



第20回 7月1日の授業内容

- § 6. 母数の推定
 - § 6.3 区間推定
 - § 6.3.3 母平均の推定(分布、母平均、母分散共に未知)
 - § 6.4 最尤法
 - § 6.4.1 尤度関数
 - § 6.4.2 最尤推定量

7/1/09

1



§ 6.3.3 母平均の推定

(分布、母平均、母分散共に未知)

- § 6.3.2 では $X_i \sim N(\mu, \sigma^2)$ で、かつ σ^2 が未知と仮定。
- しかし、実際には、 X_i の分布が正規分布であることは稀。
- 中心極限定理 (CLT) より、 n のとき、標準化した \bar{X}_n 、すなわち $(\bar{X}_n - \mu) / \sqrt{\sigma^2/n}$ が標準正規分布に従うことを用いて区間推定を行う。
- だが、問題なのは σ^2 が未知であること。
- 推定量 $\hat{\sigma}^2$ が一致推定量であれば、CLT が成立するような標本数 n のとき、 $\hat{\sigma}^2 \rightarrow \sigma^2$ となる。
- $\hat{\sigma}^2$ を σ^2 とみなして、母分散が既知のときと同様に推定する。

7/1/09

2



§ 6.3.3 母平均の推定

(分布、母平均、母分散共に未知)(2)

【結論】

- 分布が未知の時の母平均の区間推定は、中心極限定理に基づく、大標本近似による推定。
- 近似の誤差
 - 真の分布を標準正規分布で近似したときの誤差
 - $\hat{\sigma}^2$ を推定量 σ^2 で近似したときの誤差

7/1/09

3



§ 6.3.3 母平均の推定

(分布、母平均、母分散共に未知)(3)

- 近似の精度についての実験
 - 分布の近似
 - パラメータ λ の指数分布にしたがう確率変数 W_i の標本平均の分布を求める。
 - 標本の大きさは $n=1, 10, 100, 400$
 - 標準化した W_i の標本平均の分布は $n=100$ で標準正規分布に近くなる。
 - 平均、分散についての大量の法則の成立
 - シミュレーション実験の結果 ($\lambda=1.5$, 繰り返し数200回)
 - $n=10$ のとき
 - 平均()の推定量の平均 1.52 (平均2乗誤差:0.238)
 - 分散()の推定量の平均 2.29 (平均2乗誤差:4.128)
 - $n=100$ のとき
 - 平均()の推定量の平均 1.49 (平均2乗誤差:0.024)
 - 分散()の推定量の平均 2.28 (平均2乗誤差:0.506)

7/1/09

4



§ 6.4 最尤法

- § 6.4.1 尤度関数
 - 今まで紹介してきた推定量
 - 推定に際して確率変数の分布の情報を用いていない。
 - 確率変数の分布の情報を用いれば、さらに「良い」推定量が得られる可能性がある。
 - 確率変数の分布に関する情報
 - 確率密度関数(連続型の場合)
 - 確率関数(離散型の場合)

7/1/09

5



§ 6.4.1 尤度関数(2)

- 確率密度関数
 - パラメータを所与として、ある値がどのくらいの「確からしさ」で出現するかを示したもの。
 - 例: 正規分布
 - 平均 μ 、分散 σ^2 を決めたとときに、 x という値がどの程度出現するかを示した関数

$$f(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

7/1/09

6



§ 6.4.1 尤度関数(3)

- 確率密度関数 標本を抽出するときの「事前」の関係を示したもの。
 - 標本が抽出されてしまった「事後」の状態をどう表すか?
- ↓
- 同じ形の関数を、データを所与として、パラメータがある値となったときに、どの程度「尤もらしい」かを示した関数と読み替える。 尤度(ゆんど)関数

7/1/09

7



§ 6.4.1 尤度関数(4)

- 尤度関数 likelihood function
 - 正規分布の例: データxを所与としたときに、どのような μ, σ^2 がもっともらしいかの程度を表している。

$$L(\mu, \sigma^2 | x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

7/1/09


8



§ 6.4.2 最尤推定量

Maximum Likelihood Estimator

- 尤度を最大とするパラメータの推定量 = 確率変数の分布情報を用いた推定量



- 同じ確率分布にしたがうn個の独立な標本の尤度 n個の尤度関数の積
 $L(x_1, x_2, \dots, x_n) = L(x_1) \cdots L(x_n)$

7/1/09

9



§ 6.4.2 最尤推定量 (2)

- 最尤推定量
 $\max_{\mu} L(x_1, x_2, \dots, x_n)$
 を満たす μ で与えられる。
- 例: x_1, x_2 が互いに独立に $N(\mu, 1)$ にしたがう場合
 - 尤度関数

$$\begin{aligned} L(\mu | x_1, x_2) &= L(\mu | x_1) \times L(\mu | x_2) \\ &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x_1-\mu)^2}{2}\right) \times \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x_2-\mu)^2}{2}\right) \end{aligned}$$

7/1/09

10



§ 6.4.2 最尤推定量 (3)

- 最大化の1階の条件: $\frac{\partial L}{\partial \mu} = 0$
- しかし、指数関数の微分は面倒。
 - 尤度の最大化ではなく、対数尤度の最大化を考える。

$$\frac{\partial \log L}{\partial \mu} = \frac{\partial \log L}{\partial L} \times \frac{\partial L}{\partial \mu} = \frac{1}{L} \times \frac{\partial L}{\partial \mu} = 0$$

7/1/09

11



§ 6.4.2 最尤推定量(4)

- 対数尤度関数は
 $\log L(\mu | x_1, x_2) = \log L(\mu | x_1) + \log L(\mu | x_2)$
 $= -\log 2\pi - \frac{1}{2} \sum_{i=1}^2 (x_i - \mu)^2$
 と表現できる。

- 対数尤度関数 $\log L$ を μ で偏微分すると

$$\frac{\partial \log L}{\partial \mu} = -\frac{1}{2} \sum_{i=1}^2 2(-1)(x_i - \mu) = 0$$

これより1階の条件を満たす μ を $\hat{\mu}$ とあらわすと、

$$\hat{\mu} = \frac{x_1 + x_2}{2} \quad \text{この場合、最尤推定量は算術平均に一致する。}$$

7/1/09

12