

# 散布度 ( dispersion )

- 代表値のほかに、重要な特性値として「**散布度**」がある。
- 平均値に対して、**どれくらいデータが散らばっているか**を示す。
  - 分布の裾の広がり具合
  - 平均値への集中の度合い

## 標準偏差

### 偏差 ( deviation )

- 偏差  $D$  は、各データと平均との差である。
  - + の偏差と - の偏差があるため、すべての偏差の合計は0になる。

$$D_i = \bar{x} - x_i$$

### 分散(variance)と標準偏差(standard deviation)

分析対象となる全体（母集団）の分布のバラつきの度合い求める場合には、代表的な散布度である、分散と標準偏差を用いる。

- 分散  $s^2$  (または  $\sigma^2$ ) は、**偏差平方和**(偏差の二乗の和)をとって、その平均を求めたものである。
  - 全データの平均からのバラツキの程度を示す。

$$\begin{aligned}s^2 &= \frac{1}{n} \sum_{i=1}^n (\bar{x} - x_i)^2 \\ &= \frac{1}{n} \sum_{i=1}^n D_i\end{aligned}$$

- 標準偏差  $s$  は、分散の平方根を求めたものである。
    - 全データの平均からのバラツキの程度を示す(単位はデータと同じ)。
- $$s = \sqrt{\frac{\sum_{i=1}^n (\bar{x} - x_i)^2}{n}}$$
- 標準偏差や分散の値が大きい場合はデータのバラつきが大きく、小さい場合はバラつきが小さい(データが同じ程度に揃ってる)

## 不偏分散 ( unbiased variance ) と不偏標準偏差 ( unbiased standard deviation )

分析対象となる全体（母集団）ではなく、対象の一部分（標本）の分布のバラつきの度合い求める場合には、不偏分散と不偏標準偏差を用いる。

- 不偏分散  $U^2$  は、偏差平方和(偏差の二乗の和)をとって、その平均を求めたものである。

- 分散との違いは、分母は「標本数-1」であること。
- データ全体についての平均値からのバラツキの程度を示す。

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

- 不偏標準偏差  $U$  は、分散の平方根を求めたもの

- 全データの平均からのバラツキの程度を示す(単位はデータと同じ)。

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

## 標準偏差の和

$n$  組の資料（データ）があるとき、資料全体の標準偏差は次のようになる。

$$s_T = \sqrt{\frac{\sum_{i=1}^n N_i (V_i + D_i^2)}{\sum_{i=1}^n N_i}}$$

- $s_T$  ... 全体の標準偏差
- $N_i$  ... 組目の資料の標本数
- $V_i$  ... 組目の資料の分散
- $D_i$  ... 組目の資料の偏差

## 範囲 ( range )

- 範囲  $R$  は、データの最大値  $x_{max}$  と最小値  $x_{min}$  との差で、データ全体の範囲を示す。
- ハズレ値の影響を受けやすい

$$R = x_{max} - x_{min}$$

## 四分位偏差 ( quartile deviation )

- 四分位偏差はデータの変動の目安に利用される散布度で、代表値として中央値を用いたときに使われることがある。
- ハズレ値やデータ数に影響されにくい値である。

$$\text{四分位偏差} = (\text{第3四分位数} - \text{第1四分位数}) / 2$$

## 平均偏差 ( mean deviation )

- 平均偏差  $M_{dev}$  は、偏差の絶対値を平均したもので、データと平均値とのずれの程度を示す。

$$M_{dev} = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}|$$

$$= \frac{1}{n} \sum_{i=1}^n |D_i|$$

## 変異係数 ( coefficient of variance )

- 変異係数(変動係数)  $Cv$  は、標準偏差を平均で割ったもので、平均値に対する標準偏差の割合を示す(%表示)。
- 変異係数は相対的な散布度(割合を示す無名数で単位はない)で、平均値や標準偏差の異なる複数の種類のデータを比較するときに用いる。

$$Cv = s/\bar{x}$$

- 2つの系列(データの集まり)を比較するとき、次のような場合は相対的散布度が有利になる。

- 双方の単位が同じで、平均がほぼ等しい
- 双方の単位は同じだが、平均が違う
- 双方の単位が違う