

2019年度春学期 統計学 第5回
分布をまとめる—平均・分散

浅野 晃
関西大学総合情報学部



代表値 🤔

代表値とは

統計学が相手にするのは、
「分布」しているデータ

(大般若会の写真)

データをこんな
ふうには読めれば
いいけれど…

<http://www3.ic-net.or.jp/~yaguchi/houwa/daihannya.htm>

代表値とは

こんなことはできないので、

- 図示する (ヒストグラム)
- ひとつの数にまとめる

(大般若会の写真)

[代表値]

数字で表されていれば、
計算ができる

<http://www3.ic-net.or.jp/~yaguchi/houwa/daihannya.htm>

平均

とくに [算術平均] は
代表的な代表値

(算術) 平均
= (データの総和) \div (数値の個数)
↑
” / ” でも同じ意味

平均

データ x_1, x_2, \dots, x_n のとき
数値の個数
(データサイズ) n

$$\text{平均 } \bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i$$

データサイズ?

「データ」という言葉は、
数値の集まりをさす
(1つ1つの数値ではない)

データの中に含まれる数値の個数を
データの大きさ (サイズ) という

家族(family)という言葉に似ている

度数分布から平均を求める

度数分布とは、これでした

| 以上 | 未満 | 階級値 | 度数 | 相対度数 |
|----|----|-----|---------|---------------|
| 15 | 25 | 20 | 4 | 0.08 (8%) |
| 25 | 35 | 30 | 3 | 0.06 (6%) |
| 35 | 45 | 40 | 3 | 0.06 (6%) |
| 45 | 55 | 50 | 8 | 0.16 (16%) |
| 55 | 65 | 60 | 12 | 0.24 (24%) |
| 65 | 75 | 70 | 8 | 0.16 (16%) |
| 75 | 85 | 80 | 9 | 0.18 (18%) |
| 85 | 95 | 90 | 3 | 0.06 (6%) |
| x | x | x | 計 50 | 計 1 (100%) |

度数分布から平均を求める

$$\begin{aligned}\text{平均} &= (\text{データの合計}) / (\text{データサイズ}) \\ &= ([\text{階級値} \times \text{度数}] \text{の合計}) / (\text{データサイズ}) \\ &= [\text{階級値} \times (\text{度数} / \text{データサイズ})] \text{の合計} \\ &= [\text{階級値} \times \text{相対度数}] \text{の合計}\end{aligned}$$

| 以上 | 未満 | 階級値 | 度数 | 相対度数 |
|----|----|-----|---------|---------------|
| 15 | 25 | 20 | 4 | 0.08 (8%) |
| 25 | 35 | 30 | 3 | 0.06 (6%) |
| 35 | 45 | 40 | 3 | 0.06 (6%) |
| 45 | 55 | 50 | 8 | 0.16 (16%) |
| 55 | 65 | 60 | 12 | 0.24 (24%) |
| 65 | 75 | 70 | 8 | 0.16 (16%) |
| 75 | 85 | 80 | 9 | 0.18 (18%) |
| 85 | 95 | 90 | 3 | 0.06 (6%) |
| x | x | x | 計 50 | 計 1 (100%) |

2019年度春学期 統計学

39 - 9

分散と標準偏差 🤔

「ばらつき」を数字で

分布は、
大小ばらばらな数値からなるデータ

どのくらいばらばらかを、
数字で表そう

A: 0, 3, 3, 5, 5, 5, 5, 7, 7, 10 どう違う？

B: 0, 1, 2, 3, 5, 5, 7, 8, 9, 10 平均は

C: 3, 4, 4, 5, 5, 5, 5, 6, 6, 7 どれも5

2019年度春学期 統計学

39 - 11

レンジとばらつき

A: 0, 3, 3, 5, 5, 5, 5, 7, 7, 10

B: 0, 1, 2, 3, 5, 5, 7, 8, 9, 10

C: 3, 4, 4, 5, 5, 5, 5, 6, 6, 7

Cは、最大と最小の差 [レンジ] が
違う

A, Bはレンジは同じだが、
Bのほうがばらついている
ように見える

2019年度春学期 統計学

39 - 12

偏差

各数値と平均との差を [偏差] という

-5 -2 -2 0 0 0 0 +2 +2 +5

A: 0, 3, 3, 5, 5, 5, 5, 7, 7, 10

B: 0, 1, 2, 3, 5, 5, 7, 8, 9, 10

-5 -4 -3 -2 0 0 +2 +3 +4 +5

偏差を平均したら, AとBのばらつきの
違いが表せる?

偏差の平均?

だめ。平均したらゼロ

-5 -2 -2 0 0 0 0 +2 +2 +5

A: 0, 3, 3, 5, 5, 5, 5, 7, 7, 10

B: 0, 1, 2, 3, 5, 5, 7, 8, 9, 10

-5 -4 -3 -2 0 0 +2 +3 +4 +5

偏差を2乗する

偏差を2乗したら, 全部正の数に
なるから, それから平均する

25 4 4 0 0 0 0 4 4 25

-5 -2 -2 0 0 0 0 +2 +2 +5

A: 0, 3, 3, 5, 5, 5, 5, 7, 7, 10

B: 0, 1, 2, 3, 5, 5, 7, 8, 9, 10

-5 -4 -3 -2 0 0 +2 +3 +4 +5

25 16 9 4 0 0 4 9 16 25

分散

平均 6.6

25 4 4 0 0 0 0 4 4 25

-5 -2 -2 0 0 0 0 +2 +2 +5

A: 0, 3, 3, 5, 5, 5, 5, 7, 7, 10

B: 0, 1, 2, 3, 5, 5, 7, 8, 9, 10

-5 -4 -3 -2 0 0 +2 +3 +4 +5

25 16 9 4 0 0 4 9 16 25

平均 10.8

[分散] = (偏差)²の平均

分散と標準偏差

[分散] = (偏差)²の平均 式で書くと

1番の数値 データの平均

$$\sigma^2 = \frac{1}{n} \{ (x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \cdots + (x_n - \bar{x})^2 \}$$

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

n 個たして
n で割る

分散の平方根を [標準偏差] という

度数分布から分散を求める

データの平均 = [階級値 × 相対度数]の合計

分散 = (偏差)²の平均

= [(偏差)² × 相対度数]の合計

= [(階級値 - データの平均)² × 相対度数]の合計

| 以上 | 未満 | 階級値 | 度数 | 相対度数 |
|----|----|-----|----|------------|
| 15 | 25 | 20 | 4 | 0.08 (8%) |
| 25 | 35 | 30 | 3 | 0.06 (6%) |
| 35 | 45 | 40 | 3 | 0.06 (6%) |
| 45 | 55 | 50 | 8 | 0.16 (16%) |
| 55 | 65 | 60 | 12 | 0.24 (24%) |
| 65 | 75 | 70 | 8 | 0.16 (16%) |
| 75 | 85 | 80 | 9 | 0.18 (18%) |
| 85 | 95 | 90 | 3 | 0.06 (6%) |
| x | x | x | 計 | 計 |
| | | | 50 | 1 (100%) |

なぜ2乗?

偏差の2乗ではなく、
偏差の「絶対値」ではいけないの?

絶対値の関数は、途中で折れ目がある
あってむずかしい

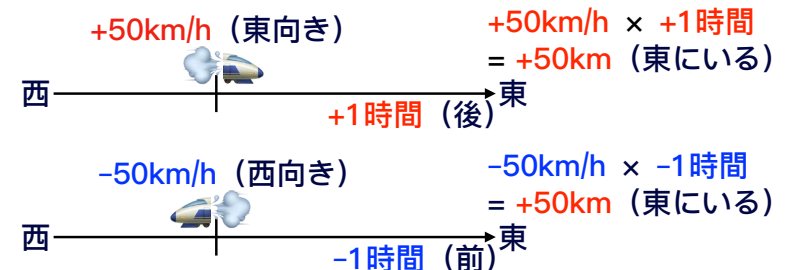
2乗を表す関数のグラフ
(放物線) には折れ目はない

マイナスかけるマイナス=プラス?

プラスとマイナスは、「向きが反対」

東に1km進むのが「+1km」なら 
西に1km進むのは「-1km」

1時間後が「+1時間」なら
1時間前は「-1時間」



標準得点 🤔

「試験で70点」は優れているのか

試験で70点をとった。
まわりより優れているのか？

一緒に受けた人たちの平均点が

50点なら 優れている

80点なら 劣っている

「試験で70点」は優れているのか

試験で70点をとった。
まわりより**とても**優れているのか？

一緒に受けた人たちの平均点が

~~50点なら まあ優れている~~


~~30点なら とても優れている ...?~~

分散も考えないと、答えられない


「試験で70点」は優れているのか

一緒に受けた人たちが

平均60点で
標準偏差5点



平均30点で
標準偏差20点




70点の
「地位」
は同じ。

「地位」を数字で表す

一緒に受けた人たちが


平均60点で標準偏差5点なら

70点の人は、平均を
標準偏差の2倍上回っている



平均30点で標準偏差20点なら


70点の人は、やはり平均を
標準偏差の2倍上回っている



70点の「地位」は同じ

標準得点

平均を
標準偏差の2倍上回っている



[標準得点] が2点

平均を標準偏差の2倍
下回っているなら

標準得点が-2点

標準得点への換算

標準得点 =

分布中のある数値が、
平均を標準偏差の何倍
上回って/下回っているか

分布そのものを


平均0, 標準偏差1に「変換」したら?

その数値の変換後の値が、
そのまま標準得点になる

分布の変換


分布中の各数値から、平均を引く

平均 μ
標準偏差 σ



各数値から μ を引く

平均 0
標準偏差 σ




分布の変換 (続き)

分布中の各数値から、平均を引いて
標準偏差で割る

各数値の偏差は $(1/\sigma)$ 倍
分散は(偏差)²の平均 $(1/\sigma)^2$ 倍
標準偏差は分散の平方根 $(1/\sigma)$ 倍

平均0


標準偏差 σ



各数値を
 $(1/\sigma)$ 倍
各数値を
 $(1/\sigma)$ 倍する

平均0

標準偏差1



式で書くと

分布そのものをXとすると

$$Z = (X - \mu) / \sigma$$

と変換すると、Zは平均0、標準偏差1

受験産業でいう「偏差値」

平均0、標準偏差1の分布Zを、さらに

$$W = 10Z + 50$$

と変換すると、Wは平均50、標準偏差10

これが [偏差値]

偏差値70

平均よりも、標準偏差の2倍
上回っている

偏差値40

平均よりも、標準偏差の1倍
下回っている