

母集団・標本抽出・推定

樋口さぶろお

龍谷大学理工学部数理情報学科

確率統計☆演習 I L10(2015-12-04 Fri)

最終更新: Time-stamp: "2015-12-04 Fri 09:40 JST hig"

今日の目標

- 母集団, 標本, 推定の意味を説明できる
- 標本から母平均値を点推定できる
- 標本から母分散を点推定できる
- 標本から母比率を点推定できる



<http://hig3.net>

L09-Q1

Quiz 解答:多次元の確率変数の期待値

$$\textcircled{1} \quad E[X + 2Y] = 0 \cdot (1 + 2 \cdot 0) + \frac{2}{12}(2 + 2 \cdot 0) + \frac{1}{12}(3 + 2 \cdot 0) + \frac{4}{12}(1 + 2 \cdot 2) + 0(2 + 2 \cdot 2) + \frac{5}{12}(3 + 2 \cdot 2) = \frac{62}{12}.$$

$$\textcircled{2} \quad E[\mathbf{1}_{[Y \geq 1]}(X, Y)] = 0 \cdot 0 + \frac{2}{12} \cdot 0 + \frac{1}{12} \cdot 0 + \frac{4}{12} \cdot 1 + 0 \cdot 1 + \frac{5}{12} \cdot 1 = \frac{9}{12}.$$

③

$$f_x^X = \begin{cases} 4/12 & (x = 1) \\ 2/12 & (x = 2) \\ 6/12 & (x = 3) \\ 0 & (\text{他}) \end{cases} \quad f_y^Y = \begin{cases} 3/12 & (y = 0) \\ 9/12 & (y = 2) \\ 0 & (\text{他}) \end{cases}$$

L09-Q2

Quiz 解答:離散型確率変数の独立性

$$\textcircled{1} \quad f_2^X = f_4^X = f_2^Y = f_4^Y = \frac{1}{2} \text{ であり, } f_x^X \cdot f_y^Y \neq f_{xy}^{XY} \text{ であり独立でない.}$$

- ② $E[X] = \frac{1}{2} \cdot 2 + \frac{1}{2} \cdot 4 = 3, E[Y] = \frac{1}{2} \cdot 2 + \frac{1}{2} \cdot 4 = 3, E[XY] = \frac{1}{2} \cdot 4 + 0 \cdot 8 + 0 \cdot 8 + 16 \cdot \frac{1}{2} = 10, E[X+Y] = 3+3 = 6, C_{XY} = 10 - 3 \times 3 = 1.$
 $C_{XY} \neq 0$ からも独立でないことがわかる.

L09-Q3

Quiz 解答: 中心極限定理 T は母平均値が 10, 分散が $\frac{10}{3}$ の正規分布 $N(10, \frac{10}{3})$ に従う.
 U は母平均値が 1, 分散が $\frac{1}{30}$ の正規分布 $N(1, \frac{1}{30})$ に従う.

ここまで来たよ

3 同時分布・確率変数の独立性・中心極限定理

4 母集団・標本抽出・推定

- 母集団と標本
- 母平均値・母分散の(点)推定
- 母比率
- 母比率の(点)推定

母集団と標本 (1) 有限母集団

AKB48 の身長ふたたび

- AKB48 メンバー全員 (→ **有限母集団**) の身長 x_i の平均値

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \text{ を求めたい!}$$

- ▶ メンバー 1 名を等確率で選んでくる, という試行を考えると, 確率変数 X の**母平均値** $E[X]$.
- メンバー全員分のデータがあれば定義の式使うだけ
- 握手会でメンバー 1 人ずつに質問しなければいけないとしたら?
- 握手会参加券 74 枚集めないで何とかすませたい.

⇨ 質問できたメンバー 5 人の身長 (= **標本**) から **推定** したい.

5 人を '無作為に' 選ぶ (= **標本抽出** する)

母集団サイズ = , 標本サイズ = , 標本の個数 = .

母集団と標本 (2) 離散 or 連続型確率変数

賞金額, 個数が謎のスピードくじ (引いて賞金額を見た後で箱に戻す).
賞金額 X は離散型確率変数 → 無限母集団 (何回でもひけるから).

- 賞金の母平均値 $E[X] = \sum_x f(x) \times x$ を求めたい.
- くじの中を見れば ($f(x)$ の式を知れば定義の式使うだけ)
- しかし, 中を見ることはできない.
- $+\infty$ 回くじを買わず, 何とかすませたい.

⇒ 引いた 5 枚のくじの賞金額 (=標本) から推定したい.

5 枚を '無作為に' 選ぶ (=標本抽出する).

母集団サイズ = , 標本サイズ = , 標本の個数 = .

母集団・標本抽出・推定

- **母集団** population = 考えたい集団. どんな分布, 母平均値, 母分散, などわかっていないことがあるが, 全体を調べるわけにはいかない集団.
- **標本** sample (名詞) = 母集団から '無作為に' とってきた一部分
- **標本抽出** する sample(動詞) = 母集団から '無作為に' とってくる ~ sampling (動名詞)
- **推定** する estimate(動詞) = 標本を調べて母集団について正しそうな事実を見つける ~ estimation (名詞)

推定には**誤差**あるかも. 標本の選び方ごとに答は違うし.

ここまで来たよ

3 同時分布・確率変数の独立性・中心極限定理

4 母集団・標本抽出・推定

- 母集団と標本
- 母平均値・母分散の(点)推定
- 母比率
- 母比率の(点)推定

母平均値の(点)推定

X_1, X_2, \dots, X_n はサイズ n の標本.

各 X_i ($i = 1, \dots, n$) は母平均値 $\mu = E[X_i]$, 母分散 $\sigma^2 = V[X_i]$ の独立同分布にしたがう確率変数.

μ, σ^2 は母集団のパラメタ.

標本平均値

$$\text{標本平均値 } \bar{X}_{(n)} = \frac{1}{n}(X_1 + \dots + X_n) = \text{先週の } U_n$$

が, 母平均値 μ の 'よい' 推定値になっている.

母平均値は μ はひとつに定まっているが, 標本平均値 \bar{X} は確率変数であり, 試行=標本抽出のたびにかわる (\bar{X} は確率分布をもつ)

L10-Q1

Quiz(母平均値, 母分散の点推定)

フライドチキン屋さんのフライドチキンの在庫(=母集団)から, 無作為に6本のチキンを取り出したところ, 重さは次のようだった.

117g, 109g, 109g, 119g, 100g, 112g.

- ① 重さの母平均値を点推定しよう.
- ② 重さの母分散を点推定しよう.

よい推定値って?

標本平均値 $\bar{X}_{(n)}$ は不偏性を持つ

「標本平均値 $\bar{X}_{(n)}$ 」の母平均値 = X_i の母平均値

先週の $E[U_n] = \mu$


$$\forall n \quad E[\bar{X}_{(n)}] = \mu$$

標本平均値 $\bar{X}_{(n)}$ は一貫性を持つ

標本サイズ n が大きくなると、 $\bar{X}_{(n)}$ と母平均値 μ が離れている確率は0に近づく。

大数の(弱)法則

$$\forall \epsilon > 0 \quad \lim_{n \rightarrow +\infty} P(|\bar{X}_{(n)} - \mu| > \epsilon) \rightarrow 0$$



母分散の(点)推定

(不偏)標本分散

$$\begin{aligned}
 \text{(不偏)標本分散 } S^2 &= \frac{1}{n-1} [(X_1 - \bar{X})^2 + \cdots + (X_n - \bar{X}_{(n)})^2] \\
 &= \frac{n}{n-1} \left[\frac{1}{n} \sum_i X_i^2 - (\bar{X}_{(n)})^2 \right]
 \end{aligned}$$

が、母分散の‘よい’推定値になっている。

ここで、 \bar{X} は母平均値でなく、上のように計算した標本平均値。

$n-1$ の理由 こうするとちょうど**不偏**: $E[S^2] = \sigma^2$.

直観的理由 \bar{X} は X_i の重心だから、 $(X_i - \bar{X})^2$ は $(X_i - \mu)^2$ より小さくなりがち ($\frac{n-1}{n}$ 倍) なので修正。

おぼえ方 (不偏)標本分散は $n=1$ のとき、

$E[S^2] = \sigma^2$ を $n = 2$ のときに確認

$$\begin{aligned} \text{左辺} &= \frac{1}{2-1} E[(X_1 - \bar{X})^2 + (X_2 - \bar{X})^2] \\ &= E[X_1^2 + X_2^2 - 2(X_1 + X_2)\bar{X} + 2\bar{X}^2] \\ &= E[X_1^2 + X_2^2 - 2\bar{X}^2] \\ &= E[X_1^2] + E[X_2^2] - 2E[\bar{X}^2] \end{aligned}$$

ここで,

$$\begin{aligned} \sigma^2 &= V[X_1] = E[X_1^2] - (E[X_1])^2 = E[X_1^2] - \mu^2, \\ \frac{\sigma^2}{n} &= V[\bar{X}] = E[\bar{X}^2] - (E[\bar{X}])^2 = E[\bar{X}^2] - \mu^2, \text{ より,} \end{aligned}$$

$$\begin{aligned} \text{左辺} &= (\mu^2 + \sigma^2) + (\mu^2 + \sigma^2) - 2(\mu^2 + \frac{\sigma^2}{2}) \\ &= \sigma^2 \\ &= \text{右辺} \end{aligned}$$

L10-Q2

Quiz(推定)

ある確率分布に従うスピードくじを10回ひいたところ、賞金は、0円, 0円, 0円, 0円, 0円, 0円, 10円, 10円, 30円, 100円だった。確率分布の母平均値と母分散と母標準偏差を推定しよう。

母標準偏差の(点)推定

$$\text{母標準偏差の(点)推定値} = \sqrt{\text{母分散の(点)推定値 } S^2}$$

L10-Q3

Quiz(標本抽出と推定)

標本抽出と推定について、正しい文の番号をすべて答えよう。

- ① 母平均値は、標本平均値の推定値である。
- ② 標本平均値は、一般に、標本抽出のたびに変化する
- ③ 不偏標本分散は、母分散の推定値であり、両者は必ずしも等しいわけではない
- ④ 標本平均値は、一般に、母平均値に等しい
- ⑤ 母分布(母集団)が与えられたとき、一般に、標本のサイズは定まっている

ここまで来たよ

3 同時分布・確率変数の独立性・中心極限定理

4 母集団・標本抽出・推定

- 母集団と標本
- 母平均値・母分散の(点)推定
- 母比率
- 母比率の(点)推定

比率=ratio

データが「A型である」「A型でない」のような値を持つとき、

母比率

$$\text{「...」の母比率 } p = \frac{\text{「...」であるデータの個数}}{\text{母集団サイズ}} = E[Y]$$

例 { 身長 165cm 未満, 身長 165cm 以上 }.

$$\text{母比率 } p = \frac{\text{身長 165cm 未満の人の数}}{\text{母集団サイズ}}.$$

例 Y { サイコロの目が 1, サイコロの目が 1 以上 }.

母比率 p = サイコロの目の 1 がでる確率

確率と言いたいそうになるけど、この文脈では比率という

ダミー変数と言われる確率変数 Y

A 型	Y	確率
「である」	1	p
「でない」	0	$1 - p$

やりたいこと:母比率の推定

- クラスの中で、血液型 A 型の人々の比率は? n 人に質問しただけで推定したい.
- 候補者 A の得票率は何%? n 人に質問しただけで推定したい.
- 工場から出荷する製品のうち、何% が不良品? n 個だけ抜き出して調査したい.
- このコインの表が出る確率は? n 回投げるだけで推定したい.

ここまで来たよ

3 同時分布・確率変数の独立性・中心極限定理

4 母集団・標本抽出・推定

- 母集団と標本
- 母平均値・母分散の(点)推定
- 母比率
- 母比率の(点)推定

母比率の (点) 推定

標本比率

サンプルのデータ n 個中 k 個が「…」であるとき,

$$\text{標本比率 } \hat{p} = \frac{k}{n}$$

が「…」の母比率 p のよい推定値になっている。

Y の母平均値 $E[Y] = 1 \times p + 0 \times (1 - p) = p$.

Y の母分散 $V[Y] = (1 - p)^2 \times p + (0 - p)^2 \times (1 - p) = p(1 - p)$.

2 値 (ベルヌーイ試行) のときの特殊事情 母分散が母平均値 p の関数.

母比率 p を推定したい = 母平均値 $E[Y]$ を推定したい

母平均値の推定

サイズ n の標本中 k 個が「…である」とき,

$$\begin{aligned} \text{母平均値 } E[Y] \text{ の推定値} &= \text{標本平均値 } \bar{Y} \\ &= \frac{1}{n} \left[\underbrace{1 + \cdots + 1}_k + \underbrace{0 + \cdots + 0}_{n-k} \right] \\ &= \frac{k}{n} = \hat{p}. \end{aligned}$$

L10-Q4

Quiz(母比率の点推定)

確率変数 Y の確率分布が次のように与えられる.

$$f_y = \begin{cases} p & (y = 1) \\ 1 - p & (y = 0) \\ 0 & (\text{他}) \end{cases}$$

ここで, p は未知のパラメタ.

Y のサイズ 20 の標本を得たところ, $y = 1$ が 12 個, $y = 0$ が 8 個だった.

- ① $p = E[Y]$ を推定しよう.
- ② $V[Y]$ を推定しよう.

L10-Q5

Quiz(母比率の点推定)

ある学部 of 学生 1200 人から, 20 人を無作為に選び出し, A 型であるかどうか質問したところ, 12 人が A 型であると答え, 残りが A 型でないと答えた.

学部の, 血液型 A である学生の母比率 p を (点) 推定しよう

連絡

- 配布資料は 1-503 向かいの引出, <http://hig3.net> で再配布.
- Quiz の略解は授業終了後に <http://hig3.net> で配布.
- 週のタイムラインで見たように, 非参照 Quiz 予習問題を RaMMoodle に金 17:00 ごろまでに公開. これで来週の Quiz に備えてね.
- Math ラウンジの配布資料訂正. 正しくは, 2015-12-23 水:授業なし, 2015-12-24 木:土曜授業.
- オフィスアワー月 4 木 6(1-502)



manaba / 出席カード
<https://manaba.ryukoku.ac.jp/s>