

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 λ 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 λ 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、 λ について解くと、 λ 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, λ の最尤推定量 $\hat{\lambda}$ は,

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

となる。

$\hat{\lambda}$ の分布を求めると, n が大きいとき,

$$\hat{\lambda} \sim N(\lambda, \sigma_\lambda^2) \quad \text{ただし, } \sigma_\lambda^2 = -\frac{1}{\sum_{i=1}^n \mathbf{E}\left(\frac{\mathbf{d}^2 \log f(X_i; \lambda)}{\mathbf{d}\lambda^2}\right)}$$

となる。

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

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

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

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

$\mathbf{E}(X_i)$ は次のように計算される。

$$\mathbf{E}(X_i) = \sum_{x=0}^{\infty} x f(x; \lambda) = \sum_{x=0}^{\infty} x \frac{\lambda^x e^{-\lambda}}{x!} = \sum_{x=1}^{\infty} x \frac{\lambda^x e^{-\lambda}}{x!} = \sum_{x=1}^{\infty} \lambda \frac{\lambda^{x-1} e^{-\lambda}}{(x-1)!} = \sum_{x'=0}^{\infty} \lambda \frac{\lambda^{x'} e^{-\lambda}}{x'!} = \lambda$$

途中で, $x' = x - 1$ と $\sum_{x=0}^{\infty} f(x; \lambda) = \sum_{x=0}^{\infty} \frac{\lambda^x e^{-\lambda}}{x!} = 1$ を使っている。

(*) 離散型確率変数 X について, その確率関数を $f(x)$ とし, X のとる範囲を x_1, x_2, \dots とするとき, $\sum_{i=1}^{\infty} f(x_i) = 1$ となる (確率の総和は 1)。

よって,

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

となり,

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

を得る。

例4： X_1, X_n, \dots, X_n は互いに独立で，それぞれパラメータ λ 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 p を求める。

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

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

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

となる。

$\hat{\lambda}$ の分布を求めると， n が大きいとき，

$$\hat{\lambda} \sim N(\lambda, \sigma_\lambda^2) \quad \text{ただし, } \sigma_\lambda^2 = -\frac{1}{\sum_{i=1}^n \mathbf{E}\left(\frac{\mathbf{d}^2 \log f(X_i; \lambda)}{\mathbf{d}\lambda^2}\right)}$$

となる。

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

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

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

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

したがって，

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

を得る。

10.2 最尤法を回帰分析へ応用

回帰モデル

$$Y_i = \alpha + \beta X_i + u_i \quad i = 1, 2, \dots, n$$

u_1, u_2, \dots, u_n は互いに独立で, すべての i について $u_i \sim N(0, \sigma^2)$ を仮定する。

Y_i の分布について, $\mathbf{E}(Y_i)$ と $\mathbf{V}(Y_i)$ を求める。

$$\mathbf{E}(Y_i) = \mathbf{E}(\alpha + \beta X_i + u_i) = \alpha + \beta X_i + \mathbf{E}(u_i) = \alpha + \beta X_i$$

$$\mathbf{V}(Y_i) = \mathbf{V}(\alpha + \beta X_i + u_i) = \mathbf{V}(u_i) = \sigma^2$$

よって、 Y_i は、平均 $\alpha + \beta X_i$ 、分散 σ^2 の正規分布となる。

したがって、 Y_i の密度関数は、

$$f(Y_i) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(Y_i - \alpha - \beta X_i)^2\right)$$

となる。

u_1, u_2, \dots, u_n は互いに独立であれば、 Y_1, Y_2, \dots, Y_n も互いに独立になるので、 Y_1, Y_2, \dots, Y_n の結合密度関数は、

$$f(Y_1, Y_2, \dots, Y_n; \theta) = \prod_{i=1}^n f(Y_i; \theta)$$

$$= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2\right)$$

となる。

これは $\theta = \begin{pmatrix} \alpha \\ \beta \\ \sigma^2 \end{pmatrix}$ の関数となっている。

よって、尤度関数は、

$$l(\theta) = (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2\right)$$

となる。

対数尤度関数は，

$$\log l(\theta) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2$$

となる。

$\log l(\theta)$ を最大にするために，

$$\frac{\partial \log l(\theta)}{\partial \alpha} = \frac{1}{\sigma^2} \sum_{i=1}^n (Y_i - \alpha - \beta X_i) = 0$$

$$\frac{\partial \log l(\theta)}{\partial \beta} = \frac{1}{\sigma^2} \sum_{i=1}^n X_i (Y_i - \alpha - \beta X_i) = 0$$

$$\frac{\partial \log l(\theta)}{\partial \sigma^2} = -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2 = 0$$

の連立方程式を解く。

上2つの式は σ^2 に依存していない。

α, β の最尤推定量は最小二乗推定量と同じになる。

すなわち,

$$\hat{\beta} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad \hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X}$$

σ^2 の最尤推定量は,

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}X_i)^2$$

となり, s^2 とは異なる。

$$\hat{\theta} = \begin{pmatrix} \hat{\alpha} \\ \hat{\beta} \\ \hat{\sigma}^2 \end{pmatrix}, \theta = \begin{pmatrix} \alpha \\ \beta \\ \sigma^2 \end{pmatrix} \text{ とする。 } n \text{ が大きいとき ,}$$

$$\hat{\theta} \sim N(\theta, \Sigma_{\theta})$$

となる。

$$\text{ただし , } \Sigma_{\theta} = \left(\sum_{i=1}^n \mathbf{E} \left[\left(\frac{\partial \log f(Y_i; \theta)}{\partial \theta} \right) \left(\frac{\partial \log f(Y_i; \theta)}{\partial \theta} \right)' \right] \right)^{-1} = - \left(\sum_{i=1}^n \mathbf{E} \left[\frac{\partial^2 \log f(Y_i; \theta)}{\partial \theta \partial \theta'} \right] \right)^{-1} \text{ とする。}$$

Y_i の密度関数 $f(Y_i; \theta)$ の対数は ,

$$\log f(Y_i; \theta) = -\frac{1}{2} \log(2\pi) - \frac{1}{2} \log(\sigma^2) - \frac{1}{2\sigma^2} (Y_i - \alpha - \beta X_i)^2$$

となる。

$$\frac{\partial \log f(Y_i; \theta)}{\partial \theta} = \begin{pmatrix} \frac{\partial \log f(Y_i; \theta)}{\partial \alpha} \\ \frac{\partial \log f(Y_i; \theta)}{\partial \beta} \\ \frac{\partial \log f(Y_i; \theta)}{\partial \sigma^2} \end{pmatrix} = \begin{pmatrix} \frac{1}{\sigma^2}(Y_i - \alpha - \beta X_i) \\ \frac{1}{\sigma^2} X_i (Y_i - \alpha - \beta X_i) \\ -\frac{1}{2\sigma^2} + \frac{1}{2\sigma^4} (Y_i - \alpha - \beta X_i)^2 \end{pmatrix}$$

$$\frac{\partial^2 \log f(Y_i; \theta)}{\partial \theta \partial \theta'} = \begin{pmatrix} \frac{\partial^2 \log f(Y_i; \theta)}{\partial \alpha^2} & \frac{\partial^2 \log f(Y_i; \theta)}{\partial \alpha \partial \beta} & \frac{\partial^2 \log f(Y_i; \theta)}{\partial \alpha \partial \sigma^2} \\ \frac{\partial^2 \log f(Y_i; \theta)}{\partial \beta \partial \alpha} & \frac{\partial^2 \log f(Y_i; \theta)}{\partial \beta^2} & \frac{\partial^2 \log f(Y_i; \theta)}{\partial \beta \partial \sigma^2} \\ \frac{\partial^2 \log f(Y_i; \theta)}{\partial \sigma^2 \partial \alpha} & \frac{\partial^2 \log f(Y_i; \theta)}{\partial \sigma^2 \partial \beta} & \frac{\partial^2 \log f(Y_i; \theta)}{\partial (\sigma^2)^2} \end{pmatrix}$$

$$= \begin{pmatrix} -\frac{1}{\sigma^2} & -\frac{X_i}{\sigma^2} & -\frac{Y_i - \alpha - \beta X_i}{\sigma^4} \\ -\frac{X_i}{\sigma^2} & -\frac{X_i^2}{\sigma^2} & -\frac{X_i(Y_i - \alpha - \beta X_i)}{\sigma^4} \\ -\frac{Y_i - \alpha - \beta X_i}{\sigma^4} & -\frac{X_i(Y_i - \alpha - \beta X_i)}{\sigma^4} & \frac{1}{2\sigma^4} - \frac{(Y_i - \alpha - \beta X_i)^2}{\sigma^6} \end{pmatrix}$$

期待値をとると，

$$\mathbf{E}\left(\frac{\partial^2 \log f(Y_i; \theta)}{\partial \theta \partial \theta'}\right) = \mathbf{E} \begin{pmatrix} -\frac{1}{\sigma^2} & -\frac{X_i}{\sigma^2} & -\frac{Y_i - \alpha - \beta X_i}{\sigma^4} \\ -\frac{X_i}{\sigma^2} & -\frac{X_i^2}{\sigma^2} & -\frac{X_i(Y_i - \alpha - \beta X_i)}{\sigma^4} \\ -\frac{Y_i - \alpha - \beta X_i}{\sigma^4} & -\frac{X_i(Y_i - \alpha - \beta X_i)}{\sigma^4} & \frac{1}{2\sigma^4} - \frac{(Y_i - \alpha - \beta X_i)^2}{\sigma^6} \end{pmatrix}$$

$$= \begin{pmatrix} -\frac{1}{\sigma^2} & -\frac{X_i}{\sigma^2} & 0 \\ -\frac{X_i}{\sigma^2} & -\frac{X_i^2}{\sigma^2} & 0 \\ 0 & 0 & -\frac{1}{2\sigma^4} \end{pmatrix}$$

となる。

$$\begin{aligned}\Sigma_{\theta} &= -\left(\sum_{i=1}^n \mathbf{E}\left[\frac{\partial^2 \log g(Y_i; \theta)}{\partial \theta \partial \theta'}\right]\right)^{-1} = -\left(\sum_{i=1}^n \begin{pmatrix} -\frac{1}{\sigma^2} & -\frac{X_i}{\sigma^2} & 0 \\ \frac{X_i}{\sigma^2} & \frac{X_i^2}{\sigma^2} & 0 \\ 0 & 0 & -\frac{1}{2\sigma^4} \end{pmatrix}\right)^{-1} \\ &= \begin{pmatrix} \frac{n}{\sigma^2} & \frac{\sum_{i=1}^n X_i}{\sigma^2} & 0 \\ \frac{\sum_{i=1}^n X_i}{\sigma^2} & \frac{\sum_{i=1}^n X_i^2}{\sigma^2} & 0 \\ 0 & 0 & \frac{n}{2\sigma^4} \end{pmatrix}^{-1} = \begin{pmatrix} n & \sum_{i=1}^n X_i & 0 \\ \sum_{i=1}^n X_i & \sum_{i=1}^n X_i^2 & 0 \\ 0 & 0 & \frac{2\sigma^4}{n} \end{pmatrix}^{-1}\end{aligned}$$

(*) 正方行列 A, B について, $\begin{pmatrix} A & 0 \\ 0 & B \end{pmatrix}^{-1} = \begin{pmatrix} A^{-1} & 0 \\ 0 & B^{-1} \end{pmatrix}$ となる。

したがって,

$$\begin{pmatrix} \hat{\alpha} \\ \hat{\beta} \end{pmatrix} \sim N\left(\begin{pmatrix} \alpha \\ \beta \end{pmatrix}, \sigma^2 \begin{pmatrix} n & \sum_{i=1}^n X_i \\ \sum_{i=1}^n X_i & \sum_{i=1}^n X_i^2 \end{pmatrix}^{-1}\right)$$

となる。

→ 最小二乗推定量の分布と同じ。

$$\sigma^2 \begin{pmatrix} n & \sum_{i=1}^n X_i \\ \sum_{i=1}^n X_i & \sum_{i=1}^n X_i^2 \end{pmatrix}^{-1} = \sigma^2 \begin{pmatrix} \frac{\sum_{i=1}^n X_i^2}{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2} & -\frac{\sum_{i=1}^n X_i}{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2} \\ -\frac{\sum_{i=1}^n X_i}{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2} & \frac{n}{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2} \end{pmatrix}$$

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

すなわち,

$$\hat{\alpha} \sim N\left(\alpha, \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}\right) \quad \hat{\beta} \sim N\left(\beta, \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2}\right)$$

となる。