

## 記述統計と推測統計

検討しているデータの見方が異なる **2つの立場**があることに注意！

- ・ **記述統計**： 検討しているデータ = 母集団 とみなす。  
要約統計 ともいう。検討しているデータを代表値で要約して記述。
- ・ **推測統計**： 検討しているデータ = 母集団の一部 = 標本 とみなす。  
欲しいものは、検討しているデータの特徴そのものではない。  
欲しいものは、母集団の特徴である。
  - > 統計量 ( statistic ) = 標本の関数 ( 未知母数を含まない )
  - > パラメトリック解析とノンパラメトリック解析
  - > 標本平均と標本分散
  - > 好ましい推定 ( 一致性 , 有効性 , 漸近正規性 , 不偏性など )

(2)

・ 標本平均：  $\bar{X} = \frac{1}{N} \sum_{i=1 \sim N} X_i$

・ 標本分散：  $s^2 = \frac{1}{N-1} \sum_{i=1 \sim N} (X_i - \bar{X})^2$

cf. いわゆる分散：  $\frac{1}{N} \sum_{i=1 \sim N} (X_i - \bar{X})^2$

? 疑問：標本平均やいわゆる分散は，N（＝標本サイズ）で除す  
のに対し，なぜ，標本分散は，N - 1 で除すのか？

その背景には，不偏性と自由度 という概念があるのです。

(3)

## 標本（確率変数）の計算（2）と不偏分散

同一の分布関数  $F$  から独立に抽出した標本(サイズ =  $N$ )  $X_{i=1 \sim N}$  を用いる .

$$\begin{aligned}
 E \sum_{i=1 \sim N} (X_i - \bar{X})^2 &= \sum_{i=1 \sim N} E(X_i^2) - 2 \sum_{i=1 \sim N} E(X_i \bar{X}) + NE(\bar{X}^2) \\
 &= N \left\{ E(X^2) - E(\bar{X}^2) \right\} \\
 12) \quad &= N \left\{ (\mu^2 + \sigma^2) - \left( \mu^2 + \frac{\sigma^2}{N} \right) \right\} = (N-1)\sigma^2
 \end{aligned}$$

なお , 上では , 6), 9) および 10) の関係を用いている .

上の関係を整理することにより , 以下が得られる .

$$13) \quad E(s^2) = \sigma^2 \quad \text{for} \quad s^2 = \frac{1}{N-1} \sum_{i=1 \sim N} (X_i - \bar{X})^2$$

言い換えれば ,  $\sum_{i=1 \sim N} (X_i - \bar{X})^2$  の変動の大きさは , 平均的にみて ,

$X_i$  の変動 (  $= (X_i - \mu)^2$  ) の大きさの  $(N-1)$  コ分 (自由度) に相当する .

## モンテカルロで確認

(4)

```
> vals <- rnorm(20) # test any other distribution: ex. rexp(12)
> vals
[1] -0.15086814 -0.53577110 -1.92426062 -1.02552999 ...

> (m.vals <- mean(vals))
[1] 0.1490854
> sum((vals - mean(vals))^2)
[1] 23.43915
> sum((vals - mean(vals))^2)/20
[1] 1.171957
> sum((vals - mean(vals))^2)/(20 - 1)
[1] 1.233639
> var(vals) # built-in function
[1] 1.233639
>
> variances <- numeric(10000)
> for(j in 1:10000) {
+   vals <- rnorm(20)
+   variances[j] <- sum((vals - mean(vals))^2)}
> mean(variances)
[1] 18.96152
>
```