

大数の法則/母集団・標本抽出・推定

樋口さぶろお <https://hig3.net>

龍谷大学工学部数理情報学科

確率統計☆演習 I L10(2019-12-09 Mon)

最終更新: Time-stamp: "2019-12-15 Sun 10:37 JST hig"

今日の目標

- 大数の法則の内容を説明できる 岩薩林 確率・統計 §4.4
- 母集団, 標本, 標本抽出, 推定の考えが説明できる 岩薩林 確率・統計 §5.1,5.2
- 母平均値, 母期待値, 母分散, 母比率を点推定でき



L08-Q4

Quiz 解答:正規分布の確率

標準正規分布 $N(0, 1^2)$ にしたがう.

$Z = \frac{X-3}{2}$ とすると, Z は

- ① $E[X^2] = V[X] + E[X]^2 = 2^2 + 3^2.$
- ② $P(X \geq 5) = P(\frac{5-3}{2} \leq Z < +\infty) = \int_1^{\infty} f(z) dz = I(+\infty) - I(1) = \frac{1}{2} - I(1) = 0.1587.$
- ③ $P(1 \leq X \leq 7) = P(-1 \leq Z \leq 2) = \int_{-1}^2 f(z) dz = I(2) - I(-1) = I(2) + I(1) = 0.8186.$

L09-Q1

Quiz 解答:二項分布

- ① 二項分布 $B(100, \frac{2}{3})$ に従う確率変数を X とする. $P(X = 40)$ を求めればよいから, ${}_{100}C_{40} p^{40} (1-p)^{100-40} = \frac{100!}{40!60!} (\frac{2}{3})^{40} (1 - \frac{2}{3})^{60}.$
- ② $E[X] = n \times p = \frac{200}{3}.$ $V[X] = n \times p(1-p) = \frac{200}{9}.$

L09-Q2

Quiz 解答:独立同分布の母期待値母分散

- ① 3μ .
- ② 3σ .
- ③ 3μ
- ④ $9\sigma^2$.
- ⑤ $3\sigma^2$.
- ⑥ $5\sigma^2$.
- ⑦ $3(\sigma^2 + \mu^2) + 3 \times 2 \times \mu^2$.

L10-Q3

Quiz 解答:独立同分布にしたがう変数の和

- ① A は母平均値が μ , 母分散が $\frac{\sigma}{n}$.
- ② B は母平均値が 0 , 母分散が σ^2 .
- ③ C は母平均値が 0 , 母分散が 1 .

二項分布の母平均値, 母分散の式の証明

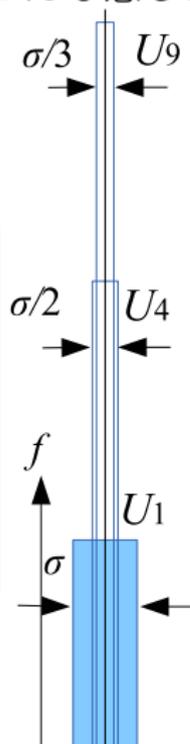
岩薩林 確率・統計例題 4.6

i.i.d にしたがう確率変数の和の $1/n$ 新しい確率変数: $U_n = \frac{1}{n}T_n = \frac{1}{n}(X_1 + \dots + X_n)$

$$E[U_n] = E\left[\frac{1}{n}T_n\right] = \frac{1}{n} \times n \times \mu.$$

$$V[U_n] = V\left[\frac{1}{n}T_n\right] = \left(\frac{1}{n}\right)^2 \times n \times \sigma^2.$$

U_n の確率関数は
こんな感じ?



ここまで来たよ

- 9 二項分布, 独立同分布の和
 - チェビシェフの不等式と大数の法則

- 10 大数の法則/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
 - 母比率とその(点)推定

チェビシェフの不等式

チェビシェフの不等式 Chebyshev's inequality

岩薩林 確率・統計 §4.3(4.15)

X を離散型または連続型確率変数とする. $\mu = E[X]$: 母平均値,
 $\sigma^2 = V[X]$: 母分散

$a > 0$: 任意の正の実数.

このとき次が成立する.

$$P(|X - \mu| \geq a\sigma) \leq \frac{1}{a^2}$$

証明 岩薩林 確率・統計 §4.3

どんな X にも使えて便利な不等式. 意味は…

大数の(弱)法則アバウト版

岩薩林 確率・統計 §4.4

X_1, \dots, X_n が独立同分布にしたがい, $E[X_i] = \mu$, $V[X_i] = \sigma^2$,
 $U_n = \frac{1}{n} \sum_{i=1}^n X_i$ のとき, n が十分大きいとき U_n は 'ほぼ μ に等しい'
(U_n が μ から外れる確率はゼロに近づく)

大数の (弱) 法則

岩薙林 確率・統計 §4.4

X_1, \dots, X_n が独立同分布にしたがい, $E[X_i] = \mu$, $V[X_i] = \sigma^2$, $U_n = \frac{1}{n} \sum_{i=1}^n X_i$ のとき,

$$\forall \epsilon > 0 \quad \lim_{n \rightarrow +\infty} P(|U_n - \mu| \geq \epsilon) = 0.$$

つまり n 大で U_n は $E[U_n] = \mu$ に「必ず近い」(確率収束).

証明 $E[U_n] = \mu$, $V[U_n] = \sigma^2/n$ に注意して, U_n に対するチェビシェフの不等式を書くと,

$$P(|U_n - \mu| \geq a \times \frac{\sigma}{\sqrt{n}}) \leq \frac{1}{a^2}$$

$a = \frac{\epsilon}{\frac{\sigma}{\sqrt{n}}}$ とすると, $n \rightarrow +\infty$ で

$$P(|U_n - \mu| \geq \epsilon) \leq \frac{\sigma^2}{\epsilon^2 n} \rightarrow 0$$

これが母平均値・母期待値の直観的意味. 要するに,



ここまで来たよ

- 9 二項分布, 独立同分布の和
 - チェビシェフの不等式と大数の法則

- 10 大数の法則/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
 - 母比率とその(点)推定

母集団と標本 (1) 有限母集団

岩薩林 確率・統計 §§5.1.5.2

某アイドルグループの身長ふたたび

- 某アイドルグループ全員 (→ **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** $\mu = E[X]$.
- 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 40 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**) (独立同分布にしたがう確率変数 X_1, X_2, \dots, X_5) 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

岩薩林 確率・統計 §5.1,5.2

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 \rightarrow 無限母集団 (何回でもひけるから).

- 賞金の母平均値 $\mu = E[X] = \sum_x x \cdot p(x)$ を求めたい.
- くじの中を見れば ($p(x)$ 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.

\rightsquigarrow 引いた 5 枚のくじの賞金額=標本)(独立同分布にしたがう確率変数 X_1, X_2, \dots, X_5) 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

岩薩林 確率・統計例 11(p.115)

- **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)
- **確率変数** X , \bar{X} 分布をもつ変数
- **実現値, 観測値** x , \bar{x} 標本を1つとって確定した値

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

- 9 二項分布, 独立同分布の和
 - チェビシエフの不等式と大数の法則

- 10 大数の法則/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
 - 母比率とその(点)推定

母平均値の(点)推定 高校 数学 B 岩薩林 確率・統計 (5.4)p.114

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.

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 $E[X]$ 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 $\bar{X}_{(n)}$ は確率変数であり, 試行=標本抽出のたびにかわる ($\bar{X}_{(n)}$ は確率分布をもつ)

標本期待値

$$g(X) \text{ の標本期待値 } \overline{g(X)}_{(n)} = \frac{1}{n}(g(X_1) + \dots + g(X_n))$$

が, $E[g(X)]$ の‘よい’推定値になっている.

L10-Q1

Quiz(母平均値, 母分散, 母比率の点推定)

フライドチキン屋さんのフライドチキンの大量の在庫 (=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 重さの二乗の母期待値を点推定しよう.
- ③ 重さの母分散を点推定しよう.
- ④ 110g 以上のものの母比率を点推定しよう.

よい推定量がもつ性質

- 不偏性 (unbiased ナントカ)
推定量の母平均値は, 推定したい母ナントカに等しい 岩薩林 確率・統計 p.141
- 一貫性 (consistency)
推定量と母ナントカに一定の差がある確率は, 標本サイズを大きくすると zero になる 岩薩林 確率・統計 p.143
- 最尤性 (maximum likelihood)

確率統計 II

母平均値の推定量 $\bar{X}_{(n)}$ は不偏性を持つ

岩薩林 確率・統計 p.113

「標本平均値 $\bar{X}_{(n)}$ 」の不偏性

母ナントカの推定量の母平均値 = 母ナントカ

$$E[\bar{X}_{(n)}] = \frac{1}{n}(E[X_1] + \cdots + E[X_n]) = \mu$$

一貫性も持つ大数の法則から

岩薩林 確率・統計 p.143

母分散の(点)推定 高校 数学 B 岩薩林 確率・統計 (5.11) の V(p.122)

不偏標本分散

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

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、上の標本平均値 ($\bar{X}_{(n)}$) の略記。

$n-1$ 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(証明). $\bar{X} = \frac{1}{2}(X_1 + X_2)$.

$$\begin{aligned} E[S^2] &= E\left[\frac{1}{2-1}((X_1 - \bar{X})^2 + (X_2 - \bar{X})^2)\right] \\ &= E\left[(X_1 - \frac{1}{2}(X_1 + X_2))^2 + (X_2 - \frac{1}{2}(X_1 + X_2))^2\right] \\ &= 2 \cdot \frac{1}{4} E[(X_1 - X_2)^2] \\ &= 2 \cdot \frac{1}{4} E[X_1^2 - 2X_1X_2 + X_2^2] \\ &= 2 \cdot \frac{1}{4} ((\sigma^2 + \mu^2) - 2\mu\mu + (\sigma^2 + \mu^2)) \\ &= 2 \cdot \frac{1}{4} (2\sigma^2) = \sigma^2. \end{aligned}$$

ここまで来たよ

- 9 二項分布, 独立同分布の和
 - チェビシェフの不等式と大数の法則

- 10 大数の法則/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
 - 母比率とその(点)推定

比率=ratio

岩薩林 確率・統計 p.107

確率変数 $Y \sim B(1, p)$ ベルヌーイ分布, を考える.

こういう Y は, いろんな母集団を, 条件 $f(X) = 「X は…である」$ の成立不成立で2つに類別して作れる. **カテゴリ変数**

- $X \sim$ ある分布, $Y = \mathbf{1}_{[…である]}(X)$, たとえば $X > 10$ なら $Y = 1$ とか.
- 母集団=日本国民, 国民 x の血液型が A である $Y = 1$.

母比率

岩薩林 確率・統計 p.107

$B(1, p)$ の p . または母集団で条件 $f(x)$ から $B(1, p)$ を作ったとき, ‘母集団の「…である」ものの母比率’, ともいう.

有限母集団なら,

$$\text{母集団の「…である」母比率 } p = \frac{\text{「…である」データ } x \text{ の個数}}{\text{母集団サイズ}} = E[Y]$$

やりたいこと:母比率の推定

ベルヌーイ分布の p (母比率) を標本から推定したい!

- 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.

母比率の(点)推定 岩薩林 確率・統計 p.115

標本比率 岩薩林 確率・統計 p.115

標本のデータ 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。

母比率 p の推定=母平均値 $E[Y]$ の推定

サイズ n の標本中 k 個が「…である」とき、

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

連絡

- 2020-01-20 月 1 テスト B1 実施. 45 分, PC 受験の予定. 教科書の p.xii-xv のコピーを配布. 他の持込不可.
- 2020-01-27 月 1(定期試験期間) テスト A2,B2 実施. A1,B1 と同等の評価内容.
- 2020-02-15 土 学力認定試験 2 年生も受験可能 <https://wiki.math.ryukoku.ac.jp> (全学認証)
- 成績の 70 ピーナッツ分= $\min(\max(A1, A2), \max(B1, B2))$.
- 予習復習問題を, 期限後も(再/初)受験できるようにしています. ピーナッツにはカウントしないけど, テスト準備に活用してね.
- 2019-12-16 は区間推定. §§6.1,7.1,7.3 読んできてね.
- 2019-12-16 の Trial 予告
- 2019-12-16 までの(短い作文の)レポート課題 <https://manaba.ryukoku.ac.jp>
- オフィスアワー木 6(1-539) 金昼 (1-542), Math ラウンジ (1-536/538)

龍大 manaba course



学籍番号での LINE 公式アカウント登録