

# エコノメトリックスIII

## (2011年度後期 講義ノート)

平成 23 年 10 月 4 日 (火) 版

谷崎 久志  
大阪大学大学院経済学研究科

### 目次

1	事象と確率	1	5	積率と積率母関数	19
1.1	事象	1	5.1	積率母関数 (1 変数)	19
1.2	確率	1	5.2	積率母関数 (多変数)	24
2	確率変数と分布	2	練習問題と解答 (1 章 ~ 5 章)		25
2.1	1 次元の確率変数と分布	2	6	大数の法則と中心極限定理	34
2.2	多次元の確率変数と分布	3	6.1	Chebyshev の不等式	34
2.3	2.4 節のための数学の公式	4	6.2	大数の (弱) 法則 (Convergence in probability)	35
2.3.1	置換積分	4	6.3	中心極限定理	35
2.3.2	部分積分	5	7	大数の強法則 (Almost sure convergence)	36
2.3.3	テーラー展開: 関数 $f(x)$ の近似	5	8	統計的推定	36
2.4	分布関数の持つ性質の証明 (いくつかの分布を例にとって)	5	8.1	推定法と標本平均および標本分散の性質	36
3	平均値, 分散	7	8.1.1	推定法	36
3.1	平均・分散の定義と公式	7	8.1.2	標本, 統計量, 推定量	37
3.2	いくつかの分布の平均・分散	10	8.1.3	母平均, 母分散の推定	37
4	変数変換と和の分布 (連続型確率変数の場合のみ)	14	8.2	点推定法: 最適性	38
4.1	一変数の場合	14	8.3	推定量の求め方: 最尤法, 積率法, 最小二乗法	42
4.2	二変数の場合	16	8.3.1	最尤法	42
			8.3.2	積率法 (モーメント法)	45
			8.3.3	最小二乗法	46

9	標本分布	46
9.1	正規母集団の場合 (標本平均, 標本不偏分散 の標本分布) . . . . .	46
9.1.1	正規分布: 標本平均 $\bar{X}$ の標本分布	46
9.1.2	$\chi^2$ (カイ自乗) 分布: 標本不偏分散 $S^2$ の標本分布 . . . . .	47
9.1.3	$t$ 分布: 標本平均 $\bar{X}$ の標本分布 .	47
9.1.4	$F$ 分布 . . . . .	48
9.2	その他の母集団の場合: 標本平均 $\bar{X}$ の標 本分布 . . . . .	48
9.3	その他の母集団の場合: 母数の推定量 $\hat{\theta}_n$ の標本分布 (一般化) . . . . .	49
10	統計的検定: 大標本検定	50
10.1	ワルド (Wald) 検定 . . . . .	50
10.2	尤度比検定 . . . . .	51
	練習問題と解答 (6章 ~ 10章)	54

- この講義ノートは ,  
<http://www2.econ.osaka-u.ac.jp/~tanizaki/class>  
からダウンロード可。

## 参考文献

- 『確率統計演習 1 確率』(国沢清典編, 1966, 培風館)
- 『確率統計演習 2 統計』(国沢清典編, 1966, 培風館)
- R.V. Hogg and A.T. Craig, 1995, *Introduction to Mathematical Statistics* (Fifth edition), Prentice Hall.
- H. Tanizaki, 2004, *Computational Methods in Statistics and Econometrics* (STATISTICS: textbooks and monographs, Vol.172), MerceL Dekker.

# 1 事象と確率

## 1.1 事象

試行, 標本点, 標本空間

試行: 考察の対象となる実験(または, 観測)を行うこと

標本点  $\omega$ : 試行によって得られる個々の結果

標本空間  $\Omega$ : 標本点全体の集合

例: サイコロ投げ:

サイコロ投げ 1 回の試行

標本点: 1, 2, 3, 4, 5, 6 の六つ

標本空間:  $\Omega = \{1, 2, 3, 4, 5, 6\}$

事象とその演算

事象  $A$ : 標本空間  $\Omega$  の部分集合

$\omega$ : 事象  $A$  を構成する標本点の一つ

$\omega \in A$

例: サイコロ投げ:

サイコロ投げ 1 回の試行

$E = \{2, 4, 6\}$ : 偶数の目が出る事象

$F = \{1, 2, 3\}$ : 3 以下の目が出る事象

和事象:  $E \cup F$ : 事象  $E$  と  $F$  のどちらか一方に属する標本点  $\omega$  の全体から成る集合

積事象:  $E \cap F$ : 事象  $E$  と  $F$  のどちらにも属する標本点全体の集合

余事象:  $E^c$ : 事象  $E$  に属さない標本点の集合

空事象:  $\phi$ : 標本点を全然含まない事象

全事象:  $\Omega$ : 全部を含む事象

排反:  $E \cap F = \phi$  のとき, 事象  $E$  と  $F$  は互いに排反である

例: コイン投げ 3 回

表を H, 裏を T とする。

標本点は次の 8 つ:

$\omega_1 = \{H, H, H\}$ ,

$\omega_2 = \{H, H, T\}$ ,

$\omega_3 = \{H, T, H\}$ ,

$\omega_4 = \{H, T, T\}$ ,

$\omega_5 = \{T, H, H\}$ ,

$\omega_6 = \{T, H, T\}$ ,

$\omega_7 = \{T, T, H\}$ ,

$\omega_8 = \{T, T, T\}$

標本空間:  $\Omega = \{\omega_1, \omega_2, \omega_3, \omega_4, \omega_5, \omega_6, \omega_7, \omega_8\}$

2 回目表であるという事象  $E$ :

$E = \{\omega_1, \omega_2, \omega_5, \omega_6\}$

2 回表が出るという事象  $F$ :

$F = \{\omega_2, \omega_3, \omega_5\}$

$E \cup F = \{\omega_1, \omega_2, \omega_3, \omega_5, \omega_6\}$

$E \cap F = \{\omega_2, \omega_5\}$

$E^c = \{\omega_3, \omega_4, \omega_7, \omega_8\}$

$F^c = \{\omega_1, \omega_4, \omega_6, \omega_7, \omega_8\}$

$(E \cup F)^c = \{\omega_4, \omega_7, \omega_8\}$

$E^c \cap F^c = \{\omega_4, \omega_7, \omega_8\}$

$(E \cup F)^c = E^c \cap F^c \implies$  ド・モルガンの法則

$(E \cap F)^c = \{\omega_1, \omega_3, \omega_4, \omega_6, \omega_7, \omega_8\}$

$E^c \cup F^c = \{\omega_1, \omega_3, \omega_4, \omega_6, \omega_7, \omega_8\}$

$(E \cap F)^c = E^c \cup F^c \implies$  ド・モルガンの法則

## 1.2 確率

事象  $A$  の確率:  $P(A)$

$0 \leq P(A) \leq 1$

$P(\Omega) = 1, P(\phi) = 0$

事象  $A$  と  $B$  は互いに排反であるとき,  $P(A \cup B) = P(A) + P(B)$

条件付き確率: 事象  $B$  の条件のもとで事象  $A$  の確率

$\implies$

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

$P(A \cap B) = P(A|B)P(B) \implies$  乗法定理

事象  $A$  と  $B$  は独立:  $P(A \cap B) = P(A)P(B)$

公式:

$$P(A^c) = 1 - P(A)$$

$P(A \cup B) = P(A) + P(B) - P(A \cap B) \implies$  加法定理

$A \subset B$  のとき,  $P(A) \leq P(B)$

## 2 確率変数と分布

### 2.1 1次元の確率変数と分布

確率変数  $X$  : 標本空間  $\Omega$  の上で定義された実数値関数  $X = X(\omega)$  を考える。

$X = X(\omega)$  : 試行結果 (標本点)  $\omega$  が定まると  $X$  の値が定まる。

$X(\omega)$  がある区間  $I$  の中の値であるような標本点  $\omega$  の集合 :  $\{\omega; X(\omega) \in I\}$

$\{\omega; X(\omega) \in I\}$  を事象  $\{X \in I\}$  と書く。

離散型確率変数と確率分布 :

確率変数  $X$  の取りうる値を  $a_1, a_2, \dots$  とするとき,

$$P(X = a_i) = f(a_i), \quad i = 1, 2, \dots$$

$f(a_i)$  :  $X$  の確率分布

性質 :

$$f(a_i) \geq 0, \quad i = 1, 2, \dots$$

$$\sum_i f(a_i) = 1$$

ある集合  $A$  について,

$$P(X \in A) = \sum_{a_i \in A} f(a_i)$$

となる。

連続型確率変数と確率密度関数 :

ある区間  $I$  について,

$$P(X \in I) = \int_I f(x) dx$$

$f(x)$  :  $X$  の確率密度関数

性質 :

$$f(x) \geq 0,$$

$$\int_{-\infty}^{\infty} f(x) dx = 1$$

また,

$$P(X = x) = \int_x^x f(t) dt = 0,$$

$$P(X \in A) = \int_A f(x) dx$$

分布関数 :  $P(X \leq x) = F(x)$

$F(x)$  :  $X$  の分布関数

性質 :

$x_1 < x_2$  のとき,  $F(x_1) \leq F(x_2)$

$P(a < X \leq b) = F(b) - F(a)$

$F(-\infty) = 0, F(+\infty) = 1$

1. 離散型確率変数 :

$$F(x) = \sum_{a_i \leq x} f(a_i),$$

$$F(a_i) - F(a_i - 0) = f(a_i)$$

2. 連続型確率変数 :

$$F(x) = \int_{-\infty}^x f(t) dt,$$

$$F'(x) = f(x)$$

重要な分布 :

1. ベルヌイ分布 :

離散型確率変数  $X$  の取りうる値は  $0, 1$  のどちらかで, その確率分布は,

$$P(X = k) = p^k (1-p)^{1-k}, \quad k = 0, 1$$

$0 < p < 1$

2. 2項分布 :

離散型確率変数  $X$  の取りうる値が  $0, 1, 2, \dots, n$  で, その確率分布は,

$$P(X = k) = b(k; n, p)$$

$$\equiv {}_n C_k p^k (1-p)^{n-k},$$

$$k = 0, 1, \dots, n$$

$0 < p < 1$

3. ポアソン分布 :

離散型確率変数  $X$  の取りうる値が  $0, 1, 2, \dots$  で, その確率分布は,

$$P(X = k) = p(k; \lambda)$$

$$\equiv e^{-\lambda} \frac{\lambda^k}{k!}, \quad k = 0, 1, \dots$$

$\lambda > 0$

$np = \lambda$  (一定)のもとで,  $n \rightarrow \infty$  のとき,

$$b(k; n, p) \rightarrow p(k; \lambda)$$

4. 正規分布:

連続型確率変数  $X$  の確率密度関数は,

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}$$

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

$$N(0, 1) \Rightarrow \text{標準正規分布}$$

5. 一様分布:

連続型確率変数  $X$  の確率密度関数は,

$$f(x) = \begin{cases} \frac{1}{b-a}, & a \leq x \leq b \text{ のとき} \\ 0, & \text{その他のとき} \end{cases}$$

6. 指数分布:

連続型確率変数  $X$  の確率密度関数は,

$$f(x) = \begin{cases} \lambda e^{-\lambda x}, & 0 < x \text{ のとき} \\ 0, & \text{その他のとき} \end{cases}$$

$$\lambda > 0$$

$\lambda = \frac{1}{2}$  のとき, 自由度 2 のカイ自乗分布に等しい。

7.  $\chi^2$  (カイ 2 乗) 分布 (自由度  $n$ ):

連続型確率変数  $X$  の確率密度関数は,

$$f(x) = \begin{cases} \frac{1}{\Gamma(\frac{n}{2})} 2^{-\frac{n}{2}} x^{\frac{n}{2}-1} e^{-\frac{x}{2}}, & x \geq 0 \text{ のとき} \\ 0, & x < 0 \text{ のとき} \end{cases}$$

$$\Gamma(s) = \int_0^\infty u^{s-1} e^{-u} du \Rightarrow \text{ガンマ関数}$$

$$\Gamma(s+1) = s\Gamma(s), \Gamma(1) = 1, \Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$$

8.  $t$  分布 (自由度  $n$ ):

連続型確率変数  $X$  の確率密度関数は,

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

9. Cauchy 分布:

連続型確率変数  $X$  の確率密度関数は,

$$f(x) = \frac{1}{\pi(1+x^2)}$$

自由度 1 の  $t$  分布に等しい。

## 2.2 多次元の確率変数と分布

離散型確率変数  $X$  と  $Y$  の取りうる値は  $a_1, a_2, \dots$  と  $b_1, b_2, \dots$  とする。

事象  $\{\omega; X(\omega) = a_i, \text{ かつ } Y(\omega) = b_j\}$  の確率は

$$P(X = a_i, Y = b_j) = h(a_i, b_j)$$

$h(a_i, b_j)$ :  $X, Y$  の結合確率分布

性質:

$$h(a_i, b_j) \geq 0, \quad i, j = 1, 2, \dots$$

$$\sum_{i,j} h(a_i, b_j) = 1$$

$f(a_i), g(b_j)$  を次のように定義する。

$$f(a_i) = \sum_j h(a_i, b_j), \quad i = 1, 2, \dots$$

$$g(b_j) = \sum_i h(a_i, b_j), \quad j = 1, 2, \dots$$

$f(a_i), g(b_j)$ :  $X, Y$  の周辺確率分布

連続型確率変数  $X$  と  $Y$

ある領域  $D$  について, 事象  $\{\omega; (X(\omega), Y(\omega)) \in D\}$  の確率は

$$P((X, Y) \in D) = \iint_D h(x, y) dx dy$$

$h(x, y)$ :  $X, Y$  の結合確率密度関数

性質:

$$h(x, y) \geq 0,$$

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} h(x, y) dx dy = 1$$

$f(x), g(y)$  を次のように定義する。

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

$$g(y) = \int_{-\infty}^{\infty} h(x, y) dx,$$

$f(x), g(y)$ :  $X, Y$  の周辺確率密度関数

条件付き分布:

離散型:

$$P(X = a_i | Y = b_j) = \frac{f(a_i | b_j)}{g(b_j)} = \frac{h(a_i, b_j)}{g(b_j)}$$

$f(a_i|b_j)$ :  $Y = b_j$  を与えたもとで  $X$  の確率分布

性質:

$$f(a_i|b_j) \geq 0, \quad i = 1, 2, \dots$$

$$\sum_i f(a_i|b_j) = 1$$

連続型:

$$f(x|y) = \frac{h(x, y)}{g(y)}$$

$f(x|y)$ :  $Y = y$  を与えたもとで  $X$  の確率密度関数

性質:

$$f(x|y) \geq 0,$$

$$\int_{-\infty}^{\infty} f(x|y) = 1$$

確率変数の独立性:

離散型:  $h(a_i, b_j) = f(a_i)g(b_j)$  のとき,  $X$  と  $Y$  は独立となる。

連続型:  $h(x, y) = f(x)g(y)$  のとき,  $X$  と  $Y$  は独立となる。

重要な分布:

1. 多項分布:

離散型確率変数  $X_1, X_2, \dots, X_r$  について,

$$P(X_1 = k_1, X_2 = k_2, \dots, X_r = k_r) = \frac{n!}{k_1! k_2! \dots k_r!} p_1^{k_1} p_2^{k_2} \dots p_r^{k_r}$$

$k_1, k_2, \dots, k_r$  は 0 以上の整数で,  $\sum_{i=1}^r k_i = n$  を満たす。

$n$  は自然数

$p_1, p_2, \dots, p_r$  は正の定数で,  $\sum_{i=1}^r p_i = 1$  を満たす。

2. 変数正規分布:

連続型確率変数  $X, Y$  の結合確率密度関数は

$$\begin{aligned} & h(x, y) \\ &= \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \\ & \times \exp\left(-\frac{1}{2(1-\rho^2)}\left(\frac{(x-\mu_1)^2}{\sigma_1^2}\right.\right. \end{aligned}$$

$$\left. -2\rho\frac{(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2}\right)$$

$$\begin{aligned} &= \frac{1}{2\pi} \left| \begin{array}{cc} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{array} \right|^{-1/2} \\ & \times \exp\left(-\frac{1}{2} \begin{pmatrix} x-\mu_1 \\ y-\mu_2 \end{pmatrix}' \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}^{-1} \begin{pmatrix} x-\mu_1 \\ y-\mu_2 \end{pmatrix}\right) \end{aligned}$$

$\mu_1, \mu_2, \sigma_1, \sigma_2, \rho$  は定数で,  $\sigma_1 > 0, \sigma_2 > 0, |\rho| < 1$  とする。

$\exp(x)$  は  $e^x$  と同じものであることに注意。

## 2.3 2.4 節のための数学の公式

### 2.3.1 置換積分

1 変数:  $f(x)$  について,  $x = \psi(y)$  の置換積分を行う。

$$\int f(x)dx = \int \psi'(y)f(\psi(y))dy$$

証明:

$$F(x) = \int f(x)dx$$

$$\implies F'(x) = f(x)$$

$F(x) = F(\psi(y))$  を  $y$  について微分する。

$$\begin{aligned} \frac{dF(\psi(y))}{dy} &= \frac{dF(x)}{dx} \frac{dx}{dy} \\ &= f(x)\psi'(y) = f(\psi(y))\psi'(y) \end{aligned}$$

2 変数:  $f(x, y)$  について,  $x = \psi_1(u, v), y = \psi_2(u, v)$  のとき,

$$\begin{aligned} & \int \int f(x, y)dx dy \\ &= \int \int \left| \begin{array}{cc} \frac{\partial x}{\partial u} & \frac{\partial x}{\partial v} \\ \frac{\partial y}{\partial u} & \frac{\partial y}{\partial v} \end{array} \right| f(\psi_1(u, v), \psi_2(u, v)) du dv \end{aligned}$$

(証明略)

$A = \begin{pmatrix} a & b \\ c & d \end{pmatrix}$  とする。

$|A| = ad - bc$  を行列式の値と言う。

### 2.3.2 部分積分

$$\int f(x)g'(x)dx = f(x)g(x) - \int f'(x)g(x)dx$$

証明：

$f(x)g(x)$  の微分を考える。

$$\left( f(x)g(x) \right)' = f'(x)g(x) + f(x)g'(x)$$

両辺を積分すると，

$$\begin{aligned} \int \left( f(x)g(x) \right)' dx &= \int f'(x)g(x)dx + \int f(x)g'(x)dx \\ &= \int f'(x)g(x)dx + \int f(x)g'(x)dx \end{aligned}$$

となり，

$$f(x)g(x) = \int f'(x)g(x)dx + \int f(x)g'(x)dx$$

を得る。よって，

$$\int f(x)g'(x)dx = f(x)g(x) - \int f'(x)g(x)dx$$

### 2.3.3 テーラー展開：関数 $f(x)$ の近似

$x = x_0$  の回りで  $f(x)$  をテーラー展開する。

$$\begin{aligned} f(x) &\approx f(x_0) + f'(x_0)(x - x_0) \\ &\quad + \frac{1}{2!}f''(x_0)(x - x_0)^2 \\ &\quad + \frac{1}{3!}f'''(x_0)(x - x_0)^3 \\ &\quad + \dots \\ &= \sum_{n=0}^{\infty} \frac{1}{n!}f^{(n)}(x_0)(x - x_0)^n \end{aligned}$$

ただし， $f^{(n)}(x_0)$  は  $f(x)$  を  $n$  回微分して， $x = x_0$  で評価したものである。

$f^{(0)}(x_0) = f(x_0)$  と  $0! = 1$  に注意。

### 2.4 分布関数の持つ性質の証明 (いくつかの分布を例にとって)

1. 2項分布  $\sum_{k=0}^n b(k; n, p) = 1$  の証明：

$$\sum_{k=0}^n b(k; n, p)$$

$$\begin{aligned} &= \sum_{k=0}^n {}_n C_k p^k (1-p)^{n-k} \\ &= (p + (1-p))^n = 1 \quad (2 \text{項定理}) \end{aligned}$$

2. ポアソン分布  $\sum_{k=0}^{\infty} p(k; \lambda) = 1$  の証明：

$$\begin{aligned} \sum_{k=0}^{\infty} p(k; \lambda) &= \sum_{k=0}^{\infty} e^{-\lambda} \frac{\lambda^k}{k!} \\ &= e^{-\lambda} \sum_{k=0}^{\infty} \frac{\lambda^k}{k!} \\ &= e^{-\lambda} e^{\lambda} \\ &= 1 \end{aligned}$$

$e^x = \sum_{k=0}^{\infty} \frac{x^k}{k!}$  に注意。

なぜなら， $f(x) = e^x$  としたとき， $f^{(k)}(x) = e^x$  となる。

テーラー展開の公式は，

$$f(x) = \sum_{k=0}^{\infty} \frac{1}{k!} f^{(k)}(x_0)(x - x_0)^k$$

なので， $x_0 = 0$  として， $x = 0$  の回りでテーラー展開すると，

$$\begin{aligned} f(x) &= \sum_{k=0}^{\infty} \frac{1}{k!} f^{(k)}(0)x^k \\ &= \sum_{k=0}^{\infty} \frac{1}{k!} x^k \\ &= \sum_{k=0}^{\infty} \frac{x^k}{k!} \end{aligned}$$

を得る。

$f^{(n)}(0) = 1$  に注意。

3. 正規分布  $X \sim N(\mu, \sigma^2)$  の確率密度関数  $f(x)$  について， $\int_{-\infty}^{\infty} f(x)dx = 1$  の証明：

$$\begin{aligned} I &= \int_{-\infty}^{\infty} f(x)dx \\ &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(x - \mu)^2\right) dx \\ &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}u^2\right) du \end{aligned}$$

$u = \frac{x - \mu}{\sigma}$  として、置換積分を行う。

$\frac{dx}{du} = \sigma$  に注意

$I = 1$  の証明は  $I^2 = 1$  の証明を行えば十分

$$\begin{aligned} I^2 &= \left( \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}u^2\right) du \right) \\ &\quad \times \left( \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}v^2\right) dv \right) \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \exp\left(-\frac{1}{2}(u^2 + v^2)\right) dudv \\ &= \frac{1}{2\pi} \left( \int_0^{2\pi} d\theta \right) \left( \int_0^{\infty} \exp\left(-\frac{1}{2}r^2\right) r dr \right) \\ &= \frac{1}{2\pi} \left( \int_0^{2\pi} d\theta \right) \left( \int_0^{\infty} \exp(-s) ds \right) \\ &= \frac{1}{2\pi} 2\pi [-\exp(-s)]_0^{\infty} \\ &= 1 \end{aligned}$$

$u = r \cos \theta, v = r \sin \theta$  として置換積分を行う。

$$\begin{vmatrix} \frac{\partial u}{\partial r} & \frac{\partial u}{\partial \theta} \\ \frac{\partial v}{\partial r} & \frac{\partial v}{\partial \theta} \end{vmatrix} = \begin{vmatrix} \cos \theta & -r \sin \theta \\ \sin \theta & r \cos \theta \end{vmatrix} = r$$

$0 < r < +\infty, 0 < \theta < 2\pi$  となることに注意

さらに、 $s = \frac{1}{2}r^2$  と置換積分される。

このように、 $I^2 = 1$  が得られ、 $f(x) \geq 0$  なので、 $I = 1$  を得る。

4. 指数分布に従う  $X$  の確率密度関数  $f(x)$  について、

$\int_{-\infty}^{\infty} f(x) dx = 1$  の証明：

$$\begin{aligned} \int_{-\infty}^{\infty} f(x) dx &= \int_0^{\infty} \lambda e^{-\lambda x} dx \\ &= [-e^{-\lambda x}]_0^{\infty} \\ &= 1 \end{aligned}$$

5. 一様分布に従う  $X$  の確率密度関数  $f(x)$  について、

$\int_{-\infty}^{\infty} f(x) dx = 1$  の証明：

$$\begin{aligned} \int_{-\infty}^{\infty} f(x) dx &= \int_a^b \frac{1}{b-a} dx \\ &= \left[ \frac{1}{b-a} x \right]_a^b \\ &= 1 \end{aligned}$$

6.  $X, Y$  は2変数正規分布に従うとき、 $X$  の周辺確率密度関数は？

連続型確率変数  $X, Y$  の結合確率密度関数は

$$\begin{aligned} h(x, y) &= \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \\ &\quad \times \exp\left(-\frac{1}{2(1-\rho^2)}\left(\frac{(x-\mu_1)^2}{\sigma_1^2} - 2\rho\frac{(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2}\right)\right) \\ &= -\frac{1}{2(1-\rho^2)}\left(\frac{(x-\mu_1)^2}{\sigma_1^2} - 2\rho\frac{(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2}\right) \\ &= -\frac{1}{2(1-\rho^2)}\left(\frac{y-\mu_2}{\sigma_2} - \rho\frac{x-\mu_1}{\sigma_1}\right)^2 \\ &\quad - \frac{1}{2}\frac{(x-\mu_1)^2}{\sigma_1^2} \\ &= -\frac{1}{2(1-\rho^2)\sigma_2^2}\left((y-\mu_2) - \rho\frac{\sigma_2}{\sigma_1}(x-\mu_1)\right)^2 \\ &\quad - \frac{1}{2}\frac{(x-\mu_1)^2}{\sigma_1^2} \end{aligned}$$

$$\begin{aligned} f(x) &= \int_{-\infty}^{\infty} h(x, y) dy \\ &= \frac{1}{\sqrt{2\pi}\sigma_1^2} \exp\left(-\frac{1}{2\sigma_1^2}(x-\mu_1)^2\right) \\ &\quad \times \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi(1-\rho^2)\sigma_2^2}} \exp\left(-\frac{1}{2(1-\rho^2)\sigma_2^2}\right. \\ &\quad \left. \times \left((y-\mu_2) - \rho\frac{\sigma_2}{\sigma_1}(x-\mu_1)\right)^2\right) dy \end{aligned}$$

積分の部分は、 $N(\mu_2 + \rho\frac{\sigma_2}{\sigma_1}(x-\mu_1), (1-\rho^2)\sigma_2^2)$  に対応し、積分値は1になる。

したがって、

$$\int \int h(x, y) dy dx = \int f(x) dx = 1$$

を得る。 $f(x)$  は、平均  $\mu_1$ 、分散  $\sigma_1^2$  の正規分布になっていることに注意せよ。

### 3 平均値, 分散

#### 3.1 平均・分散の定義と公式

1 変数: 確率変数  $X$  のある関数:  $g(X)$

定義:

$g(X)$  の期待値  $E(g(X))$ :

$$E(g(X)) = \begin{cases} \sum_i g(x_i)p_i = \sum_i g(x_i)f(x_i), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} g(x)f(x)dx, & \text{連続型確率変数} \end{cases}$$

1. 確率変数  $X$  の平均  $E(X)$

$\implies X$  の期待値,  $g(X) = X$

$$E(X) = \begin{cases} \sum_i x_i f(x_i), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} x f(x) dx, & \text{連続型確率変数} \end{cases} \\ = \mu, \quad (\text{または}, \mu_x)$$

2. 確率変数  $X$  の分散  $V(X)$

$\implies (X - \mu)^2$  の期待値,  $g(X) = (X - \mu)^2$

$$V(X) = E((X - \mu)^2) \\ = \begin{cases} \sum_i (x_i - \mu)^2 f(x_i), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx, & \text{連続型確率変数} \end{cases} \\ = \sigma^2, \quad (\text{または}, \sigma_x^2)$$

確率変数  $X$  の分散  $V(X)$

$\implies X$  の確率分布の確率関数 (離散型の場合), または, 確率密度関数 (連続型の場合) の範囲が広ければ,  $V(X)$  は大きい。

いくつかの公式:

1.  $a, b$  を定数とする。

定理:  $E(aX + b) = aE(X) + b$

証明:

$X$  が離散型確率変数の場合,

$$E(aX + b) = \sum_i (ax_i + b)f(x_i) \\ = a \sum_i x_i f(x_i) + b \sum_i f(x_i) \\ = aE(X) + b$$

途中で,  $\sum_i f(x_i) = 1$  に注意

$X$  が連続型確率変数の場合,

$$E(aX + b) = \int_{-\infty}^{\infty} (ax + b)f(x)dx \\ = a \int_{-\infty}^{\infty} xf(x)dx + b \int_{-\infty}^{\infty} f(x)dx \\ = aE(X) + b$$

途中で,  $\int_{-\infty}^{\infty} f(x)dx = 1$  に注意

2. 定理:  $V(X) = E(X^2) - \mu^2$

証明:

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

途中で,  $\mu = E(X)$  に注意

3.  $a, b$  を定数とする。

定理:  $V(aX + b) = a^2V(X)$

証明:

$E(aX + b) = a\mu + b$  に注意して,

$$V(aX + b) = E(((aX + b) - E(aX + b))^2) \\ = E((aX - a\mu)^2) \\ = E(a^2(X - \mu)^2) \\ = a^2E((X - \mu)^2) \\ = a^2V(X)$$

を得る。

4. 定理： 確率変数  $X$  について,  $E(X) = \mu, V(X) = \sigma^2$  とする。

$Z = \frac{X - \mu}{\sigma}$  を定義する。

このとき,  $E(Z) = 0, V(Z) = 1$  となる。

証明：

$$E(Z) = E\left(\frac{X - \mu}{\sigma}\right) = \frac{E(X) - \mu}{\sigma} = 0$$

$$V(Z) = V\left(\frac{1}{\sigma}X - \frac{\mu}{\sigma}\right) = \frac{1}{\sigma^2}V(X) = 1$$

2 変数： 確率変数  $X, Y$  のある関数：  $g(X, Y)$

定義：

$g(X, Y)$  の期待値  $E(g(X, Y))$ ：

$$E(g(X, Y)) = \begin{cases} \sum_i \sum_j g(x_i, y_j) f(x_i, y_j), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f(x, y) dx dy, & \text{連続型確率変数} \end{cases}$$

1. 確率変数  $X$  の平均  $E(X)$

$\implies X$  の期待値,  $g(X, Y) = X$

$$E(X) = \begin{cases} \sum_i \sum_j x_i f(x_i, y_j), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x f(x, y) dx dy, & \text{連続型確率変数} \end{cases} = \mu_x$$

2. 確率変数  $X$  の分散  $V(X)$

$\implies (X - \mu_x)^2$  の期待値,  $g(X, Y) = (X - \mu_x)^2$

$$V(X) = E((X - \mu_x)^2)$$

$$= \begin{cases} \sum_i \sum_j (x_i - \mu_x)^2 f(x_i, y_j), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \mu_x)^2 f(x, y) dx dy, & \text{連続型確率変数} \end{cases} = \sigma_x^2$$

3. 確率変数  $X, Y$  の共分散  $\text{Cov}(X, Y)$

$\implies (X - \mu_x)(Y - \mu_y)$  の期待値,  $g(X, Y) = (X - \mu_x)(Y - \mu_y)$

$$\text{Cov}(X, Y) = E((X - \mu_x)(Y - \mu_y)) = \begin{cases} \sum_i \sum_j (x_i - \mu_x)(y_j - \mu_y) f(x_i, y_j), & \text{離散型確率変数} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \mu_x)(y - \mu_y) f(x, y) dx dy, & \text{連続型確率変数} \end{cases}$$

いくつかの公式：

1. 確率変数  $X, Y$  について,

定理：  $E(X + Y) = E(X) + E(Y)$

証明：

$$\begin{aligned} E(X + Y) &= \sum_i \sum_j (x_i + y_j) f(x_i, y_j) \\ &= \sum_i \sum_j x_i f(x_i, y_j) \\ &\quad + \sum_i \sum_j y_j f(x_i, y_j) \\ &= E(X) + E(Y) \end{aligned}$$

2. 確率変数  $X$  と  $Y$  が独立のとき,

定理：  $E(XY) = E(X)E(Y)$

証明：

$$E(XY) = \sum_i \sum_j x_i y_j f(x_i, y_j)$$

$$\begin{aligned}
&= \sum_i \sum_j x_i y_j f(x_i) h(y_j) \\
&= \sum_i x_i f(x_i) \sum_j y_j h(y_j) \\
&= E(X)E(Y)
\end{aligned}$$

3. 確率変数  $X, Y$  について,

定理:  $\text{Cov}(X, Y) = E(XY) - E(X)E(Y)$

証明:

$$\begin{aligned}
&\text{Cov}(X, Y) \\
&= \sum_i \sum_j (x_i - \mu_x)(y_j - \mu_y) p_{ij} \\
&= \sum_i \sum_j (x_i y_j - \mu_x y_j - \mu_y x_i + \mu_x \mu_y) p_{ij} \\
&= \sum_i \sum_j x_i y_j f(x_i, y_j) \\
&\quad - \mu_x \sum_i \sum_j y_j f(x_i, y_j) \\
&\quad - \mu_y \sum_i \sum_j x_i f(x_i, y_j) \\
&\quad + \mu_x \mu_y \sum_i \sum_j f(x_i, y_j) \\
&= \sum_i \sum_j x_i y_j f(x_i, y_j) - \mu_x \mu_y - \mu_y \mu_x + \mu_x \mu_y \\
&= \sum_i \sum_j x_i y_j f(x_i, y_j) - \mu_x \mu_y \\
&= E(XY) - E(X)E(Y)
\end{aligned}$$

より, 一般的な証明:

$$\begin{aligned}
&\text{Cov}(X, Y) \\
&= E((X - \mu_x)(Y - \mu_y)) \\
&= E(XY - \mu_x Y - \mu_y X + \mu_x \mu_y) \\
&= E(XY) - E(\mu_x Y) - E(\mu_y X) + \mu_x \mu_y \\
&= E(XY) - \mu_x E(Y) - \mu_y E(X) + \mu_x \mu_y \\
&= E(XY) - \mu_x \mu_y - \mu_y \mu_x + \mu_x \mu_y \\
&= E(XY) - \mu_x \mu_y \\
&= E(XY) - E(X)E(Y)
\end{aligned}$$

4. 確率変数  $X$  と  $Y$  が独立のとき,

$$E(XY) = E(X)E(Y)$$

となるので,

$$\text{Cov}(X, Y) = 0$$

を得る。

5. 相関係数  $\rho_{xy}$ :

$$\begin{aligned}
\rho_{xy} &= \frac{\text{Cov}(X, Y)}{\sqrt{V(X)}\sqrt{V(Y)}} \\
&= \frac{\text{Cov}(X, Y)}{\sigma_x \sigma_y}
\end{aligned}$$

6. 確率変数  $X$  と  $Y$  が独立のとき,

$$\text{Cov}(X, Y) = 0$$

となるので,

$$\rho_{xy} = 0$$

を得る。

7. 確率変数  $X, Y$  について,

$$V(X \pm Y) = V(X) \pm 2\text{Cov}(X, Y) + V(Y)$$

証明:

$$\begin{aligned}
&V(X \pm Y) \\
&= E\left(\left((X \pm Y) - E(X \pm Y)\right)^2\right) \\
&= E\left(\left((X - \mu_x) \pm (Y - \mu_y)\right)^2\right) \\
&= E\left(\left(X - \mu_x\right)^2 \pm 2(X - \mu_x)(Y - \mu_y) \right. \\
&\quad \left. + (Y - \mu_y)^2\right) \\
&= E\left(\left(X - \mu_x\right)^2\right) \\
&\quad \pm 2E\left(\left(X - \mu_x\right)(Y - \mu_y)\right) \\
&\quad + E\left(\left(Y - \mu_y\right)^2\right) \\
&= V(X) \pm 2\text{Cov}(X, Y) + V(Y)
\end{aligned}$$

8.  $-1 \leq \rho_{xy} \leq 1$

証明:

次のような  $t$  に関する式を考える。  $f(t) = V(Xt - Y)$  分散なので, 必ずゼロ以上となる。よって, すべての  $t$  について,  $f(t) \geq 0$  となるための条件を求めればよい。  $t$  に関する 2 次方程式の判別式がゼロ以下となる条件

を求める。  $V(Xt - Y) = V(Xt) - 2\text{Cov}(Xt, Y) + V(Y)$   
 $= t^2V(X) - 2t\text{Cov}(X, Y) + V(Y)$

$$\frac{D}{2} = (\text{Cov}(X, Y))^2 - V(X)V(Y) \leq 0$$

$$\frac{(\text{Cov}(X, Y))^2}{V(X)V(Y)} \leq 1$$

$$-1 \leq \frac{\text{Cov}(X, Y)}{\sqrt{V(X)}\sqrt{V(Y)}} \leq 1$$

$$-1 \leq \rho_{xy} \leq 1$$

$\rho_{xy}$  が 1 に近いほど，正の相関が強くなる。

$\rho_{xy}$  が -1 に近いほど，負の相関が強くなる。

9. 確率変数  $X$  と  $Y$  が独立のとき，

定理：  $V(X + Y) = V(X) + V(Y)$

証明：

$$V(X + Y) = V(X) + 2\text{Cov}(X, Y) + V(Y)$$

確率変数  $X$  と  $Y$  が独立のとき，

$$\text{Cov}(X, Y) = 0$$

なので，

$$V(X + Y) = V(X) + V(Y)$$

を得る。

10.  $n$  個の確率変数  $X_1, X_2, \dots, X_n$  について：

$E(X_i) = \mu_i$  とするとき，

$$E(\sum_i X_i) = \sum_i E(X_i) = \sum_i \mu_i$$

$$V(\sum_i X_i) \equiv E\left(\sum_i (X_i - \mu_i)\right)^2$$

$$= E\left(\sum_i (X_i - \mu_i)\right)\left(\sum_j (X_j - \mu_j)\right)$$

$$= E\left(\sum_i \sum_j (X_i - \mu_i)(X_j - \mu_j)\right)$$

$$= \sum_i \sum_j E\left((X_i - \mu_i)(X_j - \mu_j)\right)$$

$$= \sum_i \sum_j \text{Cov}(X_i, X_j)$$

11.  $n$  個の確率変数  $X_1, X_2, \dots, X_n$  は互いに独立で同じ平均  $\mu$ ，分散  $\sigma^2$  を持つとする。すなわち，すべての  $i = 1, 2, \dots, n$  について，

$$E(X_i) = \mu, \quad V(X_i) = \sigma^2$$

を仮定する。

さらに，算術平均  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  を考える。

このとき，

定理：  $E(\bar{X}) = \mu, V(\bar{X}) = \frac{\sigma^2}{n}$

が成り立つ。

証明：

$$E(\bar{X}) = E\left(\sum_i \frac{X_i}{n}\right) = \sum_i E\left(\frac{X_i}{n}\right)$$

$$= \sum_i \frac{1}{n} E(X_i) = \sum_i \frac{1}{n} \mu$$

$$= \mu$$

$$V(\bar{X}) = V\left(\sum_i \frac{X_i}{n}\right) = \sum_i V\left(\frac{X_i}{n}\right)$$

$$= \sum_i \frac{1}{n^2} V(X_i) = \sum_i \frac{1}{n^2} \sigma^2$$

$$= \frac{\sigma^2}{n}$$

### 3.2 いくつかの分布の平均・分散

ベルヌイ分布の平均と分散： ベルヌイ分布：

$$f(x) = p^x(1-p)^{1-x} \quad x = 0, 1$$

$$E(X) = p, V(X) = p(1-p)$$

証明：

平均：

$$E(X) = \sum_x x f(x)$$

$$= \sum_{x=0}^1 x p^x (1-p)^{1-x}$$

$$= p$$

分散：

$\mu = E(X)$  のとき， $V(X) = E(X^2) - \mu^2$  により， $E(X^2)$  を求める。

$$E(X^2) = \sum_x x^2 f(x)$$

$$= \sum_{x=0}^1 x^2 p^x (1-p)^{1-x}$$

$$= p$$

よって,

$$\begin{aligned} V(X) &= E(X^2) - \mu^2 \\ &= p - p^2 \\ &= p(1 - p) \end{aligned}$$

2 項分布の平均と分散: 2 項分布:

$$\begin{aligned} f(x) &= {}_n C_x p^x (1-p)^{n-x} \\ &= \frac{n!}{x!(n-x)!} p^x (1-p)^{n-x}, \quad x = 0, 1, 2, \dots, n, \end{aligned}$$

$$E(X) = np, \quad V(X) = np(1-p)$$

証明:

平均:

$$\begin{aligned} E(X) &= \sum_x x f(x) \\ &= \sum_x x {}_n C_x p^x (1-p)^{n-x} \\ &= \sum_x x \frac{n!}{x!(n-x)!} p^x (1-p)^{n-x} \\ &= \sum_x \frac{n!}{(x-1)!(n-x)!} p^x (1-p)^{n-x} \\ &= np \sum_x \frac{(n-1)!}{(x-1)!(n-x)!} p^{x-1} (1-p)^{n-x} \\ &= np \sum_{x'} \frac{n!}{x'!(n'-x')!} p^{x'} (1-p)^{n'-x'} \\ &= np \sum_{x'} {}_{n'} C_{x'} p^{x'} (1-p)^{n'-x'} \\ &= np \end{aligned}$$

ただし,  $n' = n - 1$ ,  $x' = x - 1$  と定義される。

確率関数の性質より,

$$\sum_x {}_n C_x p^x (1-p)^{n-x} = 1$$

を得ることに注意。

分散:

$V(X) = E(X^2) - \mu^2$  により,  $E(X^2)$  を求める。

$X^2 = X(X-1) + X$  を利用する。

$$E(X^2) = E(X(X-1)) + E(X)$$

したがって,

$$V(X) = E(X(X-1)) + \mu - \mu^2 \text{ となる。}$$

右辺第 1 項を求める。

$$\begin{aligned} &E(X(X-1)) \\ &= \sum_x x(x-1)f(x) \\ &= \sum_x x(x-1) {}_n C_x p^x (1-p)^{n-x} \\ &= \sum_x x(x-1) \frac{n!}{x!(n-x)!} p^x (1-p)^{n-x} \\ &= \sum_x \frac{n!}{(x-2)!(n-x)!} p^x (1-p)^{n-x} \\ &= n(n-1)p^2 \sum_x \frac{(n-2)!}{(x-2)!(n-x)!} p^{x-2} (1-p)^{n-x} \\ &= n(n-1)p^2 \sum_{x'} \frac{n!}{x'!(n'-x')!} p^{x'} (1-p)^{n'-x'} \\ &= n(n-1)p^2 \sum_{x'} {}_{n'} C_{x'} p^{x'} (1-p)^{n'-x'} \\ &= n(n-1)p^2 \end{aligned}$$

途中で,  $n' = n - 2$ ,  $x' = x - 2$  と定義されている。

まとめると,

$$\begin{aligned} V(X) &= E(X^2) - \mu^2 \\ &= E(X(X-1)) + \mu - \mu^2 \\ &= n(n-1)p^2 + np - n^2p^2 \\ &= -np^2 + np \\ &= np(1-p) \end{aligned}$$

ポアソン分布の平均と分散: ポアソン分布:

$$f(x) = e^{-\lambda} \frac{\lambda^k}{k!}, \quad k = 0, 1, 2, \dots, n,$$

$$E(X) = \lambda, \quad V(X) = \lambda$$

証明:

平均:

$$\begin{aligned} E(X) &= \sum_k k f(k) \\ &= \sum_k k e^{-\lambda} \frac{\lambda^k}{k!} \\ &= \sum_k \lambda e^{-\lambda} \frac{\lambda^{k-1}}{(k-1)!} \\ &= \lambda \sum_{k'} e^{-\lambda} \frac{\lambda^{k'}}{k'!} \\ &= \lambda \end{aligned}$$

ただし,  $k' = k - 1$  と定義される。

確率関数の性質より,

$$\sum_k e^{-\lambda} \frac{\lambda^k}{k!} = 1,$$

を得ることに注意。

分散:

$V(X) = E(X^2) - \mu^2$  により,  $E(X^2)$  を求める。

$X^2 = X(X - 1) + X$  を利用する。

$$E(X^2) = E(X(X - 1)) + E(X)$$

したがって,

$$V(X) = E(X(X - 1)) + \mu - \mu^2 \text{ となる。}$$

右辺第 1 項を求める。

$$\begin{aligned} & E(X(X - 1)) \\ &= \sum_k k(k - 1)f(k) \\ &= \sum_k k(k - 1)e^{-\lambda} \frac{\lambda^k}{k!} \\ &= \sum_k \lambda^2 e^{-\lambda} \frac{\lambda^{k-2}}{(k - 2)!} \\ &= \lambda^2 \sum_{k'} e^{-\lambda} \frac{\lambda^{k'}}{k'!} \end{aligned}$$

途中で,  $k' = k - 2$  と定義されている。

まとめると,

$$\begin{aligned} V(X) &= E(X^2) - \mu^2 \\ &= E(X(X - 1)) + \mu - \mu^2 \\ &= \lambda^2 + \lambda - \lambda^2 \\ &= \lambda \end{aligned}$$

正規分布の平均と分散: 正規分布:  $X \sim N(\mu, \sigma^2)$

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}$$

$$E(X) = \mu, V(X) = \sigma^2$$

証明:

平均:

$$\begin{aligned} E(X) &= \int_{-\infty}^{\infty} x f(x) dx \\ &= \int_{-\infty}^{\infty} ((x - \mu) + \mu) f(x) dx \end{aligned}$$

$$\begin{aligned} &= \int_{-\infty}^{\infty} (x - \mu) f(x) dx + \mu \int_{-\infty}^{\infty} f(x) dx \\ &= \int_{-\infty}^{\infty} (x - \mu) \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx + \mu \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \left[ -\sigma^2 e^{-\frac{1}{2\sigma^2}(x-\mu)^2} \right]_{-\infty}^{\infty} + \mu \\ &= \mu \end{aligned}$$

確率密度関数の性質から,

$$\begin{aligned} & \int_{-\infty}^{\infty} f(x) dx \\ &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\ &= 1 \end{aligned}$$

となることに注意。

合成関数の微分:

$$y = h(g(x)) \implies y = h(u), u = g(x)$$

$$\begin{aligned} \frac{dy}{dx} &= \frac{dy}{du} \frac{du}{dx} \\ &= h'(u) g'(x) \\ &= h(g(x)) g'(x) \end{aligned}$$

上の計算では,

$$h(u) = -\sigma^2 e^u, g(x) = -\frac{1}{2\sigma^2}(x - \mu)^2$$

とすればよい。

ロピタルの定理:

ある関数  $g(x), f(x)$  について,

$$\lim_{x \rightarrow \infty} \frac{f'(x)}{g'(x)} = A$$

ならば,

$$\lim_{x \rightarrow \infty} \frac{f(x)}{g(x)} = A$$

となる。

例:

$$\begin{aligned} \lim_{x \rightarrow \infty} \frac{x}{e^x} &= \lim_{x \rightarrow \infty} \frac{1}{e^x} = 0 \\ \frac{de^x}{dx} &= e^x \text{ に注意。} \end{aligned}$$

分散:

$$V(X) = E(X - \mu)^2$$

$$\begin{aligned} V(X) &= \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx \\ &= \int_{-\infty}^{\infty} (x - \mu)^2 \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \int_{-\infty}^{\infty} (x - \mu) \frac{d\left(-\sigma^2 e^{-\frac{1}{2\sigma^2}(x-\mu)^2}\right)}{dx} dx \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \left[ (x - \mu) \left(-\sigma^2 e^{-\frac{1}{2\sigma^2}(x-\mu)^2}\right) \right]_{-\infty}^{\infty} \\ &\quad + \frac{1}{\sqrt{2\pi\sigma^2}} \int_{-\infty}^{\infty} \sigma^2 e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\ &= \sigma^2 \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\ &= \sigma^2 \end{aligned}$$

部分積分：

$$\int_a^b h(x)g'(x)dx = \left[ h(x)g(x) \right]_a^b - \int_a^b h'(x)g(x)dx \text{ を利用。}$$

$h(x) = x - \mu, g(x) = -\sigma^2 e^{-\frac{1}{2\sigma^2}(x-\mu)^2}$  とする。

指数分布の平均と分散： 指数分布：

$$f(x) = \begin{cases} \lambda e^{-\lambda x}, & 0 < x \text{ のとき} \\ 0, & \text{その他のとき} \end{cases}$$

$$E(X) = \frac{1}{\lambda}, V(X) = \frac{1}{\lambda^2}$$

証明：

平均：

$$\begin{aligned} E(X) &= \int_{-\infty}^{\infty} x f(x) dx \\ &= \int_0^{\infty} x \lambda e^{-\lambda x} dx \\ &= \int_0^{\infty} x \frac{d(-e^{-\lambda x})}{dx} dx \\ &= \left[ x(-e^{-\lambda x}) \right]_0^{\infty} + \int_0^{\infty} e^{-\lambda x} dx \\ &= \frac{1}{\lambda} \int_0^{\infty} \lambda e^{-\lambda x} dx \\ &= \frac{1}{\lambda} \end{aligned}$$

確率密度関数の性質から，

$$\begin{aligned} \int_{-\infty}^{\infty} f(x) dx &= \int_0^{\infty} \lambda e^{-\lambda x} dx \\ &= \left[ -e^{-\lambda x} \right]_0^{\infty} \\ &= 1 \end{aligned}$$

に注意。

分散：

$V(X) = E(X^2) - \mu^2$  により， $E(X^2)$  を求める。

$$\begin{aligned} E(X^2) &= \int_{-\infty}^{\infty} x^2 f(x) dx \\ &= \int_0^{\infty} x^2 \lambda e^{-\lambda x} dx \\ &= \int_0^{\infty} x^2 \frac{d(-e^{-\lambda x})}{dx} dx \\ &= \left[ x^2(-e^{-\lambda x}) \right]_0^{\infty} + 2 \int_0^{\infty} x e^{-\lambda x} dx \\ &= \frac{2}{\lambda} \int_0^{\infty} x \lambda e^{-\lambda x} dx \\ &= \frac{2}{\lambda} E(X) \\ &= \frac{2}{\lambda^2} \end{aligned}$$

$$\begin{aligned} V(X) &= E(X^2) - \mu^2 \\ &= \frac{2}{\lambda^2} - \frac{1}{\lambda^2} \\ &= \frac{1}{\lambda^2} \end{aligned}$$

一様分布の平均と分散： 一様分布：

$$f(x) = \begin{cases} \frac{1}{b-a}, & a < x < b \text{ のとき} \\ 0, & \text{その他のとき} \end{cases}$$

$$E(X) = \frac{b-a}{2}, V(X) = \frac{(b-a)^2}{12}$$

証明：

平均：

$$\begin{aligned} E(X) &= \int_{-\infty}^{\infty} x f(x) dx \\ &= \int_a^b x \frac{1}{b-a} dx \\ &= \frac{1}{b-a} \left[ \frac{x^2}{2} \right]_a^b \\ &= \frac{a+b}{2} \end{aligned}$$

分散：

$V(X) = E(X^2) - \mu^2$  により， $E(X^2)$  を求める。

$$\begin{aligned} E(X^2) &= \int_{-\infty}^{\infty} x^2 f(x) dx \\ &= \int_a^b x^2 \frac{1}{b-a} dx \end{aligned}$$

$$= \frac{1}{b-a} \left[ \frac{x^3}{3} \right]_a^b$$

$$= \frac{a^2 + ab + b^2}{3}$$

$$V(X) = \frac{a^2 + ab + b^2}{3} - \left( \frac{a+b}{2} \right)^2$$

$$= \frac{(b-a)^2}{12}$$

カイ二乗分布の平均と分散： カイ二乗分布：

$$f(x) = \begin{cases} \frac{1}{\Gamma(\frac{n}{2})} 2^{-\frac{n}{2}} x^{\frac{n}{2}-1} e^{-\frac{x}{2}}, & x \geq 0 \text{ のとき} \\ 0, & x < 0 \text{ のとき} \end{cases}$$

$$E(X) = n, V(X) = 2n$$

証明：

平均：

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

$$= \int_0^{\infty} x \frac{1}{\Gamma(\frac{n}{2})} 2^{-\frac{n}{2}} x^{\frac{n}{2}-1} e^{-\frac{x}{2}} dx$$

$$= \frac{2^{-\frac{n}{2}} \Gamma(\frac{n+2}{2})}{2^{-\frac{n+2}{2}} \Gamma(\frac{n}{2})}$$

$$\times \int_0^{\infty} \frac{1}{\Gamma(\frac{n+2}{2})} 2^{-\frac{n+2}{2}} x^{\frac{n+2}{2}-1} e^{-\frac{x}{2}} dx$$

$$= 2 \frac{n}{2} \int_0^{\infty} \frac{1}{\Gamma(\frac{n'}{2})} 2^{-\frac{n'}{2}} x^{\frac{n'}{2}-1} e^{-\frac{x}{2}} dx$$

$$= n$$

$$\Gamma(s) = \int_0^{\infty} u^{s-1} e^{-u} du \implies \text{ガンマ関数 } \Gamma(s+1) = s\Gamma(s),$$

$$\Gamma(1) = 1, \Gamma\left(\frac{1}{2}\right) = \sqrt{\pi} \text{ に注意}$$

また,  $n' = n + 2$  を使い, 確率密度関数の性質から,

$$\int_{-\infty}^{\infty} f(x) dx = \int_0^{\infty} \frac{1}{\Gamma(\frac{n}{2})} 2^{-\frac{n}{2}} x^{\frac{n}{2}-1} e^{-\frac{x}{2}} dx = 1$$

に注意。

分散：

$V(X) = E(X^2) - \mu^2$  により,  $E(X^2)$  を求める。

$$E(X^2) = \int_{-\infty}^{\infty} x^2 f(x) dx$$

$$= \int_0^{\infty} x^2 \frac{1}{\Gamma(\frac{n}{2})} 2^{-\frac{n}{2}} x^{\frac{n}{2}-1} e^{-\frac{x}{2}} dx$$

$$= \int_0^{\infty} \frac{1}{\Gamma(\frac{n}{2})} 2^{-\frac{n}{2}} x^{\frac{n+4}{2}-1} e^{-\frac{x}{2}} dx$$

$$= \frac{2^{-\frac{n}{2}} \Gamma(\frac{n+4}{2})}{2^{-\frac{n+4}{2}} \Gamma(\frac{n}{2})}$$

$$\times \int_0^{\infty} \frac{1}{\Gamma(\frac{n+4}{2})} 2^{-\frac{n+4}{2}} x^{\frac{n+4}{2}-1} e^{-\frac{x}{2}} dx$$

$$= 4 \left( \frac{n+2}{2} \right) \int_0^{\infty} \frac{1}{\Gamma(\frac{n'}{2})} 2^{-\frac{n'}{2}} x^{\frac{n'}{2}-1} e^{-\frac{x}{2}} dx$$

$$= n(n+2)$$

$n' = n + 4$  を使う。

$$V(X) = n(n+2) - n^2 = 2n$$

## 4 変数変換と和の分布 (連続型確率変数の場合のみ)

### 4.1 一変数の場合

$Y = \psi^{-1}(X)$  の分布： 連続型確率変数  $X$  の確率密度関数  $f(x)$

$X = \psi(Y)$  の一対一変換のとき,

$Y$  の確率密度関数  $g(y)$  は,

$$g(y) = |\psi'(y)| f(\psi(y))$$

証明：

確率変数  $X$  の分布関数を  $F(x)$ , 確率密度関数を  $f(x)$  とする。

(すなわち,  $F(x) = P(X \leq x)$ ,  $f(x) = F'(x)$  である。)

$Y = h(X)$  とする。

$X = \psi(Y)$  のとき,  $Y$  の分布を求める。

すなわち,  $h^{-1}(Y) = \psi(Y)$  となる。

$Y$  の分布関数を  $G(y)$ , 確率密度関数を  $g(y)$  とする。

$\psi'(X) > 0$  の場合：

$$G(y) = P(Y \leq y)$$

$$= P(h(X) \leq y)$$

$$= P(X \leq h^{-1}(y))$$

$$= P(X \leq \psi(y))$$

$$= F(\psi(y))$$

なので,

$$g(y) = G'(y)$$

$$= \psi'(y) F'(\psi(y))$$

$$= \psi'(y) f(\psi(y))$$

を得る。

$\psi'(X) < 0$  の場合：

$$\begin{aligned}
G(y) &= P(Y \leq y) \\
&= P(h(X) \leq y) \\
&= P(X \geq h^{-1}(y)) \\
&= P(X \geq \psi(y)) \\
&= 1 - P(X < \psi(y)) \\
&= 1 - F(\psi(y))
\end{aligned}$$

なので，

$$\begin{aligned}
g(y) &= G'(y) \\
&= -\psi'(y)F'(\psi(y)) \\
&= -\psi'(y)f(\psi(y))
\end{aligned}$$

を得る。 $-\psi'(y) > 0$  に注意したがって，まとめると，

$$g(y) = |\psi'(y)|f(\psi(y))$$

を得る。⇒ 変数変換

例：  $X$  は次の一様分布に従う。

$$f(x) = \begin{cases} 1, & 0 < x < 1 \text{ のとき} \\ 0, & \text{その他} \end{cases}$$

$\lambda > 0$  について， $X = e^{-\lambda Y}$  とするとき， $Y$  の分布は？

$\psi'(y) = -\lambda e^{-\lambda y}$  なので，

$$\begin{aligned}
g(y) &= |\psi'(y)|f(\psi(y)) \\
&= \lambda e^{-\lambda y}
\end{aligned}$$

となる。 $y$  のとりうる範囲は， $0 < x < 1$  により， $0 < e^{-\lambda y} < 1$  なので， $0 < y$  となる。したがって，

$$g(y) = \begin{cases} \lambda e^{-\lambda y}, & 0 < y \text{ のとき} \\ 0, & \text{その他} \end{cases}$$

特殊ケース：  $Y = X^2$  の分布について： 確率変数  $X$  の分布関数を  $F(x)$ ，確率密度関数を  $f(x)$  とする。確率変数  $Y$  の分布関数を  $G(y)$ ，確率密度関数を  $g(y)$  とする。

$Y = X^2$  の分布関数  $G(y)$  は，

$$\begin{aligned}
G(y) &= P(Y \leq y) \\
&= P(X^2 \leq y) \\
&= P(-\sqrt{y} \leq X \leq \sqrt{y}) \\
&= F(\sqrt{y}) - F(-\sqrt{y})
\end{aligned}$$

したがって，

$$\begin{aligned}
g(y) &= G'(y) \\
&= \frac{1}{2\sqrt{y}}(f(\sqrt{y}) + f(-\sqrt{y}))
\end{aligned}$$

例：  $\chi^2(1)$  分布：  $X \sim N(0, 1)$  とするとき， $Y = X^2 \sim \chi^2(1)$  となる。

証明：

$X$  の分布関数とその微分：

$$\begin{aligned}
F(x) &= \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}u^2\right) du \\
f(x) &= F'(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}x^2\right)
\end{aligned}$$

$Y$  の確率密度関数  $g(y)$  は， $y > 0$  について，

$$\begin{aligned}
g(y) &= G'(y) \\
&= \frac{1}{2\sqrt{y}}(F'(\sqrt{y}) + F'(-\sqrt{y})) \\
&= \frac{1}{\sqrt{2\pi}\sqrt{y}} \exp\left(-\frac{1}{2}y\right) \\
&= \frac{1}{\Gamma(\frac{1}{2})2^{\frac{1}{2}}} y^{\frac{1}{2}-1} \exp\left(-\frac{1}{2}y\right)
\end{aligned}$$

これは  $Y \sim \chi^2(1)$  を意味する。

$\Gamma(\frac{1}{2}) = \sqrt{\pi}$  に注意

$Y \sim \chi^2(n)$  のとき， $Y$  の確率密度関数は，

$$f(y) = \frac{1}{2^{\frac{n}{2}}\Gamma(\frac{n}{2})} y^{\frac{n}{2}-1} \exp\left(-\frac{y}{2}\right)$$

に注意

例：  $N(0, 1)$  分布：  $X \sim N(\mu, \sigma^2)$  とするとき， $Y = \frac{X - \mu}{\sigma} \sim N(0, 1)$  となる。

証明：

$X$  の分布関数：

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

$X = \psi(Y) = \sigma Y + \mu$  なので,  $Y$  の密度関数は,

$$\begin{aligned} g(y) &= |\psi'(y)|f(\psi(y)) \\ &= |\sigma| \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2}y^2\right) \\ &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}y^2\right) \end{aligned}$$

となる。これは,  $N(0, 1)$  に一致する。

## 4.2 二変数の場合

$X = \psi_1(U, V)$ ,  $Y = \psi_2(U, V)$  のとき,  $(U, V)$  の分布: 確率変数  $X, Y$  の結合密度関数  $f(x, y)$  について,  $X = \psi_1(U, V)$ ,  $Y = \psi_2(U, V)$  のとき, 確率変数  $U, V$  の結合密度関数  $g(u, v)$

$$g(u, v) = |J|f(\psi_1(u, v), \psi_2(u, v))$$

ただし,  $J$  はヤコビアンと呼ばれ,

$$J = \begin{vmatrix} \frac{\partial x}{\partial u} & \frac{\partial x}{\partial v} \\ \frac{\partial y}{\partial u} & \frac{\partial y}{\partial v} \end{vmatrix}$$

である (証明略)。

$U$  の周辺密度関数  $h(u)$ :

$$h(u) = \int g(u, v)dv$$

$V$  の周辺密度関数  $p(v)$ :

$$p(v) = \int g(u, v)du$$

例: 正規分布:  $X, Y$  は互いに独立な確率変数でそれぞれ正規分布  $N(\mu_1, \sigma_1^2)$ ,  $N(\mu_2, \sigma_2^2)$  に従うとき,  $X + Y \sim N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$  となる。

証明:

$X, Y$  の確率密度関数

$$\begin{aligned} f(x) &= \frac{1}{\sqrt{2\pi\sigma_1^2}} \exp\left(-\frac{1}{2\sigma_1^2}(x - \mu_1)^2\right) \\ g(y) &= \frac{1}{\sqrt{2\pi\sigma_2^2}} \exp\left(-\frac{1}{2\sigma_2^2}(y - \mu_2)^2\right) \end{aligned}$$

$X, Y$  の結合確率密度関数は,  $X, Y$  は互いに独立な確率変数なので,

$$\begin{aligned} h(x, y) &= f(x)g(y) \\ &= \frac{1}{2\pi\sigma_1\sigma_2} \exp\left(-\frac{1}{2\sigma_1^2}(x - \mu_1)^2 - \frac{1}{2\sigma_2^2}(y - \mu_2)^2\right) \end{aligned}$$

$U = X + Y, V = Y$  として,  $U, V$  の結合確率密度関数を求める。  $X = U - V, Y = V$  なので,

$$J = \begin{vmatrix} \frac{\partial x}{\partial u} & \frac{\partial x}{\partial v} \\ \frac{\partial y}{\partial u} & \frac{\partial y}{\partial v} \end{vmatrix} = \begin{vmatrix} 1 & -1 \\ 0 & 1 \end{vmatrix} = 1$$

となるので,  $U, V$  の結合確率密度関数  $s(u, v)$  は, 変数変換により,

$$\begin{aligned} s(u, v) &= h(u - v, v)|J| \\ &= \frac{1}{2\pi\sigma_1\sigma_2} \exp\left(-\frac{1}{2\sigma_1^2}(u - v - \mu_1)^2 - \frac{1}{2\sigma_2^2}(v - \mu_2)^2\right) \end{aligned}$$

$U$  の周辺確率密度関数  $p(u)$  を求める。

$$\begin{aligned} p(u) &= \int s(u, v)dv \\ &= \int \frac{1}{2\pi\sigma_1\sigma_2} \exp\left(-\frac{1}{2\sigma_1^2}(u - v - \mu_1)^2 - \frac{1}{2\sigma_2^2}(v - \mu_2)^2\right)dv \\ &= \int \frac{1}{2\pi\sigma_1\sigma_2} \exp\left(-\frac{1}{2\sigma_1^2}((v - \mu_2) - (u - \mu_1 - \mu_2))^2 - \frac{1}{2\sigma_2^2}(v - \mu_2)^2\right)dv \\ &= \int \frac{1}{2\pi\sigma_1\sigma_2} \exp\left(-\frac{1}{2/(1/\sigma_1^2 + 1/\sigma_2^2)}((v - \mu_2) - \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2}(u - \mu_1 - \mu_2))^2 - \frac{1}{2(\sigma_1^2 + \sigma_2^2)}(u - \mu_1 - \mu_2)^2\right)dv \\ &= \int \frac{1}{\sqrt{2\pi/(1/\sigma_1^2 + 1/\sigma_2^2)}} \times \exp\left(-\frac{1}{2/(1/\sigma_1^2 + 1/\sigma_2^2)}((v - \mu_2) - \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2}(u - \mu_1 - \mu_2))^2 - \frac{1}{2(\sigma_1^2 + \sigma_2^2)}(u - \mu_1 - \mu_2)^2\right)dv \end{aligned}$$

$$\begin{aligned}
& -\frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2}(u - \mu_1 - \mu_2)^2) \\
& \times \frac{1}{\sqrt{2\pi(\sigma_1^2 + \sigma_2^2)}} \exp\left(-\frac{1}{2(\sigma_1^2 + \sigma_2^2)}(u - \mu_1 - \mu_2)^2\right) dv \\
& = \int \frac{1}{\sqrt{2\pi/(1/\sigma_1^2 + 1/\sigma_2^2)}} \\
& \times \exp\left(-\frac{1}{2/(1/\sigma_1^2 + 1/\sigma_2^2)}((v - \mu_2) \right. \\
& \quad \left. -\frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2}(u - \mu_1 - \mu_2))^2\right) dv \\
& \times \frac{1}{\sqrt{2\pi(\sigma_1^2 + \sigma_2^2)}} \exp\left(-\frac{1}{2(\sigma_1^2 + \sigma_2^2)}(u - \mu_1 - \mu_2)^2\right) \\
& = \frac{1}{\sqrt{2\pi(\sigma_1^2 + \sigma_2^2)}} \exp\left(-\frac{1}{2(\sigma_1^2 + \sigma_2^2)}(u - \mu_1 - \mu_2)^2\right)
\end{aligned}$$

例： $\chi^2$  分布：  $X, Y$  は互いに独立で， $X \sim \chi^2(n), Y \sim \chi^2(m)$  とするとき， $U = X + Y \sim \chi^2(n + m)$  となる。

証明：

$$\begin{aligned}
f(x) &= \frac{1}{2^{\frac{n}{2}}\Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} \exp(-\frac{x}{2}), \quad x > 0 \\
g(y) &= \frac{1}{2^{\frac{m}{2}}\Gamma(\frac{m}{2})} y^{\frac{m}{2}-1} \exp(-\frac{y}{2}), \quad y > 0
\end{aligned}$$

$X, Y$  の結合確率密度関数は， $X, Y$  は互いに独立な確率変数なので，

$$\begin{aligned}
& h(x, y) \\
& = f(x)g(y) \\
& = \frac{1}{2^{\frac{n}{2}}\Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} \exp(-\frac{x}{2}) \frac{1}{2^{\frac{m}{2}}\Gamma(\frac{m}{2})} y^{\frac{m}{2}-1} \exp(-\frac{y}{2}) \\
& = C x^{\frac{n}{2}-1} y^{\frac{m}{2}-1} \exp(-\frac{x+y}{2})
\end{aligned}$$

ただし， $C = \frac{1}{2^{\frac{n+m}{2}}\Gamma(\frac{n}{2})\Gamma(\frac{m}{2})}$  とする。

$U = X + Y, V = Y$  として，変数変換を行う。

$X = U - V, Y = V$  なので，

$$J = \begin{vmatrix} \frac{\partial x}{\partial u} & \frac{\partial x}{\partial v} \\ \frac{\partial y}{\partial u} & \frac{\partial y}{\partial v} \end{vmatrix} = \begin{vmatrix} 1 & -1 \\ 0 & 1 \end{vmatrix} = 1$$

となるので， $U, V$  の結合確率密度関数  $s(u, v)$  は，変数変換により，

$$s(u, v)$$

$$\begin{aligned}
& = h(u - v, v)|J| \\
& = C(u - v)^{\frac{n}{2}-1} v^{\frac{m}{2}-1} \exp(-\frac{u}{2})
\end{aligned}$$

$U$  の周辺確率密度関数は，

$$\begin{aligned}
& p(u) \\
& = \int s(u, v) dv \\
& = C \exp(-\frac{u}{2}) \int_0^\infty (u - v)^{\frac{n}{2}-1} v^{\frac{m}{2}-1} dv \\
& = C \exp(-\frac{u}{2}) \int_0^\infty (u - uw)^{\frac{n}{2}-1} (uw)^{\frac{m}{2}-1} u dw \\
& = C u^{\frac{n+m}{2}-1} \exp(-\frac{u}{2}) \int_0^\infty (1 - w)^{\frac{n}{2}-1} w^{\frac{m}{2}-1} dw \\
& = CB\left(\frac{n}{2}, \frac{m}{2}\right) u^{\frac{n+m}{2}-1} \exp(-\frac{u}{2}) \\
& = \frac{1}{2^{\frac{n+m}{2}}\Gamma(\frac{n}{2})\Gamma(\frac{m}{2})} \frac{\Gamma(\frac{n}{2})\Gamma(\frac{m}{2})}{\Gamma(\frac{n+m}{2})} u^{\frac{n+m}{2}-1} \exp(-\frac{u}{2}) \\
& = \frac{1}{2^{\frac{n+m}{2}}\Gamma(\frac{n+m}{2})} u^{\frac{n+m}{2}-1} \exp(-\frac{u}{2})
\end{aligned}$$

$w = \frac{v}{u}$ ，すなわち， $v = uw$  として置換積分 ( $\frac{dv}{du} = u$  に注意)

ベータ関数  $B(n, m)$  は

$$\begin{aligned}
B(n, m) &= \int_0^\infty (1 - x)^{n-1} x^{m-1} dx \\
&= \frac{\Gamma(n)\Gamma(m)}{\Gamma(n+m)}
\end{aligned}$$

に注意

例： $t$  分布：  $X, Y$  は互いに独立で， $X \sim N(0, 1), Y \sim \chi^2(n)$  とするとき， $U = \frac{X}{\sqrt{Y/n}} \sim t(n)$  となる。

$U$  の密度関数  $f(u)$  は，

$$f(u) = \frac{\Gamma(\frac{n+1}{2})}{\Gamma(\frac{n}{2})} \frac{1}{\sqrt{n\pi}} \left(1 + \frac{u^2}{n}\right)^{-\frac{n+1}{2}}$$

となる。

証明：

$$\begin{aligned}
f(x) &= \frac{1}{\sqrt{2\pi}} \exp(-\frac{1}{2}x^2), \quad -\infty < x < \infty \\
g(y) &= \frac{1}{2^{\frac{n}{2}}\Gamma(\frac{n}{2})} y^{\frac{n}{2}-1} \exp(-\frac{y}{2}), \quad y > 0
\end{aligned}$$

$X, Y$  の結合確率密度関数は,  $X, Y$  は互いに独立な確率変数なので,

$$\begin{aligned} h(x, y) &= f(x)g(y) \\ &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}x^2\right) \frac{1}{2^{\frac{n}{2}}\Gamma(\frac{n}{2})} y^{\frac{n}{2}-1} \exp\left(-\frac{y}{2}\right) \\ &= \frac{1}{\sqrt{2\pi}} \frac{1}{2^{\frac{n}{2}}\Gamma(\frac{n}{2})} y^{\frac{n}{2}-1} \exp\left(-\frac{y}{2} - \frac{1}{2}x^2\right) \end{aligned}$$

$U = \frac{X}{\sqrt{Y/n}}, V = Y$  として, 変数変換を行う。

$X = U\sqrt{\frac{V}{n}}, Y = V$  なので,

$$J = \begin{vmatrix} \frac{\partial x}{\partial u} & \frac{\partial x}{\partial v} \\ \frac{\partial y}{\partial u} & \frac{\partial y}{\partial v} \end{vmatrix} = \begin{vmatrix} \sqrt{\frac{v}{n}} & \frac{u}{2\sqrt{nv}} \\ 0 & 1 \end{vmatrix} = \sqrt{\frac{v}{n}}$$

となるので,  $U, V$  の結合確率密度関数  $s(u, v)$  は, 変数変換により,

$$\begin{aligned} s(u, v) &= h\left(u\sqrt{\frac{v}{n}}, v\right) |J| \\ &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2} \frac{u^2 v}{n}\right) \frac{1}{2^{\frac{n}{2}}\Gamma(\frac{n}{2})} v^{\frac{n}{2}-1} \exp\left(-\frac{v}{2}\right) \sqrt{\frac{v}{n}} \\ &= C v^{\frac{n-1}{2}} \exp\left(-\frac{v}{2} \left(1 + \frac{u^2}{n}\right)\right) \end{aligned}$$

ただし,  $C = \frac{1}{\sqrt{\pi}} \frac{1}{2^{\frac{n+1}{2}}\Gamma(\frac{n}{2})} \frac{1}{\sqrt{n}}$  とする。

$U$  の周辺確率密度関数は,

$$\begin{aligned} p(u) &= \int s(u, v) dv \\ &= C \int v^{\frac{n-1}{2}} \exp\left(-\frac{v}{2} \left(1 + \frac{u^2}{n}\right)\right) dv \\ &= C \int \left(w \left(1 + \frac{u^2}{n}\right)^{-1}\right)^{\frac{n-1}{2}} \exp\left(-\frac{1}{2}w\right) \left(1 + \frac{u^2}{n}\right)^{-1} dw \\ &= C \left(1 + \frac{u^2}{n}\right)^{-\frac{n+1}{2}} \int w^{\frac{n+1}{2}-1} \exp\left(-\frac{1}{2}w\right) dw \\ &= C \left(1 + \frac{u^2}{n}\right)^{-\frac{n+1}{2}} 2^{\frac{n+1}{2}} \Gamma\left(\frac{n+1}{2}\right) \end{aligned}$$

$$\begin{aligned} &\times \int \frac{1}{2^{\frac{n+1}{2}}\Gamma(\frac{n+1}{2})} w^{\frac{n+1}{2}-1} \exp\left(-\frac{1}{2}w\right) dw \\ &= C \left(1 + \frac{u^2}{n}\right)^{-\frac{n+1}{2}} 2^{\frac{n+1}{2}} \Gamma\left(\frac{n+1}{2}\right) \\ &= \frac{1}{\sqrt{\pi}} \frac{1}{2^{\frac{n+1}{2}}\Gamma(\frac{n}{2})} \frac{1}{\sqrt{n}} 2^{\frac{n+1}{2}} \Gamma\left(\frac{n+1}{2}\right) \left(1 + \frac{u^2}{n}\right)^{-\frac{n+1}{2}} \\ &= \frac{\Gamma(\frac{n+1}{2})}{\Gamma(\frac{n}{2})} \frac{1}{\sqrt{n\pi}} \left(1 + \frac{u^2}{n}\right)^{-\frac{n+1}{2}} \end{aligned}$$

$w = v \left(1 + \frac{u^2}{n}\right)$  として置換積分。

$f(w) = \frac{1}{2^{\frac{n+1}{2}}\Gamma(\frac{n+1}{2})} w^{\frac{n+1}{2}-1} \exp\left(-\frac{1}{2}w\right)$  は  $\chi^2(n+1)$  の密度関数に注意。

例: Cauchy 分布:  $X, Y$  は互いに独立で,  $X \sim N(0, 1), Y \sim N(0, 1)$  とするとき,  $U = \frac{X}{Y}$  は Cauchy 分布となる。 $U$  の密度関数  $f(u)$  は,

$$f(u) = \frac{1}{\pi(1+u^2)}$$

となる。

証明:

$$\begin{aligned} f(x) &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}x^2\right), \quad -\infty < x < \infty \\ g(y) &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}y^2\right), \quad -\infty < y < \infty \end{aligned}$$

$X, Y$  の結合確率密度関数は,  $X, Y$  は互いに独立な確率変数なので,

$$\begin{aligned} h(x, y) &= f(x)g(y) \\ &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}x^2\right) \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}y^2\right) \\ &= \frac{1}{2\pi} \exp\left(-\frac{1}{2}(x^2 + y^2)\right) \end{aligned}$$

$u = \frac{x}{y}, v = y$  として, 変数変換を行う。

$x = uv, y = v$  なので,

$$J = \begin{vmatrix} \frac{\partial x}{\partial u} & \frac{\partial x}{\partial v} \\ \frac{\partial y}{\partial u} & \frac{\partial y}{\partial v} \end{vmatrix} = \begin{vmatrix} v & u \\ 0 & 1 \end{vmatrix} = v$$

となるので,  $U, V$  の結合確率密度関数  $s(u, v)$  は, 変数変換により,

$$\begin{aligned} s(u, v) &= h(uv, v)|J| \\ &= \frac{1}{2\pi} \exp\left(-\frac{1}{2}v^2(1+u^2)\right)|v| \end{aligned}$$

$U$  の周辺確率密度関数は,

$$\begin{aligned} p(u) &= \int s(u, v)dv \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} |v| \exp\left(-\frac{1}{2}v^2(1+u^2)\right)dv \\ &= \frac{1}{\pi} \int_0^{\infty} v \exp\left(-\frac{1}{2}v^2(1+u^2)\right)dv \\ &= \frac{1}{\pi} \left[ -\frac{1}{1+u^2} \exp\left(-\frac{1}{2}v^2(1+u^2)\right) \right]_{v=0}^{\infty} \\ &= \frac{1}{\pi(1+u^2)} \end{aligned}$$

## 5 積率と積率母関数

### 5.1 積率母関数 (1 変数)

確率変数  $X$  について,

積率:  $\mu'_n = E(X^n) \implies$  原点のまわりの  $n$  次の積率

積率母関数:  $\phi(\theta) = E(e^{\theta X})$

$$\begin{aligned} \phi(\theta) &= E(e^{\theta X}) \\ &= \begin{cases} \sum e^{\theta a_i} f(a_i), & \text{離散型} \\ \int_{-\infty}^{\infty} e^{\theta x} f(x) dx, & \text{連続型} \end{cases} \end{aligned}$$

性質:

1.  $\phi^{(n)}(0) = \mu'_n \equiv E(X^n)$

証明:

$\phi(\theta)$  を  $\theta = 0$  のまわりで, テーラー展開を行う。

$$\begin{aligned} \phi(\theta) &= E\left(1 + \frac{X}{1!}\theta + \frac{X^2}{2!}\theta^2 + \dots + \frac{X^n}{n!}\theta^n + \dots\right) \\ &= 1 + \frac{E(X)}{1!}\theta + \frac{E(X^2)}{2!}\theta^2 + \dots + \frac{E(X^n)}{n!}\theta^n + \dots \\ &= 1 + \frac{\mu'_1}{1!}\theta + \frac{\mu'_2}{2!}\theta^2 + \dots + \frac{\mu'_n}{n!}\theta^n + \dots \end{aligned}$$

したがって,

$$\phi^{(n)}(\theta) = \mu'_n + \frac{\mu'_{n+1}}{1!}\theta + \frac{\mu'_{n+2}}{2!}\theta^2 + \dots$$

より,  $\phi^{(n)}(0) = \mu'_n \equiv E(X^n)$

注)

関数  $f(x)$  の  $x = x_0$  の回りでテーラー展開

$$f(x) \approx \sum_{k=0}^{\infty} \frac{1}{k!} f^{(k)}(x_0) (x - x_0)^k$$

ただし,  $f^{(k)}(x_0)$  は  $f(x)$  の  $k$  回微分を  $x = x_0$  で評価したものとする。

2. 確率変数  $X$  の積率母関数と確率変数  $Y$  の積率母関数は一致するとき, 確率変数  $X$  の分布関数と確率変数  $Y$  の分布関数も一致する。
3. 互いに独立な確率変数  $X_1, X_2, \dots, X_n$  の積率母関数を  $\phi_1(\theta), \phi_2(\theta), \dots, \phi_n(\theta)$  とするとき,  $X_1 + X_2 + \dots + X_n$  の積率母関数は  $\phi_1(\theta)\phi_2(\theta)\dots\phi_n(\theta)$  となる。

証明:

$Y = X_1 + X_2 + \dots + X_n$  として,  $Y$  の積率母関数  $\phi_Y(\theta)$  は

$$\begin{aligned} \phi_Y(\theta) &= E(e^{\theta Y}) \\ &= E(e^{\theta(X_1+X_2+\dots+X_n)}) \\ &= E(e^{\theta X_1})E(e^{\theta X_2})\dots E(e^{\theta X_n}) \\ &= \phi_1(\theta)\phi_2(\theta)\dots\phi_n(\theta) \end{aligned}$$

4. 互いに独立な確率変数  $X_1, X_2, \dots, X_n$  が同一の分布に従い, その積率母関数を  $\phi(\theta)$  とするとき,  $X_1 + X_2 + \dots + X_n$  の積率母関数は  $(\phi(\theta))^n$  となる。

ベルヌイ分布の積率母関数:  $\phi(\theta) = pe^{\theta} + (1-p)$

ベルヌイ分布

$$f(x) = p^x(1-p)^{1-x}, \quad x = 0, 1$$

積率母関数

$$\begin{aligned} \phi(\theta) &= \sum_{x=0}^1 e^{\theta x} f(x) \\ &= \sum_{x=0}^1 e^{\theta x} p^x (1-p)^{1-x} \\ &= e^{\theta} p + 1 - p \end{aligned}$$

1. 平均 :

$$\begin{aligned} E(X) &= \phi'(0) \\ \phi(\theta) &= e^\theta p + 1 - p, \\ \phi'(\theta) &= pe^\theta \text{ なので,} \\ E(X) &= \phi'(0) \\ &= p \end{aligned}$$

2. 分散 :

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \text{ なので, } E(X^2) \text{ を求める.} \\ E(X^2) &= \phi''(0) \\ \phi''(\theta) &= pe^\theta \text{ なので,} \\ V(X) &= E(X^2) - (E(X))^2 \\ &= \phi''(0) - (\phi'(0))^2 \\ &= p - p^2 \\ &= p(1 - p) \end{aligned}$$

二項分布の積率母関数 :  $\phi(\theta) = (pe^\theta + (1 - p))^n$   
二項分布

$$f(x) = {}_n C_x p^x (1 - p)^{n-x}, \quad x = 0, 1, \dots, n$$

積率母関数

$$\begin{aligned} \phi(\theta) &= \sum_{x=0}^n e^{\theta x} f(x) \\ &= \sum_{x=0}^n e^{\theta x} {}_n C_x p^x (1 - p)^{n-x} \\ &= \sum_{x=0}^n {}_n C_x (e^\theta p)^x (1 - p)^{n-x} \\ &= (e^\theta p + 1 - p)^n \end{aligned}$$

(二項定理より)

1. 平均 :

$$\begin{aligned} E(X) &= \phi'(0) \\ \phi(\theta) &= (e^\theta p + 1 - p)^n, \\ \phi'(\theta) &= npe^\theta (e^\theta p + 1 - p)^{n-1} \text{ なので,} \\ E(X) &= \phi'(0) \\ &= np \end{aligned}$$

2. 分散 :

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \text{ なので, } E(X^2) \text{ を求める.} \\ E(X^2) &= \phi''(0) \\ \phi''(\theta) &= npe^\theta (e^\theta p + 1 - p)^{n-1} + n(n-1)p^2 e^{2\theta} (e^\theta p + 1 - p)^{n-2} \text{ なので,} \\ V(X) &= E(X^2) - (E(X))^2 \\ &= \phi''(0) - (\phi'(0))^2 \\ &= np + n(n-1)p^2 - (np)^2 \\ &= np(1 - p) \end{aligned}$$

ポアソン分布の積率母関数 :  $\phi(\theta) = \exp(\lambda(e^\theta - 1))$   
ポアソン分布

$$f(x) = e^{-\lambda} \frac{\lambda^x}{x!}, \quad x = 0, 1, \dots$$

積率母関数

$$\begin{aligned} \phi(\theta) &= \sum_{x=0}^{\infty} e^{\theta x} f(x) \\ &= \sum_{x=0}^{\infty} e^{\theta x} e^{-\lambda} \frac{\lambda^x}{x!} \\ &= \sum_{x=0}^{\infty} e^{-\lambda} \frac{(e^\theta \lambda)^x}{x!} \\ &= \exp(-\lambda) \exp(e^\theta \lambda) \\ &= \exp(\lambda(e^\theta - 1)) \end{aligned}$$

$$\sum_{x=0}^{\infty} \frac{\lambda^x}{x!} = e^\lambda \text{ に注意}$$

1. 平均 :

$$\begin{aligned} E(X) &= \phi'(0) \\ \phi(\theta) &= \exp(\lambda(e^\theta - 1)), \\ \phi'(\theta) &= \lambda e^\theta \exp(\lambda(e^\theta - 1)) \text{ なので,} \end{aligned}$$

$$\begin{aligned} E(X) &= \phi'(0) \\ &= \lambda \end{aligned}$$

2. 分散 :

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \text{ なので, } E(X^2) \text{ を求める.} \\ E(X^2) &= \phi''(0) \end{aligned}$$

$\phi''(\theta) = (1 + \lambda e^\theta) \lambda e^\theta \exp(\lambda(e^\theta - 1))$  なので,

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \\ &= \phi''(0) - (\phi'(0))^2 \\ &= (1 + \lambda)\lambda - \lambda^2 \\ &= \lambda \end{aligned}$$

正規分布の積率母関数:  $\phi(\theta) = \exp\left(\mu\theta + \frac{1}{2}\sigma^2\theta^2\right)$   
正規分布

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}, \quad -\infty < x < \infty$$

積率母関数

$$\begin{aligned} \phi(\theta) &= \int_{-\infty}^{\infty} e^{\theta x} f(x) dx \\ &= \int_{-\infty}^{\infty} e^{\theta x} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\ &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2 + \theta x} dx \\ &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x^2 - 2(\mu + \sigma^2\theta)x + \mu^2)} dx \\ &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x - (\mu + \sigma^2\theta))^2 + (\mu\theta + \frac{1}{2}\sigma^2\theta^2)} dx \\ &= e^{\mu\theta + \frac{1}{2}\sigma^2\theta^2} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x - (\mu + \sigma^2\theta))^2} dx \\ &= \exp\left(\mu\theta + \frac{1}{2}\sigma^2\theta^2\right) \end{aligned}$$

積分のところは,  $N(\mu + \sigma^2\theta, \sigma^2)$  の確率密度関数に注意

1. 平均:

$$\begin{aligned} E(X) &= \phi'(0) \\ \phi(\theta) &= \exp\left(\mu\theta + \frac{1}{2}\sigma^2\theta^2\right), \\ \phi'(\theta) &= (\mu + \sigma^2\theta) \exp\left(\mu\theta + \frac{1}{2}\sigma^2\theta^2\right) \text{ なので,} \end{aligned}$$

$$\begin{aligned} E(X) &= \phi'(0) \\ &= \mu \end{aligned}$$

2. 分散:

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \text{ なので, } E(X^2) \text{ を求める.} \\ E(X^2) &= \phi''(0) \end{aligned}$$

$\phi''(\theta) = \sigma^2 \exp\left(\mu\theta + \frac{1}{2}\sigma^2\theta^2\right) + (\mu + \sigma^2\theta)^2 \exp\left(\mu\theta + \frac{1}{2}\sigma^2\theta^2\right)$  なので,

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \\ &= \phi''(0) - (\phi'(0))^2 \\ &= (\sigma^2 + \mu^2) - \mu^2 \\ &= \sigma^2 \end{aligned}$$

一様分布の積率母関数:  $\phi(\theta) = \frac{e^{b\theta} - e^{a\theta}}{\theta(b-a)}$   
一様分布

$$f(x) = \frac{1}{b-a}, \quad a < x < b$$

積率母関数

$$\begin{aligned} \phi(\theta) &= \int_{-\infty}^{\infty} e^{\theta x} f(x) dx \\ &= \int_a^b e^{\theta x} \frac{1}{b-a} dx \\ &= \left[ \frac{e^{\theta x}}{\theta(b-a)} \right]_a^b \\ &= \frac{e^{\theta b} - e^{\theta a}}{\theta(b-a)} \end{aligned}$$

1. 平均:

$$\begin{aligned} E(X) &= \phi'(0) \\ \phi(\theta) &= \frac{e^{\theta b} - e^{\theta a}}{\theta(b-a)}, \\ \phi'(\theta) &= \frac{be^{\theta b} - ae^{\theta a}}{\theta(b-a)} - \frac{e^{\theta b} - e^{\theta a}}{\theta^2(b-a)} \text{ なので,} \end{aligned}$$

$$\begin{aligned} E(X) &= \phi'(0) \leftarrow \text{ロピタルの定理を利用} \\ &= (a+b) - \frac{a+b}{2} \\ &= \frac{a+b}{2} \end{aligned}$$

(\*) ロピタルの定理

ある連続関数  $f(x)$  と  $g(x)$  について,

$$\lim_{x \rightarrow \infty} \frac{f(x)}{g(x)} = \lim_{x \rightarrow \infty} \frac{f'(x)}{g'(x)},$$

または,

$$\lim_{x \rightarrow 0} \frac{f(x)}{g(x)} = \lim_{x \rightarrow 0} \frac{f'(x)}{g'(x)},$$

となる。これは,

$$\lim_{x \rightarrow \infty} \frac{f(x)}{g(x)} = \frac{\infty}{\infty} \text{ or } \frac{0}{0},$$

または,

$$\lim_{x \rightarrow 0} \frac{f(x)}{g(x)} = \frac{\infty}{\infty} \text{ or } \frac{0}{0},$$

となるときに利用する。

## 2. 分散:

$V(X) = E(X^2) - (E(X))^2$  なので,  $E(X^2)$  を求める。

$$E(X^2) = \phi''(0)$$

$$\phi''(\theta) = \frac{b^2 e^{\theta b} - a^2 e^{\theta a}}{\theta(b-a)} - 2 \frac{b e^{\theta b} - a e^{\theta a}}{\theta^2(b-a)} + 2 \frac{e^{\theta b} - e^{\theta a}}{\theta^3(b-a)}$$

なので,

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \\ &= \phi''(0) - (\phi'(0))^2 \leftarrow \text{ロピタルの定理} \\ &= \left( (b^2 + ab + a^2) - 2 \frac{b^2 + ab + a^2}{2} \right. \\ &\quad \left. + 2 \frac{b^2 + ab + a^2}{6} \right) - \left( \frac{a+b}{2} \right)^2 \\ &= \frac{(b-a)^2}{12} \end{aligned}$$

指数分布の積率母関数:  $\phi(\theta) = \frac{\lambda}{\lambda - \theta}$

指数分布

$$f(x) = \lambda e^{-\lambda x}, \quad 0 < x$$

積率母関数

$$\begin{aligned} \phi(\theta) &= \int_{-\infty}^{\infty} e^{\theta x} f(x) dx \\ &= \int_0^{\infty} e^{\theta x} \lambda e^{-\lambda x} dx \\ &= \frac{\lambda}{\lambda - \theta} \int_0^{\infty} (\lambda - \theta) e^{-(\lambda - \theta)x} dx \\ &= \frac{\lambda}{\lambda - \theta} \end{aligned}$$

積分のところは, パラメータ  $\lambda - \theta$  の指数分布に注意

## 1. 平均:

$$E(X) = \phi'(0)$$

$$\phi(\theta) = \frac{\lambda}{\lambda - \theta},$$

$$\phi'(\theta) = \frac{\lambda}{(\lambda - \theta)^2} \text{ なので,}$$

$$\begin{aligned} E(X) &= \phi'(0) \\ &= \frac{1}{\lambda} \end{aligned}$$

## 2. 分散:

$V(X) = E(X^2) - (E(X))^2$  なので,  $E(X^2)$  を求める。

$$E(X^2) = \phi''(0)$$

$$\phi''(\theta) = 2 \frac{\lambda}{(\lambda - \theta)^3} \text{ なので,}$$

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \\ &= \phi''(0) - (\phi'(0))^2 \\ &= \frac{2}{\lambda^2} - \frac{1}{\lambda^2} \\ &= \frac{1}{\lambda^2} \end{aligned}$$

$\chi^2$  分布の積率母関数:  $\phi(\theta) = \left( \frac{1}{1 - 2\theta} \right)^{\frac{n}{2}}$

$\chi^2(n)$  分布

$$f(x) = \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} \exp\left(-\frac{x}{2}\right), \quad 0 < x$$

積率母関数

$$\begin{aligned} \phi(\theta) &= \int_{-\infty}^{\infty} e^{\theta x} f(x) dx \\ &= \int_0^{\infty} e^{\theta x} \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} \exp\left(-\frac{x}{2}\right) dx \\ &= \int_0^{\infty} \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} \exp\left(-\frac{1}{2}(1 - 2\theta)x\right) dx \\ &= \int_0^{\infty} \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} \left(\frac{y}{1 - 2\theta}\right)^{\frac{n}{2}-1} \exp\left(-\frac{1}{2}y\right) \frac{1}{1 - 2\theta} dy \\ &= \left(\frac{1}{1 - 2\theta}\right)^{\frac{n}{2}} \int_0^{\infty} \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} y^{\frac{n}{2}-1} \exp\left(-\frac{1}{2}y\right) dy \\ &= \left(\frac{1}{1 - 2\theta}\right)^{\frac{n}{2}} \end{aligned}$$

$y = (1 - 2\theta)x$  として置換積分  $\left(\frac{dx}{dy} = (1 - 2\theta)^{-1}\right)$   
積分のところは, 自由度  $n$  の  $\chi^2(n)$  分布に注意

1. 平均 :

$$E(X) = \phi'(0)$$

$$\phi(\theta) = (1 - 2\theta)^{-\frac{n}{2}},$$

$$\phi'(\theta) = \left(-\frac{n}{2}\right)(-2)(1 - 2\theta)^{-\frac{n}{2}-1} \text{ なので,}$$

$$\begin{aligned} E(X) &= \phi'(0) \\ &= n \end{aligned}$$

2. 分散 :

$V(X) = E(X^2) - (E(X))^2$  なので,  $E(X^2)$  を求める。

$$E(X^2) = \phi''(0)$$

$$\phi''(\theta) = \left(-\frac{n}{2}\right)\left(-\frac{n}{2} - 1\right)(-2)^2(1 - 2\theta)^{-\frac{n}{2}-1} \text{ なので,}$$

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \\ &= \phi''(0) - (\phi'(0))^2 \\ &= n(n+2) - n^2 \\ &= 2n \end{aligned}$$

例題 : ベルヌイ分布の和の分布 :  $X_1, X_2, \dots, X_n$  はそれぞれ独立に同一のベルヌイ分布に従うものとする。このとき,  $Y = X_1 + X_2 + \dots + X_n$  は二項分布  $b(y; n, p)$  に従う。

証明 :

$P(X_i = 1) = p$  のとき,  $X_i$  の積率母関数  $\phi_i(\theta)$  は,

$$\phi_i(\theta) = pe^\theta + 1 - p$$

$Y$  の積率母関数  $\phi_y(\theta)$  は,

$$\begin{aligned} \phi_y(\theta) &= E(e^{\theta Y}) \\ &= E(e^{\theta(X_1+X_2+\dots+X_n)}) \\ &= E(e^{\theta X_1})E(e^{\theta X_2})\dots E(e^{\theta X_n}) \\ &= \phi_1(\theta)\phi_2(\theta)\dots\phi_n(\theta) \\ &= (\phi(\theta))^n \\ &= (pe^\theta + 1 - p)^n \end{aligned}$$

これは, 二項分布  $b(y; n, p)$  の積率母関数に一致する。

注)

3 つ目の等式は,  $X_1, X_2, \dots, X_n$  はそれぞれ独立であるため。

5 つ目の等式は,  $X_1, X_2, \dots, X_n$  は同一の分布に従うため。

例題 : 正規分布の和の分布 :  $X, Y$  はたがいに独立な確率変数で,  $X \sim N(\mu_1, \sigma_1^2), Y \sim N(\mu_2, \sigma_2^2)$  とする。このとき, 定数  $a, b$  について,  $aX + bY \sim N(a\mu_1 + b\mu_2, a^2\sigma_1^2 + b^2\sigma_2^2)$  となる。

証明 :

$X, Y$  の積率母関数  $\phi_x(\theta), \phi_y(\theta)$  は,

$$\phi_x(\theta) = \exp\left(\mu_1\theta + \frac{1}{2}\sigma_1^2\theta^2\right)$$

$$\phi_y(\theta) = \exp\left(\mu_2\theta + \frac{1}{2}\sigma_2^2\theta^2\right)$$

$W = aX + bY$  の積率母関数  $\phi_w(\theta)$  は,

$$\begin{aligned} \phi_w(\theta) &= E(e^{\theta W}) \\ &= E(e^{\theta(aX+bY)}) \\ &= E(e^{a\theta X})E(e^{b\theta Y}) \\ &= \phi_x(a\theta)\phi_y(b\theta) \\ &= \exp\left(\mu_1(a\theta) + \frac{1}{2}\sigma_1^2(a\theta)^2\right) \\ &\quad \times \exp\left(\mu_2(b\theta) + \frac{1}{2}\sigma_2^2(b\theta)^2\right) \\ &= \exp\left((a\mu_1 + b\mu_2)\theta + \frac{1}{2}(a^2\sigma_1^2 + b^2\sigma_2^2)\theta^2\right) \end{aligned}$$

これは, 平均  $a\mu_1 + b\mu_2$ , 分散  $a^2\sigma_1^2 + b^2\sigma_2^2$  の正規分布の積率母関数に一致する。

よって,  $aX + bY \sim N(a\mu_1 + b\mu_2, a^2\sigma_1^2 + b^2\sigma_2^2)$  となる。

例題 :  $\chi^2$  分布の和の分布  $X, Y$  は互いに独立で,  $X \sim \chi^2(n), Y \sim \chi^2(m)$  とするとき,  $Z = X + Y \sim \chi^2(n+m)$  となる。

証明 :

$X, Y$  の積率母関数  $\phi_x(\theta), \phi_y(\theta)$  とする。このとき,  $\phi_x(\theta), \phi_y(\theta)$  はそれぞれ,

$$\phi_x(\theta) = \left(\frac{1}{1-2\theta}\right)^{\frac{n}{2}},$$

$$\phi_y(\theta) = \left(\frac{1}{1-2\theta}\right)^{\frac{m}{2}},$$

となる。 $Z = X + Y$  の積率母関数  $\phi_z(t)$  は,  $X, Y$  は互いに独立な確率変数なので,

$$\begin{aligned} \phi_z(\theta) &\equiv E(e^{\theta Z}) \\ &= E(e^{\theta(X+Y)}) \\ &= E(e^{\theta X})E(e^{\theta Y}) \\ &= \phi_x(\theta)\phi_y(\theta) \end{aligned}$$

$$= \left(\frac{1}{1-2\theta}\right)^{\frac{n}{2}} \left(\frac{1}{1-2\theta}\right)^{\frac{m}{2}}$$

$$= \left(\frac{1}{1-2\theta}\right)^{\frac{n+m}{2}}$$

これは、自由度  $n+m$  の  $\chi^2$  分布の積率母関数に等しい。  
したがって、 $Z \sim \chi^2(n+m)$  となる。

ただし、3 つ目の等号が成り立つ理由は、 $X$  と  $Y$  は独立な確率変数であるためである。

## 5.2 積率母関数 (多変数)

確率変数  $X, Y$  について、

積率母関数：  $\phi(\theta_1, \theta_2) = E(e^{\theta_1 X + \theta_2 Y})$

性質：

### 1. 多変数の積率

$$\frac{\partial^{j+k} \phi(0, 0)}{\partial \theta_1^j \partial \theta_2^k} = E(X^j Y^k)$$

2.  $(X_1, Y_1)$  の積率母関数と  $(X_2, Y_2)$  の積率母関数が一致すれば、 $(X_1, Y_1)$  の分布関数と  $(X_2, Y_2)$  の分布関数も一致する。

3.  $(X, Y)$  の積率母関数  $\phi(\theta_1, \theta_2)$ ,

$X$  の積率母関数  $\phi_1(\theta_1)$ ,

$Y$  の積率母関数  $\phi_2(\theta_2)$  について、

$$\phi_1(\theta_1) = \phi(\theta_1, 0), \quad \phi_2(\theta_2) = \phi(0, \theta_2)$$

4.  $(X, Y)$  の積率母関数  $\phi(\theta_1, \theta_2)$ ,

$X$  の積率母関数  $\phi_1(\theta_1)$ ,

$Y$  の積率母関数  $\phi_2(\theta_2)$  について、

$X$  と  $Y$  が独立であるための条件は、

$$\phi(\theta_1, \theta_2) = \phi_1(\theta_1)\phi_2(\theta_2)$$

確率変数  $X_1, X_2, \dots, X_n$  について、

積率母関数：  $\phi(\theta_1, \theta_2, \dots, \theta_n) = E(e^{\theta_1 X_1 + \theta_2 X_2 + \dots + \theta_n X_n})$

2 変数正規分布の積率母関数：  $(X, Y)$  の確率密度関数

$$f(x, y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}}$$

$$\times \exp\left(-\frac{1}{2(1-\rho^2)}\left(\frac{(x-\mu_1)^2}{\sigma_1^2} - 2\rho\frac{(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2}\right)\right)$$

$$= \frac{1}{2\pi} \begin{vmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{vmatrix}^{-1}$$

$$\times \exp\left(-\frac{1}{2} \begin{pmatrix} x-\mu_1 \\ y-\mu_2 \end{pmatrix}' \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}^{-1} \begin{pmatrix} x-\mu_1 \\ y-\mu_2 \end{pmatrix}\right)$$

$$= \frac{1}{2\pi} |\Sigma|^{-1} \exp\left(-\frac{1}{2} \mathbf{x}' \Sigma^{-1} \mathbf{x}\right)$$

積率母関数

$$\phi(\theta_1, \theta_2) = E(e^{\theta_1 X + \theta_2 Y})$$

$$= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} e^{\theta_1 x + \theta_2 y} f(x, y) dx dy$$

$$= \iint e^{\theta_1(x-\mu_1) + \theta_2(y-\mu_2) + \theta_1\mu_1 + \theta_2\mu_2} f(x, y) dx dy$$

$$= \iint \exp\left(\begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix}' \begin{pmatrix} x-\mu_1 \\ y-\mu_2 \end{pmatrix} + \begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix}' \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}\right) \times f(x, y) dx dy$$

$$= \int \exp(\theta' \mathbf{x} + \theta' \boldsymbol{\mu}) f(\mathbf{x}) d\mathbf{x}$$

$$= \int \frac{1}{2\pi} |\Sigma|^{-1} \exp\left(-\frac{1}{2} \mathbf{x}' \Sigma^{-1} \mathbf{x} + \theta' \mathbf{x} + \theta' \boldsymbol{\mu}\right) d\mathbf{x}$$

$$= \int \frac{1}{2\pi} |\Sigma|^{-1} \exp\left(-\frac{1}{2} (\mathbf{x} - \boldsymbol{\theta})' \Sigma^{-1} (\mathbf{x} - \boldsymbol{\theta}) + \theta' \boldsymbol{\mu} + \frac{1}{2} \theta' \Sigma \boldsymbol{\theta}\right) d\mathbf{x}$$

$$= \exp(\theta' \boldsymbol{\mu} + \frac{1}{2} \theta' \Sigma \boldsymbol{\theta})$$

$$\times \int \frac{1}{2\pi} |\Sigma|^{-1} \exp\left(-\frac{1}{2} (\mathbf{x} - \boldsymbol{\theta})' \Sigma^{-1} (\mathbf{x} - \boldsymbol{\theta})\right) d\mathbf{x}$$

$$= \exp(\theta' \boldsymbol{\mu} + \frac{1}{2} \theta' \Sigma \boldsymbol{\theta})$$

$$= \exp\left(\mu_1 \theta_1 + \mu_2 \theta_2 + \frac{1}{2} (\sigma_1^2 \theta_1^2 + 2\sigma_1 \sigma_2 \rho \theta_1 \theta_2 + \sigma_2^2 \theta_2^2)\right)$$

ただし、

$$f(\mathbf{x}) = f(x, y),$$

$$\theta = \begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix}, \quad \mu = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}, \quad \mathbf{x} = \begin{pmatrix} x - \mu_1 \\ y - \mu_2 \end{pmatrix},$$

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}$$

$$= \left[ ax - \frac{1}{2}x^2 \right]_0^a$$

$$= \frac{1}{2}a^2$$

$$= 1$$

とする。

$$1. E(X) = \left. \frac{\partial \phi(\theta_1, \theta_2)}{\partial \theta_1} \right|_{(\theta_1, \theta_2) = (0, 0)}$$

$$2. E(Y) = \left. \frac{\partial \phi(\theta_1, \theta_2)}{\partial \theta_2} \right|_{(\theta_1, \theta_2) = (0, 0)}$$

$$3. E(X^2) = \left. \frac{\partial^2 \phi(\theta_1, \theta_2)}{\partial \theta_1^2} \right|_{(\theta_1, \theta_2) = (0, 0)}$$

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

$$4. E(Y^2) = \left. \frac{\partial^2 \phi(\theta_1, \theta_2)}{\partial \theta_2^2} \right|_{(\theta_1, \theta_2) = (0, 0)}$$

$$V(Y) = E(Y^2) - (E(Y))^2$$

$$5. E(XY) = \left. \frac{\partial^2 \phi(\theta_1, \theta_2)}{\partial \theta_1 \partial \theta_2} \right|_{(\theta_1, \theta_2) = (0, 0)}$$

$$\text{Cov}(X, Y) = E(XY) - E(X)E(Y)$$

## 練習問題と解答 (1 章 ~ 5 章)

1 連続型確率変数  $X$  の密度関数が

$$f(x) = \begin{cases} a - x, & 0 < x < a \text{ のとき} \\ 0, & \text{その他} \end{cases}$$

であるとき、次の問に答えよ。

- (1)  $a$  を求めよ。
- (2)  $X$  の平均と分散を求めよ。
- (3)  $Y = X^2$  とするとき、 $Y$  の密度関数を求めよ。

[解答]

(1) 密度関数の性質  $\int f(x)dx = 1$  から、

$$\int f(x)dx = \int_0^a (a - x)dx$$

により、 $a = \sqrt{2}$  を得る。(  $a > 0$  なので)

(2) 平均、分散の定義は、 $E(X) = \int xf(x)dx$ ,  $V(X) = \int (x - \mu)^2 f(x)dx$  (ただし、 $\mu = E(X)$  とする) である。よって、

$$E(X) = \int xf(x)dx$$

$$= \int_0^a x(a - x)dx$$

$$= \left[ \frac{1}{2}ax^2 - \frac{1}{3}x^3 \right]_0^a$$

$$= \frac{1}{6}a^3$$

$$= \frac{\sqrt{2}}{3} \quad \leftarrow a = \sqrt{2} \text{ を代入する}$$

$$V(X) = \int (x - \mu)^2 f(x)dx$$

$$= \int x^2 f(x)dx - \mu^2$$

$$= \int_0^a x^2(a - x)dx - \mu^2$$

$$= \left[ \frac{1}{3}ax^3 - \frac{1}{4}x^4 \right]_0^a - \mu^2$$

$$= \frac{1}{12}a^4 - \mu^2$$

$$= \frac{1}{3} - \left( \frac{\sqrt{2}}{3} \right)^2$$

$$= \frac{1}{9}$$

(3)  $X$  の密度関数を  $f(x)$ 、分布関数を  $F(x)$  とする。また、 $Y$  の密度関数を  $g(y)$  とし、分布関数を  $G(y)$  とする。 $Y = X^2$  なので、

$$G(y)$$

$$= P(Y < y)$$

$$= P(X^2 < y)$$

$$\begin{aligned}
&= P(-\sqrt{y} < X < \sqrt{y}) \\
&= F(\sqrt{y}) - F(-\sqrt{y}) \\
&= F(\sqrt{y}) \leftarrow F(-\sqrt{y}) = 0
\end{aligned}$$

を得る。さらに、密度関数と分布関数の関係から、

$$\begin{aligned}
g(y) &= \frac{dG(y)}{dy} \\
&= \frac{dF(\sqrt{y})}{dy} \\
&= \frac{dF(x)}{dx} \frac{d\sqrt{y}}{dy} \leftarrow x = \sqrt{y} \\
&= F'(x) \frac{1}{2\sqrt{y}} \\
&= f(x) \frac{1}{2\sqrt{y}} \\
&= f(\sqrt{y}) \frac{1}{2\sqrt{y}} \\
&= (\sqrt{2} - \sqrt{y}) \frac{1}{2\sqrt{y}} \quad 0 < y < 2 \text{ のとき}
\end{aligned}$$

$y$  の範囲は、

$$0 < x < \sqrt{2} \implies 0 < x^2 < 2 \implies 0 < y < 2$$

となる。

2 連続型確率変数  $X$  の密度関数が

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

であるとき、次の問に答えよ。

- (1)  $X$  の平均と分散を求めよ。
- (2)  $Y = X^2$  とするとき、 $Y$  の平均と分散を求めよ。
- (3)  $Z = e^X$  とするとき、 $Z$  の平均と分散を求めよ。

[解答]

- (1) 平均、分散の定義は、 $E(X) = \int xf(x)dx$ ,  $V(X) = \int (x - \mu)^2 f(x)dx$  (ただし、 $\mu = E(X)$  とする) である。よって、

$$\begin{aligned}
E(X) &= \int xf(x)dx \\
&= \int_{-\infty}^{\infty} x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx \\
&= -\frac{1}{\sqrt{2\pi}} \left[ e^{-\frac{1}{2}x^2} \right]_{-\infty}^{\infty} \\
&= 0
\end{aligned}$$

3 つ目の等式は、 $\frac{de^{-\frac{1}{2}x^2}}{dx} = -xe^{-\frac{1}{2}x^2}$  を利用する。

$$\begin{aligned}
V(X) &= \int (x - \mu)^2 f(x)dx \\
&= \int x^2 f(x)dx - \mu^2 \\
&= \int_{-\infty}^{\infty} x^2 \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx - \mu^2 \\
&= \left[ -x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \right]_{-\infty}^{\infty} \\
&\quad + \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx - \mu^2 \\
&= 1
\end{aligned}$$

4 つ目の等式では、部分積分を利用

$$\begin{aligned}
&\int_a^b h'(x)g(x)dx \\
&= [h(x)g(x)]_a^b - \int_a^b h(x)g'(x)dx
\end{aligned}$$

$g(x) = x$ ,  $h'(x) = x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2}$  とおく。

また、4 つ目の等式の第 1 項では、

$$\lim_{x \rightarrow \pm\infty} x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} = 0$$

を利用する。

4 つ目の等式の第 2 項では、密度関数の積分が 1 になることを利用。

- (2)  $Y = X^2$  とするとき、 $Y$  の平均と分散を求めよ。

$$\begin{aligned}
E(Y) &= E(X^2) \\
&= V(X) + \mu_x^2 \\
&= 1
\end{aligned}$$

- (1) より、 $V(X) = 1$ ,  $\mu_x = E(X) = 0$  に注意。

$$\begin{aligned}
V(Y) &= E(Y - \mu_y)^2 \leftarrow \mu_y = E(Y) = 1 \\
&= E(Y^2) - \mu_y^2 \\
&= E(X^4) - \mu_y^2 \\
&= \int_{-\infty}^{\infty} x^4 \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx - \mu_y^2
\end{aligned}$$

$$\begin{aligned}
&= \int_{-\infty}^{\infty} x^3 \cdot x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx - \mu_y^2 \\
&= \left[ -x^3 \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \right]_{-\infty}^{\infty} \\
&+ 3 \int_{-\infty}^{\infty} x^2 \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx - \mu_y^2 \\
&= 3E(X^2) - \mu_y^2 \quad \leftarrow \quad E(X^2) = 1, \mu_y = 1 \\
&= 2
\end{aligned}$$

6つ目の等式では，部分積分を利用

$$\begin{aligned}
&\int_a^b h'(x)g(x)dx \\
&= [h(x)g(x)]_a^b - \int_a^b h(x)g'(x)dx
\end{aligned}$$

$g(x) = x^3$ ,  $h'(x) = x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2}$  とおく。

また，6つ目の等式の第1項では，

$$\lim_{x \rightarrow \pm\infty} x^3 \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} = 0$$

を利用する。

(3)  $Z = e^X$  とするとき， $Z$  の平均と分散を求める。

$$\begin{aligned}
E(Z) &= E(e^X) \\
&= \int_{-\infty}^{\infty} e^x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx \\
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x^2-2x)} dx \\
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-1)^2 + \frac{1}{2}} dx \\
&= e^{\frac{1}{2}} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-1)^2} dx \\
&= e^{\frac{1}{2}}
\end{aligned}$$

6つ目の等式は， $\frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-1)^2}$  が，平均 1，分散 1 の正規分布となり，その積分値は 1 となることによる。

$$\begin{aligned}
V(Z) &= E(Z - \mu_z)^2 \quad \leftarrow \quad \mu_z = E(Z) = e^{\frac{1}{2}} \\
&= E(Z^2) - \mu_z^2 \\
&= E(e^{2X}) - \mu_z^2 \\
&= \int_{-\infty}^{\infty} e^{2x} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx - \mu_z^2
\end{aligned}$$

$$\begin{aligned}
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x^2-4x)} dx - \mu_z^2 \\
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-2)^2 + 2} dx - \mu_z^2 \\
&= e^2 \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-2)^2} dx - \mu_z^2 \\
&= e^2 - e
\end{aligned}$$

8つ目の等式は， $\frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-2)^2}$  が，平均 2，分散 1 の正規分布となり，その積分値は 1 となることによる。

3 連続型確率変数  $X$  の密度関数が

$$f(x) = \begin{cases} \frac{1}{\lambda} e^{-\frac{x}{\lambda}}, & 0 < x \text{ のとき} \\ 0, & \text{その他} \end{cases}$$

であるとき，次の問に答えよ。

- (1)  $X$  の平均と分散を求めよ。
- (2)  $X$  の積率母関数を求めよ。
- (3)  $X_1, X_2, \dots, X_n$  を互いに独立で上に示された分布に従うものとする。 $\lambda = 2$  のとき， $Y = X_1 + X_2 + \dots + X_n$  の密度関数は，自由度  $2n$  のカイ二乗分布となることを示せ。ただし，自由度  $n$  のカイ二乗分布とは 5 の確率変数  $X$  の密度関数である。

[解答]

- (1)  $X$  の平均と分散を求める。

$$\begin{aligned}
E(X) &= \int x f(x) dx \\
&= \int_0^{\infty} x \frac{1}{\lambda} e^{-\frac{x}{\lambda}} dx \\
&= [-\lambda e^{-\frac{x}{\lambda}}]_0^{\infty} \\
&+ \int_0^{\infty} e^{-\frac{x}{\lambda}} dx \\
&= [-\lambda e^{-\frac{x}{\lambda}}]_0^{\infty} \\
&= \lambda
\end{aligned}$$

3つ目の等式では，部分積分を利用

$$\begin{aligned}
&\int_a^b h'(x)g(x)dx \\
&= [h(x)g(x)]_a^b - \int_a^b h(x)g'(x)dx
\end{aligned}$$

$$g(x) = x, h'(x) = \frac{1}{\lambda}e^{-\frac{x}{\lambda}} \text{ とおく。}$$

また,

$$\lim_{x \rightarrow \infty} xe^{-\frac{x}{\lambda}} = 0$$

$$\lim_{x \rightarrow \infty} e^{-\frac{x}{\lambda}} = 0$$

を利用

$$\begin{aligned} V(X) &= \int (x - \mu)^2 f(x) dx \\ &= \int x^2 f(x) dx - \mu^2 \quad \leftarrow \mu = E(X) = \lambda \\ &= \int_0^\infty x^2 \frac{1}{\lambda} e^{-\frac{x}{\lambda}} dx - \mu^2 \\ &= [-x^2 e^{-\frac{x}{\lambda}}]_0^\infty + 2 \int_0^\infty x e^{-\frac{x}{\lambda}} dx - \mu^2 \\ &= [-x^2 e^{-\frac{x}{\lambda}}]_0^\infty + 2\lambda \int_0^\infty x \frac{1}{\lambda} e^{-\frac{x}{\lambda}} dx - \mu^2 \\ &= 2\lambda E(X) - \mu^2 \quad \leftarrow \mu = E(X) = \lambda \\ &= 2\lambda^2 - \lambda^2 \\ &= \lambda^2 \end{aligned}$$

3つ目の等式では, 部分積分を利用

$$\begin{aligned} &\int_a^b h'(x)g(x)dx \\ &= [h(x)g(x)]_a^b - \int_a^b h(x)g'(x)dx \end{aligned}$$

$$g(x) = x^2, h'(x) = \frac{1}{\lambda}e^{-\frac{x}{\lambda}} \text{ とおく。}$$

6つ目の等式では,

$$\lim_{x \rightarrow \infty} x^2 e^{-\frac{x}{\lambda}} = 0$$

$$\mu = E(X) = \int_0^\infty x e^{-\frac{x}{\lambda}} dx$$

を利用。

(2)  $X$  の積率母関数を求める。

$$\begin{aligned} \phi(\theta) &= E(e^{\theta X}) \\ &= \int e^{\theta x} f(x) dx \\ &= \int_0^\infty e^{\theta x} \frac{1}{\lambda} e^{-\frac{x}{\lambda}} dx \\ &= \int_0^\infty \frac{1}{\lambda} e^{-(\frac{1}{\lambda} - \theta)x} dx \\ &= \frac{1}{\frac{1}{\lambda} - \theta} \int_0^\infty (\frac{1}{\lambda} - \theta) e^{-(\frac{1}{\lambda} - \theta)x} dx \\ &= \frac{1}{1 - \lambda\theta} \end{aligned}$$

最後の等式では,  $(\frac{1}{\lambda} - \theta)e^{-(\frac{1}{\lambda} - \theta)x}$  は密度関数であるので, その積分値は1であることによる。 $f(x)$  の  $\lambda$  を  $\frac{1}{\lambda} - \theta$  で置き換えたものとなっている。

(3)  $Y$  の積率母関数と自由度  $2n$  のカイ二乗分布の積率母関数が一致することを示す。

$X_1, X_2, \dots, X_n$  を互いに独立で上に示された分布に従うので,  $X_i$  の積率母関数  $\phi_i(\theta)$  は, (2) より,  $\lambda = 2$  のとき,

$$\phi_i(\theta) = \frac{1}{1 - 2\theta} = \phi(\theta)$$

となる。

$\lambda = 2$  のとき,  $Y = X_1 + X_2 + \dots + X_n$  の積率母関数  $\phi_y(\theta)$  は,

$$\begin{aligned} \phi_y(\theta) &= E(e^{\theta Y}) \\ &= E(e^{\theta(X_1 + X_2 + \dots + X_n)}) \\ &= E(e^{\theta X_1})E(e^{\theta X_2}) \dots E(e^{\theta X_n}) \\ &= \phi_1(\theta)\phi_2(\theta) \dots \phi_n(\theta) \\ &= (\phi(\theta))^n \\ &= \left(\frac{1}{1 - 2\theta}\right)^n \\ &= \left(\frac{1}{1 - 2\theta}\right)^{\frac{2n}{2}} \end{aligned}$$

したがって,  $Y$  の積率母関数は,

$$\phi_y(\theta) = \left(\frac{1}{1 - 2\theta}\right)^{\frac{2n}{2}}$$

となる。

一方、自由度  $m$  のカイ二乗分布は、

$$f(x) = \frac{1}{2^{\frac{m}{2}} \Gamma(\frac{m}{2})} x^{\frac{m}{2}-1} e^{-\frac{x}{2}} \quad x > 0 \text{ のとき}$$

なので、その積率母関数  $\phi_{\chi^2}(\theta)$  は、

$$\begin{aligned} & \phi_{\chi^2}(\theta) \\ &= E(e^{\theta X}) \\ &= \int_0^{\infty} e^{\theta x} \frac{1}{2^{\frac{m}{2}} \Gamma(\frac{m}{2})} x^{\frac{m}{2}-1} e^{-\frac{x}{2}} dx \\ &= \int_0^{\infty} \frac{1}{2^{\frac{m}{2}} \Gamma(\frac{m}{2})} x^{\frac{m}{2}-1} e^{-\frac{1}{2}(1-2\theta)x} dx \\ &= \int_0^{\infty} \frac{1}{2^{\frac{m}{2}} \Gamma(\frac{m}{2})} \left(\frac{y}{1-2\theta}\right)^{\frac{m}{2}-1} e^{-\frac{1}{2}y} \frac{1}{1-2\theta} dy \\ &= \left(\frac{1}{1-2\theta}\right)^{\frac{m}{2}-1} \frac{1}{1-2\theta} \\ &\times \int_0^{\infty} \frac{1}{2^{\frac{m}{2}} \Gamma(\frac{m}{2})} y^{\frac{m}{2}-1} e^{-\frac{1}{2}y} dy \\ &= \left(\frac{1}{1-2\theta}\right)^{\frac{m}{2}} \end{aligned}$$

4つ目の等式で、 $y = (1-2\theta)x$  として、置換積分を利用。

$\frac{1}{2^{\frac{m}{2}} \Gamma(\frac{m}{2})} y^{\frac{m}{2}-1} e^{-\frac{1}{2}y}$  は、自由度  $m$  の  $\chi^2$  分布となっているので、その積分値は1となる。

$\phi_y(\theta)$  は、 $\phi_{\chi^2}(\theta)$  で、 $m = 2n$  に対応する。

すなわち、 $\phi_y(\theta)$  は自由度  $2n$  の  $\chi^2$  分布の積率母関数となっている。

したがって、 $Y \sim \chi^2(2n)$  となる。

4 連続型確率変数  $X$  の密度関数が

$$f(x) = \begin{cases} 1, & 0 < x < 1 \text{ のとき} \\ 0, & \text{その他} \end{cases}$$

であるとき、次の問に答えよ。

- (1)  $X$  の平均と分散を求めよ。
- (2)  $Y = -2\log X$  とするとき、 $Y$  の積率母関数を求めよ。ただし、 $\log$  は自然対数とする。 $(y = -2\log x$  は  $x = e^{-\frac{1}{2}y}$  を意味する)

- (3)  $Y_1$  と  $Y_2$  を (2) で求められた密度関数に従う確率変数であるとする。しかも、 $Y_1$  と  $Y_2$  は独立であるとする。 $Z = Y_1 + Y_2$  としたとき、 $Z$  の密度関数を求めよ。

[解答]

- (1)  $X$  の平均と分散を求める。

$$\begin{aligned} E(X) &= \int x f(x) dx \\ &= \int_0^1 x dx \\ &= \left[\frac{1}{2}x^2\right]_0^1 \\ &= \frac{1}{2} \end{aligned}$$

$$\begin{aligned} V(X) &= \int (x - \mu)^2 f(x) dx \\ &= \int x^2 f(x) dx - \mu^2 \quad \leftarrow \mu = E(X) = \frac{1}{2} \\ &= \int_0^1 x^2 dx - \mu^2 \\ &= \left[\frac{1}{3}x^3\right]_0^1 - \mu^2 \\ &= \frac{1}{3} - \left(\frac{1}{2}\right)^2 \\ &= \frac{1}{12} \end{aligned}$$

- (2)  $Y = -2\log X$  とするとき、 $Y$  の積率母関数  $\phi_y(\theta)$  を求める。

$$\begin{aligned} \phi_y(\theta) &= E(e^{\theta Y}) \\ &= E(e^{-2\theta \log X}) \\ &= E(X^{-2\theta}) \\ &= \int x^{-2\theta} f(x) dx \\ &= \int_0^1 x^{-2\theta} dx \\ &= \left[\frac{1}{1-2\theta} x^{1-2\theta}\right]_0^1 \\ &= \frac{1}{1-2\theta} \end{aligned}$$

- (3)  $Y_1$  と  $Y_2$  を (2) で求められた密度関数に従う確率変数であるとする。しかも、 $Y_1$  と  $Y_2$  は独立であるとする。  $Z = Y_1 + Y_2$  としたとき、 $Z$  の密度関数を求める。

$Z$  の積率母関数  $\phi_z(\theta)$  を求める。

$$\begin{aligned}\phi_z(\theta) &= E(e^{\theta Z}) \\ &= E(e^{\theta(Y_1+Y_2)}) \\ &= E(e^{\theta Y_1})E(e^{\theta Y_2}) \\ &= (\phi_y(\theta))^2 \\ &= \left(\frac{1}{1-2\theta}\right)^2 \\ &= \left(\frac{1}{1-2\theta}\right)^4\end{aligned}$$

これは、自由度 4 のカイ自乗分布の積率母関数に一致する。

よって、 $Z \sim \chi^2(4)$  となる。

ただし、自由度  $n$  のカイ自乗分布の密度関数は、

$$f(x) = \begin{cases} \frac{1}{2^{\frac{n}{2}}\Gamma(\frac{n}{2})}x^{\frac{n}{2}-1}e^{-\frac{x}{2}}, & x > 0 \text{ のとき} \\ 0, & \text{その他} \end{cases}$$

として表され、その積率母関数  $\phi(\theta)$  は、

$$\phi(\theta) = \left(\frac{1}{1-2\theta}\right)^{\frac{n}{2}}$$

となることに注意。

- 5 連続型確率変数  $X$  の密度関数が

$$f(x) = \begin{cases} \frac{1}{2^{\frac{n}{2}}\Gamma(\frac{n}{2})}x^{\frac{n}{2}-1}e^{-\frac{x}{2}}, & x > 0 \text{ のとき} \\ 0, & \text{その他} \end{cases}$$

であるとき、次の問に答えよ。ただし、 $\Gamma(a)$  はガンマ関数であり、

$$\Gamma(a) = \int_0^{\infty} x^{a-1}e^{-x} dx$$

と定義される。

- (1)  $X$  の平均と分散を求めよ。  
(2)  $X$  の積率母関数を求めよ。

[解答]

- (1)  $X$  の平均と分散を求める。

平均について：

$$\begin{aligned}E(X) &= \int_{-\infty}^{\infty} xf(x)dx \\ &= \int_0^{\infty} x \frac{1}{\Gamma(\frac{n}{2})} 2^{-\frac{n}{2}} x^{\frac{n}{2}-1} e^{-\frac{x}{2}} dx \\ &= \frac{2^{-\frac{n}{2}}}{2^{-\frac{n+2}{2}}} \frac{\Gamma(\frac{n+2}{2})}{\Gamma(\frac{n}{2})} \\ &\quad \times \int_0^{\infty} \frac{1}{\Gamma(\frac{n+2}{2})} 2^{-\frac{n+2}{2}} x^{\frac{n+2}{2}-1} e^{-\frac{x}{2}} dx \\ &= 2 \frac{n}{2} \int_0^{\infty} \frac{1}{\Gamma(\frac{n'}{2})} 2^{-\frac{n'}{2}} x^{\frac{n'}{2}-1} e^{-\frac{x}{2}} dx \\ &= n\end{aligned}$$

$$\Gamma(s) = \int_0^{\infty} u^{s-1}e^{-u} du \implies \text{ガンマ関数 } \Gamma(s+1) = s\Gamma(s), \Gamma(1) = 1, \Gamma\left(\frac{1}{2}\right) = \sqrt{\pi} \text{ に注意}$$

また、 $n' = n + 2$  を使い、確率密度関数の性質から、

$$\int_{-\infty}^{\infty} f(x)dx = \int_0^{\infty} \frac{1}{\Gamma(\frac{n}{2})} 2^{-\frac{n}{2}} x^{\frac{n}{2}-1} e^{-\frac{x}{2}} dx = 1$$

に注意。

分散について：

$V(X) = E(X^2) - \mu^2$  により、 $E(X^2)$  を求める。

$$\begin{aligned}E(X^2) &= \int_{-\infty}^{\infty} x^2 f(x)dx \\ &= \int_0^{\infty} x^2 \frac{1}{\Gamma(\frac{n}{2})} 2^{-\frac{n}{2}} x^{\frac{n}{2}-1} e^{-\frac{x}{2}} dx \\ &= \int_0^{\infty} \frac{1}{\Gamma(\frac{n}{2})} 2^{-\frac{n}{2}} x^{\frac{n+4}{2}-1} e^{-\frac{x}{2}} dx \\ &= \frac{2^{-\frac{n}{2}}}{2^{-\frac{n+4}{2}}} \frac{\Gamma(\frac{n+4}{2})}{\Gamma(\frac{n}{2})} \\ &\quad \times \int_0^{\infty} \frac{1}{\Gamma(\frac{n+4}{2})} 2^{-\frac{n+4}{2}} x^{\frac{n+4}{2}-1} e^{-\frac{x}{2}} dx \\ &= 4 \left(\frac{n+2}{2}\right) \int_0^{\infty} \frac{1}{\Gamma(\frac{n'}{2})} 2^{-\frac{n'}{2}} x^{\frac{n'}{2}-1} e^{-\frac{x}{2}} dx \\ &= n(n+2)\end{aligned}$$

$n' = n + 4$  を使う。

$$V(X) = n(n+2) - n^2 = 2n$$

(2)  $X$  の積率母関数を求める。

$$\begin{aligned}
 \phi(\theta) &= E(e^{\theta X}) \\
 &= \int_{-\infty}^{\infty} e^{\theta x} f(x) dx \\
 &= \int_0^{\infty} e^{\theta x} \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} \exp(-\frac{x}{2}) dx \\
 &= \int_0^{\infty} \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} \exp\left(-\frac{1}{2}(1-2\theta)x\right) dx \\
 &= \int_0^{\infty} \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} \left(\frac{y}{1-2\theta}\right)^{\frac{n}{2}-1} \exp(-\frac{1}{2}y) \frac{1}{1-2\theta} dy \\
 &= \left(\frac{1}{1-2\theta}\right)^{\frac{n}{2}} \int_0^{\infty} \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} y^{\frac{n}{2}-1} \exp(-\frac{1}{2}y) dy \\
 &= \left(\frac{1}{1-2\theta}\right)^{\frac{n}{2}}
 \end{aligned}$$

$$y = (1-2\theta)x \text{ として置換積分 } \left(\frac{dx}{dy} = (1-2\theta)^{-1}\right)$$

積分のところは、自由度  $n$  の  $\chi^2(n)$  分布に注意

6 連続型確率変数  $X, Y$  は互いに独立で、 $X \sim N(0, 1)$ ,  $Y \sim N(0, 1)$  とする。 $U = \frac{X}{Y}$  とするとき、次の問に答えよ。ただし、 $X \sim N(0, 1)$  のとき、 $X$  の密度関数は

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

と書き表される。

- (1)  $U$  の密度関数を求めよ。  
 (2)  $U$  の 1 次の積率は存在しないということを証明せよ。

[解答]

- (1)  $U$  の密度関数を求める。

$X, Y$  の密度関数は、それぞれ、

$$\begin{aligned}
 f(x) &= \frac{1}{\sqrt{2\pi}} \exp(-\frac{1}{2}x^2), \quad -\infty < x < \infty \\
 g(y) &= \frac{1}{\sqrt{2\pi}} \exp(-\frac{1}{2}y^2), \quad -\infty < y < \infty
 \end{aligned}$$

となる。

$X, Y$  の結合確率密度関数は、 $X, Y$  は互いに独立な確率変数なので、

$$\begin{aligned}
 h(x, y) &= f(x)g(y) \\
 &= \frac{1}{\sqrt{2\pi}} \exp(-\frac{1}{2}x^2) \frac{1}{\sqrt{2\pi}} \exp(-\frac{1}{2}y^2) \\
 &= \frac{1}{2\pi} \exp(-\frac{1}{2}(x^2 + y^2))
 \end{aligned}$$

$u = \frac{x}{y}, v = y$  として、変数変換を行う。

$x = uv, y = v$  なので、

$$\begin{pmatrix} \frac{\partial x}{\partial u} & \frac{\partial x}{\partial v} \\ \frac{\partial y}{\partial u} & \frac{\partial y}{\partial v} \end{pmatrix} = \begin{pmatrix} v & u \\ 0 & 1 \end{pmatrix}$$

となるので、 $U, V$  の結合確率密度関数  $s(u, v)$  は、変数変換により、

$$\begin{aligned}
 s(u, v) &= h(uv, v) \begin{vmatrix} v & u \\ 0 & 1 \end{vmatrix} \\
 &= \frac{1}{2\pi} \exp(-\frac{1}{2}v^2(1+u^2)) |v|
 \end{aligned}$$

$U$  の周辺確率密度関数は、

$$\begin{aligned}
 p(u) &= \int s(u, v) dv \\
 &= \int_{-\infty}^{\infty} \frac{1}{2\pi} |v| \exp(-\frac{1}{2}v^2(1+u^2)) dv \\
 &= \frac{1}{\pi} \int_0^{\infty} v \exp(-\frac{1}{2}v^2(1+u^2)) dv \\
 &= \frac{1}{\pi} \left[ -\frac{1}{1+u^2} \exp(-\frac{1}{2}v^2(1+u^2)) \right]_{v=0}^{\infty} \\
 &= \frac{1}{\pi(1+u^2)}
 \end{aligned}$$

これは、コーシー分布の密度関数である。

- (2)  $U$  の 1 次の積率 (すなわち、平均) は存在しないということを証明する。

$$\begin{aligned}
 E(U) &= \int u f(u) du
 \end{aligned}$$

$$\begin{aligned}
&= \int_{-\infty}^{\infty} u \frac{1}{\pi(1+u^2)} du \\
&= \int_1^{\infty} \frac{1}{2\pi x} dx \quad \leftarrow x = 1+u^2 \text{ で置換積分} \\
&= \left[ \frac{1}{2\pi} \log x \right]_1^{\infty} \quad \leftarrow \frac{d \log x}{dx} = \frac{1}{x} \\
&= \infty
\end{aligned}$$

$-\infty < u < \infty$  のとき,  $x = 1+u^2$  の範囲は,  $1 < x < \infty$  となる。

$$\begin{aligned}
&= \int_0^1 \left[ \frac{1}{3}x^3 + \frac{1}{2}yx^2 \right]_0^1 dy \\
&= \int_0^1 \left( \frac{1}{3} + \frac{1}{2}y \right) dy \\
&= \left[ \frac{1}{3}y + \frac{1}{4}y^2 \right]_0^1 \\
&= \frac{7}{12}
\end{aligned}$$

$f(x, y)$  の形は,  $x$  と  $y$  を入れ替えても同じ形なので,

$$E(Y) = E(X) = \frac{7}{12}$$

となる。

$$\begin{aligned}
V(X) &= E\left((X - \mu)^2\right) \quad \leftarrow \mu = E(X) = \frac{7}{12} \\
&= E(X^2) - \mu^2 \\
&= \int_0^1 \int_0^1 x^2 f(x, y) dx dy - \mu^2 \\
&= \int_0^1 \int_0^1 x^2(x+y) dx dy - \mu^2 \\
&= \int_0^1 \left[ \frac{1}{4}x^4 + \frac{1}{3}yx^3 \right]_0^1 dy - \mu^2 \\
&= \int_0^1 \left( \frac{1}{4} + \frac{1}{3}y \right) dy - \mu^2 \\
&= \left[ \frac{1}{4}y + \frac{1}{6}y^2 \right]_0^1 - \mu^2 \\
&= \frac{5}{12} - \left( \frac{7}{12} \right)^2 \\
&= \frac{11}{144}
\end{aligned}$$

同様に,

$$V(Y) = V(X) = \frac{11}{144}$$

となる。

$$\begin{aligned}
\text{Cov}(X, Y) &= E\left((X - \mu_x)(Y - \mu_y)\right) \\
&= E(XY) - \mu_x \mu_y \\
&= \frac{1}{3} - \frac{7}{12} \frac{7}{12} \\
&= -\frac{1}{144}
\end{aligned}$$

7 連続型確率変数  $X, Y$  の同時密度関数が

$$f(x, y) = \begin{cases} x+y, & 0 < x < 1, 0 < y < 1 \text{ のとき} \\ 0, & \text{その他} \end{cases}$$

であるとき, 次の問に答えよ。

- (1)  $XY$  の期待値を求めよ。
- (2)  $X$  と  $Y$  の相関係数を求めよ。
- (3)  $X$  の周辺密度関数を求めよ。

[解答]

- (1)  $XY$  の期待値を求める。

$$\begin{aligned}
E(XY) &= \int_0^1 \int_0^1 xyf(x, y) dx dy \\
&= \int_0^1 \int_0^1 xy(x+y) dx dy \\
&= \int_0^1 \left[ \frac{1}{3}yx^3 + \frac{1}{2}y^2x^2 \right]_0^1 dy \\
&= \int_0^1 \left( \frac{1}{3}y + \frac{1}{2}y^2 \right) dy \\
&= \left[ \frac{1}{6}y^2 + \frac{1}{6}y^3 \right]_0^1 \\
&= \frac{1}{3}
\end{aligned}$$

- (2)  $X$  と  $Y$  の相関係数  $\rho = \frac{\text{Cov}(X, Y)}{\sqrt{V(X)V(Y)}}$  を求める。

$$\begin{aligned}
E(X) &= \int_0^1 \int_0^1 xf(x, y) dx dy \\
&= \int_0^1 \int_0^1 x(x+y) dx dy
\end{aligned}$$

ただし,

$$\mu_x = E(X) = \frac{7}{12}, \quad \mu_y = E(Y) = \frac{7}{12}$$

よって,

$$\begin{aligned} \rho &= \frac{\text{Cov}(X, Y)}{\sqrt{V(X)V(Y)}} \\ &= \frac{-\frac{1}{144}}{\sqrt{\frac{11}{144} \frac{11}{144}}} = -\frac{1}{11} \end{aligned}$$

(3)  $X$  の周辺密度関数  $f_x(x)$  を求める。

$$\begin{aligned} f_x(x) &= \int f(x, y) dy \\ &= \int_0^1 (x + y) dy \\ &= \left[ xy + \frac{1}{2}y^2 \right]_{y=0}^1 \\ &= x + \frac{1}{2} \end{aligned}$$

8 離散型確率変数  $X$  の密度関数が

$$f(x) = \frac{e^{-\lambda} \lambda^x}{x!}, \quad x = 0, 1, 2, \dots,$$

であるとき, 次の問に答えよ。

- (1)  $\sum_{x=0}^{\infty} f(x) = 1$  となることを証明せよ。
- (2)  $X$  の積率母関数を求めよ。
- (3) 積率母関数をもとにして,  $X$  の平均と分散を求めよ。

[解答]

(1)  $\sum_{x=0}^{\infty} f(x) = 1$  となることを証明する。

$$\begin{aligned} \sum_{x=0}^{\infty} f(x) &= \sum_{x=0}^{\infty} e^{-\lambda} \frac{\lambda^x}{x!} \\ &= e^{-\lambda} \sum_{x=0}^{\infty} \frac{\lambda^x}{x!} \\ &= e^{-\lambda} e^{\lambda} \\ &= 1 \end{aligned}$$

$$e^x = \sum_{k=0}^{\infty} \frac{x^k}{k!} \text{ に注意。}$$

なぜなら,  $f(x) = e^x$  としたとき,  $f^{(k)}(x) = e^x$  となる。

テーラー展開の公式は,

$$f(x) = \sum_{k=0}^{\infty} \frac{1}{k!} f^{(k)}(x_0)(x - x_0)^k$$

なので,  $x_0 = 0$  として,  $x = 0$  の回りでテーラー展開すると,

$$\begin{aligned} f(x) &= \sum_{k=0}^{\infty} \frac{1}{k!} f^{(k)}(0)x^k \\ &= \sum_{k=0}^{\infty} \frac{1}{k!} x^k \\ &= \sum_{k=0}^{\infty} \frac{x^k}{k!} \end{aligned}$$

を得る。

$x$  を  $\lambda$ ,  $k$  を  $x$  で置き換える。

(2)  $X$  の積率母関数を求める。

$$\begin{aligned} \phi(\theta) &= E(e^{\theta X}) \\ &= \sum_{x=0}^{\infty} e^{\theta x} f(x) \\ &= \sum_{x=0}^{\infty} e^{\theta x} e^{-\lambda} \frac{\lambda^x}{x!} \\ &= \sum_{x=0}^{\infty} e^{-\lambda} \frac{(e^{\theta} \lambda)^x}{x!} \\ &= e^{-\lambda} \exp(e^{\theta} \lambda) \sum_{x=0}^{\infty} \exp(-e^{\theta} \lambda) \frac{(e^{\theta} \lambda)^x}{x!} \\ &= e^{-\lambda} \exp(e^{\theta} \lambda) \sum_{x=0}^{\infty} e^{-\lambda'} \frac{\lambda'^x}{x!} \\ &= \exp(-\lambda) \exp(e^{\theta} \lambda) \\ &= \exp(\lambda(e^{\theta} - 1)) \end{aligned}$$

ただし,  $\lambda' = e^{\theta} \lambda$  に注意

(3) 積率母関数をもとにして,  $X$  の平均と分散を求める。

平均について:

$$E(X) = \phi'(0)$$

$$\phi(\theta) = \exp(\lambda(e^\theta - 1)),$$

$$\phi'(\theta) = \lambda e^\theta \exp(\lambda(e^\theta - 1)) \text{ なので,}$$

$$\begin{aligned} E(X) &= \phi'(0) \\ &= \lambda \end{aligned}$$

分散について:

$$V(X) = E(X^2) - (E(X))^2 \text{ なので, } E(X^2) \text{ を求める。}$$

$$E(X^2) = \phi''(0)$$

$$\phi''(\theta) = (1 + \lambda e^\theta) \lambda e^\theta \exp(\lambda(e^\theta - 1)) \text{ なので,}$$

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \\ &= \phi''(0) - (\phi'(0))^2 \\ &= (1 + \lambda)\lambda - \lambda^2 \\ &= \lambda \end{aligned}$$

## 6 大数の法則と中心極限定理

### 6.1 Chebyshev の不等式

$g(x) \geq 0$  について,

$$P(g(X) \geq k) \leq \frac{E(g(X))}{k}$$

となる。ただし,  $k$  は正の定数とする。

証明:

$g(X) \geq k$  のとき  $U = 1$ ,  $g(X) < k$  のとき  $U = 0$  となる  
離散型確率変数  $U$  を導入する。

離散型確率変数  $U$  は 0 か 1 の値を取り, その確率関数  $f(u)$   
は次のように与えられる。

$$f(u) = P(U = u)$$

ただし,

$$P(U = 1) = P(g(X) \geq k)$$

$$P(U = 0) = P(g(X) < k)$$

となる。

このとき, 常に, 以下の式が成り立つ。

$$g(X) \geq kU$$

よって, 両辺に期待値を取ると,

$$E(g(X)) \geq kE(U)$$

となる。 $E(U)$  を求める。

$$\begin{aligned} E(U) &= \sum_{u=0}^1 uP(U = u) \\ &= 1 \times P(U = 1) + 0 \times P(U = 0) \\ &= 1 \times P(g(X) \geq k) + 0 \times P(g(X) < k) \\ &= P(g(X) \geq k) \end{aligned}$$

したがって,

$$E(g(X)) \geq kP(g(X) \geq k)$$

から,

$$P(g(X) \geq k) \leq \frac{E(g(X))}{k}$$

を得る。

代表的な例：  $E(X) = \mu, V(X) = \sigma^2, \lambda > 1$  を任意の定数とする。このとき，

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

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

となる。

証明：

$g(X) = (X - \mu)^2, k = \lambda^2\sigma^2$  とすると，

$$P(g(X) \geq k) \leq \frac{E(g(X))}{k}$$

から，

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

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

を得る。

さらに， $\epsilon = \lambda\sigma$  とすると，

$$P(|X - \mu| > \epsilon) \leq \frac{\sigma^2}{\epsilon^2}$$

とも書き表される。

## 6.2 大数の (弱) 法則 (Convergence in probability)

$X_1, X_2, \dots, X_n$  が互いに独立な確率変数ですべて同じ分布に従うとし，すべての  $i$  について  $E(X_i) = \mu$  とする。このとき任意の正数  $\epsilon$  について， $n \rightarrow \infty$  のとき，

$$P(|\bar{X}_n - \mu| > \epsilon) \rightarrow 0$$

が成り立つ。ただし，

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

とする。

このとき， $\bar{X}_n$  は  $\mu$  に確率収束するという。

証明：

$E(\bar{X}_n) = \mu, V(\bar{X}_n) = \frac{\sigma^2}{n}$  なので，

$$P(|\bar{X}_n - \mu| > \epsilon) \leq \frac{\sigma^2}{n\epsilon^2}$$

が成り立つ。したがって， $n \rightarrow \infty$  のとき，

$$P(|\bar{X}_n - \mu| > \epsilon) \leq \frac{\sigma^2}{n\epsilon^2} \rightarrow 0$$

となる。すなわち， $\bar{X}_n \rightarrow \mu$  が得られる。

系：また， $X_1, X_2, \dots, X_n$  が同じ分布に従わなくても，独立性もなくても，

$$m_n = E\left(\sum_{i=1}^n X_i\right),$$

$$V_n = V\left(\sum_{i=1}^n X_i\right),$$

が存在し， $n \rightarrow \infty$  のとき，

$$\frac{V_n}{n^2} \rightarrow 0$$

が成り立てば，

$$\frac{\sum_{i=1}^n X_i - m_n}{n} \rightarrow 0$$

が成り立つ。(証明略)

2 つとも，大数の (弱) 法則と呼ばれる。

## 6.3 中心極限定理

$X_1, X_2, \dots, X_n$  が互いに独立な確率変数ですべて同じ分布に従うとし，すべての  $i$  について  $E(X_i) = \mu, V(X_i) = \sigma^2$  とする。以上の仮定のもとで， $n \rightarrow \infty$  のとき，

$$P\left(\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} < x\right) \rightarrow \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}u^2} du$$

が成り立つ。⇒ 中心極限定理

証明：

$Y_i = \frac{X_i - \mu}{\sigma}$  と  $Y_i$  を定義する。

$$\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} = \frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{X_i - \mu}{\sigma}$$

$$= \frac{1}{\sqrt{n}} \sum_{i=1}^n Y_i$$

一方， $E(Y_i) = 0, V(Y_i) = 1$  を利用して， $Y_i$  の積率母関数は，

$$\phi(\theta) \equiv E(e^{Y_i\theta})$$

$$= E\left(1 + Y_i\theta + \frac{1}{2}Y_i^2\theta^2 + \frac{1}{3!}Y_i^3\theta^3 \dots\right)$$

$$= 1 + \frac{1}{2}\theta^2 + O(\theta^3)$$

となる。(  $\theta = 0$  の回りで,  $e^{Y_i\theta}$  をテーラー展開する。 )

$Z = \frac{1}{\sqrt{n}} \sum_{i=1}^n Y_i$  の積率母関数  $\Phi(\theta)$  は,

$$\begin{aligned}\Phi(\theta) &= E(e^{Z\theta}) \\ &= E\left(e^{\frac{\theta}{\sqrt{n}} \sum_{i=1}^n Y_i}\right) \\ &= \prod_{i=1}^n E\left(e^{\frac{\theta}{\sqrt{n}} Y_i}\right) \\ &= \prod_{i=1}^n \phi_i\left(\frac{\theta}{\sqrt{n}}\right) \\ &= \left(\phi\left(\frac{\theta}{\sqrt{n}}\right)\right)^n \\ &= \left(1 + \frac{1}{2} \frac{\theta^2}{n} + O\left(\frac{\theta^3}{n^{\frac{3}{2}}}\right)\right)^n \\ &= \left(1 + \frac{1}{2} \frac{\theta^2}{n} + O\left(n^{-\frac{3}{2}}\right)\right)^n\end{aligned}$$

注)

$Y_1, Y_2, \dots, Y_n$  はそれぞれ独立で, 同じ分布関数を持つので, 積率母関数は同じになる。すなわち,

$$\phi_1(\theta) = \phi_2(\theta) = \dots = \phi_n(\theta) = \phi(\theta)$$

となる。

さらに,  $x = \frac{1}{2} \frac{\theta^2}{n} + O(n^{-\frac{3}{2}})$  とおき,  $\frac{n}{x}$  を両辺に掛けて,  $n = \frac{1}{x} \left(\frac{1}{2} \theta^2 + O(n^{-\frac{1}{2}})\right)$  を代入する。

$$\begin{aligned}\Phi(\theta) &= \left(1 + \frac{1}{2} \frac{\theta^2}{n} + O\left(n^{-\frac{3}{2}}\right)\right)^n \\ &= (1+x)^{\frac{1}{x}(\frac{\theta^2}{2} + O(n^{-\frac{1}{2}}))} \\ &= \left((1+x)^{\frac{1}{x}}\right)^{\frac{\theta^2}{2} + O(n^{-\frac{1}{2}})} \rightarrow e^{\frac{\theta^2}{2}}\end{aligned}$$

$n \rightarrow \infty$  のとき,  $x \rightarrow 0$  となる。

注)

$e$  の定義について,

$$\begin{aligned}e &= \lim_{x \rightarrow 0} (1+x)^{\frac{1}{x}} = \lim_{h \rightarrow \infty} \left(1 + \frac{1}{h}\right)^h \\ &= 2.71828182845905\end{aligned}$$

に注意。

$e^{\frac{\theta^2}{2}}$  は標準正規分布  $N(0, 1)$  の積率母関数であるので,

$$P\left(\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} < x\right) \rightarrow \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}u^2} du$$

が成り立つ。

系:  $X_1, X_2, \dots, X_n$  が同じ分布に従わなくても, 独立性もなくても,  $n \rightarrow \infty$  のとき,

$$\begin{aligned}P\left(\frac{\sum_{i=1}^n X_i - E(\sum_{i=1}^n X_i)}{\sqrt{V(\sum_{i=1}^n X_i)}} < x\right) \\ \rightarrow \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}u^2} du\end{aligned}$$

が成り立つ。(証明略)

## 7 大数の強法則 (Almost sure convergence)

大数の強法則 (その 1):  $X_1, X_2, \dots, X_n$  が互いに独立な確率変数ですべて同じ分布に従うとし, すべての  $i$  について  $E(X_i) = \mu$  とする。このとき,

$$P\left(\lim_{n \rightarrow \infty} \bar{X}_n = \mu\right) = 1$$

ただし,  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$  とする。

大数の強法則 (その 2):  $X_1, X_2, \dots, X_n$  が互いに独立な確率変数で, 平均と分散が存在するものとする (同一の分布に従わなくてもよい)。  $V(X_i) = \sigma_i^2$ ,  $S_n = \sum_{i=1}^n X_n$ ,  $m_n = E(S_n)$  とする。  $\sum_{i=1}^{\infty} \frac{\sigma_i^2}{i^2} < \infty$  のとき,

$$P\left(\lim_{n \rightarrow \infty} \frac{S_n - m_n}{n} = 0\right) = 1$$

が成り立つ。

## 8 統計的推定

### 8.1 推定法と標本平均および標本分散の性質

#### 8.1.1 推定法

点推定: 母集団の分布型は既知, その分布のある特性値  $\theta$  (母数) は未知とする。

その母集団の分布は  $f(x; \theta)$  で与えられている。

このとき, 標本の実現値  $(x_1, x_2, \dots, x_n)$  から適当な値  $\hat{\theta}_n(x_1, x_2, \dots, x_n)$  を計算する。

$\hat{\theta}_n(x_1, x_2, \dots, x_n)$  を  $\theta$  の推定値とする。⇒ 点推定  
例：

母平均  $\mu$  の点推定値 (= 標本平均  $\bar{x}$ )

$$\hat{\mu}_n(x_1, x_2, \dots, x_n) \equiv \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

母分散  $\sigma^2$  の点推定値 (= 標本不偏分散  $s^2$ )

$$\hat{\sigma}_n^2(x_1, x_2, \dots, x_n) \equiv s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

区間推定： 母集団の分布の未知母数  $\theta$  を推定するとき，  
実現値  $(x_1, x_2, \dots, x_n)$  より  $\hat{\theta}_L(x_1, x_2, \dots, x_n)$  と  $\hat{\theta}_U(x_1,$   
 $x_2, \dots, x_n)$  を作り，区間  $(\hat{\theta}_L, \hat{\theta}_U)$  の中に  $\theta$  は  $1 - \alpha$  の確  
率で入っていることを示す推定法を区間推定法という。

区間  $(\hat{\theta}_L, \hat{\theta}_U)$  は信頼係数  $1 - \alpha$  の  $\theta$  の信頼区間である。

$\hat{\theta}_L$  ⇒ 信頼下限

$\hat{\theta}_U$  ⇒ 信頼上限

信頼区間の幅はなるべく狭くなるように  $\hat{\theta}_L, \hat{\theta}_U$  を選ぶ。

### 8.1.2 標本，統計量，推定量

母集団の分布型は既知，その分布のある特性値  $\theta$  (母数) は  
未知とする。

その母集団の分布は  $f(x; \theta)$  で与えられている。

標本：  $X_1, X_2, \dots, X_n$  ⇒ 母集団の部分集合

実現値：  $x_1, x_2, \dots, x_n$

母数  $\theta$  の推定量：  $\hat{\theta}(X_1, X_2, \dots, X_n)$

母数  $\theta$  の推定値：  $\hat{\theta}(x_1, x_2, \dots, x_n)$

例：  $\theta = (\mu, \sigma^2)$  とする。

$\mu$  の推定量：  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$

$\mu$  の推定値：  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$

$\sigma^2$  の推定量：  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$

$\sigma^2$  の推定値：  $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$

注)

確率変数の関数 ⇒ 統計量

母数の推定のために使われる統計量 ⇒ 推定量

### 8.1.3 母平均，母分散の推定

$X_1, X_2, \dots, X_n$  は互いに独立で，すべて同一の分布 (すな  
わち，平均  $\mu$ ，分散  $\sigma^2$  ですべて同一の分布) に従うものと  
する。

1. 母平均  $\mu$  の推定量：

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

2. 母分散  $\sigma^2$  の推定量：

- 母平均  $\mu$  が既知のとき：  $S^{*2} = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$

- 母平均  $\mu$  が未知のとき：  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$

$\bar{X}$  の性質：

$$\begin{aligned} E(\bar{X}) &= E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \\ &= \frac{1}{n} E\left(\sum_{i=1}^n X_i\right) \\ &= \frac{1}{n} \sum_{i=1}^n E(X_i) \\ &= \frac{1}{n} \sum_{i=1}^n \mu \\ &= \frac{1}{n} n\mu \\ &= \mu \end{aligned}$$

$$\begin{aligned} V(\bar{X}) &= V\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \\ &= \frac{1}{n^2} V\left(\sum_{i=1}^n X_i\right) \\ &= \frac{1}{n^2} \sum_{i=1}^n V(X_i) \\ &= \frac{1}{n^2} \sum_{i=1}^n \sigma^2 \\ &= \frac{1}{n^2} n\sigma^2 \\ &= \frac{\sigma^2}{n} \end{aligned}$$

必要な公式：

$$E(aX) = aE(X)$$

$$V(aX) = a^2V(X)$$

$$E(X + Y) = E(X) + E(Y)$$

$$V(X + Y) = V(X) + V(Y) \iff X \text{ と } Y \text{ は独立のとき}$$

$S^{*2}$ ,  $S^2$  の性質：

$$\begin{aligned} E(S^{*2}) &= E\left(\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2\right) \\ &= \frac{1}{n} E\left(\sum_{i=1}^n (X_i - \mu)^2\right) \\ &= \frac{1}{n} \sum_{i=1}^n E\left((X_i - \mu)^2\right) \\ &= \frac{1}{n} \sum_{i=1}^n V(X_i) \\ &= \frac{1}{n} \sum_{i=1}^n \sigma^2 \\ &= \frac{1}{n} n\sigma^2 \\ &= \sigma^2 \end{aligned}$$

$$\begin{aligned} E(S^2) &= E\left(\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2\right) \\ &= \frac{1}{n-1} E\left(\sum_{i=1}^n (X_i - \bar{X})^2\right) \\ &= \frac{1}{n-1} E\left(\sum_{i=1}^n ((X_i - \mu) - (\bar{X} - \mu))^2\right) \\ &= \frac{1}{n-1} E\left(\sum_{i=1}^n ((X_i - \mu)^2 - 2(X_i - \mu)(\bar{X} - \mu) + (\bar{X} - \mu)^2)\right) \\ &= \frac{1}{n-1} E\left(\sum_{i=1}^n (X_i - \mu)^2 - 2(\bar{X} - \mu) \sum_{i=1}^n (X_i - \mu) + n(\bar{X} - \mu)^2\right) \\ &= \frac{1}{n-1} E\left(\sum_{i=1}^n (X_i - \mu)^2 - 2n(\bar{X} - \mu)^2 + n(\bar{X} - \mu)^2\right) \end{aligned}$$

$$\begin{aligned} &= \frac{1}{n-1} E\left(\sum_{i=1}^n (X_i - \mu)^2 - n(\bar{X} - \mu)^2\right) \\ &= \frac{1}{n-1} E\left(\sum_{i=1}^n (X_i - \mu)^2\right) - \frac{1}{n-1} E\left(n(\bar{X} - \mu)^2\right) \\ &= \frac{1}{n-1} \sum_{i=1}^n E\left((X_i - \mu)^2\right) - \frac{n}{n-1} E\left((\bar{X} - \mu)^2\right) \\ &= \frac{1}{n-1} \sum_{i=1}^n V(X_i) - \frac{n}{n-1} V(\bar{X}) \\ &= \frac{1}{n-1} \sum_{i=1}^n \sigma^2 - \frac{n}{n-1} \frac{\sigma^2}{n} \\ &= \frac{1}{n-1} n\sigma^2 - \frac{1}{n-1} \sigma^2 \\ &= \sigma^2 \end{aligned}$$

必要な公式：

$$E(X_i - \mu)^2 = V(X_i) = \sigma^2$$

$$E(\bar{X} - \mu)^2 = V(\bar{X}) = \frac{\sigma^2}{n}$$

$$\sum_{i=1}^n (X_i - \mu) = n(\bar{X} - \mu)$$

したがって,  $S^{**2} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$  とすると,

$$\begin{aligned} E(S^{**2}) &= E\left(\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2\right) \\ &= E\left(\frac{n-1}{n} \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2\right) \\ &= E\left(\frac{n-1}{n} S^2\right) \\ &= \frac{n-1}{n} E(S^2) \\ &= \frac{n-1}{n} \sigma^2 \end{aligned}$$

## 8.2 点推定法：最適性

母数： $\theta$

推定値： $\hat{\theta}_n(x_1, x_2, \dots, x_n)$

推定量:  $\hat{\theta}_n(X_1, X_2, \dots, X_n)$

$\hat{\theta}_n(X_1, X_2, \dots, X_n)$  を  $\hat{\theta}_n$  と書く。

$\hat{\theta}_n$  の望ましい性質: 不偏性, 有効性, 十分性, 一致性

⇒ 最適性

⇒ 最適推定量

不偏性:  $E(\hat{\theta}_n) = \theta$

⇒  $\theta$  を中心にして  $\hat{\theta}_n$  は分布している。

$\hat{\theta}_n$  は  $\theta$  の不偏推定量であるという。

$E(\hat{\theta}_n) - \theta$  をバイアス (bias) と呼ぶ。

$X_1, X_2, \dots, X_n$  は互いに独立で, すべて同一の分布 (すなわち, 平均  $\mu$ , 分散  $\sigma^2$  ですべて同一の分布) に従うものとする。

1. 母平均  $\mu$  の推定量:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

2. 母分散  $\sigma^2$  の推定量:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

$E(\bar{X}) = \mu, E(S^2) = \sigma^2$  なので,  $\bar{X}, S^2$  は  $\mu, \sigma^2$  の不偏推定量である。

有効性: 2つの不偏推定量  $\hat{\theta}_n, \tilde{\theta}_n$  を考える。

すなわち,  $E(\hat{\theta}_n) = \theta, E(\tilde{\theta}_n) = \theta$

$V(\hat{\theta}_n) < V(\tilde{\theta}_n)$  のとき,  $\hat{\theta}_n$  が  $\tilde{\theta}_n$  より有効であるという。

⇒ バラツキの小さい推定量の方が望まれる。

クラメル・ラオの不等式 (Cramer-Rao Inequality): 任意の不偏推定量  $\hat{\theta}_n$  について,

$$V(\hat{\theta}_n) \geq \frac{\sigma^2}{n}$$

が成り立つ。ただし,

$$\begin{aligned} \sigma^2 &= \sigma^2(\theta) \\ &= \frac{1}{E\left[\left(\frac{\partial \log f(X; \theta)}{\partial \theta}\right)^2\right]} \\ &= \frac{1}{E\left(\frac{\partial^2 \log f(X; \theta)}{\partial \theta^2}\right)} \end{aligned}$$

とする。

等号が成り立つ  $\hat{\theta}_n$  が存在するとき,  $\hat{\theta}_n$  は最小分散の不偏推定量である。

⇒ 有効推定量

クラメル・ラオの不等式の証明:

まず, 準備として, 尤度関数  $l(\theta; x) = l(\theta; x_1, x_2, \dots, x_n)$  は  $(X_1, X_2, \dots, X_n)$  の結合密度関数なので, その積分値は 1 となる。

尤度関数については, 後述。

すなわち,

$$1 = \int l(\theta; x) dx$$

を得る。

ただし,  $l(\theta; x) = \prod_{i=1}^n f(x_i; \theta)$  とする。

$\int \dots dx$  は  $n$  重積分を意味するものとする。

両辺を  $\theta$  で微分して整理する。

$$\begin{aligned} 0 &= \int \frac{\partial l(\theta; x)}{\partial \theta} dx \\ &= \int \frac{1}{l(\theta; x)} \frac{\partial l(\theta; x)}{\partial \theta} l(\theta; x) dx \\ &= \int \frac{\partial \log l(\theta; x)}{\partial \theta} l(\theta; x) dx \\ &= E\left[\frac{\partial \log l(\theta; X)}{\partial \theta}\right] \end{aligned}$$

これは  $\frac{\partial \log l(\theta; X)}{\partial \theta}$  の期待値はゼロを意味する。

3行目では,  $\frac{d \log x}{dx} = \frac{1}{x}$  に注意。

今,  $\theta$  の推定量を  $\hat{\theta}_n$  とおく。

$$E(\hat{\theta}_n) = \int \hat{\theta}_n l(\theta; x) dx$$

$\theta$  について微分

$$\begin{aligned} &\frac{\partial E(\hat{\theta}_n)}{\partial \theta} \\ &= \int \hat{\theta}_n \frac{\partial l(\theta; x)}{\partial \theta} dx \\ &= \int \hat{\theta}_n \frac{\partial \log l(\theta; x)}{\partial \theta} l(\theta; x) dx \\ &= \int (\hat{\theta}_n - E(\hat{\theta}_n)) \left( \frac{\partial \log l(\theta; x)}{\partial \theta} - E\left(\frac{\partial \log l(\theta; x)}{\partial \theta}\right) \right) \end{aligned}$$

$$= \text{Cov} \left( \hat{\theta}_n, \frac{\partial \log l(\theta; X)}{\partial \theta} \right) \times l(\theta; x) dx$$

簡単化のために,  $\hat{\theta}_n, \theta$  をスカラーとする。

このとき,

$$\begin{aligned} & \left( \frac{\partial \text{E}(\hat{\theta}_n)}{\partial \theta} \right)^2 \\ &= \left[ \text{Cov} \left( \hat{\theta}_n, \frac{\partial \log l(\theta; X)}{\partial \theta} \right) \right]^2 \\ &= \rho^2 \text{V}(\hat{\theta}_n) \text{V} \left( \frac{\partial \log l(\theta; X)}{\partial \theta} \right) \\ &\leq \text{V}(\hat{\theta}_n) \text{V} \left( \frac{\partial \log l(\theta; X)}{\partial \theta} \right) \end{aligned}$$

ただし,  $\rho$  は  $\hat{\theta}_n$  と  $\frac{\partial \log l(\theta; X)}{\partial \theta}$  との相関係数とする。すなわち,  $-1 \leq \rho \leq 1$  で, その定義は,

$$\rho = \frac{\text{Cov} \left( \hat{\theta}_n, \frac{\partial \log l(\theta; X)}{\partial \theta} \right)}{\sqrt{\text{V}(\hat{\theta}_n)} \sqrt{\text{V} \left( \frac{\partial \log l(\theta; X)}{\partial \theta} \right)}}$$

となる。よって,

$$\left( \frac{\partial \text{E}(\hat{\theta}_n)}{\partial \theta} \right)^2 \leq \text{V}(\hat{\theta}_n) \text{V} \left( \frac{\partial \log l(\theta; X)}{\partial \theta} \right)$$

すなわち,

$$\text{V}(\hat{\theta}_n) \geq \frac{\left( \frac{\partial \text{E}(\hat{\theta}_n)}{\partial \theta} \right)^2}{\text{V} \left( \frac{\partial \log l(\theta; X)}{\partial \theta} \right)}$$

$\text{E}(\hat{\theta}_n) = \theta$  のとき,

$$\begin{aligned} \text{V}(\hat{\theta}_n) &\geq \frac{\left( \frac{\partial \text{E}(\hat{\theta}_n)}{\partial \theta} \right)^2}{\text{V} \left( \frac{\partial \log l(\theta; X)}{\partial \theta} \right)} \\ &= \frac{1}{\text{V} \left( \frac{\partial \log l(\theta; X)}{\partial \theta} \right)} \end{aligned}$$

さらに,

$$\text{V} \left( \frac{\partial \log l(\theta; X)}{\partial \theta} \right)$$

$$\begin{aligned} &= \text{V} \left( \sum_{i=1}^n \frac{\partial \log f(X_i; \theta)}{\partial \theta} \right) \\ &= \sum_{i=1}^n \text{V} \left( \frac{\partial \log f(X_i; \theta)}{\partial \theta} \right) \quad (\text{互いに独立により}) \\ &= \sum_{i=1}^n \text{V} \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right) \\ &= n \text{V} \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right) \quad (\text{同一の分布により}) \\ &= n \text{E} \left[ \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right)^2 \right] \\ &= n \int_{-\infty}^{\infty} \left( \frac{\partial \log f(x; \theta)}{\partial \theta} \right)^2 f(x; \theta) dx \end{aligned}$$

$\int f(x; \theta) dx = 1$  から,  $\text{E} \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right) = 0$  となるので, 5 つ目の等号が成り立つ。

したがって,

$$\text{V}(\hat{\theta}_n) \geq \frac{1}{n \text{E} \left[ \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right)^2 \right]} = \frac{\sigma^2(\theta)}{n}$$

となる。

次に,

$$\begin{aligned} & - \text{E} \left( \frac{\partial^2 \log f(X; \theta)}{\partial \theta^2} \right) \\ &= \text{E} \left[ \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right)^2 \right] \\ &= \text{V} \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right) \end{aligned}$$

を証明する。

$$\int f(x; \theta) dx = 1$$

$\theta$  について微分

$$\int \frac{\partial f(x; \theta)}{\partial \theta} dx = 0$$

( $x$  の範囲は  $\theta$  に依存しないもの, 微分  $\partial f(x; \theta)/\partial \theta$  が存在するものと仮定される)

上式の変形により

$$\int \frac{\partial \log f(x; \theta)}{\partial \theta} f(x; \theta) dx = 0$$

すなわち,

$$E\left(\frac{\partial \log f(x; \theta)}{\partial \theta}\right) = 0$$

さらに,  $\theta$  について微分

$$\begin{aligned} & \int \frac{\partial^2 \log f(x; \theta)}{\partial \theta^2} f(x; \theta) dx \\ & + \int \frac{\partial \log f(x; \theta)}{\partial \theta} \frac{\partial f(x; \theta)}{\partial \theta} dx \\ & = \int \frac{\partial^2 \log f(x; \theta)}{\partial \theta^2} f(x; \theta) dx \\ & + \int \left(\frac{\partial \log f(x; \theta)}{\partial \theta}\right)^2 f(x; \theta) dx \end{aligned}$$

よって,

$$\begin{aligned} & - E\left(\frac{\partial^2 \log f(X; \theta)}{\partial \theta \partial \theta'}\right) \\ & = E\left[\left(\frac{\partial \log f(X; \theta)}{\partial \theta}\right)^2\right] \\ & = V\left(\frac{\partial \log f(X; \theta)}{\partial \theta}\right) \end{aligned}$$

を得る。

したがって,

$$\begin{aligned} \sigma^2(\theta) &= \frac{1}{E\left[\left(\frac{\partial \log f(X; \theta)}{\partial \theta}\right)^2\right]} \\ &= \frac{1}{E\left(\frac{\partial^2 \log f(X; \theta)}{\partial \theta^2}\right)} \end{aligned}$$

となる。

例:  $X_1, X_2, \dots, X_n$  は互いに独立で, すべて同一の正規分布 (すなわち, 平均  $\mu$ , 分散  $\sigma^2$  ですべて同一の分布) に従うものとする。ただし,  $\sigma^2$  は既知とする。このとき,  $\mu$  の推定量  $\bar{X}$  は有効推定量である。

証明:

$V(\bar{X})$  は分布形にかかわらず,  $\sigma^2 < \infty$  のとき,  $\frac{\sigma^2}{n}$  となる。..... (A)

一方,

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

なので, クラメール・ラオの不等式は, この場合,

$$V(\bar{X}) \geq \frac{1}{nE\left[\left(\frac{\partial \log f(X; \mu)}{\partial \mu}\right)^2\right]}$$

となる。

$$\log f(X; \mu) = -\frac{1}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2}(X - \mu)^2$$

なので,

$$\frac{\partial \log f(X; \mu)}{\partial \mu} = \frac{1}{\sigma^2}(X - \mu)$$

となる。

したがって,

$$\begin{aligned} V(\bar{X}) &\geq \frac{1}{nE\left[\left(\frac{1}{\sigma^2}(X - \mu)\right)^2\right]} \\ &= \frac{1}{n\frac{1}{\sigma^4}E[(X - \mu)^2]} \\ &= \frac{\sigma^2}{n} \end{aligned}$$

となる。..... (B)

(A) と (B) より,  $V(\bar{X}) = \frac{\sigma^2}{n}$  (クラメール・ラオの不等式の下限) が成り立つので,  $\bar{X}$  は有効推定量であると言える。

十分性 (充分性, 充足性):  $X_1, X_2, \dots, X_n$  の同時密度関数が,

$$\begin{aligned} & f(x_1, x_2, \dots, x_n; \theta) \\ & = h(x_1, x_2, \dots, x_n)g(\hat{\theta}_n(x_1, x_2, \dots, x_n); \theta) \end{aligned}$$

と分解できるとき,  $\hat{\theta}_n \equiv \hat{\theta}_n(X_1, X_2, \dots, X_n)$  は  $\theta$  の十分推定量であるという。

すなわち,

$$h(x_1, x_2, \dots, x_n; \theta) = h(x_1, x_2, \dots, x_n)$$

が成り立つとき ( $\hat{\theta}_n$  を与えたときの  $X_1, X_2, \dots, X_n$  の条件付き分布が母数  $\theta$  に依存しないとき),  $\hat{\theta}_n \equiv \hat{\theta}_n(X_1, X_2, \dots, X_n)$  は  $\theta$  の十分推定量となる。

⇒ 標本  $X_1, X_2, \dots, X_n$  に含まれている  $\theta$  に関する情報は, すべて  $\hat{\theta}_n$  に含まれている。

$X_1, X_2, \dots, X_n$  は互いに独立で, すべて同一の正規分布 (すなわち, 平均  $\mu$ , 分散  $\sigma^2$  ですべて同一の分布) に従う

ものとする。ただし、 $\sigma^2$  は既知とする。このとき、 $\bar{X}$  は十分推定量である。

証明：

$$\begin{aligned} & f(x_1, x_2, \dots, x_n; \mu) \\ &= \prod_{i=1}^n f(x_i; \mu) \\ &= \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left( -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right) \\ &= \left( \frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \\ &\quad \times \exp \left( -\frac{1}{2\sigma^2} \left( \sum_{i=1}^n (x_i - \bar{x})^2 + n(\bar{x} - \mu)^2 \right) \right) \\ &= \frac{1}{\sqrt{n}(\sqrt{2\pi\sigma^2})^{n-1}} \exp \left( -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \bar{x})^2 \right) \\ &\quad \times \frac{1}{\sqrt{2\pi\sigma^2/n}} \exp \left( -\frac{1}{2\sigma^2/n} (\bar{x} - \mu)^2 \right) \\ &= h(x_1, x_2, \dots, x_n) g(\bar{x}; \mu) \end{aligned}$$

以上のように、分解可能である。

したがって、 $\bar{X}$  は十分推定量である。

十分推定量の補足

Rao-Blackwell の定理：

$t$  を  $\theta$  の十分統計量、 $\hat{\theta}_n$  を  $\theta$  の不偏推定量とする。このとき、 $E(\hat{\theta}_n|t)$  は  $\theta$  の不偏推定量で、しかも、 $\hat{\theta}_n$  よりも分散は小さい。

⇒ 任意の不偏推定量  $\hat{\theta}_n$  について、 $\hat{\theta}_n = v(t)$  でない限り (不偏推定量  $\hat{\theta}_n$  が  $t$  だけの関数でない限り)、 $v(t) = E(\hat{\theta}_n|t)$  を作ることにより改善される。

どの  $\hat{\theta}_n$  に対しても、同じ  $v(t)$  が一意に決まれば、それ以上の改善は出来ないので、 $v(t)$  は  $\theta$  のあらゆる不偏推定量の中で最小な分散を持つことになる。

⇒  $v(t)$  は有効推定量

一貫性：  $n$  が大きくなるにつれて、任意の  $\epsilon > 0$  について、

$$P(|\hat{\theta}_n - \theta| > \epsilon) \rightarrow 0, \quad n \rightarrow \infty$$

となるとき、 $\hat{\theta}_n$  は  $\theta$  の一致推定量であるという。

$X_1, X_2, \dots, X_n$  は互いに独立で、すべて同一の正規分布 (すなわち、平均  $\mu$ 、分散  $\sigma^2$  ですべて同一の分布) に従う

ものとする。ただし、 $\sigma^2$  は既知とする。このとき、 $\bar{X}$  は一致推定量である。

証明：

チェビシエフの不等式：

$$P(|X - \mu| > \epsilon) \leq \frac{\sigma^2}{\epsilon^2}$$

ただし、 $E(X) = \mu, V(X) = \sigma^2$  とする。

ここで、 $X$  を  $\bar{X}$  にして、 $E(\bar{X}), V(\bar{X})$  を求める。

$$E(\bar{X}) = \mu, \quad V(\bar{X}) = \frac{\sigma^2}{n}$$

を得る。

したがって、 $n \rightarrow \infty$  のとき、

$$P(|\bar{X} - \mu| > \epsilon) \leq \frac{\sigma^2}{n\epsilon^2} \rightarrow 0$$

となる。

よって、 $\bar{X}$  は  $\mu$  の一致推定量である。

定理

$$\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta \quad (\text{漸近的な不偏})$$

かつ

$$\lim_{n \rightarrow \infty} V(\hat{\theta}_n) = 0$$

のとき、 $\hat{\theta}_n$  は  $\theta$  の一致推定量となる。

### 8.3 推定量の求め方：最尤法、積率法、最小二乗法

#### 8.3.1 最尤法

標本  $X_1, X_2, \dots, X_n$  の密度関数：

$$f(x_1, x_2, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i; \theta)$$

$\theta$  は未知母数 ⇒  $\hat{\theta}_n(x_1, x_2, \dots, x_n)$  によって推定

$$l(\theta) = l(\theta; x) = l(\theta; x_1, x_2, \dots, x_n) = \prod_{i=1}^n f(x_i; \theta)$$

のように、 $\theta$  の関数として考える。

$l(\theta)$ ：尤度関数

尤度関数を最大にする  $\theta$  を  $\hat{\theta}_n$  とする。

$\hat{\theta}_n \equiv \hat{\theta}_n(X_1, X_2, \dots, X_n) \Rightarrow$  最尤推定量

$\hat{\theta}_n(x_1, x_2, \dots, x_n) \implies$  最尤推定値  
すなわち,

$$\frac{\partial l(\theta)}{\partial \theta} = 0$$

を解くことによって, 最尤推定量  $\hat{\theta}_n \equiv \hat{\theta}_n(X_1, X_2, \dots, X_n)$  が得られる。

最尤推定量の性質:

小標本について ( $n$  が小さいとき):

- 一般に, 最尤推定量は不偏性を持っていないが, 適当な変換によって, 不偏推定量を作ることが出来る場合が多い。
- 有効推定量が存在すれば (すなわち, クラメール・ラオの不等式の等号を満たすような推定量が存在するならば), 最尤推定量は有効推定量に一致する。
- 十分統計量が存在すれば, 最尤推定量は十分統計量の関数となる。

大標本について ( $n$  が大きいとき):

$n \rightarrow \infty$  のとき,

$$\sqrt{n}(\hat{\theta}_n - \theta) \rightarrow N(0, \sigma^2)$$

となる。  $\implies$  一致性, 漸近的正規性, 漸近の有効性  
ただし,

$$\sigma^2 = \sigma^2(\theta) = \frac{1}{E \left[ \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right)^2 \right]}$$

すなわち,  $n \rightarrow \infty$  のとき,

$$\frac{\sqrt{n}(\hat{\theta}_n - \theta)}{\sigma(\theta)} = \frac{\hat{\theta}_n - \theta}{\sigma(\theta)/\sqrt{n}} \rightarrow N(0, 1)$$

となる。

したがって, 厳密ではないが,  $n$  が大きいとき,

$$\hat{\theta}_n \sim N \left( \theta, \frac{\sigma^2(\theta)}{n} \right)$$

と近似できる。

すなわち,  $n \rightarrow \infty$  のとき,  $\hat{\theta}_n$  の分散はクラメール・ラオの不等式の下限  $\frac{\sigma^2(\theta)}{n}$  に近づくことを意味する。

$\implies$  漸近的に有効推定量

さらに, 分母の  $\theta$  を最尤推定量  $\hat{\theta}_n$  で置き換えて,  $n \rightarrow \infty$  のとき,

$$\frac{\hat{\theta}_n - \theta}{\sigma(\hat{\theta}_n)/\sqrt{n}} \rightarrow N(0, 1)$$

となる。

実際には,  $n$  が大きいとき,

$$\hat{\theta}_n \sim N \left( \theta, \frac{\sigma^2(\hat{\theta}_n)}{n} \right)$$

と近似して用いる。

例:

$X_1, X_2, \dots, X_n$  は互いに独立で, すべて同一の正規分布 (すなわち, 平均  $\mu$ , 分散  $\sigma^2$  ですべて同一の分布) に従うものとする。 $\mu, \sigma^2$  の最尤推定量を求める。

$$\begin{aligned} & f(x_1, x_2, \dots, x_n; \mu, \sigma^2) \\ &= \prod_{i=1}^n f(x_i; \mu, \sigma^2) \\ &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left( -\frac{1}{2\sigma^2} (x_i - \mu)^2 \right) \\ &= (2\pi\sigma^2)^{-n/2} \exp \left( -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right) \\ &= l(\mu, \sigma^2) \end{aligned}$$

対数をとる。(最大化しやすくなる場合が多い)

$$\begin{aligned} \log l(\mu, \sigma^2) &= -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) \\ &\quad - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \end{aligned}$$

対数尤度関数  $\log l(\mu, \sigma^2)$  を  $\mu$  と  $\sigma^2$  について微分して, ゼロと置く。

$$\begin{aligned} \frac{\partial \log l(\mu, \sigma^2)}{\partial \mu} &= \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) \\ &= 0 \\ \frac{\partial \log l(\mu, \sigma^2)}{\partial \sigma^2} &= -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 \\ &= 0 \end{aligned}$$

この2つの連立方程式を解く。

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

$\mu, \sigma^2$  の最尤推定量は,

$$\bar{X}, S^{**2} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

となる。

$E(\bar{X}) = \mu$  なので,  $\mu$  の最尤推定量  $\bar{X}$  は不偏推定量である。

$E(S^{**2}) = \frac{n-1}{n} \sigma^2 \neq \sigma^2$  なので,  $\sigma^2$  の最尤推定量  $S^{**2}$  は不偏推定量でない。

例:

$X_1, X_2, \dots, X_n$  は互いに独立で, すべて同一のベルヌイ分布ですべて同一の分布) に従うものとする。すなわち,  $X$  の確率関数は  $P(X = x) = f(x; p) = p^x (1-p)^{1-x}, x = 0, 1,$  となる。  $p$  の最尤推定量を求める。

$$\begin{aligned} & f(x_1, x_2, \dots, x_n; p) \\ &= \prod_{i=1}^n f(x_i; p) \\ &= \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i} \\ &= p^{\sum_i x_i} (1-p)^{n-\sum_i x_i} \\ &= l(p) \end{aligned}$$

対数をとる。

$$\log l(p) = \left( \sum_i x_i \right) \log(p) + \left( n - \sum_i x_i \right) \log(1-p)$$

対数尤度関数  $\log l(p)$  を  $p$  について微分して, ゼロと置く。

$$\begin{aligned} \frac{\partial \log l(p)}{\partial p} &= \frac{\sum_i x_i}{p} - \frac{n - \sum_i x_i}{1-p} \\ &= \frac{\sum_i x_i - np}{p(1-p)} \\ &= 0 \end{aligned}$$

この方程式を解く。

$$p = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

$p$  の最尤推定量は,

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

となる。

$E(\bar{X}) = p$  なので,  $p$  の最尤推定量  $\bar{X}$  は不偏推定量である。  
 $X$  がベルヌイ分布  $f(x; p)$  のとき,  $E(X) = p$  に注意。

例:

$X_1, X_2, \dots, X_n$  は互いに独立で, すべて同一のポアソン分布 (すなわち, 平均  $\lambda$  ですべて同一の分布) に従うものとする。 $\lambda$  の最尤推定量を求める。

ポアソン分布の確率関数は,

$$P(X = x) = f(x; \lambda) = \frac{\lambda^x e^{-\lambda}}{x!}, \quad x = 0, 1, 2, \dots$$

なので, 尤度関数は,

$$\begin{aligned} l(\lambda) &= \prod_{i=1}^n f(x_i; \lambda) \\ &= \prod_{i=1}^n \frac{\lambda^{x_i} e^{-\lambda}}{x_i!} \\ &= \frac{\lambda^{\sum_{i=1}^n x_i} e^{-n\lambda}}{\prod_{i=1}^n x_i!} \end{aligned}$$

対数尤度関数は,

$$\log l(\lambda) = \log(\lambda) \sum_{i=1}^n x_i - n\lambda - \log\left(\prod_{i=1}^n x_i!\right)$$

となる。

$$\begin{aligned} \frac{\partial \log l(\lambda)}{\partial \lambda} &= \frac{1}{\lambda} \sum_{i=1}^n x_i - n \\ &= 0 \end{aligned}$$

これを解いて,  $\lambda$  の最尤推定量  $\hat{\lambda}$  は,

$$\hat{\lambda} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

となる。

$\hat{\lambda}$  は,  $\lambda$  の不偏推定量, 有効推定量, 十分推定量, 一致推定量である。

証明:

$X$  がパラメータ  $\lambda$  のポアソン分布に従うとき,

$$E(X) = V(X) = \lambda$$

となる。

不偏性：

$$\begin{aligned} E(\hat{\lambda}) &= E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \\ &= \frac{1}{n} \sum_{i=1}^n E(X_i) \\ &= \frac{1}{n} \sum_{i=1}^n \lambda \\ &= \lambda \end{aligned}$$

有効性：

$$\begin{aligned} V(\hat{\lambda}) &= V\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \\ &= \frac{1}{n^2} \sum_{i=1}^n V(X_i) \\ &= \frac{1}{n^2} \sum_{i=1}^n \lambda \\ &= \frac{\lambda}{n} \\ &= \frac{1}{nE\left[\left(\frac{\partial \log f(X; \lambda)}{\partial \lambda}\right)^2\right]} \\ &= \frac{1}{nE\left[\left(\frac{\partial (X \log \lambda - \lambda - \log X!)}{\partial \lambda}\right)^2\right]} \\ &= \frac{1}{nE\left[\left(\frac{X}{\lambda} - 1\right)^2\right]} \\ &= \frac{\lambda^2}{nE[(X - \lambda)^2]} \\ &= \frac{\lambda^2}{nV(X)} \\ &= \frac{\lambda^2}{n\lambda} \\ &= \frac{\lambda}{n} \end{aligned}$$

したがって、

$$V(\hat{\lambda}) = \frac{1}{nE\left[\left(\frac{\partial \log f(X; \lambda)}{\partial \lambda}\right)^2\right]}$$

となり、 $V(\hat{\lambda})$  は、クラメール・ラオの下限に一致する。よって、 $\hat{\lambda}$  は有効推定量である。

十分性：

$$\begin{aligned} \prod_{i=1}^n f(x_i; \lambda) &= \frac{\lambda^{\sum_{i=1}^n x_i} e^{-n\lambda}}{\prod_{i=1}^n x_i!} \\ &= \frac{\lambda^{n\bar{x}} e^{-n\lambda}}{(n\bar{x})!} \frac{(n\bar{x})!}{\prod_{i=1}^n x_i!} \\ &= g(\bar{x}; \lambda) h(x_1, x_2, \dots, x_n) \end{aligned}$$

と分解できる。

一致性：

$$E(\bar{X}) = \lambda, \quad V(\bar{X}) = \frac{\lambda}{n}$$

なので、チェビシエフの不等式に当てはめる。

$$P(|\bar{X} - \lambda| > \epsilon) < \frac{\lambda}{n\epsilon^2} \rightarrow \infty$$

したがって、一致性も成り立つ。

### 8.3.2 積率法 (モーメント法)

$\nu$  次の原点の回りの積率： $E(X^\nu) \equiv \mu'_\nu = \mu'_\nu(\theta)$

$E(X^\nu)$  の推定量を  $\frac{1}{n} \sum_{i=1}^n X_i^\nu$  とする。

$$\frac{1}{n} \sum_{i=1}^n X_i^\nu = \mu'_\nu(\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k)$$

$\nu = 1, 2, \dots, k$  として、 $k$  個の連立方程式を  $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k$  について解く。

その解：

$$\hat{\theta}_1(X_1, X_2, \dots, X_n),$$

$$\hat{\theta}_2(X_1, X_2, \dots, X_n),$$

⋮

$$\hat{\theta}_k(X_1, X_2, \dots, X_n)$$

⇒ 積率法 (モーメント法) による推定量

例：

$X_1, X_2, \dots, X_n$  は互いに独立で、平均  $\mu$ 、分散  $\sigma^2$  の正規分布に従うものとする。 $\mu, \sigma^2$  の積率法による推定値を求める。

$$E(X) = \mu \implies \frac{1}{n} \sum_{i=1}^n X_i = \hat{\mu}$$

$$E(X^2) = \sigma^2 + \mu^2 \implies \frac{1}{n} \sum_{i=1}^n X_i^2 = \hat{\sigma}^2 + \hat{\mu}^2$$

連立方程式を解いて,

$$\hat{\mu} = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

を得る。この場合, 最尤推定量に一致する。

例:

$X_1, X_2, \dots, X_n$  は互いに独立で, パラメータ  $\alpha, \beta$  のガンマ分布に従うものとする。 $\alpha, \beta$  の積率法による推定値を求める。パラメータ  $\alpha, \beta$  のガンマ分布とは次の分布である。

$$f(x) = \begin{cases} \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-\frac{x}{\beta}}, & x > 0 \text{ のとき,} \\ 0, & x \leq 0 \text{ のとき} \end{cases}$$

ただし,  $\Gamma(\alpha)$  はガンマ関数と呼ばれ,

$$\Gamma(\alpha) = \int_0^\infty x^{\alpha-1} e^{-x} dx,$$

と表される。ガンマ関数の性質は,  $\Gamma(\alpha + 1) = \alpha \Gamma(\alpha)$ ,

$\Gamma(1) = 1, \Gamma(\frac{1}{2}) = \sqrt{\pi}$  である。このとき,

$$E(X) = \alpha\beta, \quad V(X) = E(X^2) - (E(X))^2 = \alpha\beta^2$$

なので,

$$\frac{1}{n} \sum_{i=1}^n X_i = \bar{X} = \hat{\alpha}\hat{\beta}, \quad \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2 = \hat{\alpha}\hat{\beta}^2,$$

となる。よって,

$$\hat{\alpha} = \frac{(1/n) \sum_{i=1}^n X_i^2 - \bar{X}^2}{\bar{X}} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n\bar{X}}$$

$$\hat{\beta} = \frac{\bar{X}}{\hat{\alpha}} = \frac{n\bar{X}^2}{\sum_{i=1}^n (X_i - \bar{X})^2}$$

を得る。

### 8.3.3 最小二乗法

$X_i$  と  $\mu$  の差  $X_i - \mu$  を考える。

$X_i - \mu$  の二乗和を最小にする  $\mu$  を求める。

すなわち,

$$\min_{\mu} \sum_{i=1}^n (X_i - \mu)^2$$

を最小にする  $\mu$  を求める。  $\implies$

$$\frac{dS(\mu)}{d\mu} = 0$$

の解を求める。ただし,

$$S(\mu) = \sum_{i=1}^n (X_i - \mu)^2$$

とする。

$$\frac{dS(\mu)}{d\mu} = -2 \sum_{i=1}^n (X_i - \mu) = 0$$

を満たす  $\mu$  を  $\hat{\mu}$  とする。  $\implies$

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i$$

を得る。  $\implies$  最小二乗推定量

## 9 標本分布

### 9.1 正規母集団の場合 (標本平均, 標本不偏分散の標本分布)

大きさ  $n$  の無作為標本  $\{X_1, X_2, \dots, X_n\}$ 。

すべての  $i = 1, 2, \dots, n$  について,  $X_i \sim N(\mu, \sigma^2)$  とする。

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

#### 9.1.1 正規分布: 標本平均 $\bar{X}$ の標本分布

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

証明:

積率母関数を利用する。 $X \sim N(\mu, \sigma^2)$  のとき,  $X$  の積率母関数  $\phi(\theta)$  は,

$$\begin{aligned} \phi(\theta) &\equiv E(e^{\theta X}) \\ &= \int_{-\infty}^{\infty} e^{\theta x} f(x) dx \\ &= \int_{-\infty}^{\infty} e^{\theta x} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\ &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2 + \theta x} dx \end{aligned}$$

$$\begin{aligned}
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x^2 - 2(\mu + \sigma^2\theta)x + \mu^2)} dx \\
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x - (\mu + \sigma^2\theta))^2 + (\mu\theta + \frac{1}{2}\sigma^2\theta^2)} dx \\
&= e^{\mu\theta + \frac{1}{2}\sigma^2\theta^2} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x - (\mu + \sigma^2\theta))^2} dx \\
&= \exp\left(\mu\theta + \frac{1}{2}\sigma^2\theta^2\right)
\end{aligned}$$

と計算される。積分のところは、 $N(\mu + \sigma^2\theta, \sigma^2)$  の確率密度関数に注意

よって、 $X_i \sim N(\mu, \sigma^2)$  のとき、 $X_i$  の積率母関数  $\phi_i(\theta)$  は、

$$\phi_i(\theta) = \exp\left(\mu\theta + \frac{1}{2}\sigma^2\theta^2\right)$$

となる。

今、 $\bar{X}$  の積率母関数  $\phi_{\bar{X}}(\theta)$  を考える。

$$\begin{aligned}
\phi_{\bar{X}}(\theta) &\equiv E(e^{\theta\bar{X}}) \\
&= E(e^{\theta\frac{1}{n}\sum_{i=1}^n X_i}) \\
&= E\left(\prod_{i=1}^n e^{\frac{\theta}{n}X_i}\right) \\
&= \prod_{i=1}^n E(e^{\frac{\theta}{n}X_i}) \\
&= \prod_{i=1}^n \phi_i\left(\frac{\theta}{n}\right) \\
&= \prod_{i=1}^n \exp\left(\mu\frac{\theta}{n} + \frac{1}{2}\sigma^2\left(\frac{\theta}{n}\right)^2\right) \\
&= \exp\left(\mu\theta + \frac{1}{2}\sigma^2\frac{\theta^2}{n}\right) \\
&= \exp\left(\mu\theta + \frac{1}{2}\frac{\sigma^2}{n}\theta^2\right)
\end{aligned}$$

となり、これは、平均  $\mu$ 、分散  $\sigma^2/n$  の正規分布の積率母関数に一致する。

さらに、標準化によって、

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$

を得る。これも、同様に、積率母関数で証明できる。

### 9.1.2 $\chi^2$ (カイ自乗) 分布： 標本不偏分散 $S^2$ の標本分布

$$\frac{\sum_{i=1}^n (X_i - \mu)^2}{\sigma^2} \sim \chi^2(n)$$

証明：

$$\frac{X_i - \mu}{\sigma} \sim N(0, 1)$$

なので、

$$\left(\frac{X_i - \mu}{\sigma}\right)^2 \sim \chi^2(1)$$

$\frac{X_i - \mu}{\sigma}$ ,  $i = 1, 2, \dots, n$  は互いに独立なので、

$$\sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma}\right)^2 \sim \chi^2(n)$$

となる。(積率母関数によって証明可)

$\mu$  を  $\bar{X}$  で置き換えることによって、

$$\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2} = \frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$$

を得る。(証明略)

### 9.1.3 $t$ 分布： 標本平均 $\bar{X}$ の標本分布

$Z \sim N(0, 1)$ ,  $U \sim \chi^2(m)$ ,  $Z$  と  $U$  は独立のとき、

$$\frac{Z}{\sqrt{U/m}} \sim t(m)$$

となる。

これを利用して、 $\bar{X}$  の標本分布を求める。

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$

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

$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$  と  $\frac{(n-1)S^2}{\sigma^2}$  は独立なので (後述)、

$$\frac{\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}}{\sqrt{\frac{(n-1)S^2}{\sigma^2} / (n-1)}} = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t(n-1)$$

を得る。

(\*)  $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$  と  $\frac{(n-1)S^2}{\sigma^2}$  の独立性

証明：

$X_1, X_2, \dots, X_n$  は互いに独立に正規分布に従うので， $E((\bar{X} - \mu)S^2) = 0$  を証明すればよい。

$$\bar{X} - \mu = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)$$

$$\begin{aligned} S^2 &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \\ &= \frac{1}{n-1} \sum_{i=1}^n \left( (X_i - \mu) - (\bar{X} - \mu) \right)^2 \\ &= \frac{1}{n-1} \left( \sum_{i=1}^n (X_i - \mu)^2 - n(\bar{X} - \mu)^2 \right) \end{aligned}$$

$$\begin{aligned} &E((\bar{X} - \mu)S^2) \\ &= \frac{1}{n-1} E\left( (\bar{X} - \mu) \sum_{i=1}^n (X_i - \mu)^2 - n(\bar{X} - \mu)^3 \right) \\ &= \frac{n}{n-1} E\left( \sum_{j=1}^n (X_j - \mu) \sum_{i=1}^n (X_i - \mu)^2 \right) \\ &\quad - \frac{n}{n-1} E((\bar{X} - \mu)^3) \\ &= \frac{n}{n-1} E\left( \sum_{i=1}^n \sum_{j=1}^n (X_i - \mu)^2 (X_j - \mu) \right) \\ &\quad - \frac{n}{n-1} E((\bar{X} - \mu)^3) \\ &= \frac{n}{n-1} \sum_{i=1}^n \sum_{j=1}^n E((X_i - \mu)^2 (X_j - \mu)) \\ &\quad - \frac{n}{n-1} E((\bar{X} - \mu)^3) \\ &= \frac{n}{n-1} \sum_{i=1}^n E((X_i - \mu)^3) \\ &\quad - \frac{n}{n-1} E((\bar{X} - \mu)^3) \\ &= 0 \end{aligned}$$

$Z \sim N(\mu_z, \sigma_z^2)$  のとき， $E((Z - \mu_z)^{2k-1}) = 0, k = 1, 2, \dots$  となる。(積率母関数より証明可)

したがって， $E((X_i - \mu)^3) = E((\bar{X} - \mu)^3) = 0$  となる。

よって，

$$E((\bar{X} - \mu)S^2) = 0$$

を得る。

### 9.1.4 F 分布

$U \sim \chi^2(n), V \sim \chi^2(m)$ ， $U$  と  $V$  は独立のとき，

$$\frac{U/n}{V/m} \sim F(n, m)$$

となる。

公式：

$$t(m)^2 = F(1, m)$$

$$F(n, m) = 1/F(m, n)$$

## 9.2 その他の母集団の場合：標本平均 $\bar{X}$ の標本分布

中心極限定理を利用する。

中心極限定理： 大きさ  $n$  の無作為標本  $X_1, X_2, \dots, X_n$  すべての  $i$  について， $E(X_i) = \mu, V(X_i) = \sigma^2$  とする。

標本平均  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  の分布を考える。

$n \rightarrow \infty$  のとき，

$$\begin{aligned} \frac{\bar{X} - E(\bar{X})}{\sqrt{V(\bar{X})}} &= \frac{\bar{X} - \mu}{\sqrt{\sigma^2/n}} \\ &= \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \rightarrow N(0, 1) \end{aligned}$$

が成り立つ。

さらに，分母の  $\sigma$  をその標本不偏分散  $S$  で置き換えても，

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \rightarrow N(0, 1)$$

が成り立つ。(証明略)

例題：母比率の推定量の標本分布：離散型確率変数  $X$  の取りうる値は  $0, 1$  のどちらかで，その確率分布は，

$$P(X = x) = f(x) = p^x (1-p)^{1-x} \quad x = 0, 1$$

となる。すなわち，

$$P(X = 1) = p$$

$$P(X = 0) = 1 - p$$

となる。

何等かの実験を行い,成功すれば  $X = 1$ ,失敗すれば  $X = 0$  として,確率変数  $X$  に数値を割り当てる。

または,アンケート調査によって, Yes と答えれば  $X = 1$ , No と答えれば  $X = 0$  として,確率変数  $X$  に数値を割り当てる。

このとき,  $X = 1$  となる確率  $P(X = 1) = p$  を推定することを考える。

$E(X)$ ,  $V(X)$  を求めておく。

$$\begin{aligned} E(X) &= \sum_x x f(x) \\ &= \sum_{x=0}^1 x p^x (1-p)^{1-x} \\ &= p \end{aligned}$$

$\mu = E(X)$  のとき,  $V(X) = E(X^2) - \mu^2$  により, まず,  $E(X^2)$  を求める。

$$\begin{aligned} E(X^2) &= \sum_x x^2 f(x) \\ &= \sum_{x=0}^1 x^2 p^x (1-p)^{1-x} \\ &= p^2 \end{aligned}$$

よって,

$$\begin{aligned} V(X) &= E(X^2) - \mu^2 \\ &= p - p^2 \\ &= p(1-p) \end{aligned}$$

$n$  個の無作為標本  $X_1, X_2, \dots, X_n$  を考える。

$X_1, X_2, \dots, X_n$  はそれぞれ独立に, しかも上記のように, 同一のベルヌイ分布に従うものとする。

このときの母比率  $p$  の推定量を  $\hat{P} = \frac{1}{n} \sum_{i=1}^n X_i$  とする。

すなわち,  $\hat{P}$  は  $n$  人の中で成功した回数 (または, Yes と答えた人数) を表し, 標本平均である。

中心極限定理を当てはめる。  $n \rightarrow \infty$  のとき,

$$\frac{\hat{P} - E(\hat{P})}{\sqrt{V(\hat{P})}} = \frac{\hat{P} - p}{\sqrt{p(1-p)/n}} \rightarrow N(0, 1)$$

が成り立つ。  $E(\hat{P}), V(\hat{P})$  は

$$\begin{aligned} E(\hat{P}) &= E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \\ &= \frac{1}{n} E\left(\sum_{i=1}^n X_i\right) \\ &= \frac{1}{n} \sum_{i=1}^n E(X_i) \\ &= \frac{1}{n} \sum_{i=1}^n p \\ &= p \end{aligned}$$

$$\begin{aligned} V(\hat{P}) &= V\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \\ &= \frac{1}{n^2} V\left(\sum_{i=1}^n X_i\right) \\ &= \frac{1}{n^2} \sum_{i=1}^n V(X_i) \leftarrow \text{互いに独立} \\ &= \frac{1}{n^2} \sum_{i=1}^n p(1-p) \\ &= \frac{p(1-p)}{n} \end{aligned}$$

となることに注意。  $E(X_i) = p, V(X_i) = p(1-p)$  を途中で利用する。

さらに, 分母の  $p$  をその推定量  $\hat{P}$  で置き換えても,

$$\frac{\hat{P} - p}{\sqrt{\hat{P}(1-\hat{P})/n}} \rightarrow N(0, 1)$$

が成り立つ。(証明略)

### 9.3 その他の母集団の場合: 母数の推定量 $\hat{\theta}_n$ の標本分布 (一般化)

母集団の分布:  $f(x; \theta)$

より一般的に, 母数  $\theta$  の推定量の標本分布を求める。

最尤推定量の性質を利用する。

すなわち, 母数  $\theta$  の最尤推定量  $\hat{\theta}_n$  の標本分布について:  $n \rightarrow \infty$  のとき,

$$\sqrt{n}(\hat{\theta}_n - \theta) \rightarrow N(0, \sigma^2)$$

となる。ただし,

$$\sigma^2 = \sigma^2(\theta) = \left( E \left[ \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right)^2 \right] \right)^{-1}$$

となる。

標準化 (基準化) によって,  $n \rightarrow \infty$  のとき,

$$\frac{\sqrt{n}(\hat{\theta}_n - \theta)}{\sigma(\theta)} = \frac{\hat{\theta}_n - \theta}{\sigma(\theta)/\sqrt{n}} \rightarrow N(0, 1)$$

となる。

さらに, 分母の  $\theta$  を最尤推定量  $\hat{\theta}_n$  で置き換えても,  $n \rightarrow \infty$  のとき,

$$\frac{\hat{\theta}_n - \theta}{\sigma(\hat{\theta}_n)/\sqrt{n}} \rightarrow N(0, 1)$$

が成り立つ。(証明略)

⇒ 区間推定, 仮説検定

## 10 統計的検定: 大標本検定

### 10.1 ワルド (Wald) 検定

最尤推定量の性質を利用

母集団の分布:  $f(x; \theta)$

母数  $\theta$  の最尤推定量  $\hat{\theta}_n$  の標本分布について:

$n \rightarrow \infty$  のとき,

$$\sqrt{n}(\hat{\theta}_n - \theta) \rightarrow N(0, \sigma^2)$$

ただし,

$$\begin{aligned} \sigma^2 &= \sigma^2(\theta) \\ &= \left( \mathbb{E} \left[ \left( \frac{\partial \log f(X; \theta)}{\partial \theta} \right)^2 \right] \right)^{-1} \\ &= - \left( \mathbb{E} \left( \frac{\partial^2 \log f(X; \theta)}{\partial \theta^2} \right) \right)^{-1} \end{aligned}$$

となる。

$\frac{\sigma^2}{n}$  はクラメール・ラオの下限に一致することに注意。

(復習) クラメール・ラオの不等式:

母数  $\theta$  の不偏推定量  $\hat{\theta}_n$  について,

$$V(\hat{\theta}_n) \geq \frac{\sigma^2}{n}$$

が成り立つ。 $\sigma^2$  は上で定義されたものとなる。

言い換えると,

$$\frac{\hat{\theta}_n - \theta}{\sigma/\sqrt{n}} \rightarrow N(0, 1)$$

を得る。

さらに, 分母の  $\theta$  を最尤推定量  $\hat{\theta}_n$  で置き換えても,  $n \rightarrow \infty$  のとき, 近似的に,

$$\frac{\hat{\theta}_n - \theta}{\sigma(\hat{\theta}_n)/\sqrt{n}} \sim N(0, 1)$$

が成り立つ。

したがって,  $H_0: \theta = \theta_0$  が正しいもとで,  $n \rightarrow \infty$  のとき, 近似的に,

$$\frac{\hat{\theta}_n - \theta_0}{\sigma(\hat{\theta}_n)/\sqrt{n}} \sim N(0, 1)$$

が成り立つ。

よって,  $H_0: \theta = \theta_0$  と  $H_1: \theta \neq \theta_0$  について,

$\hat{\theta}_n$  を実現値で置き換えて,

$$\left| \frac{\hat{\theta}_n - \theta_0}{\sigma(\hat{\theta}_n)/\sqrt{n}} \right| > z_{\alpha/2} \text{ のとき, } H_0 \text{ を棄却する。}$$

(\*) 検定を行う段階では,  $\hat{\theta}_n$  を最尤推定値とみなしていることに注意。すなわち,  $\hat{\theta}_n$  はもともと最尤推定量で  $X_1, X_2, \dots, X_n$  の関数である。しかし, 検定を行う段階では,  $X_1, X_2, \dots, X_n$  を  $x_1, x_2, \dots, x_n$  で置き換えて,  $\hat{\theta}_n$  を最尤推定値とみなしている。

また,  $H_0: \theta = \theta_0$  と  $H_1: \theta > \theta_0$  について,

$\hat{\theta}_n$  を実現値で置き換えて,

$$\frac{\hat{\theta}_n - \theta_0}{\sigma(\hat{\theta}_n)/\sqrt{n}} > z_{\alpha} \text{ のとき, } H_0 \text{ を棄却する。}$$

最後に,  $H_0: \theta = \theta_0$  と  $H_1: \theta < \theta_0$  について,

$\hat{\theta}_n$  を実現値で置き換えて,

$$\frac{\hat{\theta}_n - \theta_0}{\sigma(\hat{\theta}_n)/\sqrt{n}} < -z_{\alpha} \text{ のとき, } H_0 \text{ を棄却する。}$$

例題: 指数分布から生成された  $n$  個の互いに独立な確率変数  $X_1, X_2, \dots, X_n$  を考える。指数分布は,

$$f(x; \gamma) = \gamma e^{-\gamma x} \quad x > 0$$

である。

帰無仮説  $H_0: \gamma = \gamma_0$ , 対立仮説  $H_1: \gamma \neq \gamma_0$  を, ワルド検定によって, 検定する。

一般的に, 母数  $\gamma$  の最尤推定量  $\hat{\gamma}_n$  の標本分布について,  $n \rightarrow \infty$  のとき, 近似的に,

$$\frac{\hat{\gamma}_n - \gamma}{\sigma(\hat{\gamma}_n)/\sqrt{n}} \sim N(0, 1)$$

が成り立つ。ただし,

$$\begin{aligned} \sigma^2 &= \sigma^2(\gamma) \\ &= \left( E \left[ \left( \frac{d \log f(X; \gamma)}{d\gamma} \right)^2 \right] \right)^{-1} \\ &= - \left( E \left( \frac{d^2 \log f(X; \gamma)}{d\gamma^2} \right) \right)^{-1} \end{aligned}$$

となる。

したがって,  $H_0: \gamma = \gamma_0$  が正しいもとで,  $n \rightarrow \infty$  のとき, 近似的に,

$$\frac{\hat{\gamma}_n - \gamma_0}{\sigma(\hat{\gamma}_n)/\sqrt{n}} \sim N(0, 1)$$

が成り立つ。

よって,  $H_0: \gamma = \gamma_0$  と  $H_1: \gamma \neq \gamma_0$  について,

$\hat{\gamma}_n$  を実現値で置き換えて,

$$\left| \frac{\hat{\gamma}_n - \gamma_0}{\sigma(\hat{\gamma}_n)/\sqrt{n}} \right| > z_{\alpha/2} \text{ のとき, } H_0 \text{ を棄却する。}$$

まず,  $\sigma^2(\gamma)$  を求める。

$$\begin{aligned} \sigma^2 &= \sigma^2(\gamma) \\ &= - \left( E \left( \frac{d^2 \log f(X; \gamma)}{d\gamma^2} \right) \right)^{-1} \\ &= \gamma^2 \end{aligned}$$

$\log f(X; \gamma)$  の 2 回微分は,

$$\begin{aligned} \frac{d \log f(X; \gamma)}{d\gamma} &= \frac{1}{\gamma} - X \\ \frac{d^2 \log f(X; \gamma)}{d\gamma^2} &= -\frac{1}{\gamma^2} \end{aligned}$$

に注意。

次に,  $\gamma$  の最尤推定量  $\hat{\gamma}_n$  を求める。

$X_1, \dots, X_n$  は互いに独立で, 指数分布  $f(x; \gamma)$  に従うので, 尤度関数  $l(\gamma)$  は

$$\begin{aligned} l(\gamma) &= \prod_{i=1}^n f(x_i; \gamma) \\ &= \prod_{i=1}^n \gamma e^{-\gamma x_i} \\ &= \gamma^n e^{-\gamma \sum x_i} \end{aligned}$$

対数尤度関数は

$$\log l(\gamma) = n \log(\gamma) - \gamma \sum_{i=1}^n x_i$$

$\log l(\gamma)$  を最大にするような  $\gamma$  を求める。

$$\frac{d \log l(\gamma)}{d\gamma} = \frac{n}{\gamma} - \sum_{i=1}^n x_i = 0$$

を解いて,  $x_i$  を  $X_i$  で置き換えて,  $\gamma$  の最尤推定量  $\hat{\gamma}_n$  は,

$$\hat{\gamma}_n = \frac{n}{\sum_{i=1}^n X_i}$$

となる。

したがって,  $n \rightarrow \infty$  のとき, 近似的に,

$$\frac{\hat{\gamma}_n - \gamma}{\sigma(\hat{\gamma}_n)/\sqrt{n}} = \frac{\hat{\gamma}_n - \gamma}{\hat{\gamma}_n/\sqrt{n}}$$

が成り立つ。

よって,  $H_0: \gamma = \gamma_0$  と  $H_1: \gamma \neq \gamma_0$  について,

$\hat{\gamma}_n$  を実現値で置き換えて,

$$\left| \frac{\hat{\gamma}_n - \gamma_0}{\hat{\gamma}_n/\sqrt{n}} \right| > z_{\alpha/2} \text{ のとき, } H_0 \text{ を棄却する。}$$

ただし,  $\gamma$  の最尤推定値  $\hat{\gamma}_n$  は,

$$\hat{\gamma}_n = \frac{n}{\sum_{i=1}^n x_i}$$

となる。

## 10.2 尤度比検定

仮説検定: 母集団の分布  $f(x; \theta)$  が与えられているときに, 母数  $\theta = (\theta_1, \theta_2)$  についての仮説  $\theta_1 = \theta_1^*$  が正しいかどうかを, 標本  $(X_1, X_2, \dots, X_n)$  の実現値  $(x_1, x_2, \dots, x_n)$  から判断する。

$\theta_1: 1 \times k_1$  ベクトル

$\theta_2$ :  $1 \times k_2$  ベクトル

$\theta = (\theta_1, \theta_2)$ :  $1 \times (k_1 + k_2)$  ベクトル

帰無仮説  $H_0$ :  $\theta_1 = \theta_1^* \implies$  制約の数は  $k_1$  個

尤度関数

$$l(\theta_1, \theta_2) = \prod_{i=1}^n f(x_i; \theta_1, \theta_2)$$

$(\tilde{\theta}_1, \tilde{\theta}_2)$  を  $(\theta_1, \theta_2)$  の最尤推定量とする。

すなわち,  $(\tilde{\theta}_1, \tilde{\theta}_2)$  は,

$$\frac{\partial l(\theta_1, \theta_2)}{\partial \theta_1} = 0, \quad \frac{\partial l(\theta_1, \theta_2)}{\partial \theta_2} = 0$$

の連立方程式を,  $(\theta_1, \theta_2)$  について解いた解である。

$\implies$  制約なし最尤推定量

$\hat{\theta}_2$  を, 帰無仮説  $H_0$ :  $\theta_1 = \theta_1^*$  が正しいという条件のもとで,  $\theta_2$  の最尤推定量とする。

すなわち,  $(\hat{\theta}_2)$  は,

$$\frac{\partial l(\theta_1^*, \theta_2)}{\partial \theta_2} = 0$$

を,  $\theta_2$  について解いた解である。  $\implies$  制約付き最尤推定量 ( $\theta_1 = \theta_1^*$  という制約)

$$\text{尤度比: } \lambda = \frac{l(\theta_1^*, \hat{\theta}_2)}{l(\tilde{\theta}_1, \tilde{\theta}_2)}$$

$n$  が大きいとき, 近似的に,

$$-2 \log(\lambda) \sim \chi^2(k_1)$$

となる。「 $k_1 =$  制約の数」に注意。

$-2 \log(\lambda) > \chi_\alpha^2(k_1)$  のとき, 有意水準  $\alpha$  で, 帰無仮説  $H_0$ :  $\theta_1 = \theta_1^*$  を棄却する。

$-2 \log(\lambda)$  がゼロに近ければ, 帰無仮説を採択する。

$\implies (\theta_1^*, \hat{\theta}_2)$  が  $(\tilde{\theta}_1, \tilde{\theta}_2)$  に近い値であれば,  $-2 \log(\lambda)$  はゼロに近くなる。

母数の推定量  $(\tilde{\theta}_1, \tilde{\theta}_2)$  の分布が求められることが出来ない場合に, 尤度比検定は有効である。

例題: 指数分布から生成された  $n$  個の互いに独立な確率変数  $X_1, X_2, \dots, X_n$  を考える。指数分布は,

$$f(x) = \gamma e^{-\gamma x} \quad x > 0$$

である。

帰無仮説  $H_0$ :  $\gamma = \gamma_0$  を, 尤度比検定によって, 検定する。

尤度比

$$\lambda = \frac{l(\gamma_0)}{\max_{\gamma} l(\gamma)} = \frac{l(\gamma_0)}{l(\hat{\gamma})}$$

について, 制約の数は 1 なので,

$$-2 \log \lambda \rightarrow \chi^2(1)$$

となる。

$X_1, \dots, X_n$  は互いに独立で, 指数分布  $f(x)$  に従うので,

尤度関数  $l(\gamma)$  は

$$\begin{aligned} l(\gamma) &= \prod_{i=1}^n f(x_i) \\ &= \prod_{i=1}^n \gamma e^{-\gamma x_i} \\ &= \gamma^n e^{-\gamma \sum x_i} \end{aligned}$$

分子について:

$$l(\gamma_0) = \gamma_0^n e^{-\gamma_0 \sum X_i}$$

分母について:

対数尤度関数は

$$\log l(\gamma) = n \log(\gamma) - \gamma \sum_{i=1}^n x_i$$

$\log l(\gamma)$  を最大にするような  $\gamma$  を求める。

$$\frac{d \log l(\gamma)}{d\gamma} = \frac{n}{\gamma} - \sum_{i=1}^n x_i = 0$$

を解いて,  $x_i$  を  $X_i$  で置き換えて,  $\gamma$  の最尤推定量  $\hat{\gamma}$  は

$$\hat{\gamma} = \frac{n}{\sum_{i=1}^n X_i}$$

となる。

$$l(\hat{\gamma}) = \hat{\gamma}^n e^{-n}$$

したがって, 尤度比

$$\begin{aligned} \lambda &= \frac{l(\gamma_0)}{l(\hat{\gamma})} \\ &= \frac{\gamma_0^n e^{-\gamma_0 \sum X_i}}{\hat{\gamma}^n e^{-n}} \end{aligned}$$

を得る。

よって、近似的に、

$$-2 \log \lambda \sim \chi^2(1)$$

となる。

$-2 \log \lambda > \chi_\alpha^2(1)$  のとき、有意水準  $\alpha$  で、帰無仮説  $H_0: \mu = \mu_0$  を棄却する。 $\chi_\alpha^2(1)$  は自由度 1 のカイ二乗分布の  $100 \times \alpha$  % 点とする。

例題：  $X_1, X_2, \dots, X_n$  の  $n$  個の確率変数は、それぞれ独立に、平均  $\mu$ 、分散  $\sigma^2$  の分布をするものとする。

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

$$f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}$$

与えられる。

帰無仮説  $H_0: \mu = \mu_0$  を、尤度比検定によって、検定する。

尤度比

$$\lambda = \frac{\max_{\sigma^2} l(\mu_0, \sigma^2)}{\max_{\mu, \sigma^2} l(\mu, \sigma^2)} = \frac{l(\mu_0, \tilde{\sigma}^2)}{l(\hat{\mu}, \hat{\sigma}^2)}$$

について、制約の数は 1 なので、

$$-2 \log \lambda \rightarrow \chi^2(1)$$

となる。

ここで、 $l(\mu, \sigma^2)$  は、

$$\begin{aligned} l(\mu, \sigma^2) &= f(x_1, x_2, \dots, x_n; \mu, \sigma^2) \\ &= \prod_{i=1}^n f(x_i; \mu, \sigma^2) \\ &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(x_i - \mu)^2\right) \\ &= (2\pi\sigma^2)^{-n/2} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right) \end{aligned}$$

であり、 $\log l(\mu, \sigma^2)$  は、

$$\begin{aligned} \log l(\mu, \sigma^2) &= -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) \\ &\quad - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \end{aligned}$$

である。

分子について：

$\mu = \mu_0$  のもとで、 $\log l(\mu_0, \sigma^2)$  を  $\sigma^2$  について最大化する。

$$\frac{\partial \log l(\mu_0, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu_0)^2 = 0$$

この解が  $\tilde{\sigma}^2$  である。したがって、

$$\tilde{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu_0)^2$$

を得る。よって、 $l(\mu_0, \tilde{\sigma}^2)$  は、

$$\begin{aligned} l(\mu_0, \tilde{\sigma}^2) &= (2\pi\tilde{\sigma}^2)^{-n/2} \exp\left(-\frac{1}{2\tilde{\sigma}^2} \sum_{i=1}^n (x_i - \mu_0)^2\right) \\ &= (2\pi\tilde{\sigma}^2)^{-n/2} \exp\left(-\frac{n}{2}\right) \end{aligned}$$

となる。

分母について：

$$\begin{aligned} \hat{\mu} &= \frac{1}{n} \sum_{i=1}^n x_i \\ \hat{\sigma}^2 &= \frac{1}{n} \sum_{i=1}^n (x_i - \hat{\mu})^2 \end{aligned}$$

を得る。よって、 $l(\hat{\mu}, \hat{\sigma}^2)$  は、

$$\begin{aligned} l(\hat{\mu}, \hat{\sigma}^2) &= (2\pi\hat{\sigma}^2)^{-n/2} \exp\left(-\frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n (x_i - \hat{\mu})^2\right) \\ &= (2\pi\hat{\sigma}^2)^{-n/2} \exp\left(-\frac{n}{2}\right) \end{aligned}$$

となる。

したがって、

$$\begin{aligned} \lambda &= \frac{\max_{\sigma^2} l(\mu_0, \sigma^2)}{\max_{\mu, \sigma^2} l(\mu, \sigma^2)} \\ &= \frac{l(\mu_0, \tilde{\sigma}^2)}{l(\hat{\mu}, \hat{\sigma}^2)} \\ &= \frac{(2\pi\tilde{\sigma}^2)^{-n/2} \exp\left(-\frac{n}{2}\right)}{(2\pi\hat{\sigma}^2)^{-n/2} \exp\left(-\frac{n}{2}\right)} \\ &= \left(\frac{\tilde{\sigma}^2}{\hat{\sigma}^2}\right)^{-n/2} \end{aligned}$$

よって、近似的に、

$$-2 \log \lambda = n(\log \hat{\sigma}^2 - \log \tilde{\sigma}^2) \sim \chi^2(1)$$

となる。

$-2 \log \lambda > \chi_\alpha^2(1)$  のとき、有意水準  $\alpha$  で、帰無仮説  $H_0: \mu = \mu_0$  を棄却する。 $\chi_\alpha^2(1)$  は自由度 1 のカイ二乗分布の  $100 \times \alpha$  % 点とする。

## 練習問題と解答 (6 章 ~ 10 章)

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

$$f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}$$

で与えられる。 $X_1, X_2, \dots, X_n$  は互いに独立で、しかも、それぞれは平均  $\mu$ 、分散  $\sigma^2$  の正規分布に従うものとする。このとき、次の問に答えよ。

- (1) 平均  $\mu$ 、分散  $\sigma^2$  の最尤推定量を求めよ。
- (2)  $\sigma^2$  の最尤推定量は不偏推定量であるかどうかを調べよ。もし、 $\sigma^2$  の最尤推定量が不偏推定量でないときは、不偏推定量を求めよ (最尤推定量をもとにして考えればよい)。
- (3) 帰無仮説  $H_0: \mu = \mu_0$  を、尤度比検定によって、検定したい。どのようにすればよいかを説明せよ。

[解答]

- (1) 平均  $\mu$ 、分散  $\sigma^2$  の最尤推定量を求める。

$$\begin{aligned} & f(x_1, x_2, \dots, x_n; \mu, \sigma^2) \\ &= \prod_{i=1}^n f(x_i; \mu, \sigma^2) \\ &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(x_i - \mu)^2\right) \\ &= (2\pi\sigma^2)^{-n/2} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right) \\ &= l(\mu, \sigma^2) \end{aligned}$$

対数をとる。(最大化しやすくなる場合が多い)

$$\begin{aligned} \log l(\mu, \sigma^2) &= -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) \\ &\quad - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \end{aligned}$$

対数尤度関数  $\log l(\mu, \sigma^2)$  を  $\mu$  と  $\sigma^2$  について微分して、ゼロと置く。

$$\begin{aligned} \frac{\partial \log l(\mu, \sigma^2)}{\partial \mu} &= \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) \\ &= 0 \\ \frac{\partial \log l(\mu, \sigma^2)}{\partial \sigma^2} &= -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 \\ &= 0 \end{aligned}$$

この 2 つの連立方程式を解く。

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

$\mu, \sigma^2$  の最尤推定量は、

$$\bar{X}, S^{**2} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

となる。

- (2)  $\sigma^2$  の最尤推定量  $S^{**2}$  は不偏推定量であるかどうかを調べる。

$$\begin{aligned} E(S^{**2}) &= E\left(\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2\right) \\ &= \frac{1}{n} E\left(\sum_{i=1}^n (X_i - \bar{X})^2\right) \\ &= \frac{1}{n} E\left(\sum_{i=1}^n ((X_i - \mu) - (\bar{X} - \mu))^2\right) \\ &= \frac{1}{n} E\left(\sum_{i=1}^n ((X_i - \mu)^2 - 2(X_i - \mu)(\bar{X} - \mu) + (\bar{X} - \mu)^2)\right) \\ &= \frac{1}{n} E\left(\sum_{i=1}^n (X_i - \mu)^2 - 2(\bar{X} - \mu) \sum_{i=1}^n (X_i - \mu) + n(\bar{X} - \mu)^2\right) \end{aligned}$$

$$\begin{aligned}
&= \frac{1}{n} E \left( \sum_{i=1}^n (X_i - \mu)^2 \right. \\
&\quad \left. - 2n(\bar{X} - \mu)^2 + n(\bar{X} - \mu)^2 \right) \\
&= \frac{1}{n} E \left( \sum_{i=1}^n (X_i - \mu)^2 - n(\bar{X} - \mu)^2 \right) \\
&= \frac{1}{n} E \left( \sum_{i=1}^n (X_i - \mu)^2 \right) \\
&\quad - \frac{1}{n} E \left( n(\bar{X} - \mu)^2 \right) \\
&= \frac{1}{n} \sum_{i=1}^n E \left( (X_i - \mu)^2 \right) \\
&\quad - E \left( (\bar{X} - \mu)^2 \right) \\
&= \frac{1}{n} \sum_{i=1}^n V(X_i) - V(\bar{X}) \\
&= \frac{1}{n} \sum_{i=1}^n \sigma^2 - \frac{\sigma^2}{n} \\
&= \sigma^2 - \frac{1}{n} \sigma^2 \\
&= \frac{n-1}{n} \sigma^2 \\
&\neq \sigma^2
\end{aligned}$$

なので、 $S^{**2}$  は  $\sigma^2$  の不偏推定量ではない。

$S^{**2}$  をもとにして、 $\sigma^2$  の不偏推定量を求め。

$$E(S^{**2}) = \frac{n-1}{n} \sigma^2$$

なので、両辺に  $\frac{n}{n-1}$  をかけて、

$$\frac{n}{n-1} E(S^{**2}) = \sigma^2$$

を得る。

よって、

$$\frac{n}{n-1} S^{**2} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = S^2$$

が  $\sigma^2$  の不偏推定量となる。

- (3) 帰無仮説  $H_0: \mu = \mu_0$  を、尤度比検定によって、検定する。

尤度比

$$\lambda = \frac{\max_{\sigma^2} l(\mu_0, \sigma^2)}{\max_{\mu, \sigma^2} l(\mu, \sigma^2)} = \frac{l(\mu_0, \tilde{\sigma}^2)}{l(\hat{\mu}, \hat{\sigma}^2)}$$

について、制約の数は 1 なので、

$$-2 \log \lambda \rightarrow \chi^2(1)$$

となる。

ここで、 $l(\mu, \sigma^2)$  は、

$$l(\mu, \sigma^2) = (2\pi\sigma^2)^{-n/2} \exp \left( -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right)$$

であり、 $\log l(\mu, \sigma^2)$  は、

$$\begin{aligned}
\log l(\mu, \sigma^2) &= -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) \\
&\quad - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2
\end{aligned}$$

である。

分子について：

$\mu = \mu_0$  のもとで、 $\log l(\mu_0, \sigma^2)$  を  $\sigma^2$  について最大化する。

$$\frac{\partial \log l(\mu_0, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu_0)^2 = 0$$

この解が  $\tilde{\sigma}^2$  である。したがって、

$$\tilde{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu_0)^2$$

を得る。よって、 $l(\mu_0, \tilde{\sigma}^2)$  は、

$$\begin{aligned}
&l(\mu_0, \tilde{\sigma}^2) \\
&= (2\pi\tilde{\sigma}^2)^{-n/2} \exp \left( -\frac{1}{2\tilde{\sigma}^2} \sum_{i=1}^n (x_i - \mu_0)^2 \right) \\
&= (2\pi\tilde{\sigma}^2)^{-n/2} \exp \left( -\frac{n}{2} \right)
\end{aligned}$$

となる。

分母について：

問 (1) より,

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{\mu})^2$$

を得る。よって,  $l(\hat{\mu}, \hat{\sigma}^2)$  は,

$$l(\hat{\mu}, \hat{\sigma}^2)$$

$$= (2\pi\hat{\sigma}^2)^{-n/2} \exp\left(-\frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n (x_i - \hat{\mu})^2\right)$$

$$= (2\pi\hat{\sigma}^2)^{-n/2} \exp\left(-\frac{n}{2}\right)$$

となる。

したがって,

$$\lambda = \frac{\max_{\sigma^2} l(\mu_0, \sigma^2)}{\max_{\mu, \sigma^2} l(\mu, \sigma^2)}$$

$$= \frac{l(\mu_0, \tilde{\sigma}^2)}{l(\hat{\mu}, \hat{\sigma}^2)}$$

$$= \frac{(2\pi\tilde{\sigma}^2)^{-n/2} \exp\left(-\frac{n}{2}\right)}{(2\pi\hat{\sigma}^2)^{-n/2} \exp\left(-\frac{n}{2}\right)}$$

$$= \left(\frac{\tilde{\sigma}^2}{\hat{\sigma}^2}\right)^{-n/2}$$

よって, 近似的に,

$$-2 \log \lambda = n(\log \tilde{\sigma}^2 - \log \hat{\sigma}^2) \sim \chi^2(1)$$

となる。

$-2 \log \lambda > \chi_{\alpha}^2(1)$  のとき, 有意水準  $\alpha$  で, 帰無仮説  $H_0: \mu = \mu_0$  を棄却する。 $\chi_{\alpha}^2(1)$  は自由度 1 のカイ二乗分布の  $100 \times \alpha$  % 点とする。

2 次の問に答えよ。

- (1) 離散型確率変数  $X$  がベルヌイ分布に従うとき, その確率関数は次の式で表される。

$$f(x) = p^x(1-p)^{1-x} \quad x = 0, 1$$

このベルヌイ分布から抽出された大きさ  $n$  の無作為標本を  $X_1, X_2, \dots, X_n$  とするとき,  $p$  の最尤推定量を求めなさい。

- (2)  $Y$  を二項分布  $f(y)$  に従う確率変数とする。このとき,  $\frac{Y}{n}$  は,  $n$  が大きくなると,  $p$  に近づくことを証明せよ。ただし, 二項分布は

$$f(y) = {}_n C_y p^y (1-p)^{n-y} \quad y = 0, 1, 2, \dots, n$$

で与えられる。

- (3) 問 (2) の確率変数  $Y$  について, 確率変数  $Z_n \equiv \frac{Y - np}{\sqrt{np(1-p)}}$  を定義する。このとき,  $n$  が大きくなるにつれて,  $Z_n$  は標準正規分布に近づくことを証明せよ。

- (4) 連続型確率変数  $X$  の密度関数が

$$f(x) = \begin{cases} \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} e^{-\frac{x}{2}}, & x > 0 \text{ のとき} \\ 0, & \text{その他} \end{cases}$$

とする。 $\frac{X}{n}$  は,  $n \rightarrow \infty$  のとき, 1 に近づくことを示せ。ただし,  $\Gamma(a)$  はガンマ関数であり,

$$\Gamma(a) = \int_0^{\infty} x^{a-1} e^{-x} dx$$

と定義される。

[解答]

- (1) 離散型確率変数  $X$  がベルヌイ分布に従うとき, その確率関数は次の式で表される。

$$f(x; p) = p^x(1-p)^{1-x} \quad x = 0, 1$$

このベルヌイ分布から抽出された大きさ  $n$  の無作為標本を  $X_1, X_2, \dots, X_n$  とするとき,  $p$  の最尤推定量を求めよ。

$$f(x_1, x_2, \dots, x_n; p)$$

$$= \prod_{i=1}^n f(x_i; p)$$

$$= \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i}$$

$$= p^{\sum_i x_i} (1-p)^{n - \sum_i x_i}$$

$$= l(p)$$

対数をとる。

$$\begin{aligned} & \log l(p) \\ &= \left( \sum_i x_i \right) \log(p) + (n - \sum_i x_i) \log(1-p) \end{aligned}$$

対数尤度関数  $\log l(p)$  を  $p$  について微分して、ゼロと置く。

$$\begin{aligned} \frac{d \log l(p)}{dp} &= \frac{\sum_i x_i}{p} - \frac{n - \sum_i x_i}{1-p} \\ &= \frac{\sum_i x_i - np}{p(1-p)} \\ &= 0 \end{aligned}$$

この方程式を解く。

$$p = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

$p$  の最尤推定量は、

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

となる。

- (2)  $Y$  を二項分布  $f(y)$  に従う確率変数とすると、 $\frac{Y}{n}$  は、 $n$  が大きくなると、 $p$  に近づくことを証明する。

$Y$  の平均、分散は、

$$E(Y) = np, \quad V(Y) = np(1-p)$$

なので、

$$\begin{aligned} E\left(\frac{Y}{n}\right) &= \frac{1}{n} E(Y) = p \\ V\left(\frac{Y}{n}\right) &= \frac{1}{n^2} V(Y) = \frac{p(1-p)}{n} \end{aligned}$$

となる。

チェビシェフの不等式：

確率変数  $X$  と  $g(x) \geq 0$  について、

$$P(g(X) \geq k) \leq \frac{E(g(X))}{k}$$

となる。 $k > 0$  とする。

ここで、 $g(X) = (X - E(X))^2$ ,  $k = \epsilon^2$  とすると、

$$P(|X - E(X)| \geq \epsilon) \leq \frac{V(X)}{\epsilon^2}$$

を得る。 $\epsilon > 0$  とする。

$X$  を  $\frac{Y}{n}$  に置き換えて、そのままチェビシェフの不等式を当てはめると、

$$P\left(\left|\frac{Y}{n} - E\left(\frac{Y}{n}\right)\right| \geq \epsilon\right) \leq \frac{V\left(\frac{Y}{n}\right)}{\epsilon^2}$$

すなわち、 $n \rightarrow \infty$  のとき、

$$P\left(\left|\frac{Y}{n} - p\right| \geq \epsilon\right) \leq \frac{p(1-p)}{n\epsilon^2} \rightarrow 0$$

となる。したがって、

$$\frac{Y}{n} \rightarrow p$$

を得る。

- (3)  $n$  個の無作為標本  $X_1, X_2, \dots, X_n$  はそれぞれ独立に、同一のベルヌイ分布に従うものとする。ただし、 $P(X_i = x) = p^x(1-p)^{1-x}$ ,  $x = 0, 1$  とする。

$Y = X_1 + X_2 + \dots + X_n$  を定義すると、 $Y$  は二項分布に従うので、 $\frac{Y}{n}$  は標本平均とみなすことができる。

$$\text{すなわち、} \frac{Y}{n} = \frac{1}{n} \sum_{i=1}^n X_i$$

よって、 $E\left(\frac{Y}{n}\right) = p$ ,  $V\left(\frac{Y}{n}\right) = p(1-p)/n$  を用いて、中心極限定理により、 $n \rightarrow \infty$  のとき、

$$\frac{\frac{Y}{n} - p}{\sqrt{p(1-p)/n}} \rightarrow N(0, 1)$$

を得る。

$$Z_n \equiv \frac{Y - np}{\sqrt{np(1-p)}} = \frac{\frac{Y}{n} - p}{\sqrt{p(1-p)/n}}$$

なので、

$$Z_n \rightarrow N(0, 1)$$

を得る。

(4)  $X \sim \chi^2(n)$  のとき,

$E(X) = n, V(X) = 2n$  となるので,

$E\left(\frac{X}{n}\right) = 1, V\left(\frac{X}{n}\right) = \frac{2}{n}$  となる。

チェビシェフの不等式を当てはめる。

$$P\left(\left|\frac{X}{n} - E\left(\frac{X}{n}\right)\right| \geq \epsilon\right) \leq \frac{V\left(\frac{X}{n}\right)}{\epsilon^2}$$

$\epsilon > 0$  とする。すなわち,  $n \rightarrow \infty$  のとき,

$$P\left(\left|\frac{X}{n} - 1\right| \geq \epsilon\right) \leq \frac{2}{n\epsilon^2} \rightarrow 0$$

となる。したがって,

$$\frac{X}{n} \rightarrow 1$$

を得る。

**3** 指数分布から生成された  $n$  個の互いに独立な確率変数  $X_1, X_2, \dots, X_n$  を考える。ただし, 指数分布とは次の分布である。

$$f(x) = \lambda e^{-\lambda x} \quad x > 0$$

で与えられる。このとき, 次の問に答えよ。

- (1)  $\lambda$  最尤推定量を  $\hat{\lambda}$  とするとき,  $\hat{\lambda}$  を求めよ。
- (2)  $n$  が大きいとき,  $\hat{\lambda}$  の平均, 分散を求めよ。

[解答]

- (1)  $X_1, \dots, X_n$  は互いに独立で, 指数分布  $f(x)$  に従うので, 尤度関数  $l(\lambda)$  は

$$\begin{aligned} L(\lambda) &= \prod_{i=1}^n f(x_i) \\ &= \prod_{i=1}^n \lambda e^{-\lambda x_i} \\ &= \lambda^n e^{-\lambda \sum x_i} \end{aligned}$$

対数尤度関数は

$$\log l(\lambda) = n \log(\lambda) - \lambda \sum_{i=1}^n x_i$$

$\log l(\lambda)$  を最大にするような  $\lambda$  を求める。

$$\frac{d \log l(\lambda)}{d\lambda} = \frac{n}{\lambda} - \sum_{i=1}^n x_i = 0$$

を解いて,  $x_i$  を  $X_i$  で置き換えて,  $\lambda$  の最尤推定量  $\hat{\lambda}$  は

$$\hat{\lambda} = \frac{n}{\sum_{i=1}^n X_i}$$

となる。

- (2)  $n$  個の無作為標本  $X_1, X_2, \dots, X_n$

$X_i$  の密度関数  $f(X_i; \lambda)$

母数  $\lambda$  の最尤推定量  $\hat{\lambda}_n$  について,  $n \rightarrow \infty$  のとき,

$$\sqrt{n}(\hat{\lambda}_n - \lambda) \rightarrow N(0, \sigma^2)$$

となる。ただし,

$$\sigma^2 = \sigma^2(\lambda) = \frac{1}{E\left[\left(\frac{d \log f(X; \lambda)}{d\lambda}\right)^2\right]}$$

とする。

まず,  $\sigma^2 = \sigma^2(\lambda)$  を求める。

$$\begin{aligned} &E\left[\left(\frac{d \log f(X; \lambda)}{d\lambda}\right)^2\right] \\ &= E\left[\left(\frac{1}{\lambda} - X\right)^2\right] \\ &= E\left(\frac{1}{\lambda^2} - \frac{2}{\lambda}X + X^2\right) \\ &= \frac{1}{\lambda^2} - \frac{2}{\lambda}E(X) + E(X^2) \\ &= \frac{1}{\lambda^2} \end{aligned}$$

$E(X), E(X^2)$  は

$$E(X) = \frac{1}{\lambda}, \quad E(X^2) = \frac{2}{\lambda^2}$$

となる。

したがって,

$$\sigma^2 = \sigma^2(\lambda) = \frac{1}{E\left[\left(\frac{d \log f(X; \lambda)}{d\lambda}\right)^2\right]} = \lambda^2$$

よって,  $n$  が大きいとき,

$$\hat{\lambda}_n \sim N\left(\lambda, \frac{\lambda^2}{n}\right)$$

と近似して用いる。

$$\begin{aligned} &= \frac{1}{n^2} V\left(\sum_{i=1}^n X_i\right) \\ &= \frac{1}{n^2} \sum_{i=1}^n V(X_i) \\ &= \frac{1}{n^2} \sum_{i=1}^n \sigma^2 \\ &= \frac{\sigma^2}{n} \end{aligned}$$

4  $X_1, X_2, \dots, X_n$  の  $n$  個の確率変数は, それぞれ独立に, 平均  $\mu$ , 分散  $\sigma^2$  の分布をするものとする。次のような 2 つの  $\mu$  の推定量  $\bar{X}, \tilde{X}$  を考える。

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad \tilde{X} = \frac{1}{2}(X_1 + X_n)$$

このとき, 次の問に答えよ。

- (1)  $\bar{X}, \tilde{X}$  は不偏性を持つかどうかを調べよ。
- (2)  $\bar{X}, \tilde{X}$  のどちらが有効かを調べよ。
- (3)  $\bar{X}, \tilde{X}$  の一貫性について調べよ。

[解答]

- (1)  $\bar{X}, \tilde{X}$  は不偏性を持つかどうかを調べる。

$$\begin{aligned} E(\bar{X}) &= E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \\ &= \frac{1}{n} E\left(\sum_{i=1}^n X_i\right) \\ &= \frac{1}{n} \sum_{i=1}^n E(X_i) \\ &= \frac{1}{n} \sum_{i=1}^n \mu \\ &= \mu \end{aligned}$$

$$\begin{aligned} E(\tilde{X}) &= \frac{1}{2} (E(X_1) + E(X_n)) \\ &= \frac{1}{2} (\mu + \mu) \\ &= \mu \end{aligned}$$

よって, 両方とも  $\mu$  の不偏推定量である。

- (2)  $\bar{X}, \tilde{X}$  のどちらが有効かを調べる。

$$V(\bar{X}) = V\left(\frac{1}{n} \sum_{i=1}^n X_i\right)$$

$$\begin{aligned} V(\tilde{X}) &= \frac{1}{4} (V(X_1) + V(X_n)) \\ &= \frac{1}{4} (\sigma^2 + \sigma^2) \\ &= \frac{\sigma^2}{2} \end{aligned}$$

なので,  $n > 2$  のとき,  $V(\bar{X}) < V(\tilde{X})$  となり,  $\bar{X}$  が  $\tilde{X}$  より有効となる。

- (3)  $\bar{X}, \tilde{X}$  の一貫性について調べる。

チェビシェフの不等式を当てはめる。 $\bar{X}$  について,

$$P(|\bar{X} - E(\bar{X})| \geq \epsilon) \leq \frac{V(\bar{X})}{\epsilon^2}$$

$\epsilon > 0$  とする。すなわち,  $n \rightarrow \infty$  のとき,

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

となる。したがって,

$$\bar{X} \rightarrow \mu$$

を得る。

一方,  $\tilde{X}$  について,

$$P(|\tilde{X} - E(\tilde{X})| \geq \epsilon) \leq \frac{V(\tilde{X})}{\epsilon^2}$$

$\epsilon > 0$  とする。すなわち,  $n \rightarrow \infty$  のとき,

$$P(|\tilde{X} - \mu| \geq \epsilon) \leq \frac{\sigma^2}{2\epsilon^2} > 0$$

となる。

$\bar{X}$  は  $\mu$  の一致推定量であるが,  $\tilde{X}$  は一貫性はない。

5 正規母集団  $N(\mu, \sigma^2)$  から 9 個の無作為標本  
21 23 32 20 36 27 26 28 30  
が得られた。このとき、次の各問に答えなさい。

- (1)  $\mu$  と  $\sigma^2$  の不偏推定値を求めよ。  
 (2) 信頼係数 0.90 および 0.95 の  $\mu$  の信頼区間を求めよ。  
 (3) 帰無仮説  $H_0: \mu = 24$  を対立仮説  $H_1: \mu > 24$  に対して有意水準 0.10 および 0.05 で検定しなさい。

[解答]

(1)  $\mu$  と  $\sigma^2$  の不偏推定量  $\bar{X}, S^2$  は

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

で、不偏推定値は

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

である。

$$\begin{aligned} \bar{x} &= \frac{1}{n} \sum_{i=1}^n x_i \\ &= \frac{1}{9} (21 + 23 + 32 + 20 \\ &\quad + 36 + 27 + 26 + 28 + 30) \\ &= 27 \end{aligned}$$

$$\begin{aligned} s^2 &= \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \\ &= \frac{1}{8} \left( (21-27)^2 + (23-27)^2 + (32-27)^2 \right. \\ &\quad \left. + (20-27)^2 + (36-27)^2 + (27-27)^2 \right. \\ &\quad \left. + (26-27)^2 + (28-27)^2 + (30-27)^2 \right) \\ &= \frac{1}{8} (36 + 16 + 25 + 49 \\ &\quad + 81 + 0 + 1 + 1 + 9) \\ &= 27.25 \end{aligned}$$

(2)  $\mu$  の信頼区間を求める。

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

を利用する。

$$P\left(\left|\frac{\bar{X} - \mu}{S/\sqrt{n}}\right| < t_{\alpha/2}(n-1)\right) = 1 - \alpha$$

$t_{\alpha/2}(n-1)$  は  $100 \times \frac{\alpha}{2} \%$  点で、確率  $\alpha$  と自由度  $n-1$  が与えられると、 $t$  分布表から得られる。

したがって、

$$\begin{aligned} P\left(\bar{X} - t_{\alpha/2}(n-1) \frac{S}{\sqrt{n}} < \mu < \bar{X} + t_{\alpha/2}(n-1) \frac{S}{\sqrt{n}}\right) \\ = 1 - \alpha \end{aligned}$$

$\bar{X}, S^2$  を  $\bar{x}, s^2$  で置き換えて、

信頼係数  $1 - \alpha$  の  $\mu$  の信頼区間： $\implies$

$$\left(\bar{x} - t_{\alpha/2}(n-1) \frac{s}{\sqrt{n}}, \bar{x} + t_{\alpha/2}(n-1) \frac{s}{\sqrt{n}}\right)$$

さらに、 $\bar{x} = 27, s^2 = 27.25, n = 9, t_{0.05}(8) = 1.860, t_{0.025}(8) = 2.306$  なので、

信頼係数 0.90 の  $\mu$  の信頼区間は、

$$\begin{aligned} (27 - 1.860 \sqrt{\frac{27.25}{9}}, 27 + 1.860 \sqrt{\frac{27.25}{9}}) \\ = (23.76, 30.24) \end{aligned}$$

となり、信頼係数 0.95 の  $\mu$  の信頼区間は、

$$\begin{aligned} (27 - 2.306 \sqrt{\frac{27.25}{9}}, 27 + 2.306 \sqrt{\frac{27.25}{9}}) \\ = (22.99, 31.01) \end{aligned}$$

となる。

(3) 帰無仮説  $H_0: \mu = 24$  を対立仮説  $H_1: \mu > 24$  に対して有意水準 0.10 および 0.05 で検定する。

$\bar{X}$  の分布は、 $\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t(n-1)$  なので、帰無仮説

$H_0: \mu = \mu_0$  が正しいもとで、 $\frac{\bar{X} - \mu_0}{S/\sqrt{n}} \sim t(n-1)$  となる ( $\mu$  を  $\mu_0$  で置き換える)。このとき、検定統計量  $\frac{\bar{X} - \mu_0}{S/\sqrt{n}}$ 。検定統計量の値  $\frac{\bar{x} - \mu_0}{s/\sqrt{n}}$ 。

対立仮説  $H_1: \mu > \mu_0$  (片側検定) について：

$$P\left(\frac{\bar{X} - \mu_0}{S/\sqrt{n}} > t_{\alpha}(n-1)\right) = \alpha \text{ なので、}$$

$$\frac{\bar{x} - \mu_0}{s/\sqrt{n}} > t_{\alpha}(n-1) \text{ のとき,}$$

有意水準  $\alpha$  で  $H_0: \mu = \mu_0$  を棄却する。

$$\bar{x} = 27, s^2 = 27.25, \mu_0 = 24, n = 9, t_{0.10}(8) = 1.397, t_{0.05}(8) = 1.860 \text{ を当てはめると,}$$

$$\frac{\bar{x} - \mu_0}{s/\sqrt{n}} = \frac{27 - 24}{\sqrt{27.25/9}} = 1.724 > t_{0.10}(8) = 1.397 \text{ となり,}$$

有意水準 0.10 で  $H_0: \mu = 24$  を棄却する。

$$\frac{\bar{x} - \mu_0}{s/\sqrt{n}} = \frac{27 - 24}{\sqrt{27.25/9}} = 1.724 < t_{0.05}(8) = 1.860 \text{ となり,}$$

有意水準 0.05 で  $H_0: \mu = 24$  を棄却しない。

6 平均  $\mu$ , 分散が既知で  $\sigma^2 = 2^2$  である正規母集団から 16 個の無作為標本  $X_1, X_2, \dots, X_{16}$  を抽出し, その標本平均を計算したところ,  $\bar{x} = 36$  であった。このとき, 次の各問に答えよ。

- (1) 平均  $\mu$  の信頼係数 0.95 の信頼区間を求めよ。
- (2) 帰無仮説  $H_0: \mu = 35$  を対立仮説  $H_1: \mu = 36.5$  に対して, 有意水準 0.05 で検定せよ。
- (3) 問 (2) で行った検定の検出力を求めよ。

[解答]

- (1) 平均  $\mu$  の信頼係数 0.95 の信頼区間を求める。

$\bar{X}$  の分布は

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1),$$

となる。

$$P\left(\left|\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}\right| < z_{\alpha/2}\right) = 1 - \alpha$$

$z_{\alpha/2}$  は  $100 \times \frac{\alpha}{2} \%$  点で, 確率  $\alpha$  が与えられると, 正規分布表から得られる。

したがって,

$$P\left(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

$\bar{X}$  を  $\bar{x}$  で置き換えて,

信頼係数  $1 - \alpha$  の  $\mu$  の信頼区間:  $\Rightarrow$

$$\left(\bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}\right)$$

$\bar{x} = 36, \sigma^2 = 2^2, n = 16, z_{0.025} = 1.960$  を代入すると,

平均  $\mu$  の信頼係数 0.95 の信頼区間は,

$$\left(36 - 1.960 \frac{2}{\sqrt{16}}, 36 + 1.960 \frac{2}{\sqrt{16}}\right) = (35.02, 36.98)$$

となる。

- (2) 帰無仮説  $H_0: \mu = 35$  を対立仮説  $H_1: \mu = 36.5$  に対して, 有意水準 0.05 で検定する。

$\bar{X}$  の分布は,  $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$  なので, 帰無仮説  $H_0: \mu = \mu_0$  が正しいもとで,

$\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \sim N(0, 1)$  となる ( $\mu$  を  $\mu_0$  で置き換える)。こ

のとき, 検定統計量  $\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}}$ 。検定統計量の値  $\frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}}$ 。

対立仮説  $H_1: \mu > \mu_0$  (片側検定) について:

$P\left(\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} > z_{\alpha}\right) = \alpha$  なので,  $\frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}} > z_{\alpha}$  のとき, 有意水準  $\alpha$  で帰無仮説  $H_0: \mu = \mu_0$  を棄却する。

$\bar{x} = 36, \sigma^2 = 2^2, n = 16, z_{0.05} = 1.645$  を代入すると,

$$\frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}} = \frac{36 - 35}{2/\sqrt{16}} = 2 > z_{\alpha} = 1.645 \text{ なので, 有意水準 } \alpha = 0.05 \text{ で帰無仮説 } H_0: \mu = 35 \text{ を棄却する。}$$

- (3) 問 (2) で行った検定の検出力を求める。

検出力とは, 対立仮説のもとで, 帰無仮説を棄却する確率である。

すなわち, 帰無仮説  $H_0: \mu = \mu_0$  のもとで, 帰無仮説を棄却する棄却域は,  $P\left(\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} > z_{\alpha}\right) = \alpha$  なので,

$$\bar{X} > \mu_0 + z_{\alpha} \sigma/\sqrt{n} \text{ となる。}$$

対立仮説  $H_1: \mu = \mu_1$  のもとで, 帰無仮説を棄却する確率を求める。

すなわち, 対立仮説  $H_1: \mu = \mu_1$  のもとで,

$$P\left(\bar{X} > \mu_0 + z_{\alpha} \sigma/\sqrt{n}\right) \text{ を求める。}$$

対立仮説  $H_1: \mu = \mu_1$  のもとで,

$$\frac{\bar{X} - \mu_1}{\sigma/\sqrt{n}} \sim N(0, 1) \text{ となるので,}$$

$$P\left(\frac{\bar{X} - \mu_1}{\sigma/\sqrt{n}} > \frac{\mu_0 - \mu_1}{\sigma/\sqrt{n}} + z_{\alpha}\right)$$

となる確率を求めればよい。

$\sigma = 2, n = 16, \mu_0 = 35, \mu_1 = 36.5, z_\alpha = 1.645$  を代入すると,

$$\begin{aligned} P\left(\frac{\bar{X} - \mu_1}{\sigma/\sqrt{n}} > \frac{35 - 36.5}{2/\sqrt{16}} + 1.645\right) \\ = P\left(\frac{\bar{X} - \mu_1}{\sigma/\sqrt{n}} > -1.355\right) \\ = 1 - 0.0877 = 0.9123 \text{ を得る.} \end{aligned}$$

( $z_{0.0885} = 1.35, z_{0.0869} = 1.36$  に注意)

7  $X_1, X_2, \dots, X_n$  は互いに独立で, すべて同一のポアソン分布に従うものとする。ただし, ポアソン分布の確率関数は

$$P(X = x) = f(x; \lambda) = \frac{\lambda^x e^{-\lambda}}{x!}, \quad x = 0, 1, 2, \dots$$

である。

このとき, 次の問に答えよ。

- (1)  $\lambda$  の最尤推定量  $\hat{\lambda}$  を求めよ。
- (2)  $\hat{\lambda}$  は,  $\lambda$  の不偏推定量であることを証明せよ。
- (3)  $\hat{\lambda}$  は,  $\lambda$  の有効推定量であることを証明せよ。
- (4)  $\hat{\lambda}$  は,  $\lambda$  の一致推定量であることを証明せよ。

[解答]

- (1)  $\lambda$  の最尤推定量  $\hat{\lambda}$  を求める。

ポアソン分布の確率関数は,

$$P(X = x) = f(x; \lambda) = \frac{\lambda^x e^{-\lambda}}{x!}, \quad x = 0, 1, 2, \dots$$

なので, 尤度関数は,

$$\begin{aligned} l(\lambda) &= \prod_{i=1}^n f(x_i; \lambda) \\ &= \prod_{i=1}^n \frac{\lambda^{x_i} e^{-\lambda}}{x_i!} \\ &= \frac{\lambda^{\sum_{i=1}^n x_i} e^{-n\lambda}}{\prod_{i=1}^n x_i!} \end{aligned}$$

対数尤度関数は,

$$\log l(\lambda) = \log(\lambda) \sum_{i=1}^n x_i - n\lambda - \log\left(\prod_{i=1}^n x_i!\right)$$

となる。

$$\begin{aligned} \frac{\partial \log l(\lambda)}{\partial \lambda} &= \frac{1}{\lambda} \sum_{i=1}^n x_i - n \\ &= 0 \end{aligned}$$

これを解いて,  $\lambda$  の最尤推定量  $\hat{\lambda}$  は,

$$\hat{\lambda} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

となる。

- (2)  $\hat{\lambda}$  は,  $\lambda$  の不偏推定量であることを証明する。

$$\begin{aligned} E(\hat{\lambda}) &= E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \\ &= \frac{1}{n} \sum_{i=1}^n E(X_i) \\ &= \frac{1}{n} \sum_{i=1}^n \lambda \\ &= \lambda \end{aligned}$$

- (3)  $\hat{\lambda}$  は,  $\lambda$  の有効推定量であることを証明する。

クラメル・ラオの不等式の等号が成り立つことを証明すればよい。

$$\begin{aligned} V(\hat{\lambda}) &= V\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \\ &= \frac{1}{n^2} \sum_{i=1}^n V(X_i) \\ &= \frac{1}{n^2} \sum_{i=1}^n \lambda \\ &= \frac{\lambda}{n} \\ &= \frac{1}{nE\left[\left(\frac{\partial \log f(X; \lambda)}{\partial \lambda}\right)^2\right]} \\ &= \frac{1}{nE\left[\left(\frac{\partial (X \log \lambda - \lambda - \log X!)}{\partial \lambda}\right)^2\right]} \end{aligned}$$

$$\begin{aligned}
&= \frac{1}{nE\left[\left(\frac{X}{\lambda} - 1\right)^2\right]} \\
&= \frac{\lambda^2}{nE[(X - \lambda)^2]} \\
&= \frac{\lambda^2}{nV(X)} \\
&= \frac{\lambda^2}{n\lambda} \\
&= \frac{\lambda}{n}
\end{aligned}$$

したがって,

$$V(\hat{\lambda}) = \frac{1}{nE\left[\left(\frac{\partial \log f(X; \lambda)}{\partial \lambda}\right)^2\right]}$$

となり,  $V(\hat{\lambda})$  は, クラメル・ラオの下限に一致する。よって,  $\hat{\lambda}$  は有効推定量である。

(4)  $\hat{\lambda}$  は,  $\lambda$  の一致推定量であることを証明する。

$$E(\hat{\lambda}) = \lambda, \quad V(\hat{\lambda}) = \frac{\lambda}{n}$$

である。チェビシェフの不等式

$$P(|\hat{\lambda} - E(\hat{\lambda})| \geq \epsilon) \leq \frac{V(\hat{\lambda})}{\epsilon^2}$$

に,  $E(\hat{\lambda}), V(\hat{\lambda})$  を代入すると,

$$P(|\hat{\lambda} - \lambda| > \epsilon) < \frac{\lambda}{n\epsilon^2} \rightarrow 0$$

が得られる。したがって, 一致性も成り立つ。

**8** 連続型確率変数  $X_1, X_2, \dots, X_n$  は互いに独立に同一の正規分布に従うものとする。このとき, 以下の問に答えよ。ただし, 正規分布の密度関数は

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}$$

で表される。

(1) 標本平均  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  の分布は, 平均  $\mu$ , 分散  $\frac{\sigma^2}{n}$  の正規分布に従うことを示せ。

(2)  $Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$  を定義する。 $Z$  の分布は, 平均 0, 分散 1 の正規分布に従うことを示せ。

(3) 標本不偏分散  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  を考える。

$\frac{(n-1)S^2}{\sigma^2}$  の分布は自由度  $n-1$  のカイ二乗分布であることが知られている。これを利用して,  $S^2$  の平均と分散を求めよ。

ただし, 自由度  $m$  のカイ二乗分布の密度関数は,

$$f(x) = \begin{cases} \frac{1}{2^{\frac{m}{2}} \Gamma(\frac{m}{2})} x^{\frac{m}{2}-1} e^{-\frac{x}{2}}, & x > 0 \text{ のとき} \\ 0, & \text{その他} \end{cases}$$

として表される。

(4)  $S^2$  は  $\sigma^2$  の一致推定量であることを示せ。

[解答]

(1) 標本平均  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  の分布は, 平均  $\mu$ , 分散  $\frac{\sigma^2}{n}$  の正規分布に従うことを示す。

積率母関数を利用する。

$X \sim N(\mu, \sigma^2)$  のとき,  $X$  の積率母関数  $\phi(\theta)$  は,

$$\begin{aligned}
\phi(\theta) &\equiv E(e^{\theta X}) \\
&= \int_{-\infty}^{\infty} e^{\theta x} f(x) dx \\
&= \int_{-\infty}^{\infty} e^{\theta x} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} dx \\
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2 + \theta x} dx \\
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x^2 - 2(\mu + \sigma^2\theta)x + \mu^2)} dx \\
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x - (\mu + \sigma^2\theta))^2 + (\mu\theta + \frac{1}{2}\sigma^2\theta^2)} dx \\
&= e^{\mu\theta + \frac{1}{2}\sigma^2\theta^2} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x - (\mu + \sigma^2\theta))^2} dx \\
&= \exp\left(\mu\theta + \frac{1}{2}\sigma^2\theta^2\right)
\end{aligned}$$

と計算される。積分のところは,  $N(\mu + \sigma^2\theta, \sigma^2)$  の確率密度関数に注意

よって,  $X_i \sim N(\mu, \sigma^2)$  のとき,  $X_i$  の積率母関数  $\phi_i(\theta)$  は,

$$\phi_i(\theta) = \exp\left(\mu\theta + \frac{1}{2}\sigma^2\theta^2\right)$$

となる。

今,  $\bar{X}$  の積率母関数  $\phi_{\bar{X}}(\theta)$  を考える。

$$\begin{aligned}\phi_{\bar{X}}(\theta) &\equiv E(e^{\theta\bar{X}}) \\ &= E(e^{\theta\frac{1}{n}\sum_{i=1}^n X_i}) \\ &= E\left(\prod_{i=1}^n e^{\frac{\theta}{n}X_i}\right) \\ &= \prod_{i=1}^n E(e^{\frac{\theta}{n}X_i}) \\ &= \prod_{i=1}^n \phi_i\left(\frac{\theta}{n}\right) \\ &= \prod_{i=1}^n \exp\left(\mu\frac{\theta}{n} + \frac{1}{2}\sigma^2\left(\frac{\theta}{n}\right)^2\right) \\ &= \exp\left(\mu\theta + \frac{1}{2}\sigma^2\frac{\theta^2}{n}\right) \\ &= \exp\left(\mu\theta + \frac{1}{2}\frac{\sigma^2}{n}\theta^2\right)\end{aligned}$$

となり, これは, 平均  $\mu$ , 分散  $\sigma^2/n$  の正規分布の積率母関数に一致する。

- (2)  $Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$  の分布は, 平均 0, 分散 1 の正規分布に従うことを示す。

$\bar{X}$  の積率母関数  $\phi_{\bar{X}}(\theta)$  は, 問 (1) より,

$$\begin{aligned}\phi_{\bar{X}}(\theta) &\equiv E(e^{\theta\bar{X}}) \\ &= \exp\left(\mu\theta + \frac{1}{2}\frac{\sigma^2}{n}\theta^2\right)\end{aligned}$$

と計算されることを利用する。

$Z$  の積率母関数  $\phi_z(\theta)$  は,

$$\begin{aligned}\phi_z(\theta) &\equiv E(e^{\theta Z}) \\ &= E\left(\exp\left(\theta\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}\right)\right) \\ &= \exp\left(-\theta\frac{\mu}{\sigma/\sqrt{n}}\right) E\left(\exp\left(\frac{\theta}{\sigma/\sqrt{n}}\bar{X}\right)\right) \\ &= \exp\left(-\theta\frac{\mu}{\sigma/\sqrt{n}}\right) \phi_{\bar{X}}\left(\frac{\theta}{\sigma/\sqrt{n}}\right)\end{aligned}$$

$$\begin{aligned}&= \exp\left(-\theta\frac{\mu}{\sigma/\sqrt{n}}\right) \\ &\quad \times \exp\left(\mu\frac{\theta}{\sigma/\sqrt{n}} + \frac{1}{2}\frac{\sigma^2}{n}\left(\frac{\theta}{\sigma/\sqrt{n}}\right)^2\right) \\ &= \exp\left(\frac{1}{2}\theta^2\right)\end{aligned}$$

これは,  $N(0, 1)$  の積率母関数となっている。

- (3) まず, 準備として, 自由度  $m$  のカイ二乗分布の平均と分散を計算する。

自由度  $m$  のカイ二乗分布は,

$$f(x) = \frac{1}{2^{\frac{m}{2}}\Gamma(\frac{m}{2})}x^{\frac{m}{2}-1}e^{-\frac{x}{2}} \quad x > 0 \text{ のとき}$$

なので, その積率母関数  $\phi_{\chi^2}(\theta)$  は,

$$\begin{aligned}\phi_{\chi^2}(\theta) &= E(e^{\theta X}) \\ &= \int_0^\infty e^{\theta x} \frac{1}{2^{\frac{m}{2}}\Gamma(\frac{m}{2})}x^{\frac{m}{2}-1}e^{-\frac{x}{2}}dx \\ &= \int_0^\infty \frac{1}{2^{\frac{m}{2}}\Gamma(\frac{m}{2})}x^{\frac{m}{2}-1}e^{-\frac{1}{2}(1-2\theta)x}dx \\ &= \int_0^\infty \frac{1}{2^{\frac{m}{2}}\Gamma(\frac{m}{2})}\left(\frac{y}{1-2\theta}\right)^{\frac{m}{2}-1}e^{-\frac{1}{2}y}\frac{1}{1-2\theta}dy \\ &= \left(\frac{1}{1-2\theta}\right)^{\frac{m}{2}-1}\frac{1}{1-2\theta} \\ &\quad \times \int_0^\infty \frac{1}{2^{\frac{m}{2}}\Gamma(\frac{m}{2})}y^{\frac{m}{2}-1}e^{-\frac{1}{2}y}dy \\ &= (1-2\theta)^{-\frac{m}{2}}\end{aligned}$$

となる。

4つ目の等式で,  $y = (1-2\theta)x$  として, 置換積分を利用。

$\frac{1}{2^{\frac{m}{2}}\Gamma(\frac{m}{2})}y^{\frac{m}{2}-1}e^{-\frac{1}{2}y}$  は, 自由度  $m$  の  $\chi^2$  分布となっているので, その積分値は 1 となる。

積率母関数を微分して,

$$\begin{aligned}\phi'_{\chi^2}(\theta) &= m(1-2\theta)^{-\frac{m}{2}-1} \\ \phi''_{\chi^2}(\theta) &= m(m+2)(1-2\theta)^{-\frac{m}{2}-2}\end{aligned}$$

を用いると,

$$\begin{aligned}E(X) &= \phi'_{\chi^2}(0) = m \\ E(X^2) &= \phi''_{\chi^2}(0) = m(m+2)\end{aligned}$$

が得られる。

よって、自由度  $m$  の  $\chi^2$  分布の平均は  $m$ 、分散は、

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \\ &= m(m+2) - m^2 \\ &= 2m \end{aligned}$$

となる。

$\frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$  なので、これを利用すると、

$$\begin{aligned} E\left(\frac{(n-1)S^2}{\sigma^2}\right) &= n-1 \\ V\left(\frac{(n-1)S^2}{\sigma^2}\right) &= 2(n-1) \end{aligned}$$

となる。よって、

$$\begin{aligned} \frac{n-1}{\sigma^2} E(S^2) &= n-1 \\ \left(\frac{n-1}{\sigma^2}\right)^2 V(S^2) &= 2(n-1) \end{aligned}$$

を利用して、 $S^2$  の平均と分散は、

$$\begin{aligned} E(S^2) &= \sigma^2 \\ V(S^2) &= \frac{2\sigma^4}{n-1} \end{aligned}$$

となる。

(4)  $S^2$  は  $\sigma^2$  の一致推定量であることを示す。

チェビシエフの不等式を用いる。

$$P(|S^2 - E(S^2)| \geq \epsilon) \leq \frac{V(S^2)}{\epsilon^2}$$

に、 $E(S^2)$ 、 $V(S^2)$  を代入すると、

$$P(|S^2 - \sigma^2| \geq \epsilon) \leq \frac{2\sigma^4}{(n-1)\epsilon^2} \rightarrow 0$$

が得られる。したがって、一貫性も成り立つ。