

例 2:  $X_1, X_2, \dots, X_n$  は互いに独立で, それぞれパラメータ  $p$  を持ったベルヌイ分布に従うものとする。すなわち,  $X_i$  の確率関数は,

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

となる。

このとき尤度関数は,

$$l(p) = \prod_{i=1}^n f(x_i; p) = \prod_{i=1}^n p^{x_i}(1 - p)^{1-x_i}$$

となり, 対数尤度関数は,

$$\begin{aligned} \log l(p) &= \sum_{i=1}^n \log f(x_i; p) \\ &= \log(p) \sum_{i=1}^n x_i + \log(1 - p) \sum_{i=1}^n (1 - x_i) \end{aligned}$$

$$= \log(p) \sum_{i=1}^n x_i + \log(1-p)(n - \sum_{i=1}^n x_i)$$

となる。

$\log l(p)$  を最大にする  $p$  を求める。

$$\frac{d \log l(p)}{dp} = \frac{1}{p} \sum_{i=1}^n x_i - \frac{1}{1-p} (n - \sum_{i=1}^n x_i) = 0$$

したがって、 $p$  について解くと、 $p$  の最尤推定値  $\hat{p}$  は、

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n x_i$$

となる。

さらに、 $x_i$  を  $X_i$  で置き換えて、 $p$  の最尤推定量  $\hat{p}$  は、

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i$$

となる。

$\hat{p}$  の分布を求める。確率関数の対数を取って，

$$\log f(X_i; p) = X_i \log(p) + (1 - X_i) \log(1 - p)$$

となる。 $p$  について微分すると，

$$\frac{d \log f(X_i; p)}{dp} = \frac{X_i}{p} - \frac{1 - X_i}{1 - p} = \frac{X_i - p}{p(1 - p)}$$

となる。さらに，両辺を二乗して，期待値を取ると，

$$E\left[\left(\frac{d \log f(X_i; p)}{dp}\right)^2\right] = \frac{E[(X_i - p)^2]}{p^2(1 - p)^2}$$

となる。期待値を計算すると，

$$\begin{aligned} E[(X_i - p)^2] &= \sum_{x_i=0}^1 (x_i - p)^2 f(x_i; p) = \sum_{x_i=0}^1 (x_i - p)^2 p^{x_i} (1 - p)^{1-x_i} \\ &= p^2(1 - p) + (1 - p)^2 p = p(1 - p) \end{aligned}$$

となるので ,

$$\sigma_{\theta}^2 = \frac{1}{\sum_{i=1}^n \mathbb{E}\left[\left(\frac{d \log f(X_i; p)}{dp}\right)^2\right]} = \frac{p(1-p)}{n}$$

が得られる。したがって ,  $\hat{p}$  の分布は ,  $n$  が大きいとき ,

$$\hat{p} \sim N\left(p, \frac{p(1-p)}{n}\right)$$

となる。

例3:  $X_1, X_2, \dots, X_n$  は互いに独立で, それぞれパラメータ  $\lambda$  を持ったポアソン分布に従うものとする。すなわち,  $X_i$  の確率関数は,

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

となる。

このとき尤度関数は,

$$l(\lambda) = \prod_{i=1}^n f(x_i; \lambda) = \prod_{i=1}^n \frac{\lambda^{x_i} e^{-\lambda}}{x_i!}$$

となり, 対数尤度関数は,

$$\log l(\lambda) = \sum_{i=1}^n \log f(x_i; \lambda) = \log(\lambda) \sum_{i=1}^n x_i - n\lambda - \sum_{i=1}^n \log(x_i!)$$

となる。

$\log l(\lambda)$  を最大にする  $\lambda$  を求める。

$$\frac{d \log l(\lambda)}{d\lambda} = \frac{1}{\lambda} \sum_{i=1}^n x_i - n = 0$$

したがって、 $\lambda$  について解くと、 $\lambda$  の最尤推定値  $\hat{\lambda}$  は、

$$\hat{\lambda} = \frac{1}{n} \sum_{i=1}^n x_i$$

となる。

さらに、 $x_i$  を  $X_i$  で置き換えて、 $\lambda$  の最尤推定量  $\hat{\lambda}$  は、

$$\hat{\lambda} = \frac{1}{n} \sum_{i=1}^n X_i$$

となる。

$\hat{\lambda}$  の分布を求める。確率関数に対数を取って、

$$\log f(X_i; \lambda) = X_i \log(\lambda) - \lambda - \log(X_i!)$$

となる。 $\lambda$  に関して、微分すると、

$$\frac{d \log f(X_i; \lambda)}{d\lambda} = \frac{X_i}{\lambda} - 1$$

を得る。再度， $\lambda$  に関して，微分すると，

$$\frac{d^2 \log f(X_i; \lambda)}{d\lambda^2} = -\frac{X_i}{\lambda^2}$$

となる。期待値をとって，

$$E\left(\frac{d^2 \log f(X_i; \lambda)}{d\lambda^2}\right) = -\frac{E(X_i)}{\lambda^2}$$

が得られる。期待値を計算すると，

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

となる。したがって，

$$\sigma_{\theta}^2 = -\frac{1}{\sum_{i=1}^n E\left(\frac{d^2 \log f(X_i; \lambda)}{d\lambda^2}\right)} = \frac{\lambda}{n}$$

となる。よって、 $\hat{\lambda}$  の分布は、 $n$  が大きいとき、

$$\hat{\lambda} \sim N\left(\lambda, \frac{\lambda}{n}\right)$$

を得る。

例 4:  $X_1, X_2, \dots, X_n$  は互いに独立で, それぞれパラメータ  $\lambda$  を持った指数分布に従うものとする。すなわち,  $X_i$  の密度関数は,

$$f(x; \lambda) = \lambda e^{-\lambda x} \quad x > 0$$

となる。

このとき尤度関数は,

$$l(\lambda) = \prod_{i=1}^n f(x_i; \lambda) = \prod_{i=1}^n \lambda e^{-\lambda x_i}$$

となり, 対数尤度関数は,

$$\log l(\lambda) = \sum_{i=1}^n \log f(x_i; \lambda) = n \log \lambda - \lambda \sum_{i=1}^n x_i$$

となる。

$\log l(\lambda)$  を最大にする  $\lambda$  を求める。

$$\frac{d \log l(\lambda)}{d\lambda} = \frac{n}{\lambda} - \sum_{i=1}^n x_i = 0$$

したがって、 $\lambda$  について解くと、 $\lambda$  の最尤推定値  $\hat{\lambda}$  は、

$$\hat{\lambda} = \frac{n}{\sum_{i=1}^n x_i}$$

となる。

さらに、 $x_i$  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。

$\hat{\lambda}$  の分布を求める。密度関数の対数を取って、

$$\log f(X_i; \lambda) = \log \lambda - \lambda X_i$$

となる。 $\lambda$  について微分すると、

$$\frac{d \log f(X_i; \lambda)}{d\lambda} = \frac{1}{\lambda} - X_i$$

を得る。再度，微分して，

$$\frac{d^2 \log f(X_i; \lambda)}{d\lambda^2} = -\frac{1}{\lambda^2}$$

が得られる。

$$\sigma_{\theta}^2 = -\frac{1}{\sum_{i=1}^n E\left(\frac{d^2 \log f(X_i; \lambda)}{d\lambda^2}\right)} = \frac{\lambda^2}{n}$$

となるので， $n$  が大きいとき，

$$\hat{\lambda} \sim N\left(\lambda, \frac{\lambda^2}{n}\right)$$

を得る。

## 2 Maximum Likelihood Estimation (MLE, 最尤法) — More Formally Review

1. We have random variables  $X_1, X_2, \dots, X_n$ , which are assumed to be mutually independently and identically distributed.
2. The distribution function of  $\{X_i\}_{i=1}^n$  is  $f(x; \theta)$ , where  $x = (x_1, x_2, \dots, x_n)$  and  $\theta = (\mu, \Sigma)$ .

Note that  $X$  is a vector of random variables and  $x$  is a vector of their realizations (i.e., observed data).

Likelihood function  $L(\cdot)$  is defined as  $L(\theta; x) = f(x; \theta)$ .

Note that  $f(x; \theta) = \prod_{i=1}^n f(x_i; \theta)$  when  $X_1, X_2, \dots, X_n$  are mutually independently and

identically distributed.

The maximum likelihood estimator (MLE) of  $\theta$  is  $\theta$  such that:

$$\max_{\theta} L(\theta; X). \quad \iff \quad \max_{\theta} \log L(\theta; X).$$

MLE satisfies the following two conditions:

- (a)  $\frac{\partial \log L(\theta; X)}{\partial \theta} = 0.$
- (b)  $\frac{\partial^2 \log L(\theta; X)}{\partial \theta \partial \theta'}$  is a negative definite matrix.

3. **Fisher's information matrix** (フィッシャーの情報行列) is defined as:

$$I(\theta) = -E\left(\frac{\partial^2 \log L(\theta; X)}{\partial \theta \partial \theta'}\right),$$

where we have the following equality:

$$-E\left(\frac{\partial^2 \log L(\theta; X)}{\partial \theta \partial \theta'}\right) = E\left(\frac{\partial \log L(\theta; X)}{\partial \theta} \frac{\partial \log L(\theta; X)}{\partial \theta'}\right) = V\left(\frac{\partial \log L(\theta; X)}{\partial \theta}\right)$$

**Proof of the above equality:**

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

Take a derivative with respect to  $\theta$ .

$$\int \frac{\partial L(\theta; x)}{\partial \theta} dx = 0$$

(We assume that (i) the domain of  $x$  does not depend on  $\theta$  and (ii) the derivative  $\frac{\partial L(\theta; x)}{\partial \theta}$  exists.)

Rewriting the above equation, we obtain:

$$\int \frac{\partial \log L(\theta; x)}{\partial \theta} L(\theta; x) dx = 0,$$

i.e.,

$$E\left(\frac{\partial \log L(\theta; X)}{\partial \theta}\right) = 0.$$

Again, differentiating the above with respect to  $\theta$ , we obtain:

$$\begin{aligned}
 & \int \frac{\partial^2 \log L(\theta; x)}{\partial \theta \partial \theta'} L(\theta; x) dx + \int \frac{\partial \log L(\theta; x)}{\partial \theta} \frac{\partial L(\theta; x)}{\partial \theta'} dx \\
 &= \int \frac{\partial^2 \log L(\theta; x)}{\partial \theta \partial \theta'} L(\theta; x) dx + \int \frac{\partial \log L(\theta; x)}{\partial \theta} \frac{\partial \log L(\theta; x)}{\partial \theta'} L(\theta; x) dx \\
 &= E\left(\frac{\partial^2 \log L(\theta; X)}{\partial \theta \partial \theta'}\right) + E\left(\frac{\partial \log L(\theta; X)}{\partial \theta} \frac{\partial \log L(\theta; X)}{\partial \theta'}\right) = 0.
 \end{aligned}$$

Therefore, we can derive the following equality:

$$-E\left(\frac{\partial^2 \log L(\theta; X)}{\partial \theta \partial \theta'}\right) = E\left(\frac{\partial \log L(\theta; X)}{\partial \theta} \frac{\partial \log L(\theta; X)}{\partial \theta'}\right) = V\left(\frac{\partial \log L(\theta; X)}{\partial \theta}\right),$$

where the second equality utilizes  $E\left(\frac{\partial \log L(\theta; X)}{\partial \theta}\right) = 0$ .

4. **Cramer-Rao Lower Bound** (クラメル・ラオの下限):  $(I(\theta))^{-1}$

Suppose that an unbiased estimator of  $\theta$  is given by  $s(X)$ .

Then, we have the following:

$$V(s(X)) \geq (I(\theta))^{-1}$$

**Proof:**

The expectation of  $s(X)$  is:

$$E(s(X)) = \int s(x)L(\theta; x)dx.$$

Differentiating the above with respect to  $\theta$ ,

$$\begin{aligned} \frac{\partial E(s(X))}{\partial \theta} &= \int s(x) \frac{\partial L(\theta; x)}{\partial \theta} dx = \int s(x) \frac{\partial \log L(\theta; x)}{\partial \theta} L(\theta; x) dx \\ &= \text{Cov} \left( s(X), \frac{\partial \log L(\theta; X)}{\partial \theta} \right) \end{aligned}$$