

公開講座 2000年7月3日

統計数理研究所 下平英寿

午前： 統計学のおさらい (1-2章)

午後： **AIC**入門 (3-4章)

参考書： 情報量統計学，統計学辞典

A1

## 1 確率と確率変数

この章のトピック — 確率変数

- 事象と確率
- 条件付確率と独立性
- 確率変数と分布関数
- 期待値
- 多次元の確率分布

A3

「情報量統計学」の1章から4章まで (第I編 理論編)の範囲

統計学のおさらい

1章 確率と確率変数

2章 確率分布と統計モデル

**AIC**入門

3章 推定

4章 **AIC**

A2

### 1.1 事象と確率

「確率」の定義 — あることがらが起こりうる割合．確からしさの度合い．

おなじ条件でくりかえし実験をおこなう (頻度論)

現代では「測度論」という数学を用いて，抽象的に定義される．

現象が必ずしも「確率的」でなくても，情報不足による不確実さを表現する手段として，現象を確率的と見なすと便利ながある．

A4

**[例] 画びょうをなげる (上, 下)**

1	2	3	4	5	6	7	8	9	10
上	下	上	下	下	上	下	下	下	上
11	12	13	14	15	16	17	18	19	20
下	下	下	上	上	上	下	下	下	上
91	92	93	94	95	96	97	98	99	100
下	上	上	上	下	上	下	下	上	下

上=43回, 下=57回

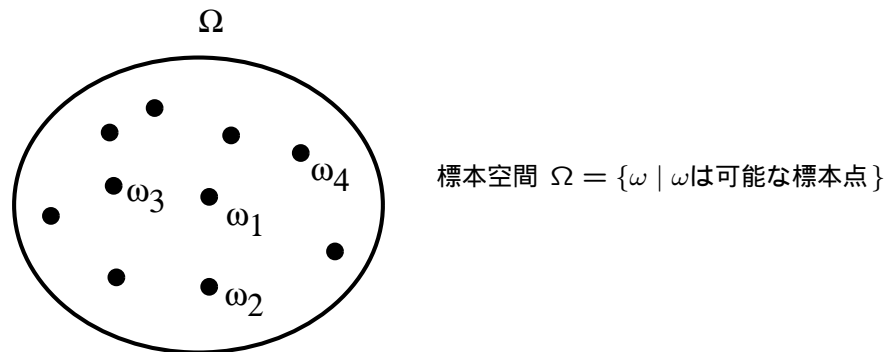
$$\frac{43}{100} = 0.43$$

A5

**実験の数学的モデル**

測度論 (集合, 面積をみつかう数学理論)

確率空間  $(\Omega, \mathcal{F}, P)$       $\Omega =$  標本空間,  $\mathcal{F} =$  事象の全体,  $P =$  確率



A7

**画びょうが上になる割合**

	1-10	11-20	21-30	31-40	41-50	51-60	61-70	71-80	81-90	91-100	1-100
上	4	4	4	3	6	3	3	5	6	5	43
下	6	6	6	7	4	7	7	5	4	5	57
上の割合	0.4	0.4	0.4	0.3	0.6	0.3	0.3	0.5	0.6	0.5	0.43

画びょうが上になる確率 = 実験回数を増やしたときの極限

- 母集団 = 実験回数が非常に多い(無限)のとき
- 確率 = 母集団における割合

実際には有限回しか実験は行えない

同じ条件で実験を多数繰り返すのは大変難しい

⇒ 確率というのは抽象的な概念


A6

**[標本空間の例]**

- $\Omega = \{\omega_1, \omega_2\}$ ;  $\omega_1 =$  画びょうが上,  $\omega_2 =$  画びょうが下
- $\Omega = \{\omega_1, \dots, \omega_6\}$ ;  $\omega_1 =$  サイコロの目が1, ...,  $\omega_6 =$  サイコロの目が6
- $\Omega = \{\omega_1, \dots, \omega_{52}\}$ ;  $\omega_1 =$  ハートの1, ...,  $\omega_{52} =$  スペードのキング
- $\Omega = \{\text{「表表」, 「表裏」, 「裏表」, 「裏裏」}\}$ ; 2枚のコイン
- $\Omega = \{\text{「たろう, はなこ, ... (クラスの人)}\}$
- $\Omega = \{0, 1, 2, \dots\}$ ; 0以上の整数
- $\Omega = \{x \mid x \in \text{実数全体}\}$

A8

## 事象 ( $\Omega$ の部分集合)



- 事象  $A \subset \Omega$ , 事象  $B \subset \Omega$
- $A$ と $B$ の和事象  $A \cup B$  ( $A$ と $B$ のすくなくともどちらかが起こる)
- $A$ と $B$ の積事象  $A \cap B$  ( $A$ と $B$ の両方が起こる)
- $A$ の余事象  $A^c$  ( $A$ が起こらない)

A9

## [事象の例]

- $A = \{\omega\}$ ; 根元事象
- $A =$  画びょうが上  $= \{\omega_1\}$
- $A =$  サイコロの目が偶数  $= \{\omega_2, \omega_4, \omega_6\}$
- $A =$  マークがスペード,  $B =$  数字が1
- $A$ と $B$ の和事象: 少なくとも一方に属する標本の集合  
 $A \cup B =$  スペードの1から13までと, ハート, ダイヤ, クラブの1 (16枚)
- $A$ と $B$ の積事象: いずれにも属する標本の集合  
 $A \cap B =$  スペードの1
- $A \cap B = \phi$ なら,  $A$ と $B$ は排反 (同時にはおこらない)
- 余事象  $A^c$ は $A$ に属さない標本の集合
- 部分事象  $A$ が $B$ に含まれるとき  $A \subset B$

A10

## 事象の全体 $\mathcal{F}$

- $\Omega = \{\omega_1, \omega_2\}$  のとき  $\mathcal{F} = \{\phi, \{\omega_1\}, \{\omega_2\}, \{\omega_1, \omega_2\}\}$
- $\Omega = \{\omega_1, \dots, \omega_6\}$  のとき  $\mathcal{F} = \{\phi, \{\omega_1\}, \dots, \{\omega_1, \dots, \omega_6\}\}$

### 完全加法族

- $\phi \in \mathcal{F}$
- $A \in \mathcal{F} \Rightarrow A^c \in \mathcal{F}$
- $A_n \in \mathcal{F}, n = 1, 2, \dots \Rightarrow A_1 \cup A_2 \cup \dots \in \mathcal{F}$

### 確率の公理系

- $\mathcal{F}$ の上で定義された実数値関数 $P$  (これが確率を与える関数)
- 任意の $A \in \mathcal{F}$ に対して $P(A) \geq 0$
- $P(\Omega) = 1$
- $A_i \cap A_j = \phi$ ならば $P(A_1 \cup A_2 \cup \dots) = P(A_1) + P(A_2) + \dots$

A11

## 1.2 条件付確率と独立性

二つの事象 $A$ と $B$ について,

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

ただし  $P(B) > 0$  とする.

$P(A|B)$ は事象 $B$ を条件とする事象 $A$ の「条件付確率」という.

[例] トランプで全てのカードの確率が等しく $\frac{1}{52}$ とする.

$A =$  数字が1か2,  $B =$  数字が奇数

$$P(A \cap B) = \frac{1}{13}, P(B) = \frac{7}{13}$$

従って $P(A|B) = \frac{1}{7}$ であり,  $P(A) = \frac{2}{13}$ より小さい.

A12

“chain rule”

$$P(A|B) = P(A \cap B) / P(B)$$


と書き換えると

$$P(A \cap B) = P(A|B)P(B)$$

を得る．これを繰り返し用いると，

$$P(A \cap B \cap C) = P(A|B \cap C)P(B|C)P(C)$$

などが得られる．



A13


独立性

一般に  $P(A \cap B) = P(A|B)P(B)$  であるが，とくに  $P(A|B) = P(A)$  のとき，事象  $A$  と  $B$  は互いに「独立」という．このとき， $P(A \cap B) = P(A)P(B)$  とかける．

事象  $A_1, A_2, \dots$  が独立とは，

$$P(A_1 \cap A_2 \cap \dots) = P(A_1)P(A_2) \dots$$

が成り立つとき．



$$P(A \cap B) = P(A) P(B)$$

A15

ベイズの定理

$H_1, H_2, \dots$  のどの二つも互いに排反で，かつ  $H_1 \cup H_2 \cup \dots = \Omega$  であるとき，

$$P(H_k|A) = \frac{P(A|H_k)P(H_k)}{\sum_i P(A|H_i)P(H_i)}$$

$H_k$  原因， $A$  結果

$P(H_k)$  事前確率， $P(H_k|A)$  事後確率

[証明]

$$\sum_i P(A|H_i)P(H_i) = \sum_i P(A \cap H_i) = P(A)$$

これをベイズの定理の式の両辺にかけると

$$P(H_k|A)P(A) = P(A \cap H_k) = P(A|H_k)P(H_k)$$

となる．

適用上の注意点：事前分布の決めかた

Thomas Bayes (1702-1761) イギリスの牧師

A14

[独立性の例]

- $A = \text{エース}$ ， $B = \text{ハート}$  とする．全てのカードの確率は  $\frac{1}{52}$  とする．

$$P(A) = \frac{4}{52} = \frac{1}{13}，P(B) = \frac{13}{52} = \frac{1}{4}，P(A \cap B) = \frac{1}{52}．$$

$$P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{\frac{1}{52}}{\frac{1}{4}} = \frac{1}{13} = P(A)$$

したがって  $A$  と  $B$  は独立．

- 10個のコインを投げてすべてが表である確率は？

$$\frac{1}{2} \times \dots \times \frac{1}{2} = \left(\frac{1}{2}\right)^{10} = \frac{1}{1024}$$

- 一台あたりの故障の確率が 0.001 の装置が 100 台すべて故障の無い確率は？

$$(1 - 0.001)^{100} = 0.905$$

A16


### 1.3 確率変数と分布関数

標本空間  $\Omega$  上で定義された実数値関数  $X(\omega)$  があって任意の実数  $x$  に対して  $X(\omega)$  が  $x$  以下となる様な標本点の集合

$$\{\omega | X(\omega) \leq x\}$$

に対してその確率が常に定義できるとき,  $X(\omega)$  を「確率変数」と呼ぶ.

実験の結果  $X(\omega) = x$  が観測されたとき,  $x$  を確率変数  $X$  の「実現値」と呼ぶ.



A17

- 「離散型確率変数」  $X(\omega)$  のとる値が有限個または可算無限個
- 「連続型確率変数」  $X(\omega)$  のとる値が連続的

確率変数  $X$  の「分布関数」

$$F(x) = P(\{\omega | X(\omega) \leq x\})$$

ただし, 簡単のために

$$F(x) = P(X \leq x)$$

のように  $\omega$  を明記しないことが多い.

実際の応用では, 確率空間, 分布関数を通して確率変数を定義することはあまりない.

後述の確率関数, 密度関数を通して確率変数を導入するのが一般的.

A19

#### 【確率変数の例】

- 画びょうが上るとき 1, 下るとき 0 となる確率変数は,

$$X(\omega) = \begin{cases} 1 & \omega = \omega_1 \text{ のとき} \\ 0 & \omega = \omega_2 \text{ のとき} \end{cases}$$

- 2枚のコインなげで, 表の枚数

$$X(\omega) = \begin{cases} 2 & \omega = \text{「表表」のとき} \\ 1 & \omega = \text{「表裏」又は「裏表」のとき} \\ 0 & \omega = \text{「裏裏」のとき} \end{cases}$$

- $\Omega = \{\text{クラスの人}\}$

$$X(\omega) = \text{身長}, \quad \text{または} \quad X(\omega) = \text{体重}$$

- $\Omega = \text{実数全体のとき}, X(\omega) = \omega$

A18

#### 【例】画びょうなげ (上の確率が 0.4 とする)


$$F(x) = \begin{cases} 0 & -\infty < x < 0 \\ 0.6 & 0 \leq x < 1 \\ 1 & 1 \leq x < \infty \end{cases}$$



#### 【例】正規分布 (平均 0, 分散 1)

$$F(x) = \int_{-\infty}^x \phi(y) dy$$

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



A20

## 確率関数

$X$ が離散型確率変数のときは「確率関数」

$$p(x) = P(X = x)$$

を用いるのが便利．確率分布関数は

$$F(x) = \sum_{x_i \leq x} p(x_i)$$

と表現される．ただし  $x_i, i = 1, 2, \dots$  は,  $x$ の取り得る値．

$$\sum_{x_i} p(x_i) = 1; \quad p(x_i) \geq 0$$

[例] 2枚のコインの表の枚数の確率関数は, 表裏の確率が等しいとして,

$$p(0) = 1/4, \quad p(1) = 1/2, \quad p(2) = 1/4$$

A21

## (確率)密度関数

$X$ が連続型確率変数のときは, (確率)密度関数  $f(x)$ が便利．確率分布関数は

$$F(x) = \int_{-\infty}^x f(y) dy$$

と表現される．

$$\int f(x) dx = 1; \quad f(x) \geq 0$$

直観的には, ヒストグラムの極限 (データ数無限, 分点の間隔ゼロ)

$$f(x) = \lim_{h \rightarrow +0} \frac{P(x < X \leq x + h)}{h} = \lim_{h \rightarrow +0} \frac{F(x + h) - F(x)}{h} = \frac{dF}{dx}$$

A22

## 1.4 期待値

離散型確率変数  $X$ が,  $x_1, x_2, \dots$ という値を確率  $p(x_1), p(x_2), \dots$ でとるものとする．

$$\mu = E[X] = \sum_i x_i p(x_i)$$

を確率変数の「期待値」あるいは平均と呼ぶ．

[例] サイコロの目がすべて同じ確率  $\frac{1}{6}$ ならば,  $x_1 = 1, x_2 = 2, \dots, x_6 = 6; p(x_i) = \frac{1}{6}$ とにおいて, その期待値は

$$E[X] = 1 \times \frac{1}{6} + 2 \times \frac{1}{6} + \dots + 6 \times \frac{1}{6} = 3.5$$

$X$ が連続型確率変数の場合には密度関数  $f(x)$ を用いて,

$$\mu = E[X] = \int_{-\infty}^{\infty} x f(x) dx$$

A23

確率変数  $X$ のある関数を  $g(X)$ とするとその期待値は

$$E[g(X)] = \sum_i g(x_i) p(x_i) \quad \text{又は} \quad E[g(X)] = \int_{-\infty}^{\infty} g(x) f(x) dx$$

とくに  $g(X) = (X - \mu)^2$ とおくと,  $X$ の「分散」が得られる．

$$\sigma^2 = V[X] = E[(X - \mu)^2] = \sum_i (x_i - \mu)^2 p(x_i) \quad \text{又は} \quad \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx$$

$(X - \mu)^2$ は,  $X$ の  $\mu$ からのへだたりをあらわしている．

サイコロの目の分散は

$$V[X] = (1 - 3.5)^2 \times \frac{1}{6} + (2 - 3.5)^2 \times \frac{1}{6} + \dots + (6 - 3.5)^2 \times \frac{1}{6} = \frac{35}{12} \approx 2.92$$

「標準偏差」(standard deviation)は

$$\sigma = \sqrt{V[X]} = \sqrt{\frac{35}{12}} \approx 1.71$$

A24

(公式)

$$V[X] = E[X^2] - (E[X])^2$$

[例] サイコロの目では  $E[X^2] = 91/6$ ,  $E[X]^2 = (7/2)^2$

$$\frac{91}{6} - \left(\frac{7}{2}\right)^2 = \frac{35}{12}$$

[証明]

$$E[(X - \mu)^2] = E[X^2 - 2\mu X + \mu^2] = E[X^2] - 2\mu E[X] + \mu^2 = E[X^2] - \mu^2$$

[参考]

$$E[X + Y] = E[X] + E[Y]$$

$$E[aX] = aE[X]$$

A25

•  $X$  が離散型の場合は、「同時確率関数」

$$p(x_1, \dots, x_k) = P(X_1 = x_1, \dots, X_k = x_k)$$

をもちいて分布関数は

$$F(x_1, \dots, x_k) = \sum_{y_1 \leq x_1} \dots \sum_{y_k \leq x_k} p(x_1, \dots, x_k)$$

•  $X$  が連続型の場合は、「同時密度関数」

$$f(x_1, \dots, x_k)$$

をもちいて分布関数は

$$F(x_1, \dots, x_k) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_k} f(y_1, \dots, y_k) dy_1 \dots dy_k$$

A27


## 1.5 多次元の確率分布

多次元確率変数 ( $k$ 次元確率ベクトル)

$$X(\omega) = (X_1(\omega), \dots, X_k(\omega))$$

同時分布関数

$$\begin{aligned} F(x_1, \dots, x_k) &= P(X_1 \leq x_1, \dots, X_k \leq x_k) \\ &= P(\{\omega | X_1(\omega) \leq x_1, \dots, X_k(\omega) \leq x_k\}) \end{aligned}$$



[例]  $\Omega = \{\text{クラスの人}\}$

$$X_1(\omega) = \omega\text{さんの身長}, \quad X_2(\omega) = \omega\text{さんの体重}$$

A26

同時確率関数 (離散型); 同時確率密度 (連続型)

$$p(x, y) = P(X = x, Y = y); \quad f(x, y) = \frac{d^2 F}{dx dy}$$

$(X, Y)$  の同時分布

$$F(x, y) = P(X \leq x, Y \leq y) = \sum_{x' \leq x} \sum_{y' \leq y} p(x', y'); \quad \int_{-\infty}^x \int_{-\infty}^y f(x', y') dx' dy'$$

$X$  の「周辺分布」の確率関数; 密度関数

$$p(x) = \sum_y p(x, y); \quad f(x) = \int_{-\infty}^{\infty} f(x, y) dy$$


$X = x$  の時の  $Y$  の「条件付」確率関数; 密度関数

$$p(y|x) = \frac{p(x, y)}{p(x)}; \quad f(y|x) = \frac{f(x, y)}{f(x)}$$

[注意] 本来なら  $p_X(x)$ ,  $p_Y(y)$ ,  $p_{XY}(x, y)$ ,  $p_{Y|X}(y|x)$  などと添字をつけて区別すべきだが、特に混乱の恐れがない限り、簡単のため省略する。

A28

周辺分布, 条件つき分布



$$A = \{\omega | Y(\omega) = y\}, \quad B = \{\omega | X(\omega) = x\}$$

$$P(B) = \sum_y p(x, y) = p(x), \quad P(A \cap B) = p(x, y)$$

$$p(y|x) = P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{p(x, y)}{p(x)}$$

A29

確率関数の “chain rule”

- $(X_1, \dots, X_k) = (Y, Z)$

$$Y = (X_1, \dots, X_m), \quad Z = (X_{m+1}, \dots, X_k)$$

と分割すれば

$$p(x_1, \dots, x_m) = p(y) = \sum_z p(y, z) = \sum_{x_{m+1}, \dots, x_k} p(x_1, \dots, x_k)$$

$$p(x_{m+1}, \dots, x_k | x_1, \dots, x_m) = p(z|y) = \frac{p(y, z)}{p(y)} = \frac{p(x_1, \dots, x_k)}{p(x_1, \dots, x_m)}$$

- 繰り返し適用すると,

$$p(x_1, \dots, x_k) = p(x_k | x_1, \dots, x_{k-1}) p(x_{k-1} | x_1, \dots, x_{k-2}) \cdots p(x_3 | x_1, x_2) p(x_2 | x_1) p(x_1)$$

A30

時系列 (マルコフモデル)

$$x_1, x_2, \dots, x_k$$

が時系列のとき, しばしば 1 時刻前の影響だけを考えれば良いことがある.

$$p(x_m | x_1, \dots, x_{m-1}) = p(x_m | x_{m-1})$$

という仮定が用いられる. このとき “chain rule” より,

$$p(x_1, \dots, x_k) = p(x_k | x_{k-1}) p(x_{k-1} | x_{k-2}) \cdots p(x_3 | x_2) p(x_2 | x_1) p(x_1)$$

もし 2 時刻まえの影響までを考慮するなら,

$$p(x_1, \dots, x_k) = p(x_k | x_{k-1}, x_{k-2}) p(x_{k-1} | x_{k-2}, x_{k-3}) \cdots p(x_4 | x_3, x_2) p(x_3 | x_2, x_1) p(x_2 | x_1) p(x_1)$$

A31

確率変数の独立性

確率変数  $X$  と  $Y$  が独立とは, 事象  $\{\omega | X(\omega) \leq x\}$  と  $\{\omega | Y(\omega) \leq y\}$  が独立のとき.

$$P(X \leq x, Y \leq y) = P(X \leq x) P(Y \leq y)$$

これより

$$p(x, y) = p(x)p(y); \quad f(x, y) = f(x)f(y)$$

$X_1, X_2, \dots, X_k$  が「独立」

$$p(x_1, \dots, x_k) = p(x_1) \cdots p(x_k); \quad f(x_1, \dots, x_k) = f(x_1) \cdots f(x_k)$$

$x_1, \dots, x_k$  を「時系列」とみなすと, これは前の時刻の影響が全くないモデルに相当する.

A32



## 独立性と無相関

もし  $X$  と  $Y$  が独立なら,

$$E[g(X)h(Y)] = \int f(x)g(x) dx \int f(y)h(y) dy = E[g(X)]E[h(Y)]$$

したがって「共分散」(covariance)

$$C(X, Y) = E[(X - \mu_X)(Y - \mu_Y)] = E[X - \mu_X]E[Y - \mu_Y] = 0$$

もしくは「相関」(correlation)

$$\rho(X, Y) = \frac{C(X, Y)}{\sqrt{V(X)V(Y)}} = 0$$

[注意] ただし  $C(X, Y) = 0$  だからといって  $X$  と  $Y$  が独立とは言えない。独立性の指標には「相互情報量」(後述)が便利。

( $X, Y$ ) が多変量正規分布の場合には, 独立性と無相関はおなじ。

A33

## 2 確率分布と統計モデル

この章のトピック — パラメトリック・モデル

- 離散型確率分布
- 連続型確率分布
- 統計的モデル

A35

## 条件つき独立とマルコフ性

- 確率変数  $X, Y, Z$  の同時分布が


$$p(x, y, z) = p(x|z)p(y|z)p(z)$$

を満たすとき,  $X$  と  $Y$  は  $Z$  の下で「条件つき独立」であるという。

- 同時分布のグラフ表現 (グラフィカルモデル)

$$p(x_m|x_1, \dots, x_{m-1}) = p(x_m|x_i, i \in C_m)$$

のとき  $X_m$  に向かう矢印を  $X_i, i \in C_m$  から引く



A34

### 2.1 離散型確率分布

1A 2項分布

1B ポアソン分布

1C 多項分布

### 2.2 連続型確率分布

2A 一様分布

2B 正規分布

2C 多次元正規分布

2D カイ2乗分布

A36

## 1A. 2項分布

$n$  回コイン (画びょう) を投げたとき, 表の出る回数  $k$  の分布.

$$p(k|\theta) = \binom{n}{k} \theta^k (1-\theta)^{n-k}; \quad k = 0, 1, \dots, n$$

$\theta$ : 1 回のコイン投げで表の出る確率

**[例]** コイン投げ  $\theta = 0.5$ ,  $n = 10$  として計算すると,

	0	1	2	3	4	5	6	7	8	9	10
2項分布	.001	.010	.044	.117	.205	.246	.205	.117	.044	.010	.001
正規近似*	.002	.010	.042	.113	.207	.252	.207	.113	.042	.010	.002
数値実験**	.001	.010	.045	.120	.199	.254	.204	.112	.047	.008	.001

\* 後述の正規分布を利用して近似計算

\* コンピュータによるシミュレーション 10 回の画びょう投げ=1 セットとして, 10000 セットの実験 (3, 4, 6, 6, 5, 7, 2, 3, 5, 6, ..., 6, 7, 2, 6, 7, 5, 4, 7, 3, 6.)

A37

## 1B. ポアソン分布

毎日の事故の回数の分布.

$$p(k|\lambda) = \frac{\lambda^k}{k!} \exp(-\lambda); \quad k = 0, 1, 2, \dots$$

平均, 分散

$$E(k) = \sum_{k=0}^{\infty} kp(k|\lambda) = \lambda; \quad V(k) = \sum_{k=0}^{\infty} (k-\lambda)^2 p(k|\lambda) = \lambda$$

**[参考]** 先程の 2 項分布を  $p_{Bi}$ , ポアソン分布を  $p_{Po}$  と書くと,

$$\lim_{n \rightarrow \infty} p_{Bi}(k|\lambda/n) = p_{Po}(k|\lambda)$$

である.

A39

**[導出]**  $(x_1, \dots, x_n)$  を各コイン投げでの表  $x_i = 1$  が裏  $x_i = 0$  を表すベクトルとする.

例えば, 全て表なら  $(1, \dots, 1)$ , 裏なら  $(0, \dots, 0)$  となる.

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

$$\begin{aligned} p(x_1, \dots, x_n|\theta) &= \theta^{x_1} (1-\theta)^{(1-x_1)} \times \dots \times \theta^{x_n} (1-\theta)^{(1-x_n)} \\ &= \theta^{(\sum_i x_i)} \times (1-\theta)^{\sum_i (1-x_i)} \\ &= \theta^k (1-\theta)^{n-k} \end{aligned}$$

これに組合わせの数をかけて  $p(k|\theta)$  を得る.

平均, 分散

$$\sum_{k=0}^n kp(k|\theta) = n\theta; \quad \sum_{k=0}^n (k-n\theta)^2 p(k|\theta) = n\theta(1-\theta)$$

$$\theta = 0.5, n = 10 \text{ のとき } E(k) = 5, V(k) = 2.5$$

A38

## 1C. 多項分布

(かたよりのある) サイコロを  $n$  回投げたときの出る目の分布.

$$p(k_1, \dots, k_c|\theta_1, \dots, \theta_c) = \frac{n!}{k_1! \dots k_c!} \theta_1^{k_1} \dots \theta_c^{k_c}$$

$c$  は目の数,  $k_1, \dots, k_c$  はそれぞれの目の出た回数,  $\theta_1, \dots, \theta_c$  はそれぞれの目の確率.

$$\sum_{i=1}^c k_i = n, \quad k_i \geq 0; \quad \sum_{i=1}^c \theta_i = 1, \quad \theta_i \geq 0$$

$$\sum_{k_1, \dots, k_c} p(k_1, \dots, k_c|\theta_1, \dots, \theta_c) = 1$$

**[導出]** 第  $i$  回目の試行でとる値を  $x_i$  とすると

$$p(x_1, \dots, x_n|\theta_1, \dots, \theta_c) = \theta_{x_1} \dots \theta_{x_n} = \theta_1^{k_1} \dots \theta_c^{k_c}$$

これに組合わせの数をかける.

A40

[参考]  $c = 2$  のとき, 2項分布になる.

$$p(k_1, k_2 | \theta_1, \theta_2) = \frac{n!}{k_1! k_2!} \theta_1^{k_1} \theta_2^{k_2}$$

ここで

$$k_1 = k, \quad k_2 = n - k; \quad \theta_1 = \theta, \quad \theta_2 = 1 - \theta$$

[参考]  $c$  個の独立なポアソン分布

$$p_{Po}(k_i | \lambda_i), \quad i = 1, \dots, c$$

$\sum_i k_i = n$  という条件付きでの  $(k_1, \dots, k_c)$  の分布は, 多項分布


$$\frac{p_{Po}(k_1 | \lambda_1) \cdots p_{Po}(k_c | \lambda_c)}{\sum_{k_1 + \dots + k_c = n} p_{Po}(k_1 | \lambda_1) \cdots p_{Po}(k_c | \lambda_c)} = \frac{n!}{k_1! \cdots k_c!} (\lambda_1/n)^{k_1} \cdots (\lambda_c/n)^{k_c}$$

A41

## 2A. 一様分布

区間  $[0, 1]$  上の一様分布の密度関数

$$f(x) = \begin{cases} 1 & 0 \leq x \leq 1 \\ 0 & x < 0, x > 1 \end{cases}$$



0.17, 0.66, 0.62, 0.48, 0.97, 0.65, 0.09, 0.10, 0.46, 0.28, 0.78, 0.73, 0.65, 0.37, 0.79, 0.39, 0.59, 0.36, 0.41, 0.64, ...

A42

## 2B. 正規分布

平均  $\mu$ , 分散  $\sigma^2$  の正規分布の密度関数

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

確率変数  $X$  がこの分布に従うとき

$$X \sim N(\mu, \sigma^2)$$

とかく.


$$E(X) = \int_{-\infty}^{\infty} x f(x | \mu, \sigma^2) dx = \mu, \quad V(X) = \int_{-\infty}^{\infty} (x - \mu)^2 f(x | \mu, \sigma^2) dx = \sigma^2$$

[参考]  $X \sim N(0, 1)$  なら,  $\sigma X + \mu \sim N(\mu, \sigma^2)$


A43

標準正規分布  $N(0, 1)$

密度関数  $\phi(x)$ , 分布関数  $\Phi(x) = \int_{-\infty}^x \phi(y) dy$



$$\phi(x) = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{x^2}{2}\right\}$$



0.37, -0.57, 0.65, 1.89, 1.32, 1.52, 0.37, 0.36, -0.63, 0.90, 3.34, -0.71, -2.06, -0.09, -0.29, -0.60, 2.20, -1.43, -0.49, 0.02, ...

A44

## 2C. 多次元正規分布

平均ベクトル  $\mu$  , 共分散行列  $\Sigma$  の  $k$  次元正規分布の密度関数


$$f(x|\mu, \Sigma) = (2\pi)^{-k/2} |\Sigma|^{-1/2} \exp \left\{ -\frac{1}{2} (x - \mu)' \Sigma^{-1} (x - \mu) \right\}$$

確率変数  $X = (X_1, \dots, X_k)'$  がこの分布に従うとき ,

$$X \sim N(\mu, \Sigma)$$

とかく . ただし  $x = (x_1, \dots, x_k)'$  ,  $\mu = (\mu_1, \dots, \mu_k)'$  ,  $\Sigma = (\sigma_{ij}; i, j = 1, \dots, k)$  .

$$E(X) = \mu, \quad V(X) = E((X - \mu)(X - \mu)') = \Sigma$$



A45

- とくに  $\mu = 0$  ,  $\Sigma = I = \text{diag}(1, \dots, 1)$  ならば

$$X \sim N(0, I)$$

$$f(x|0, I) = \prod_{i=1}^k \phi(x_i)$$

$X_1, \dots, X_k$  は独立に  $N(0, 1)$  に従う .

- 任意の  $\Sigma$  (正定値行列) は

$$\Sigma = LL'$$

と分解できるので ,

$$LX + \mu \sim N(\mu, \Sigma); \quad X \sim N(0, I)$$

とかける .

A46

## 2D. カイ2乗分布

$X \sim N(0, I)$  のとき ,  $\|X\|^2 = \sum_{i=1}^k X_i^2$  は , 自由度  $k$  のカイ2乗分布に従う .

$$\|X\|^2 \sim \chi_k^2$$

とかく .

$$E(\|X\|^2) = k; \quad V(\|X\|^2) = 2k$$

[平均の導出]

$$E(\|X\|^2) = E(X_1^2 + \dots + X_k^2) = E(X_1^2) + \dots + E(X_k^2) = k$$

$X \sim N(\mu, \Sigma)$  ,  $\Sigma = LL'$  ならば ,

$$L^{-1}(X - \mu) \sim N(0, I)$$

従って

$$\|L^{-1}(X - \mu)\|^2 = (X - \mu)' \Sigma^{-1} (X - \mu) \sim \chi_k^2$$

A47

## 極限定理

$\{X_1, X_2, \dots\}$  が独立に同一の分布に従い , その平均と分散を  $\mu$  ,  $\sigma^2$  とし ,  $n \rightarrow \infty$  の極限を考える .

$$S_n = \sum_{i=1}^n X_i$$

[大数の法則]

$$\frac{S_n}{n} \rightarrow \mu$$

[中心極限定理]


$$\frac{S_n - n\mu}{\sqrt{n}\sigma} \rightarrow N(0, 1)$$

A48

## 2.3 統計的モデル

- パラメトリック・モデル
- モデルの合成
- モデルの制約
- リパラメトリゼーション
- 条件つき分布モデル

A49



モデルは必ずしも正しいとは限らない

むしろ、現実の応用ではモデルが「正しい」ことはまれ

**misspecification**

A51

## パラメトリック・モデル

$X \sim g(\cdot)$ ;  $g(x)$  は真の密度関数 (or 確率関数)

目的: データ  $x$  から  $g(\cdot)$  を推定すること

「モデル」を用いる

$$f(x|\theta)$$

$$\theta = (\theta_1, \dots, \theta_K); \quad \theta \in \Theta = \{\theta | \theta \text{ に関する制約}\}$$

パラメタを動かして得られるモデル全体を

$$f(\cdot | \Theta) = \{f(x|\theta) | \theta \in \Theta\}$$

と書く。後述の「最尤法(さいゆうほう)」によって  $\theta$  を推定する。

A50

自由なパラメタの数 (自由パラメタ数)  $k$

「パラメタのうち  $k$  個の値を決めてしまうと残りのパラメタの値が一意に定まる」

【例】正規分布  $N(\theta_1, \theta_2)$

$$f(x|\theta) = \frac{1}{\sqrt{2\pi\theta_2}} \exp\left(-\frac{(x-\theta_1)^2}{2\theta_2}\right)$$

$$\theta = (\theta_1, \theta_2) = (\mu, \sigma^2); \quad \Theta = \{\theta | \theta_2 > 0\}$$

自由パラメタ数 = 2

【例】多項分布

$$\theta = (\theta_1, \dots, \theta_c); \quad \Theta = \{\theta | \sum_{i=1}^c \theta_i = 1, \theta_1 \geq 0, \dots, \theta_c \geq 0\}$$

自由パラメタ数 =  $c - 1$

A52

## モデルの合成

- 「混合モデル」  $f(x|\theta_f)$  の  $g(x|\theta_g)$  混合は

$$h(x|\theta_h) = \alpha f(x|\theta_f) + (1 - \alpha)g(x|\theta_g)$$

$$\theta_h = (\alpha, \theta_f, \theta_g)$$

- 「指数型混合モデル」  $f(x|\theta_f)$ ,  $g(x|\theta_g)$  の混合は

$$h(x|\theta_h) = \exp\{\alpha \log f(x|\theta_f) + (1 - \alpha) \log g(x|\theta_g)\} / C(\alpha, \theta_f, \theta_g)$$

- 「独立モデル」  $X \sim f(x|\theta_f)$ ,  $Y \sim g(y|\theta_g)$  の合成は

$$h(x, y|\theta_f, \theta_g) = f(x|\theta_f)g(y|\theta_g)$$

A53

## 条件つき分布モデル

$X$  の実現値  $x$  が与えられたときの  $Y$  の条件つき分布 — 回帰分析

$X$  : 説明変数,  $Y$  : 目的変数

モデル

$$f(y|\lambda); \quad \lambda = r(x; \theta), \theta \in \Theta$$

なお, 説明変数のモデル  $f(x|\theta_X)$  とあわせると,  $(X, Y)$  の同時分布のモデル

$$f(x|\theta_X)f(y|r(x; \theta))$$

**【例】** 正規回帰モデル:  $Y \sim N(\mu(x), \sigma^2(x))$ ,  $\sigma^2(x) = \theta_1$

線形回帰:  $\mu(x) = \theta_2 + \theta_3x$

3次回帰モデル:  $\mu(x) = \theta_2 + \theta_3x + \theta_4x^2 + \theta_5x^3$

フーリエ級数:  $\mu(x) = \theta_2 + \sum_{m=1}^M (\theta_{2m+1} \sin 2m\pi x + \theta_{2m+2} \cos 2m\pi x)$

A55

## モデルの制約

$$f(\cdot|\Theta) = \{f(x|\theta) | \theta \in \Theta\}$$

$$f(\cdot|\Theta') = \{f(x|\theta) | \theta \in \Theta'\}; \quad \Theta' \subset \Theta$$

## リパラメトリゼーション

$$f(\cdot|\Lambda) = \{f(x|\lambda) | \lambda \in \Lambda\}$$

$$f(\cdot|\Theta) = \{f(x|r(\theta)) | \theta \in \Theta\}; \quad r(\theta), \theta \in \Theta$$

**【例】**  $X \sim N(\mu, I)$ ,  $\mu = (\mu_1, \dots, \mu_k)$  がパラメタ.  $\mu = r(\theta)$  の例は

- $\mu_1 = \theta, \dots, \mu_k = \theta$
- $\mu_i = \theta_1 + (i - 1)\theta_2, i = 1, \dots, k$
- $\mu_1 = \theta_1 \cos \theta_2 \sin \theta_3, \mu_2 = \theta_1 \sin \theta_2 \sin \theta_3, \mu_3 = \theta_1 \cos \theta_3;$   
 $\theta_1 \geq 0, -\pi < \theta_2 \leq \pi, -\pi/2 \leq \theta_3 \leq \pi/2$

A54