

# 応用システム工学

## 第五回 回帰分析

平成23年05月13日

2011/05/13

1

## チェビシェフの不等式

- 集合  $I = \{x : |x - E[x]| \geq k\sqrt{V[x]}\}$  ただし  $k > 0$
- 確率変数  $X$  が  $x$  となる確率  $P(X=x)$  の確率頻度関数  $f(x)$   $P[|X - E[X]| \geq k\sqrt{V[X]}] = \sum_{x \in I} f(x)$ 
  - 確率  $P$  で分散を表す

$$\begin{aligned} V[X] &\geq \sum_{x \in I} (x - E[X])^2 f(x) \\ &\geq k^2 V[X] P[|X - E[X]| \geq k\sqrt{V[X]}] \end{aligned}$$

$$\frac{1}{k^2} \geq P[|X - E[X]| \geq k\sqrt{V[X]}]$$

- 確率変数と期待値の差が分散の根より大きくなる確率は小さい ( $1/k^2$ )

2011/05/06

2

# 確率収束

- 確率変数として標本平均を考える

– 期待値と分散  $E[\bar{X}_n] = \mu$      $V[\bar{X}_n] = \frac{1}{n}\sigma^2$

– チェビシエフの不等式

$$\frac{1}{k^2} \geq P\left[\bar{X}_n - E[\bar{X}_n] \geq k\sqrt{V[\bar{X}_n]}\right] = P\left[|\bar{X}_n - \mu| \geq k\sqrt{\frac{\sigma^2}{n}}\right]$$

$$\varepsilon = k\sqrt{\frac{\sigma^2}{n}} \text{ とすると } \frac{1}{k^2} = \frac{\sigma^2}{n\varepsilon^2} = P\left[|\bar{X}_n - \mu| \geq k\sqrt{\frac{\sigma^2}{n}}\right]$$

$$\lim_{n \rightarrow \infty} P\left[|\bar{X}_n - \mu| \geq k\sqrt{\frac{\sigma^2}{n}}\right] = \lim_{n \rightarrow \infty} \frac{\sigma^2}{n\varepsilon^2} = 0$$

標本サイズnを大きくすると、標本平均と母平均に差がある確率が0となる

# 不変分散

- 一致推定量 → 標本サイズが十分大きいとき、標本平均が母平均に確率収束する性質をもつ推定量 → 標本平均は母平均に確率収束
- 不変推定量 → 期待値が母数に等しい推定量

– 標本平均  $\bar{X}$  は不偏推定量

• 母平均  $\mu$  に対して  $E[\bar{X}] = \mu$

標本平均は  
母平均と等しくなる

– 標本の分散は不偏推定量となるか？

• 標本の分散

$$S^2 = \frac{(X_1 - \bar{X})^2 + (X_2 - \bar{X})^2 + \dots + (X_n - \bar{X})^2}{n}$$

# 不変分散

- 標本の分散

$$\begin{aligned} S^2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \\ &= \frac{1}{n} \sum_{i=1}^n [(X_i - \mu) - (\bar{X} - \mu)]^2 \\ &= \frac{1}{n} \sum_{i=1}^n [Y_i - \bar{Y}]^2 \\ &= \frac{1}{n} \sum_{i=1}^n Y_i^2 - 2 \frac{\bar{Y}}{n} \sum_{i=1}^n Y_i + \frac{\bar{Y}^2}{n} \sum_{i=1}^n 1 \\ &= \frac{1}{n} \sum_{i=1}^n Y_i^2 - 2\bar{Y}\bar{Y} + \frac{\bar{Y}^2 n}{n} = \frac{1}{n} \sum_{i=1}^n Y_i^2 - \bar{Y}^2 \end{aligned}$$

変数変換

$$Y_i = X_i - \mu$$

$$\bar{Y} = \bar{X} - \mu$$

2011/05/13

5

# 不変分散

- 標本の分散の期待値

$$\begin{aligned} E[S^2] &= E\left[\frac{1}{n} \sum_{i=1}^n Y_i^2 - \bar{Y}^2\right] = E\left[\frac{1}{n} \sum_{i=1}^n Y_i^2\right] - E[\bar{Y}^2] \\ &= \frac{1}{n} \sum_{i=1}^n E[Y_i^2] - E[\bar{Y}^2] = \frac{1}{n} \sum_{i=1}^n E[(X_i - \mu)^2] - E[(\bar{X} - \mu)^2] \end{aligned}$$

– 標本サイズが大きいときの標本と母平均の差の二乗平均

$$E[(X_i - \mu)^2] \rightarrow \sigma^2$$

– 標本平均の分散

$$E[(\bar{X} - \mu)^2] = \frac{\sigma^2}{n}$$

2011/05/13

6

# 不変分散

- 標本分散の期待値

$$E[S^2] = \frac{1}{n} \sum_{i=1}^n \sigma^2 - \frac{\sigma^2}{n}$$
$$= \frac{1}{n} n \sigma^2 - \frac{\sigma^2}{n} = \frac{n-1}{n} \sigma^2$$

- 標本分散  $S^2$  の期待値  $E[S^2]$  は母分散  $\sigma^2$  とは等しくない  
→ 標本分散  $S^2$  は母分散の不偏推定量ではない  
 $\frac{n}{n-1} S^2$  が母分散の不偏推定量に相当

- 不偏分散(自由度n-1)

$$s^2 = \frac{(X_1 - \bar{X})^2 + (X_2 - \bar{X})^2 + \dots + (X_n - \bar{X})^2}{n-1}$$

2011/05/13

7

# 検定

- 仮説検定 → 統計的推測により母集団に対して判断する
- 帰無仮説 → 推論
  - 例 コイン投げの表が出る確率は50%
  - 帰無仮説を棄却する → 表が出る確率が50%  
というのは間違いである
- 対立仮説 → 帰無仮説が棄却された結果得られる結論
  - 表が出る確率は50%より小さい(大きい)

2011/05/13

8

# 検定


- 有意水準 → 帰無仮説が正しい時に、帰無仮説を棄却する確率
  - 第一種の誤り → 帰無仮説が正しい時に、帰無仮説を棄却する誤り
  - 第二種の誤り → 対立仮説が正しい時に、帰無仮説を採用する誤り
    - 第一種の誤りの低減と、第二種の誤りの低減にはトレードオフの関係がある

2011/05/13

9

# 検定

- 確率変数 $X$ 
  - 標準正規分布 $N(0,1)$ 
    - 期待値0, 分散1
  - 発生する確率 (有意水準)5%以下
    - $X \leq -1.64$
    - $X$ が-1.64より小さければ、有意水準5%で帰無仮説が棄却される
  - 検出力 → 対立仮説が正しく、帰無仮説を棄却する確率(標本サイズが大きくなると検出力は大きくなる)



2011/05/13

10

# 区間推定

- 正規分布する母集団の母平均を, 標本平均を用いて推測

– 区間推定 母平均がある区間に入っている確率を求める

- 信頼係数  $W \rightarrow W \times 100\%$  信頼区間

– 母集団 平均 $\mu$ , 分散 $\sigma^2$ の正規分布 $N(\mu, \sigma^2)$

- 確率密度関数  $f_x(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right]$

- 標本(n個)も正規分布する

$$x_1, x_2, \dots, x_n$$

– 標本平均も正規分布

正規分布の再生性

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n}$$

2011/05/13

確率変数 $X, Y$ が独立で, 各々正規分布となるとき $X+Y$ も

正規分布となる

11

# 確率分布

- 確率変数 $X$ の確率密度関数  $f(x)$

–  $X$ が $a$ から $b$ の値をとる確率

$$P[a \leq x \leq b] = \int_a^b f(x) dx$$

- 累積分布関数  $\rightarrow$  確率変数 $X$ が $x$ 以下の値である確率

$$F[X] = P[X \leq x] = \int_{-\infty}^x f(t) dt$$

2011/05/13


12

# 区間推定

- 標本平均を正規分布化して考える  $Z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}}$   
 $X \rightarrow Z$ 
    - 標本平均の分散  $\frac{\sigma^2}{n}$
- $$P(-u \leq Z \leq u) = W$$

-  $-u \leq Z \leq u$ となる確率W

- 標本平均で表す



$$P\left(-u \leq \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \leq u\right) = W$$

2011/05/13

13

# 区間推定

- 信頼区間Wの上限と下限

$$P\left(-\bar{X} - u\sqrt{\frac{\sigma^2}{n}} \leq -\mu \leq -\bar{X} + u\sqrt{\frac{\sigma^2}{n}}\right) = W$$

$$P\left(\bar{X} - u\sqrt{\frac{\sigma^2}{n}} \leq \mu \leq \bar{X} + u\sqrt{\frac{\sigma^2}{n}}\right) = W$$

- 100W%信頼区間

$$\left[ \bar{X} - u\sqrt{\frac{\sigma^2}{n}}, \bar{X} + u\sqrt{\frac{\sigma^2}{n}} \right]$$

2011/05/13

14

# 信頼区間

- 復元抽出
  - 標本を取り出した後、標本を母集団に戻した後、改めて標本を抽出
    - 標本の値のデータが母集団で占める割合は変化しない
  - 母集団の大きさが、信頼区間の幅に影響しない
    - 標本サイズが信頼区間の幅に影響する
- 非復元抽出
  - 標本を取り出した後、標本を母集団に戻さない
    - 標本の値のデータが母集団で占める割合は変化する

2011/05/13

15

# $\chi^2$ 分布

- 母平均の区間推定 → 母分散 $\sigma^2$ を用いて、標本平均の分散 $\sigma^2/n$ を表す
  - 母分散の点推定 → 不変分散で表す
- 各々標準正規分布 $N(0,1)$ の独立な確率変数 $Z_1, Z_2, \dots, Z_n$  に対する次式で定義される確率変数 $\chi^2$

$$\chi^2 = Z_1^2 + Z_2^2 + \dots + Z_n^2 = \sum_{i=1}^n Z_i^2$$

の確率分布 → 自由度 $n$ の $\chi^2$ 分布  $\chi^2(n)$

2011/05/13

16



# $\chi^2$ 分布

- 母分散 $\sigma^2$ を不偏分散 $s^2$ と $\chi^2$ 分布で表す

– 母集団 → 正規分布 $N(\mu, \sigma^2)$

- 標本サイズ $n$ 個  $Z_1, Z_2, \dots, Z_n$

– 標本平均  $\bar{Z}$ , 不偏分散  $s^2$

$$\begin{aligned} s^2 &= \frac{1}{n-1} \left\{ (Z_1 - \bar{Z})^2 + (Z_2 - \bar{Z})^2 + \dots + (Z_n - \bar{Z})^2 \right\} \\ &= \frac{1}{n-1} \sum_{i=1}^n (Z_i - \bar{Z})^2 = \frac{1}{n-1} \sum_{i=1}^n [(Z_i - \mu) - (\bar{Z} - \mu)]^2 \\ &= \frac{1}{n-1} \left\{ \sum_{i=1}^n (Z_i - \mu)^2 - 2(\bar{Z} - \mu) \sum_{i=1}^n (Z_i - \mu) + (\bar{Z} - \mu)^2 \sum_{i=1}^n 1 \right\} \end{aligned}$$

2011/05/13

17

# $\chi^2$ 分布

$$\begin{aligned} s^2 &= \frac{1}{n-1} \left\{ \sum_{i=1}^n (Z_i - \mu)^2 - 2(\bar{Z} - \mu)n(\bar{Z} - \mu) + (\bar{Z} - \mu)^2 n \right\} \\ &= \frac{1}{n-1} \left\{ \sum_{i=1}^n (Z_i - \mu)^2 - n(\bar{Z} - \mu)^2 \right\} \\ (n-1)s^2 &= \sum_{i=1}^n (Z_i - \mu)^2 - n(\bar{Z} - \mu)^2 \\ \frac{(n-1)s^2}{\sigma^2} + \left( \frac{\bar{Z} - \mu}{\sqrt{\sigma^2/n}} \right)^2 &= \sum_{i=1}^n \left( \frac{Z_i - \mu}{\sigma} \right)^2 \end{aligned}$$

2011/05/13

18

# $\chi^2$ 分布


$$\frac{(n-1)s^2}{\sigma^2} + \left( \frac{\bar{Z} - \mu}{\sqrt{\sigma^2/n}} \right)^2 = \sum_{i=1}^n \left( \frac{Z_i - \mu}{\sigma} \right)^2$$

$$\sum_{i=1}^n \left( \frac{Z_i - \mu}{\sigma} \right)^2$$




自由度nの $\chi^2$ 分布

$$\left( \frac{\bar{Z} - \mu}{\sqrt{\sigma^2/n}} \right)^2$$



$\bar{Z}$  の確率分布は  $N\left(\mu, \frac{\sigma^2}{n}\right)$   
より, 自由度1の $\chi^2$ 分布

$$\frac{(n-1)s^2}{\sigma^2}$$



自由度n-1の $\chi^2$ 分布となる