

# 条件付き分布，ベイズ推定

樋口さぶろお <https://hig3.net>

龍谷大学 先端理工学部 数理・情報科学課程

確率統計 I L15(2025-07-28 Mon)

最終更新: Time-stamp: "2025-07-28 Mon 07:51 JST hig"

## 今日の目標

- 第1種, 第2種の過誤, 有意水準と検出力を説明できる

久保川 統計学入門 §9.3

- 適合度のカイ二乗検定ができる

久保川 統計学入門 §11.1

- ベイズ推定できる

久保川 統計学入門 §3.4



## L14-Q1(上側片側)

解答は 確率統計 I(2025)L14 に掲載

## L14-Q2 (下側片側)

## Quiz 解答: 母比率の片側検定

- ① 有意水準  $\alpha = 0.01$  で正規近似による母比率の片側 (二項) 検定を行う。
- ② 帰無仮説を母比率  $r = \frac{1}{10}$ , 対立仮説を母比率  $r < \frac{1}{10}$  とする。
- ③ 帰無仮説のもとで, 100 本中のあたりの回数  $T \sim B(\frac{1}{10}, 100)$ . あたりの標本比率を  $\hat{r}$  とすると,  $Z = \frac{\hat{r} - \frac{1}{10}}{\sqrt{\frac{1}{100} \cdot \frac{1}{10} (1 - \frac{1}{10})}}$  は近似的に標準正規分布  $N(0, 1^2)$  にしたがう。
- ④ この標本に対して  $\hat{r} = \frac{5}{100}$  なので, 検定統計量の実現値は  $z = -\frac{5}{3} = -1.667$ .

- 5. 棄却限界は  $-z_{0.01} = \Phi^{-1}(0.01) = \text{scipy.stats.norm}(loc=0, scale=1).ppf(0.01) = -2.326$ . 棄却域は  $z < -z_{0.01}$ .
- 6. 検定統計量の実現値  $z$  は棄却域に含まれない. 帰無仮説を受容する. 母比率  $r < \frac{1}{10}$  と結論できない.

### p 値による場合

- 5. p 値は  $p = P(Z < -\frac{5}{3}) = \Phi(-\frac{5}{3}) - \Phi(-\infty) = \text{scipy.stats.norm}(loc=0, scale=1).cdf(-\frac{5}{3}) = 0.0475$ .
- 6.  $0.0475 = p > \alpha = 0.01$  なので帰無仮説を受容する. よって母比率  $r < \frac{1}{10}$  と結論できない.

棄却域に含まれる場合. p 値が  $\alpha$  より小さい場合.

- 6. 帰無仮説を棄却する. 母比率  $r < \frac{1}{10}$  と結論する.

## ここまで来たよ

### 14 片側検定

### 15 条件付き分布, ベイズ推定

- 検定の第 1 種・第 2 種の過誤・適合度のカイ二乗検定
- 条件付き確率

## 母平均値・母分散・母比率・適合度・独立性の検定

	両側	片側
母平均値	<b>両側 t 検定</b> 久保川 統計学入門 公式 9.4	<b>片側 t 検定</b> 久保川 統計学入門 公式 9.4
母分散	<b>両側カイ二乗検定</b> 久保川 統計学入門 公式 9.7	<b>片側カイ二乗検定</b> 久保川 統計学入門 公式 9.7
母比率	<b>両側二項検定</b> 久保川 統計学入門 (9.7)	<b>片側二項検定</b> 久保川 統計学入門 例題 9.10
適合度	NA	<b>片側カイ二乗検定</b> 久保川 統計学入門 公式 11.2
独立性	NA	<b>片側カイ二乗検定</b> 久保川 統計学入門 公式 11.4
母平均値の差	<b>両側 t 検定</b> 対応なし (等分散, Welch) 久保川 統計学入門 公式 10.7, あり 久保川 統計学入門 公式 10.5	<b>片側 t 検定</b> 対応なし (等分散, Welch), あり
母分散の比	<b>両側 F 検定</b> 久保川 統計学入門 公式 10.3	<b>片側 F 検定</b>

## 仮説検定での第 1 種・第 2 種の過誤と混同行列

久保川 統計学入門 §9.3

	帰無仮説を棄却, 有意である	帰無仮説を受容, 有意でない
対立仮説が成立 $\mu \neq \mu_0$	確率 $1 - \beta$	第 2 種の過誤 確率 $\beta$
帰無仮説が成立 $\mu = \mu_0$	第 1 種の過誤 確率 $\alpha$	確率 $1 - \alpha$

$\alpha, \beta$  はどちらも小さくしたいが, 両立しない。

$\alpha$  はほぼゼロ ( $\alpha = 0.01$  or  $0.05$ ) に固定して, その上で  $\beta$  をなるべく小さくするように試みる習慣。

検定とは, 発色 (検出) したら (まれな誤検出を除いて) ほぼ確かなんだけど, 見逃すことはある異常検査薬のようなもの。

$\alpha$  誤検出率, 有意水準, 危険率

$\beta$ : 見逃し率 (検出力:  $1 - \beta$ )

類似: 混同行列

## カテゴリ変数 久保川 統計学入門 §1.5

量的変数の確率変数 ... 平均や分散に意味がある

- 離散型 確率関数=表 二項分布, ポアソン分布,  $\dots$ ,  $x$  は整数
- 連続型 確率密度関数 正規分布, カイ二乗分布, 指数分布, 一様分布,  $\dots$ ,  $x$  は実数

質的変数の確率変数 ... 平均や分散が考えられない

その中でも, 名義変数=カテゴリ (カル) 変数

順序や距離がなくぜんぶが対等. 例: 血液型, 性別, 携帯電話番号, チーム A 型, B 型などがカテゴリ

2 カテゴリなら, 0,1 のように番号を振って離散型と思える

3 カテゴリ以上なら, 順序や間隔によるので離散型には帰着できない.

あえてやるなら one-hot vector.

# カテゴリ分布と多項分布 (multinomial distribution) 久保川 統計学入門 §14.1.3

定義 ( $k$  カテゴリのカテゴリ分布  $C(p_1, \dots, p_k)$ )

カテゴリ番号  $i = 1, \dots, k$  と, パラメタ  $p_1 + \dots + p_k = 1$ . 略記  $= (p_1, \dots, p_k)$  に対して,

$$\text{確率関数 } p(i) = P(X = i) = p_i = \begin{cases} p_1 & (i = 1) \\ p_2 & (i = 2) \\ \vdots & \\ p_k & (i = k) \end{cases}$$

ベルヌイ分布  $Ber(p_1)$  は  $k = 2$  の  $C(1 - p, p)$ .

定義 ( $k$  カテゴリの多項分布  $Mult_k(n, p_1, \dots, p_k)$ )

確率変数は整数値ベクトル  $(X_1, \dots, X_k)$ . パラメタ  $p_1, \dots, p_k, n$ .

$$\text{確率関数 } P(X_1 = x_1, \dots, X_k = x_k) = f(x_1, \dots, x_k) = \begin{cases} \frac{n!}{x_1! \dots x_k!} p_1^{x_1} \dots p_k^{x_k} & (x_i \geq 0, x_1 + \dots + x_k = n) \\ 0 & (\text{他}) \end{cases}$$

カテゴリ分布にしたがう確率変数の  $n$  個の実現値を得て, カテゴリ  $1, \dots, k$  をそれぞれ  $x_1, \dots, x_k$  回ずつ得る確率.

	$n = 1$	$n$	ベイズ共役分布	
$k = 1$	ベルヌイ分布 $Ber(p)$	二項分布 $Bin(n, p)$	二項検定	ベータ分布
$k$	カテゴリ分布 $C(p_1, \dots, p_k)$	多項分布 $Mult_k(1, p_1, \dots, p_k)$	適合度の検定	ディリクレ分布

## 適合度基準 久保川 統計学入門 §11.1

カテゴリの個数  $k = 4$  の例

カテゴリ	O 型	A 型	AB 型	B 型	$\sum_{i=1}^k p_i = 1.$
確率 $p_i$	$p_1 = 0.12$	$p_2 = 0.51$	$p_3 = 0.17$	$p_4 = 0.20$	

カテゴリ分布のサイズ  $n = 12$  の標本

番号	血液型
1	B 型
2	O 型
⋮	⋮
12	A 型

度数分布表は多項分布  $M(, 12)$  の実現値のはず

カテゴリ	O 型	A 型	AB 型	B 型
度数 $x_i$	$x_1 = 2$	$x_2 = 3$	$x_3 = 6$	$x_4 = 1$

$$\rightarrow \sum_{i=1}^k x_i = n = 12.$$

## 適合度を表す量

カテゴリ  $i$  の期待度数 = 標本サイズ  $\times$  母分布の確率  $= np_i$

命題 (ピアソンの適合度基準  $Q$  久保川 統計学入門 §11.1)

カテゴリ  $k$  個, カテゴリ分布の確率  $p_i (i = 1, \dots, k)$

サイズ  $n$  の標本の度数  $x_i (i = 1, \dots, k)$

サイズ  $n$  の標本の, 母分布から考えた期待度数  $np_i (i = 1, \dots, k)$

$$\text{ピアソンの適合度基準 } Q(x) = \frac{(\text{度数} - \text{期待度数})^2}{\text{期待度数}} \text{ の合計} = \sum_{i=1}^k \frac{(x_i - np_i)^2}{np_i}$$

が小さいほど, 標本は母分布から予想されるものに近い

命題 久保川 統計学入門 公式 11.2

$n$  大のとき, ピアソンの適合度基準  $Q$  は, 自由度  $k - 1$  のカイ二乗分布にしたがう.

このことを利用して, 帰無仮説「 $p_1, \dots, p_k$  のカテゴリ分布にしたがう」対立仮説「したがわない ( $\Leftrightarrow p_i$  が 1 個は異なる)」で検定が行える **適合度のカイ二乗検定** 久保川 統計学入門 §11.1

## ここまで来たよ

### 14 片側検定

### 15 条件付き分布, ベイズ推定

- 検定の第1種・第2種の過誤・適合度のカイ二乗検定
- 条件付き確率

## 復習：同時分布と周辺分布

久保川 統計学入門 §6.1

確率統計 I(2025)L06

 $X, Y$  確率変数

同時分布

$$p(x, y) = P(X = x \text{かつ} Y = y) =$$

$y \backslash x$	150	160	165	計
45	3/8	0	1/12	
50	1/8	1/3	1/12	
計				

周辺分布

 $X, Y$  の周辺分布  $p_X(x), p_Y(y)$  は,

$$\text{離散型 } p_X(x) = p(x, \bullet) = \sum_y p(x, y), \quad p_Y(y) = p(\bullet, y) = \sum_x p(x, y)$$

要するに 一方を無視した分布. 小計.

## 条件付き確率 久保川 統計学入門 §3.3

定義 (条件付き確率 久保川 統計学入門 定義 3.7, 公式 3.8)

条件 (事象)  $A$  のもとでの, 事象  $B$  の条件付き確率

$$P(B|A) = \frac{P(A \cap B)}{P(A)}$$

縦棒「|」=given」の前後は不平等:  $P(\text{確率を考える事象}|\text{条件の事象})$   
 $P(B|A) \neq P(A|B), \neq P(A \cup B)$ .

意味  $A$  が起きる場合に限定した,  $B$  が起きる確率

$P(B|A)$  を  $P(\text{of})B \text{ given } A$  と発音する人がいる. given 条件=条件が与えられたとき, という言い方から.

縦棒の前だけ見る (縦棒の後を固定する) と, ただの確率. 全事象は 1.

# 離散型確率変数に対する条件付き確率

久保川 統計学入門 §6.3

同時確率分布

$$p(x, y) = P(X = x \text{かつ} Y = y) =$$

$y \backslash x$	150	160	165
45	3/8	0	1/12
50	1/8	1/3	1/12

定義 (離散型確率変数に対する条件付き確率)

条件 (事象)  $Y = y$  のもとでの, 事象  $X = x$  の条件付き確率の記号

$$P(X = x | Y = y) = p_{x|y}(x \text{ の値} | y \text{ の値})$$

例  $p_{x|y}(150|45), p_{y|x}(45|150)$ . 縦棒の前だけ見る (縦棒の後ろを固定すると, 前の変数についての, ただの確率分布. 意味 **自分の言葉でどうぞ**)

命題 (条件付き確率を同時確率分布と周辺分布で表す式 [久保川 統計学入門 定義 6.9](#))

$$P(X = x | Y = y) = p_{x|y}(x|y) = \frac{p(x, y)}{p_Y(y)},$$

$$P(Y = y | X = x) = p_{y|x}(y|x) = \frac{p(x, y)}{p_X(x)}.$$

## L15-Q1

## Quiz(条件付き分布)

次の6枚のカードから無作為に1枚のカードを引く.

♥7   ♥8   ♥9   ♦8   ♠9   ♣9

$X =$  数,  $Y = 0$ (赤札),  $1$ (黒札) とすると同時分布は次のようになる.

$y \backslash x$	7	8	9	計
0	$\frac{1}{6}$	$\frac{1}{3}$	$\frac{1}{6}$	
1	0	0	$\frac{1}{3}$	
計				

- ① 9の札が出る条件のもとで赤札が出る, 条件付き確率を求めよう.
- ② 赤札が出る条件のもとで9の札が出る, 条件付き確率を求めよう.

## 条件付き確率と周辺分布から, 同時確率分布, 周辺分布

命題 (同時確率分布, 周辺分布, 条件付き確率の関係)

乗法公式 (同時確率分布との関係) 久保川 統計学入門 公式 3.8

$$\begin{aligned} p_{XY}(x, y) &= p_{X|Y}(x|y) \times p_Y(y) \\ &= p_{Y|X}(y|x) \times p_X(x). \end{aligned}$$

全確率の法則 (周辺分布との関係) 久保川 統計学入門 §3.4

$$\begin{aligned} p_X(x) &= \sum_y p_{X|Y}(x|y) \times p_Y(y), \\ p_Y(y) &= \sum_x p_{Y|X}(y|x) \times p_X(x) \end{aligned}$$

## ベイズの定理 久保川 統計学入門 §3.4 |

### 定理 (ベイズの定理) 久保川 統計学入門 公式 3.15

$$p_{X|Y}(x|y) \stackrel{\text{定義}}{=} \frac{p(x, y)}{p_Y(y)} = \frac{p_{Y|X}(y|x)p_X(x)}{\sum_{x'} p_{Y|X}(y|x')p_X(x')},$$

$$p_{Y|X}(y|x) \stackrel{\text{定義}}{=} \frac{p(x, y)}{p_X(x)} = \frac{p_{X|Y}(x|y)p_Y(y)}{\sum_{y'} p_{X|Y}(x|y')p_Y(y')}.$$

$p_{X|Y}(x|y)$  を  $p_{Y|X}(y|x')$  (と  $p_X(x')$ ) で書き表す式,

$p_{Y|X}(y|x)$  を  $p_{X|Y}(x|y')$  (と  $p_Y(y')$ ) で書き表す式.

定義の分子分母を, 乗法公式と全確率の公式で書き直しただけ (なので余分の記憶は不要).

## L15-Q2

## Quiz(同時分布・条件付き分布・周辺分布)


離散型確率変数  $X$  は値 2, 3,  $Y$  は値 20, 30 をとる. 次の通りとする.

$$p_Y(y) = \begin{cases} \frac{1}{3} & (y = 20) \\ \frac{2}{3} & (y = 30) \\ 0 & (\text{他}) \end{cases}$$

$$p_{X|Y}(x|20) = \begin{cases} \frac{3}{4} & (x = 2) \\ \frac{1}{4} & (x = 3) \end{cases}, \quad p_{X|Y}(x|30) = \begin{cases} \frac{1}{2} & (x = 2) \\ \frac{1}{2} & (x = 3) \end{cases}.$$

- ① 同時分布を求めよう
- ②  $X$  の周辺分布を求めよう.
- ③ 条件付き確率  $p_{Y|X}(20|2), p_{Y|X}(30|3)$  を求めよう.

## ベイズ推定



追加の情報が得られるたびに, 事後確率は正確になっていく.

**主観確率** 事前確率に主観を許す考え方. 事後確率にも主観が含まれる.

## 例えばこんな問 I

L15-Q3

### Quiz(ベイズの推定)

甘い品種 1 と渋い品種 2 の柿が袋に入っている.

甘い品種 1 は, 確率 0.95 で赤に, 確率 0.05 で黄色になる.

渋い品種 2 は, 確率 0.125 で赤に, 確率 0.875 で黄色になる.

- ① 袋の柿の  $1/5$  が甘い品種 1 である. いま, 無作為に 1 個の柿を取りだしたところ, 赤い柿だった. 取り出した赤い柿が甘い品種 1 である確率を求めよう.
- ② 袋から取り出すの柿の  $1/5$  が渋い品種 2 であると考えている. いま, 1 個の柿を取りだしたところ, 黄色い柿だった. この柿が渋い確率を求めよう.



## L15-Q4

## Quiz(ベイズ推定)

ある病気の人割合は全体の  $0.005$  と思われている。  
検査では、病気の人  $0.99$  は陽性となり (真陽性),  $0.01$  の人は陰性になる (偽陰性)。また、病気でない人  $0.02$  は (誤って) 陽性となり (偽陽性),  $0.98$  の人は陰性になる (真陰性)。

- 1 回の検査で陽性となった人が、病気である確率を求めよう。
- 1 回の検査で陽性となった人が、さらにもう 1 回検査してやはり陽性だった。その人が病気である確率を求めよう。

## 混同行列 confusion matrix

- 検査の性能を表現する数値は1通りではない.
- 現実には本当の確率はわからなくて, 人数の表 (混同行列) で記録する
  - ▶ 今後出てくる, 標本抽出, 推定の考えが混ざっている

	検査で陽性	検査で陰性
病気	○ (TP 真陽性)	× (FN 見逃し, 偽陰性)
病気でない	× (FP 誤検出, 偽陽性)	○ (TN 真陰性)

真/偽=True/False, 陽性/陰性=Positive/Negative

どれも大きい方がいいが, 一つを大きくすると他が小さくなりがち

- 感度=再現率=真陽性率=recall=sensitivity=  $\frac{TP}{TP+FN}$
- 特異度=真陰性率=specificity=  $\frac{TN}{TN+FP}$
- 適合率=precision=  $\frac{TP}{TP+FP}$
- 正解率=精度=accuracy =  $\frac{TP+TN}{\text{すべて}}$
- F 値=recall と precision の調和平均

病気に限らない. 例: 猫画像判定 AI の性能, 陽性=画像は猫, 検査で陽性=AI が画像は猫と判定

## ふつうじゃない trialL15(締切 2025-08-04 月 20:00)

- trialL15-1 LearnMoodle 練習問題的なものだが, 受験は2回まで. チェックは使えない
  - ▶ ほぼ同内容の予行演習用の練習問題 L15 に合格すると開放されます.
  - ▶ 趣旨: 対面でやる機会がない
- trialL15-2 LearnMoodle 作文
  - ▶ まずアンケートにご協力をお願いします. 回答すると開放されます.
  - ▶ 学習履歴分析への同意をお願いします

### 定期試験期間中の任意参加授業内小テスト

用途:LearnMoodle 成績評価方法参照.

2025-08-04 月 09:15-10:15, 参照なし. 7-002. 事前の出欠連絡不要. 理由を問わず, 欠席したときの追試や配慮はなし. Trial L01-08 の出題計画をあわせたもの (注: 2024 年度と L08 の内容が異なる). 要学生証, 個人別座席指定.

すべて持込不可.

災害や交通機関などにより全学的に定期試験が中止・延期になるときは同様に中止・延期.

### 成績評価

考慮対象になるかもしれないものは LearnMoodle 欠席届に 2025-07-30 水までに提出.

### メッセージ

- 教科書は売らないで. 確率統計 II,III (3年後期) 他で使います.
- 数理と社会 (3年 1Q) でお会いしましょう.