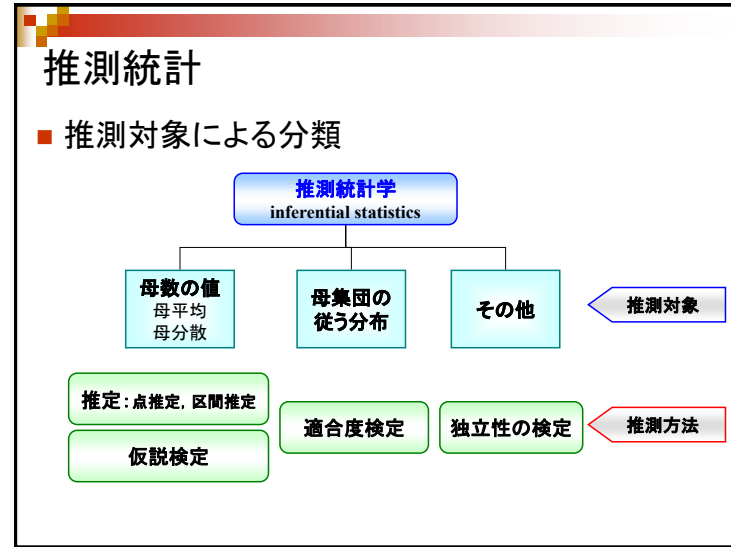


統計の分析と利用

(旧カリ: データ分布と予測)

推定: 点推定と区間推定

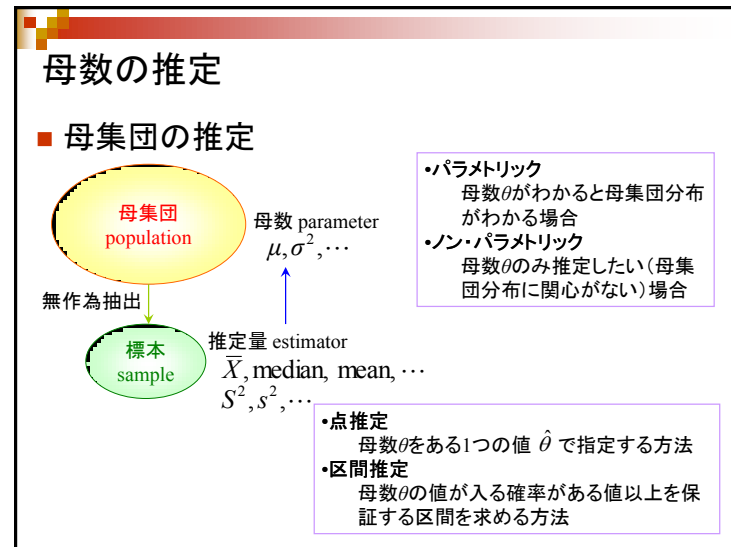
堀田 敬介
2009/12/18, Fri.



Contents

■ 推定

- 点推定と区間推定
 - 点推定 point estimation
 - モーメント法 method of moments
 - 最尤法 maximum likelihood method
 - 区間推定 interval estimation
 - 母平均の推定: 母分散が既知の場合 [Z推定]
 - 母平均の推定: 母分散が未知の場合 [t推定]
 - 母分散の推定: [F推定]
 - 母比率の推定: [Z推定]
- 2つの正規母集団の比較
 - 母平均の差の区間推定
 - 母分散の比の区間推定



母数の推定: 不偏推定量

標本の観測値から計算される量

- 母数の推定量・推定値
 - 母数 θ を推定するために用いる統計量 W を、 θ の**推定量**という
 - 推定量 W の実現値を θ の**推定値**という
- 不偏推定量
 - $E(W)=\theta$ が成り立つとき、統計量 W を θ の**不偏推定量**という
 - 例1: 標本平均 \bar{X}
 $E(\bar{X}) = \mu$ より不偏推定量
 - 例2: 標本分散 S^2
 $E(S^2) = \frac{n-1}{n} \sigma^2$ より不偏推定量ではない
 - 例3: 不偏分散 $s^2 = \frac{1}{n-1} \{(X_1 - \bar{X})^2 + \dots + (X_n - \bar{X})^2\}$
 $E(s^2) = \sigma^2$ より不偏推定量

母平均の点推定

■ 点推定

X の(原点まわりの) r 次積率 $\mu_r = E(X^r)$
 X の期待値まわりの r 次積率 $\mu'_r = E(X - \mu)^r$
 X の r 次標準化積率 $\alpha_r = E\{(X - \mu)/\sigma\}^r$

- 積率法 method of moments
 - 積率(モーメント)を利用する方法
- 最尤法 maximum likelihood method
 - 最尤原理: 「現実の標本は確率最大のものが実現した」に基づく方法

母数 θ
 標本 X_1, \dots, X_n n 個の標本の実現値(観測値) x_1, x_2, \dots, x_n
 母集団確率分布 $f(x, \theta)$

\rightarrow 尤度関数 $L(\theta) = f(x_1, \theta) \times \dots \times f(x_n, \theta) = \prod_{i=1}^n f(x_i, \theta)$

尤度関数を母数空間 Θ 上で最大にするものを推定値・推定量とする
 ▽ 尤度関数を最大にする θ : 最尤推定値 maximum likelihood estimate
 ▽ 母数空間 Θ parameter space: 母数がとりうる値の集合

※注意: 最尤法は尤度関数を作る関係上、母集団分布がわからないときは使えない!

母平均の推定: 点推定 [point estimation]

- ある店舗の36日分の週末来客数のデータ

300	356	319	213	229	244	標本
317	306	390	287	268	257	sample
274	231	370	275	186	327	母集団 population ある店舗の週末来客数
365	272	335	167	289	352	
351	299	327	405	259	376	
301	337	229	244	279	243	

この店舗の週末の平均来客数を知りたい!

標本平均値: 294

点推定
この店舗の平均来客数は294である

母平均の点推定

- 最尤法 maximum likelihood method

□ 例: 母集団分布が $X=1,0$ で1をとる確率 p のベルヌーイ分布 $Bi(1,p)$ とする。母数 p を推定したい。

5つの標本をとったところ...
 $X_1=1, X_2=1, X_3=0, X_4=1, X_5=1$

\rightarrow 尤度関数は
 $L(p) = p^4(1-p)$

\rightarrow 尤度関数を最大にする p を求めると...
 $\frac{dL(p)}{dp} = p^3(4-5p) = 0$
 $\rightarrow \hat{p} = 4/5$ **最尤推定値**

p を推定したい!

補足: 母平均の点推定

■ 点推定の基準

□ 不偏性

- 推定量 $\hat{\theta}$ の期待値が、真の母数 θ の値となる性質
 - 例1: 標本平均 \bar{X} は母平均 μ の不偏推定量
 - 例2: 標本分散 S^2 は母分散 σ^2 の不偏推定量ではない
 - 例3: 不偏分散 s^2 は母分散 σ^2 の不偏推定量

□ 一致性

- 標本数 n が大きくなれば、推定量 $\hat{\theta}$ が真の母数 θ に近づく性質
 - 例1: 標本平均 \bar{X} は母平均 μ の一致推定量
 - 例2: 標本分散 S^2 は母分散 σ^2 の一致推定量
 - 例3: 不偏分散 s^2 は母分散 σ^2 の一致推定量

不偏推定量
unbiased estimator

一致推定量
consistent estimator

モーメント法による
■ 母平均の推定量 \bar{X}
■ 母分散の推定量 S^2

$E(\hat{\theta}) = \theta$

$\forall \varepsilon > 0, P(|\hat{\theta}_n - \theta| > \varepsilon) \rightarrow 0$

この2つの性質は、推定量が最小限満たすべき性質

母平均の点推定

■ 例題

□ 40人のクラスでテストを行った。10人の採点をしたところ結果は以下のとおりとなった。クラス全体の平均は何点だろうか？ ただし満点は100点である

70	62	82	73	67	75	85	71	60	65
----	----	----	----	----	----	----	----	----	----

(1) 点推定で母平均を推定せよ

$$\frac{70 + 62 + 82 + 73 + 67 + 75 + 85 + 71 + 60 + 65}{10} = 71.0$$

補足: 母平均の点推定

■ 点推定の基準

□ 漸近正規性 asymptotic normality

- 標本分布の漸近分布が正規分布である性質
 - 例: 標本平均 \bar{X} の漸近分布は、中心極限定理より、母集団分布に関係なく正規分布となる

□ 有効性 efficiency

- 不偏性と一致性を満たす他のいかなる推定量よりも、分散が小さいという性質
 - 例: 母集団分布が正規分布の場合、標本平均 \bar{X} は母平均 μ の有効推定量

□ 漸近有効性 asymptotic efficiency

- 漸近分布が正規分布となる推定量のうち、漸近分散が最小となる性質
 - 例: 最尤推定量は一般に漸近有効性を持つ

漸近正規推定量
asymptotically normal estimator

有効推定量 efficient estimator
(最小分散不偏推定量 minimum variance unbiased estimator)

漸近的有効推定量
asymptotically efficient estimator

有効性の検証が難しいため、漸近有効性を用いる

母数の推定: 区間推定 [interval estimation]

■ 母平均・母分散の区間推定

● 母平均 μ の区間推定

- 母分散 σ^2 が既知の場合
→ Z 推定 (標準正規分布)
- 母分散 σ^2 が未知の場合
→ t 推定 (自由度 $n-1$ の t 分布)

● 母分散 σ^2 の区間推定

- χ^2 推定 (自由度 $n-1$ の χ^2 分布)

母平均の区間推定

- 母平均の区間推定 ... 母平均の取り得る区間を推定
「母平均 μ は〇〇から△△の間にある」

推測の区間の幅が広ければ広いほど、
当たる可能性は高くなる

例: 文教大学の男子学生の平均身長は?
 「平均身長は0cm~300cmの間にある」
 「平均身長は100cm~200cmの間にある」
 「平均身長は160cm~180cmの間にある」
 「平均身長は170cm~175cmの間にある」

↓

推測の区間だけではなく、
推測の当たる可能性(確からしさ)も重要

「母平均 μ は
 $\square\square\%$ の確からしさで、**信頼度(信頼係数)**
 $\bigcirc\bigcirc$ から $\triangle\triangle$ の間にある」**信頼区間**

母平均の区間推定

中心極限定理より $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ ⇔ 標準化 $Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0,1)$

- 母平均の区間推定
 - 標準正規分布 $N(0,1)$ に従う確率変数 Z を使う
 - 標準正規分布 $N(0,1)$ に従う確率変数 Z が -1.96 以上 1.96 以下の値をとる確率は 0.95 である

↓

$$0.95 = P(-1.96 \leq Z \leq 1.96)$$

$$= P(-1.96 \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq 1.96)$$

$$= P(\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + 1.96 \frac{\sigma}{\sqrt{n}})$$

母平均の区間推定

- 母平均の区間推定
 - 信頼度(信頼係数)
 - 推測した結果がどれだけ信頼できるかの目安
 - 信頼区間
 - 推測の範囲

ある程度充分な数の標本(n個)を収集し、信頼度を保ちながら、なるべく狭い信頼区間を推定したい!

例: 文教大学の男子学生の平均身長は?

信頼区間の幅が**広い**
 ⇒ 推測が当たる可能性**高い**
 ⇒ 信頼度が**高い**

信頼区間の幅が**狭い**
 ⇒ 推測が当たる可能性**低い**
 ⇒ 信頼度が**低い**

母平均の区間推定

- 母平均の区間推定 (母分散が**既知**の場合)
 - 母平均 μ は信頼度 95% で以下信頼区間にあると推定

$$\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + 1.96 \frac{\sigma}{\sqrt{n}}$$

母分散 σ^2 がわかれば計算可能

標本数(n)が分母にある。即ち、
 n が大きければ、区間幅は狭くなり、
 n が小さければ、区間幅は広がる。
 つまり、たくさん標本をとってくれば、同じ信頼度で区間幅を狭くできる!

【95%信頼区間】
 μ はこの区間のどこかにいる(注: どこかはわからない)

注: 母集団が有限(N)の場合
 $\sigma \rightarrow \sigma \sqrt{\frac{N-n}{N-1}}$

母平均の区間推定

■ Z推定 (母分散が既知の場合)

□ 母平均 μ は100(1- α)%の信頼度で以下信頼区間の間にある

$$\bar{X} - Z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + Z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$$

標準正規分布 $N(0,1)$ で $Z_{\alpha/2}$ のとる確率によって定まる

信頼度	90%	95%	99%
$Z_{\alpha/2}$	1.64	1.96	2.58

信頼度・標本数と信頼区間の相対的關係

信頼度: 大	標本数: 小
信頼度: 小	標本数: 大

信頼区間: 広 (信頼度大, 標本数小) / 狭 (信頼度小, 標本数大)

母平均の区間推定

自由度 $n-1$ の t 分布に従う

$$T = \frac{\bar{X} - \mu}{S/\sqrt{n-1}} \sim t(n-1)$$

■ 母平均の区間推定 (母分散が未知の場合)

□ 自由度 $n-1$ の t 分布 $t(n-1)$ に従う確率変数 T を使う

□ 標本数10のとき, 自由度9の t 分布 $t(9)$ に従う確率変数 T が -2.262 以上 2.262 以下の値をとる確率は 0.95 である

$$0.95 = P(-2.262 \leq T \leq 2.262)$$

$$= P(-2.262 \leq \frac{\bar{X} - \mu}{S/\sqrt{n-1}} \leq 2.262)$$

$$= P(\bar{X} - 2.262 \frac{S}{\sqrt{n-1}} \leq \mu \leq \bar{X} + 2.262 \frac{S}{\sqrt{n-1}})$$

母平均の区間推定

■ 例題

□ 40人のクラスでテストを行った。10人の採点をしたところ結果は以下のとおりとなった。クラス全体の平均は何点だろうか？ただし満点は100点である

70	62	82	73	67	75	85	71	60	65
----	----	----	----	----	----	----	----	----	----

(1) 母分散が59のとき, 信頼度95%で区間推定せよ

信頼度95% $\rightarrow \alpha=0.05 \rightarrow Z_{\alpha/2}=1.96$

$$\rightarrow 71.0 - 1.96 \frac{\sqrt{59}}{\sqrt{10}} \leq \mu \leq 71.0 + 1.96 \frac{\sqrt{59}}{\sqrt{10}}$$

$$\leftrightarrow 66.239 \leq \mu \leq 75.761$$

母平均の区間推定

■ 母平均の区間推定 (母分散が未知の場合)

□ 母平均 μ は信頼度95%で以下信頼区間にあると推定 (自由度9の場合)

$$\bar{X} - 2.262 \frac{S}{\sqrt{n-1}} \leq \mu \leq \bar{X} + 2.262 \frac{S}{\sqrt{n-1}}$$

標本分散 S^2 から計算可能

標本数 (n) が分母にある, 即ち, n が大きければ, 区間幅は狭くなり, n が小さければ, 区間幅は広くなる。つまり, たくさん標本をとってくれば, 同じ信頼度で区間幅を狭くできる!

【95%信頼区間】

μ はこの区間のどこかにいる (注: どこかはわからない)

母平均の区間推定

- 母平均の区間推定 (母分散が**未知**の場合: **t推定**)
 - 母平均 μ は100(1- α)%の信頼度で以下信頼区間の間にある

$$\bar{X} - t_{\alpha/2}(n-1) \frac{S}{\sqrt{n-1}} \leq \mu \leq \bar{X} + t_{\alpha/2}(n-1) \frac{S}{\sqrt{n-1}}$$

↑ ↑
自由度 $n-1$ の t 分布で $t_{\alpha/2}$ のとる確率によって定まる

信頼度	90%	95%	99%
$t_{\alpha/2}(9)$	1.833	2.262	3.250

信頼度・標本数と信頼区間の相対的關係

信頼度:大 標本数:n:小
信頼度:小 標本数:n:大

母数(母平均)の推定: 区間推定

- 演習
 - 正規母集団から標本
9, 7, 12, 8, 9
を得た.

- 母平均 μ を点推定せよ.
- 母分散 $\sigma^2=4$ の時, 信頼度95%で母平均 μ を区間推定せよ.
- 母分散 $\sigma^2=4$ の時, 信頼度99%で母平均 μ を区間推定せよ.
- 母分散が未知の時, 信頼度90%で母平均 μ を区間推定せよ.
- 母分散が未知の時, 信頼度95%で母平均 μ を区間推定せよ.

母平均の区間推定

- 例題
 - 40人のクラスでテストを行った. 10人の採点をしたところ結果は以下のとおりとなった. クラス全体の平均は何点だろうか? ただし満点は100点である

70	62	82	73	67	75	85	71	60	65
----	----	----	----	----	----	----	----	----	----

(1) 母分散が未知のとき, 信頼度90%で区間推定せよ

信頼度90% $\rightarrow \alpha=0.10 \rightarrow t_{\alpha/2}(9)=1.833$

$$\rightarrow 71.0 - 1.833 \frac{\sqrt{59.20}}{\sqrt{10-1}} \leq \mu \leq 71.0 + 1.833 \frac{\sqrt{59.20}}{\sqrt{10-1}}$$

$$\leftrightarrow 66.299 \leq \mu \leq 75.701$$

母平均の区間推定(まとめ)

- 母平均 μ の区間推定
 - 母分散が**既知**のとき $\bar{X} - Z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + Z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$ [信頼率 1- α]
 \Rightarrow **Z推定**
 母分散 σ^2 の値が既知のときに, **標準正規分布N(0,1)**の性質を利用して母平均 μ の信頼区間を求める
 - 母分散が**未知**のとき $\bar{X} - t_{\alpha/2}(n-1) \frac{S}{\sqrt{n-1}} \leq \mu \leq \bar{X} + t_{\alpha/2}(n-1) \frac{S}{\sqrt{n-1}}$ [信頼率 1- α]
 \Rightarrow **t推定**
 母分散 σ^2 の値が未知のときに, **標本分散 S^2** を用い, **自由度n-1のt分布**の性質を利用して母平均 μ の信頼区間を求める

参考: 母平均区間推定の標本数設計法

■ 母平均 μ の信頼区間(信頼率 $1-\alpha$) [母分散 σ^2 既知の場合]

$$\bar{X} - Z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + Z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$$

この幅を δ 以下にしたい!

□ 信頼区間を δ 以下に抑えるために必要な標本数の設計

$$2Z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \delta \quad \Leftrightarrow \quad n \geq \frac{4Z_{\alpha/2}^2 \sigma^2}{\delta^2}$$

よって、標本数 n をこの数以上にすればよい。

□ 例題: 全国男子大学生の平均身長を区間推定したい。95%信頼区間を2cm以下にするには、何人の学生を調査すればよいか? ただし、母分散は $\sigma^2=49$ とする。

$$n \geq \frac{4 \cdot (1.96)^2 \cdot 49}{2^2} = 188.2384$$

よって、 $n=189$ 人を調べれば充分

母数(母分散)の推定: 区間推定

■ 母分散の区間推定

$$\chi^2 = \frac{nS^2}{\sigma^2} \sim \chi^2(n-1)$$

□ 自由度 $n-1$ の χ^2 分布に従う確率変数 χ^2 を使う

□ 自由度9の χ^2 分布に従う確率変数 χ^2 が -2.700 以上 19.023 以下の値をとる確率は0.95

↓

$$0.95 = P(2.700 \leq \chi^2 \leq 19.023)$$

$$= P(2.700 \leq \frac{nS^2}{\sigma^2} \leq 19.023)$$

$$= P(\frac{nS^2}{19.023} \leq \sigma^2 \leq \frac{nS^2}{2.700})$$

注: χ^2 分布は左右対称ではないので、左右それぞれのその面積が0.025となる点を考える必要がある。

参考: 母平均区間推定の標本数設計法

■ 母平均 μ の信頼区間(信頼率 $1-\alpha$) [母分散 σ^2 未知の場合]

$$\bar{X} - t_{\alpha/2}(n-1) \frac{S}{\sqrt{n-1}} \leq \mu \leq \bar{X} + t_{\alpha/2}(n-1) \frac{S}{\sqrt{n-1}}$$

この幅を δ 以下にしたい!

□ 信頼区間を δ 以下に抑えるために必要な標本数の設計

区間幅 $2t_{\alpha/2}(n-1) \frac{S}{\sqrt{n-1}}$ を δ 以下にすればよいが、確率変数 S が含まれているので、区間幅の期待値を δ 以下に抑える。

$$2t_{\alpha/2}(n-1) \frac{E(S)}{\sqrt{n-1}} \leq \delta$$

$E(S)$ は未知母数 σ に依存するので、何らかの情報から σ を想定し、標本数 n を設定することになる。

$$n \geq 1 + \frac{4 \cdot t_{\alpha/2}^2(n-1)^2 \cdot (E(S))^2}{\delta^2}$$

$E(S^2) = \frac{n-1}{n} \sigma^2$ だが $E(S) = \frac{N}{N-1} \cdot \frac{n-1}{n} \sigma^2$ (有限母集団の場合)

$E(S) \neq \sqrt{\frac{n-1}{n}} \sigma$ であることに注意

母数(母分散)の推定: 区間推定

■ 母分散の区間推定

□ 母分散 σ^2 は95%の信頼度で以下の信頼区間の間にあると推測できる! (自由度9の時)

$$2.700 \leq \frac{nS^2}{\sigma^2} \leq 19.023$$

$$\Leftrightarrow \frac{nS^2}{19.023} \leq \sigma^2 \leq \frac{nS^2}{2.700}$$

標本分散 S^2 から計算できる

母数(母分散)の推定: 区間推定

■ 母分散の区間推定 (χ^2 推定)

□ 母分散 σ^2 が $100(1-\alpha)\%$ の信頼度で以下信頼区間の間

$$\frac{nS^2}{\chi_{\alpha/2}^2(n-1)} \leq \sigma^2 \leq \frac{nS^2}{\chi_{1-\alpha/2}^2(n-1)}$$

↑ ↑
自由度 $n-1$ の χ^2 分布で $\chi_{1-\alpha/2}^2, \chi_{\alpha/2}^2$ のとる確率によって定まる

信頼度・標本数と信頼区間の相対的關係

信頼区間	信頼度: 大	標本数: 小
↓	↓	↓
↑	↑	↑
信頼区間	信頼度: 小	標本数: 大

母数(母分散)の推定: 区間推定

■ 演習 (出展:「確率・統計の仕組みがわかる本」技評p.367)

□ 養鶏場における卵の重さのばらつきを調べたい。無作為に16個の卵を抽出したときの重さは下表のとおりとなった。

46	52	54	46	51	47	52	44
50	53	48	51	48	49	54	47

- (1) 信頼度90%で母分散 σ^2 を区間推定せよ。
- (2) 信頼度95%で母分散 σ^2 を区間推定せよ。
- (3) 信頼度99%で母分散 σ^2 を区間推定せよ。

母数(母分散)の推定: 区間推定

■ 例題

□ 40人のクラスでテストを行った。10人の採点をしたところ結果は以下のとおりとなった。クラス全体の標準偏差はどのぐらいだろう？ ただし、満点は100点である。

70	62	82	73	67	75	85	71	60	65
----	----	----	----	----	----	----	----	----	----

- (1) 信頼度95%で区間推定せよ

信頼度95% → $\alpha=0.05$ → $\chi_{1-\alpha/2}^2(9)=2.70039, \chi_{\alpha/2}^2(9)=19.0228$

$$\frac{nS^2}{\chi_{\alpha/2}^2(n-1)} \leq \sigma^2 \leq \frac{nS^2}{\chi_{1-\alpha/2}^2(n-1)} \rightarrow \frac{10 \cdot 59.2}{19.0228} \leq \sigma^2 \leq \frac{10 \cdot 59.2}{2.70039}$$

$$\leftrightarrow 31.12055 \leq \sigma^2 \leq 219.2276$$

$$\rightarrow 5.57858 \leq \sigma \leq 14.80634$$

母数の推定: 区間推定

■ 演習 (参考:「統計学入門」東大出版会 p.231)

□ 東京都の2005年11月1日～10日までの最高気温、最低気温は下表のとおりであった。正規母集団を仮定する。

日にち	11/1	11/2	11/3	11/4	11/5	11/6	11/7	11/8	11/9	11/10
最高気温(°C)	17	19	19	21	21	16	24	22	19	18
最低気温(°C)	10	10	12	12	13	13	13	12	10	10

(データ:「Yahoo!天気情報」より)

- (1) 最高気温について、信頼度99%で母平均 μ の信頼区間を求めよ。
- (2) 最高気温について、信頼度95%で母分散 σ^2 の信頼区間を求めよ。
- (3) 最低気温について、信頼度95%で母平均 μ の信頼区間を求めよ。
- (3) 最低気温について、信頼度90%で母分散 σ^2 の信頼区間を求めよ。

母数(母分散)の推定: 区間推定(まとめ)

- 母分散の区間推定
 - χ^2 推定

自由度 $n-1$ の χ^2 分布の性質を利用して母分散 σ^2 の信頼区間を求める

$$\frac{nS^2}{\chi^2_{\alpha/2}(n-1)} \leq \sigma^2 \leq \frac{nS^2}{\chi^2_{1-\alpha/2}(n-1)}$$

【信頼率 $1-\alpha$ 】

母数(母比率)の推定: 区間推定

第 i 番目の人について
 $X_i = \begin{cases} 1 & (\text{意見Aである}) \\ 0 & (\text{意見Bである}) \end{cases}$
 $\Rightarrow X = X_1 + \dots + X_n$
 $[X_i \sim B(1,p)]$

- 母比率 p の推定
 - 充分大きい N 人から n 人を無作為抽出

母集団 [N 人]

意見Aの人々 人数: Np 人 比率: p

意見Bの人々 人数: $N(1-p)$ 人 比率: $1-p$

➡

標本 [n 人]

意見Aの人々 人数: X 人 比率: X/n

意見Bの人々 人数: $n-X$ 人 比率: $(n-X)/n$

- X は二項分布 $B(n,p)$ に従う $X \sim B(n,p)$
 - 中心極限定理 $\left\{ \begin{array}{l} E(X) = np \\ V(X) = np(1-p) \end{array} \right.$
- X は正規分布 $N(np, np(1-p))$ に従う $X \sim N(np, np(1-p))$
- X/n は正規分布 $N(p, p(1-p)/n)$ に従う $X/n \sim N(p, p(1-p)/n)$
 - $P := X/n$ $\left\{ \begin{array}{l} E(\frac{X}{n}) = \frac{1}{n}E(X) = p \\ V(\frac{X}{n}) = \frac{1}{n^2}V(X) = \frac{p(1-p)}{n} \end{array} \right.$
- Z は正規分布 $N(0,1)$ に従う $Z = \frac{P-p}{\sqrt{p(1-p)/n}} \sim N(0,1)$
 - $\left\{ \begin{array}{l} E(Z) = 0 \\ V(Z) = 1 \end{array} \right.$

標準化: 平均を引いて標準偏差で割る

母数(母比率)の推定: 区間推定

- 母比率 p の推定
 - 充分大きい N 人から n 人を無作為抽出

母集団 [N 人]

意見Aの人々 人数: Np 人 比率: p

意見Bの人々 人数: $N(1-p)$ 人 比率: $1-p$

➡

標本 [n 人]

意見Aの人々 人数: X 人 比率: X/n

意見Bの人々 人数: $n-X$ 人 比率: $(n-X)/n$

意見A [Np 人] 比率: p

意見B [$N(1-p)$ 人] 比率: $1-p$

母比率

知りたい数値

賛成か反対か〔二者択一〕

意見A [X 人] 確率: p

意見B [$n-X$ 人] 確率: $1-p$

標本比率

推定

二項分布 $B(n,p)$

$X \sim N(np, np(1-p))$ (中心極限定理)

$(X$ は正規分布 $N(np, np(1-p))$ に従う)

$(X$ は二項分布 $B(n,p)$ に従う) $\left\{ \begin{array}{l} E(X) = np \\ V(X) = np(1-p) \end{array} \right.$

母数(母比率)の推定: 区間推定

- 母比率 p の推定
 - 母比率 p の信頼度 $100(1-\alpha)\%$ の信頼区間

注: 標本数 n が充分大きいときの信頼区間。 n が小さいときは、修正式が提案されている。

$$P - Z_{\alpha/2} \sqrt{\frac{P(1-P)}{n}} \leq p \leq P + Z_{\alpha/2} \sqrt{\frac{P(1-P)}{n}}$$

標準正規分布 $N(0,1)$ で $Z_{\alpha/2}$ のとる確率によって定まる

式中の P は標本比率で、 $P := X/n$ である

信頼度	90%	95%	99%
$Z_{\alpha/2}$	1.64	1.96	2.58

信頼度・標本数と信頼区間の相対的關係

信頼区間 広 ← 信頼度: 大 → 標本数: 小

信頼区間 狭 ← 信頼度: 小 → 標本数: 大

注: 点推定の場合

母比率は X/n と推定

母数(母比率)の推定: 区間推定

■ 例題 (出展:「図解雑学 統計解析」ナツメ社 p.170)

□ ある新聞社による内閣支持率調査では3000人の対象者のうち1674人が現行内閣を指示すると回答した。この国の内閣支持率はどのくらいだろうか? 信頼度95%で母比率 p の区間推定をしよう。

■ 標本比率: $P = \frac{X}{n} = \frac{1674}{3000} = 0.558$

■ 信頼度95%とは $\alpha=0.05$, 即ち, $Z_{0.05/2}=1.96$

■ 信頼区間:

$$P - Z_{\alpha/2} \sqrt{\frac{P(1-P)}{n}} \leq p \leq P + Z_{\alpha/2} \sqrt{\frac{P(1-P)}{n}}$$

$$\rightarrow 0.558 - 1.96 \sqrt{\frac{0.558(1-0.558)}{3000}} \leq p \leq 0.558 + 1.96 \sqrt{\frac{0.558(1-0.558)}{3000}}$$

$$\leftrightarrow 0.540229 \leq p \leq 0.575771$$

■ 故に、内閣支持率は、信頼度95%で54.0%~57.6%の間にある。

母数(母比率)の推定: 区間推定(まとめ)

■ 母比率の区間推定

□ Z推定

標準正規分布 $N(0,1)$ の性質を利用して母平均 μ の信頼区間を求める

$$P - Z_{\alpha/2} \sqrt{\frac{P(1-P)}{n}} \leq p \leq P + Z_{\alpha/2} \sqrt{\frac{P(1-P)}{n}}$$

[信頼率 $1-\alpha$]

式中の P は標本比率で, $P = X/n$ である

(X は二項分布 $B(n,p)$ に従うが, 中心極限定理から
 Z は正規分布 $N(0,1)$ に従う)

母数(母比率)の推定: 区間推定

■ 演習 (出展:「確率・統計の仕組みがわかる本」技評p.375)

□ ある薬を常用している女性は女の子を産む確率が高いらしい。該当者のうち200人を調査したところ、赤ちゃんの124人が女の子だった。この薬を常用している女性が女の子を産む比率はどの程度か?

(1) 信頼度90%で母比率 p の区間推定をせよ

(2) 信頼度95%で母比率 p の区間推定をせよ

(3) 信頼度99%で母比率 p の区間推定をせよ

参考: 母比率推定に必要な標本数

■ 適切な標本数

□ 母比率推定における信頼区間の幅と上限

$$2Z_{\alpha/2} \sqrt{\frac{P(1-P)}{n}} \leq \frac{Z_{\alpha/2}}{\sqrt{n}} \quad [\because P(1-P) = -(P - \frac{1}{2})^2 + \frac{1}{4}]$$

□ 信頼区間の幅を $\beta\%$ 以内にした場合の標本数

$$\frac{Z_{\alpha/2}}{\sqrt{n}} \leq \beta \Leftrightarrow n \geq \frac{Z_{\alpha/2}^2}{\beta^2}$$

■ 例題: 信頼度95%の信頼区間の幅を5%以内にした場合

$$n \geq \frac{Z_{\alpha/2}^2}{\beta^2} = \frac{1.96^2}{0.05^2} = 1536.64$$

より、標本数は1537あれば充分。

二つの正規母集団の推定

- **母平均の差**の区間推定
 - 母分散が等しいとき ($\sigma_1^2 = \sigma_2^2$)
 - 母分散が等しくないとき ($\sigma_1^2 \neq \sigma_2^2$)
- **母分散の比**の区間推定

$N(\mu_1, \sigma_1^2)$

↓ m 個 無作為抽出
 X_1, X_2, \dots, X_m

標本平均: $\bar{X} \sim N(\mu_1, \sigma_1^2/m)$

$N(\mu_2, \sigma_2^2)$

↓ n 個 無作為抽出
 Y_1, Y_2, \dots, Y_n

標本平均: $\bar{Y} \sim N(\mu_2, \sigma_2^2/n)$

二つの正規母集団の平均値の差の推定

- **母平均の差**の区間推定 ($\sigma_1^2 \neq \sigma_2^2$ のとき)
 - 母集団分布が $N(\mu_1, \sigma_1^2), N(\mu_2, \sigma_2^2)$ である2つの正規母集団から、個別に2つの標本 X_1, \dots, X_m と Y_1, \dots, Y_n を抽出したときの、母平均の差 $\theta = \mu_1 - \mu_2$ の信頼度 $100(1-\alpha)\%$ の信頼区間

$$\bar{X} - \bar{Y} - t_{\alpha/2}(v) \sqrt{\frac{S_X^2}{v_1} + \frac{S_Y^2}{v_2}} \leq \theta \leq \bar{X} - \bar{Y} + t_{\alpha/2}(v) \sqrt{\frac{S_X^2}{v_1} + \frac{S_Y^2}{v_2}}$$

↑
自由度 v の t 分布

(ただし、 v は $\left(\frac{S_X^2}{v_1} + \frac{S_Y^2}{v_2}\right)^2 / \left(\frac{S_X^4}{v_1^3} + \frac{S_Y^4}{v_2^3}\right)$ に一番近い整数であり、
 $v_1 = m-1, v_2 = n-1$)

二つの正規母集団の平均値の差の推定

- **母平均の差**の区間推定 ($\sigma_1^2 = \sigma_2^2$ のとき)
 - 母集団分布が $N(\mu_1, \sigma_1^2), N(\mu_2, \sigma_2^2)$ である2つの正規母集団から、個別に2つの標本 X_1, \dots, X_m と Y_1, \dots, Y_n を抽出したときの、母平均の差 $\theta = \mu_1 - \mu_2$ の信頼度 $100(1-\alpha)\%$ の信頼区間

$$\bar{X} - \bar{Y} - t_{\alpha/2}(m+n-2) \sqrt{\frac{mS_X^2 + nS_Y^2}{m+n-2} \left(\frac{1}{m} + \frac{1}{n}\right)} \leq \theta \leq \bar{X} - \bar{Y} + t_{\alpha/2}(m+n-2) \sqrt{\frac{mS_X^2 + nS_Y^2}{m+n-2} \left(\frac{1}{m} + \frac{1}{n}\right)}$$

↑
自由度 $m+n-2$ の t 分布

注: ただし、先に $\sigma_1^2 = \sigma_2^2$ の検定を行う必要がある。

二つの正規母集団の平均値の差の推定

- **例題** (出展:「統計学入門」東大出版会 p.231)
 - 20匹のラットを10匹ずつ2群に分け、一方は普通の食餌、他方は血中の赤血球数を減らすと考えられる薬を混入した食餌を与えた。その結果、各群のラットの血液1mm³中の赤血球数が下表のようになった。この薬の効果を測定したい。

投薬群 (100万個)	7.97	7.66	7.59	8.44	8.05	8.08	8.35	7.77	7.98	8.15
対照群 (100万個)	8.06	8.27	8.45	8.05	8.51	8.14	8.09	8.15	8.16	8.42

薬の効果(平均の差)を信頼度95%で区間推定をする。母分散は等しいと仮定。

$$\begin{cases} \bar{X} = 8.004, \bar{Y} = 0.230 \rightarrow \bar{X} - \bar{Y} = -0.226 \\ S_X^2 = 0.0685, S_Y^2 = 0.0264 \end{cases}$$

信頼度95% $\rightarrow \alpha=0.05 \rightarrow t_{0.025}(18)=2.101$

$$\bar{X} - \bar{Y} - t_{\alpha/2}(m+n-2) \sqrt{\frac{mS_X^2 + nS_Y^2}{m+n-2} \left(\frac{1}{m} + \frac{1}{n}\right)} \leq \mu_1 - \mu_2 \leq \bar{X} - \bar{Y} + t_{\alpha/2}(m+n-2) \sqrt{\frac{mS_X^2 + nS_Y^2}{m+n-2} \left(\frac{1}{m} + \frac{1}{n}\right)}$$

$$\rightarrow -0.226 \pm 2.101 \sqrt{\frac{10 \cdot 0.0685 + 10 \cdot 0.0264}{10+10-2} \left(\frac{1}{10} + \frac{1}{10}\right)}$$

$$\rightarrow -0.226 - 0.216 \leq \mu_1 - \mu_2 \leq -0.226 + 0.216$$

$$\leftrightarrow -0.0101 \leq \mu_1 - \mu_2 \leq -0.442$$

二つの正規母集団の平均値の差の推定

■ **例題** (参考:「統計学入門」東大出版会 p.228)

□ 京都は東京より暑いのか?

日付	8/1	8/2	8/3	8/4	8/5	8/6	8/7	8/8	8/9	8/10
東京(°C)	32	31	32	35	35	34	33	32	32	30
京都(°C)	35	35	35	36	36	33	35	36	35	35

(2005年8月1日~10日の東京と京都の最高気温:「Yahoo!天気情報」より)

各観測値が対として対応

対標本paired sample の場合は、2標本 t 統計量ではなく、差で1標本推定を行う。

東京-京都	-3	-4	-3	-1	-1	1	-2	-4	-3	-5
-------	----	----	----	----	----	---	----	----	----	----

t 推定

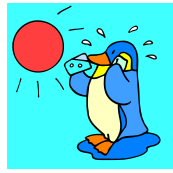
信頼度95%で母平均μの区間推定をすると...

信頼度95% → α=0.05 → t_{0.025}(9)=2.262

$$\rightarrow -2.5 - 2.262 \cdot \frac{1.688}{\sqrt{10-1}} \leq \mu \leq -2.5 + 2.262 \cdot \frac{1.688}{\sqrt{10-1}}$$

$$\leftrightarrow -3.77 \leq \mu \leq -1.23$$

京都の方が東京より、信頼度95%で夏の最高気温平均が1.2~3.8°Cの間にある。 [→ 平均値の差の検定]



二つの正規母集団の分散値の比の推定

■ **例題** (出展:「なるほど統計学」海鳴社 p.101)

□ 某町工場では、技能オリンピック出場者を決める所である。Alpha君、Bravoさんの2人のうち、どちらかを派遣したいので、最近の2人の仕事ぶりから技能を評価する。旋盤工員である彼らが行った30mmのパイプ加工の品質検査をした結果以下の通りであった。どちらが優れているのだろうか?

工員	標本数	平均値(mm)	標準偏差(mm)
Alpha	4	30	2
Bravo	10	30	3


注:腕のいい旋盤工は、実際にはこんなにずれないそうです。

信頼度90%で各々の標準偏差を区間推定すると...

$$\frac{nS^2}{\chi^2_{0.05}(3)} \leq \sigma_1^2 \leq \frac{nS^2}{\chi^2_{0.95}(3)} \rightarrow \frac{4 \cdot 4}{7.81473} \leq \sigma_1^2 \leq \frac{4 \cdot 4}{0.351846} \rightarrow (1.43)^2 \leq \sigma_1^2 \leq (6.74)^2$$

$$\frac{nS^2}{\chi^2_{0.05}(9)} \leq \sigma_2^2 \leq \frac{nS^2}{\chi^2_{0.95}(9)} \rightarrow \frac{10 \cdot 9}{16.919} \leq \sigma_2^2 \leq \frac{10 \cdot 9}{3.32511} \rightarrow (2.31)^2 \leq \sigma_2^2 \leq (5.20)^2$$

いっそのこと分散比を区間推定しよう! 結局どっちが優秀なの?



二つの正規母集団の分散値の比の推定

■ **母分散の比の区間推定**

□ 母集団分布が $N(\mu_1, \sigma_1^2), N(\mu_2, \sigma_2^2)$ である2つの正規母集団から、個別に2つの標本 X_1, \dots, X_m と Y_1, \dots, Y_n を抽出したときの、母分散の比 $\theta = \sigma_2^2 / \sigma_1^2$ の信頼度 $100(1-\alpha)\%$ の信頼区間

$$\frac{1}{F_{\alpha/2}(n-1, m-1)} \frac{\frac{n-1}{m} S_2^2}{\frac{m-1}{n} S_1^2} \leq \frac{\sigma_2^2}{\sigma_1^2} \leq F_{\alpha/2}(m-1, n-1) \frac{\frac{n-1}{m} S_2^2}{\frac{m-1}{n} S_1^2}$$

自由度 (n-1, m-1) の F 分布 自由度 (m-1, n-1) の F 分布

母分散の不偏推定値: $\hat{\sigma}^2 = \frac{n}{n-1} S^2$

$$F = \frac{\hat{\sigma}_1^2 / \sigma_1^2}{\hat{\sigma}_2^2 / \sigma_2^2} = \frac{\frac{n}{n-1} S_1^2 / \sigma_1^2}{\frac{m}{m-1} S_2^2 / \sigma_2^2} = \frac{\frac{n}{n-1} \frac{S_1^2}{\sigma_1^2}}{\frac{m}{m-1} \frac{S_2^2}{\sigma_2^2}} \sim F(m-1, n-1)$$

$$(\cdot) \chi^2 = \frac{nS^2}{\sigma^2}$$

$P(0 \leq F \leq \infty) = 1 - \alpha$
 $\Leftrightarrow F_{1-\alpha/2}(m-1, n-1) \leq F \leq F_{\alpha/2}(m-1, n-1)$
 $\Leftrightarrow F_{1-\alpha/2}(m-1, n-1) \leq \frac{\frac{n}{n-1} S_1^2 / \sigma_1^2}{\frac{m}{m-1} S_2^2 / \sigma_2^2} \leq F_{\alpha/2}(m-1, n-1)$
 $\Leftrightarrow F_{1-\alpha/2}(m-1, n-1) \frac{\frac{n-1}{m} S_2^2}{\frac{m-1}{n} S_1^2} \leq \frac{\sigma_2^2}{\sigma_1^2} \leq F_{\alpha/2}(m-1, n-1) \frac{\frac{n-1}{m} S_2^2}{\frac{m-1}{n} S_1^2}$

二つの正規母集団の分散値の比の推定

■ **例題** (出展:「なるほど統計学」海鳴社 p.101)

信頼度90%で分散比を区間推定すると...

$$\frac{1}{F_{\alpha/2}(n-1, m-1)} \frac{\frac{n}{m-1} S_2^2}{\frac{m}{n-1} S_1^2} \leq \frac{\sigma_2^2}{\sigma_1^2} \leq F_{\alpha/2}(m-1, n-1) \frac{\frac{n}{m-1} S_2^2}{\frac{m}{n-1} S_1^2}$$

$$\rightarrow \frac{1}{F_{0.05}(9,3)} \frac{10-1}{4} \frac{9}{4} \leq \frac{\sigma_2^2}{\sigma_1^2} \leq F_{0.05}(3,9) \frac{10-1}{4} \frac{9}{4}$$

$$\Leftrightarrow (0.46)^2 \leq \frac{\sigma_2^2}{\sigma_1^2} \leq (2.69)^2$$

結局このデータだけでは、どちらが優秀かはわからない。

優劣を判定するには、もう少しデータを集める必要があるよ。


参考文献

- 東大教養学部統計学教室編「統計学入門」東大出版会(1991)
- 東大教養学部統計学教室編「自然科学の統計学」東大出版会(1992)
- 鈴木達三・高橋宏一「標本抽出の計画と方法」放送大学(1991)
- 永田靖「サンプルサイズの決め方」朝倉書店(2003)
- 永田靖「統計的方法のしくみ」日科技連(1996)
- 村上雅人「なるほど統計学」海鳴社(2002)
- 久保応助・藤沢偉作「全問精解 確率・統計演習」聖文社(1983)
- 丹慶勝市「図解雑学 統計解析」ナツメ社(2003)
- 高橋信[著]・トレンドプロ[マンガ]「マンガでわかる統計学」オーム社(2004)

母数の推定：区間推定 interval estimation

■ パーセント点 percentage point

- 例：自由度10の t 分布の
- 例：自由度5の χ^2 分布の



母数の推定：区間推定 interval estimation

■ パーセント点 percentage point

- 分布の $100\alpha\%$ 点

- 上側 $100\alpha\%$ 点
- 下側 $100\alpha\%$ 点
- 両側 $100\alpha\%$ 点

- 例：標準正規分布の
両側 $100\alpha\%$ 点

例：信頼率0.95(95%)なら、 $\alpha=0.05$
信頼率0.90(90%)なら、 $\alpha=0.10$

例：正規分布の両側5%点(上側2.5%,下側2.5%)
約1.96, 約-1.96

