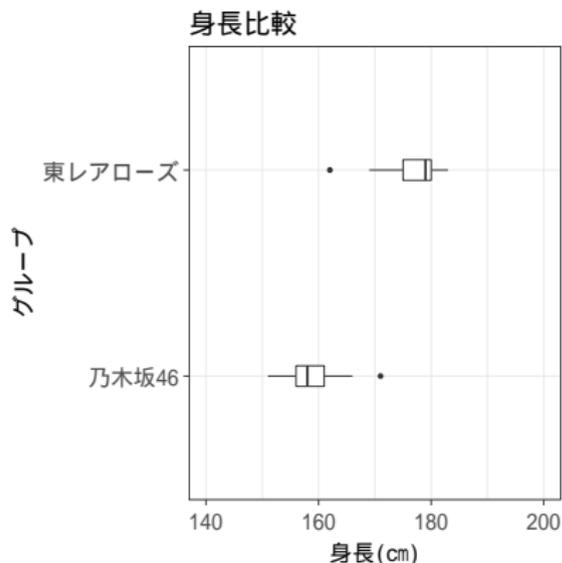
Quiz(範囲)

次のデータの、範囲, 四分位範囲, 四分位偏差 を求めよう.

14 14 15 16 18 18 18 25

箱ひげ図 (Box Plot, Box and Whisker diagram)

最小最大値 Q_0, Q_4 , 四分位点
 Q_1, Q_2, Q_3



箱ひげ図を描く手順高校 数学 I

- Q_0, Q_4 Q_1, Q_2, Q_3 と平均値 \bar{x} を求める
- Q_2 に縦線をいれる
- Q_1, Q_3 を左右の端として箱を描く
- Q_0, Q_4 に短い縦線をいれ, 点線のひげで箱とつなぐ
- (平均値に + を 1 個描く)
- (「外れ値」を○で描く)

外れ値 = Q_1, Q_3 から IQR の $\alpha = 1.5$ 倍より離れているデータ

<https://www.geogebra.org/m/dbfbkews>

ここまで来たよ

1 データの分布

2 データの代表値と散布度

- 中央値と四分位数
- 平均値
- レンジ (範囲, range) ・ 四分位範囲 (IQR) ・ 箱ひげ図
- 分散・標準偏差

分散・標準偏差の定義

高校 数学 I 岩薩林 確率・統計 (1.4),(1.5)

データ: x_1, x_2, \dots, x_n .

分散タイプの量の定義

- データの**分散** (variance)

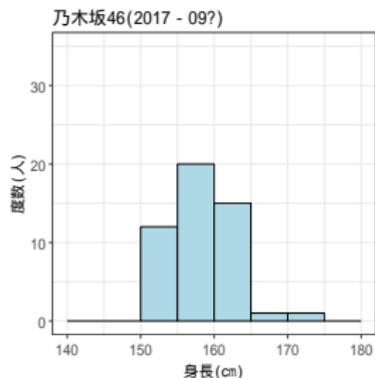
$$S^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

- データの**標準偏差** (standard deviation) = $S = \sqrt{S^2} \geq 0$

岩薩林 確率・統計定理 1.1(p.6)

$$0 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^1$$

(例) グループ (49 人) の身長 I



$n - 1 = 49 - 1$ で割りたくなかった人もい
 るかも. ここは 49 で OK
 そのうちちゃんと区別を説明します.
 データの単位 \neq 分散の単位

- 平均値 $\bar{x} = \frac{171+166+165+\dots+151}{49} = 158.7(\text{cm})$
- 分散 $S^2 = \frac{(171-158.7)^2+(166-158.7)^2+\dots+(151-158.7)^2}{49} = 17.7 (\text{cm}^2)$
- 標準偏差 $S = \sqrt{17.7} = 4.21 (\text{cm})$

大注意: 平均値 158.7 cm を 159 や 160 に四捨五入すると,

に加えて の危険

数値計算法

度数分布表からの分散・標準偏差の求め方

高校 数学 I 岩薩林 確率・統計 §1.2.3,(1.14)p.17

$$S^2 = \frac{1}{n} \sum_j (x_j - \bar{x})^2 f_j = \frac{\sum_j (x_j - \bar{x})^2 f_j}{\sum_j f_j}$$

ヒストグラムからの標準偏差の読み取り方



力学のりでの分散の求め方

$$\text{質点系の慣性モーメント } I = \frac{\sum_{j=1}^k (x_j - x_G)^2 m_j}{\sum_j m_j}$$

力学

j 番目の質点の位置 x_j , 質量 m_j

分散公式 (便利な (こともある) 計算方法) 高校 数学 I 岩薩林 確率・統計定理 1.2(p.10)

$$S^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - (\bar{x})^2$$

岩薩林 確率・統計例題 1.3(p.7)

, 岩薩林 確率・統計例題 1.4(p.11)

L02-Q3

Quiz(平均値・分散・標準偏差)

データ 87kg, 93kg, 89kg, 91kg, 90kg の平均値・分散・標準偏差を求めよう.

連絡

- 次回はたぶん 3-202 講義室
- 樋口オフィスアワー木 6(1-539) 金屋 (1-542), Math ラウンジ (1-536/538)
- Trial 予告
- 来週は教科書 岩薩林 確率・統計 SS1.3,1.2.2 読んできて。
- 統計検定. 2019-11-24 日 40%ディスカウント団体受験受付中.

統計検定団体受験 申込は Moodle モバイルアプリ
来週月まで



で URL 指定

<https://note.math.ryukoku.ac.jp/moodle>

または Safari/Chrome で.

