

12 推定量の求め方

12.1 最小二乗法

- n 個のデータ (実現値) : $x_1, x_2, \dots, x_n$
 - 背後に対応する確率変数を仮定 : $X_1, X_2, \dots, X_n$
 - $E(X_i) = \mu, V(X_i) = \sigma^2$ を仮定
- 母数 (μ, σ^2) を推定する。

観測データ $x_1, x_2, \dots, x_n$ をもとにして, μ の最小二乗推定値を求める。

$$\min_{\mu} \sum_{i=1}^n (x_i - \mu)^2$$

μ の解を $\hat{\mu}$ とすると,

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

となり, $\hat{\mu} \equiv \bar{x}$ を得る。

すなわち,

$$\frac{d \sum_{i=1}^n (x_i - \mu)^2}{d\mu} = 0$$

を μ について解く。

μ の最小二乗推定量はデータ x_i を対応する確率変数 X_i で置き換えて,

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

となり, $\hat{\mu} \equiv \bar{X}$ を得る ($\hat{\mu}$ について, 推定値と推定量は同じ記号を使っている)。

以上を回帰分析に応用すると,

$$\min_{\alpha, \beta} \sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2$$

を解くことになる。

すなわち,

$$\begin{aligned} \frac{\partial \sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2}{\partial \alpha} &= 0 \\ \frac{\partial \sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2}{\partial \beta} &= 0 \end{aligned}$$

の連立方程式を α, β について解く。

12.2 最尤法

n 個の確率変数 $X_1, X_2, \dots, X_n$ は互いに独立で, 同じ確率分布 $f(x) \equiv f(x; \theta)$ とする。ただし, θ は母数で, 例えば, $\theta = (\mu, \sigma^2)$ である。

$X_1, X_2, \dots, X_n$ の結合分布は, 互いに独立なので,

$$f(x_1, x_2, \dots, x_n; \theta) \equiv \prod_{i=1}^n f(x_i; \theta)$$

と表される。

観測データ $x_1, x_2, \dots, x_n$ を与えたもとで, $\prod_{i=1}^n f(x_i; \theta)$ は θ の関数として表される。すなわち,

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

となる。

$l(\theta)$ を尤度関数と呼ぶ。

$$\max_{\theta} l(\theta)$$

となる θ を最尤推定値 $\hat{\theta} = \hat{\theta}(x_1, x_2, \dots, x_n)$ と呼ぶ。

データ $x_1, x_2, \dots, x_n$ を確率変数 $X_1, X_2, \dots, X_n$ で置き換えて, $\hat{\theta} = \hat{\theta}(X_1, X_2, \dots, X_n)$ を最尤推定量と呼ぶ。

$$\max_{\theta} \log l(\theta)$$

と

$$\max_{\theta} \log l(\theta)$$

の θ の解はともに同じものであることに注意。 $\log l(\theta)$ を対数尤度関数と呼ぶ。

最尤推定量の性質 : n が大きいとき,

$$\hat{\theta} \sim N(\theta, \sigma_{\theta}^2)$$

ただし,

$$\begin{aligned} \sigma_{\theta}^2 &= \frac{1}{\sum_{i=1}^n E \left[\left(\frac{d \log f(X_i; \theta)}{d\theta} \right)^2 \right]} \\ &= - \frac{1}{\sum_{i=1}^n E \left[\frac{d^2 \log f(X_i; \theta)}{d\theta^2} \right]} \end{aligned}$$

θ がベクトル ($k \times 1$) の場合, n が大きいとき,

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

ただし,

$$\begin{aligned}\Sigma_{\theta} &= \left(\sum_{i=1}^n E \left[\left(\frac{\partial \log f(X_i; \theta)}{\partial \theta} \right) \left(\frac{\partial \log f(X_i; \theta)}{\partial \theta} \right)' \right] \right)^{-1} \\ &= - \left(\sum_{i=1}^n E \left[\frac{\partial^2 \log f(X_i; \theta)}{\partial \theta \partial \theta'} \right] \right)^{-1}\end{aligned}$$

例 1: 正規母集団 $N(\mu, \sigma^2)$ からの標本値 $x_1, x_2, \dots, x_n$ を用いて,

- (1) σ^2 が既知のとき, μ の最尤推定値と最尤推定量
- (2) σ^2 が未知のとき, μ と σ^2 の最尤推定値と最尤推定量をそれぞれ求める。

【解】 $N(\mu, \sigma^2)$ の密度関数は,

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

となる。したがって, 互いに独立な $X_1, X_2, \dots, X_n$ の結合分布は,

$$\begin{aligned}f(x_1, x_2, \dots, x_n; \mu, \sigma^2) &\equiv \prod_{i=1}^n f(x_i; \mu, \sigma^2) \\ &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(x_i - \mu)^2\right) \\ &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right)\end{aligned}$$

となる。

- (1) σ^2 が既知のとき, 尤度関数 $l(\mu)$ は,

$$l(\mu) = (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right)$$

となる。

$l(\mu)$ を最大にする μ と $\log l(\mu)$ を最大にする μ は同じになる。

したがって, 対数尤度関数は,

$$\log l(\mu) = -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

となり,

$$\frac{d \log l(\mu)}{d\mu} = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0$$

となる μ を求める。 μ の解を $\hat{\mu}$ とすると, μ の最尤推定値は,

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i \equiv \bar{x}$$

を得る。

さらに, 観測値 $x_1, x_2, \dots, x_n$ をその確率変数 $X_1, X_2, \dots, X_n$ で置き換えて, μ の最尤推定量は,

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

となる。

$\hat{\mu}$ の分散を求めるために,

$$\log f(X_i; \mu) = -\frac{1}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} (X_i - \mu)^2$$

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

$$\left(\frac{d \log f(X_i; \mu)}{d\mu} \right)^2 = \frac{1}{\sigma^4} (X_i - \mu)^2$$

$$E \left[\left(\frac{d \log f(X_i; \mu)}{d\mu} \right)^2 \right] = \frac{1}{\sigma^4} E[(X_i - \mu)^2] = \frac{1}{\sigma^2}$$

と計算される。

最尤推定量の性質から, n が大きいとき,

$$\hat{\mu} \sim N(\mu, \sigma_{\mu}^2)$$

ただし,

$$\sigma_{\mu}^2 = \frac{1}{\sum_{i=1}^n E \left[\left(\frac{d \log f(X_i; \mu)}{d\mu} \right)^2 \right]} = \frac{\sigma^2}{n}$$

この場合は, n の大きさに関わらず, $\hat{\mu} \sim N(\mu, \sigma_{\mu}^2)$ が成り立つ。

- (2) σ^2 が未知のとき, μ と σ^2 の尤度関数は,

$$l(\mu, \sigma^2) = (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right)$$

となる。

対数尤度関数は,

$$\begin{aligned}\log l(\mu, \sigma^2) &= -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log \sigma^2 \\ &\quad - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\end{aligned}$$

と表される。

μ と σ^2 について, 最大化するためには,

$$\begin{aligned}\frac{\partial \log l(\mu, \sigma^2)}{\partial \mu} &= \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0 \\ \frac{\partial \log l(\mu, \sigma^2)}{\partial \sigma^2} &= -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 = 0\end{aligned}$$

の連立方程式を解く。

μ, σ^2 の解を $\hat{\mu}, \hat{\sigma}^2$ とすると, 最尤推定値は,

$$\begin{aligned}\hat{\mu} &= \frac{1}{n} \sum_{i=1}^n x_i \equiv \bar{x} \\ \hat{\sigma}^2 &= \frac{1}{n} \sum_{i=1}^n (x_i - \hat{\mu})^2 \equiv \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\end{aligned}$$

となる。

観測値 $x_1, x_2, \dots, x_n$ をその確率変数 $X_1, X_2, \dots, X_n$ で置き換えて, μ, σ^2 の最尤推定量は,

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

となる。

σ^2 の最尤推定量 $\hat{\sigma}^2$ は, σ^2 の不偏推定量 $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ とは異なることに注意。

$\theta = (\mu, \sigma^2)'$ とする。 n が大きいとき,

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

ただし,

$$\Sigma_\theta = -\left(\sum_{i=1}^n \mathbb{E} \left[\frac{\partial^2 \log f(X_i; \theta)}{\partial \theta \partial \theta'} \right] \right)^{-1}$$

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

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

$$\begin{aligned}\frac{\partial^2 \log f(X_i; \theta)}{\partial \theta \partial \theta'} &= \begin{pmatrix} \frac{\partial^2 \log f(X_i; \theta)}{\partial \mu^2} & \frac{\partial^2 \log f(X_i; \theta)}{\partial \mu \partial \sigma^2} \\ \frac{\partial^2 \log f(X_i; \theta)}{\partial \sigma^2 \partial \mu} & \frac{\partial^2 \log f(X_i; \theta)}{\partial (\sigma^2)^2} \end{pmatrix} \\ &= \begin{pmatrix} -\frac{1}{\sigma^2} & -\frac{1}{\sigma^4} (X_i - \mu) \\ -\frac{1}{\sigma^4} (X_i - \mu) & \frac{1}{2\sigma^4} - \frac{1}{\sigma^6} (X_i - \mu)^2 \end{pmatrix}\end{aligned}$$

$$\begin{aligned}\mathbb{E} \left[\frac{\partial^2 \log f(X_i; \theta)}{\partial \theta \partial \theta'} \right] &= \begin{pmatrix} -\frac{1}{\sigma^2} & -\frac{1}{\sigma^4} \mathbb{E}(X_i - \mu) \\ -\frac{1}{\sigma^4} \mathbb{E}(X_i - \mu) & \frac{1}{2\sigma^4} - \frac{1}{\sigma^6} \mathbb{E}[(X_i - \mu)^2] \end{pmatrix} \\ &= \begin{pmatrix} -\frac{1}{\sigma^2} & 0 \\ 0 & -\frac{1}{2\sigma^4} \end{pmatrix}\end{aligned}$$

よって,

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

まとめると, μ, σ^2 の最尤推定量 $\hat{\mu} = (1/n) \sum_{i=1}^n X_i$, $\hat{\sigma}^2 = (1/n) \sum_{i=1}^n (X_i - \bar{X})^2$ の分布は, n が大きいとき,

$$\begin{pmatrix} \hat{\mu} \\ \hat{\sigma}^2 \end{pmatrix} \sim N \left(\begin{pmatrix} \mu \\ \sigma^2 \end{pmatrix}, \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^4}{n} \end{pmatrix} \right)$$

となる。

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、

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

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。

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

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

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

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

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

したがって、

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

を得る。

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 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、

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

となる。

$\log l(\lambda)$ を最大にする p 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。

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

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

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

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

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

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

したがって,

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

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,

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

となる。

$\log l(\lambda)$ を最大にする p 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, 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。

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

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

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

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

したがって,

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

を得る。

12.2.1 変数変換

確率変数 X の密度関数を $f(x)$ 、分布関数を $F(x) \equiv P(X < x)$ とする。 $Y = aX + b$ とするとき、 Y の密度関数 $g(y)$ を求める。

Y の分布関数を $G(y)$ として、次のように変形できる。

$$\begin{aligned} G(y) &= P(Y < y) = P(aX + b < y) \\ &= \begin{cases} P\left(X < \frac{y-b}{a}\right), & a > 0 \text{ のとき} \\ P\left(X > \frac{y-b}{a}\right), & a < 0 \text{ のとき} \end{cases} \\ &= \begin{cases} P\left(X < \frac{y-b}{a}\right), & a > 0 \text{ のとき} \\ 1 - P\left(X < \frac{y-b}{a}\right), & a < 0 \text{ のとき} \end{cases} \\ &= \begin{cases} F\left(\frac{y-b}{a}\right), & a > 0 \text{ のとき} \\ 1 - F\left(\frac{y-b}{a}\right), & a < 0 \text{ のとき} \end{cases} \end{aligned}$$

分布関数と密度関数との関係は、

$$\frac{dF(x)}{dx} = f(x) \quad \frac{dG(x)}{dx} = g(x)$$

であるので、 Y の密度関数は、

$$\begin{aligned} g(y) &= \frac{dG(y)}{dy} \\ &= \begin{cases} \frac{1}{a} f\left(\frac{y-b}{a}\right), & a > 0 \text{ のとき} \\ -\frac{1}{a} f\left(\frac{y-b}{a}\right), & a < 0 \text{ のとき} \end{cases} \\ &= \left| \frac{1}{a} \right| f\left(\frac{y-b}{a}\right) \end{aligned}$$

と表される。

一般に、確率変数 X の密度関数を $f(x)$ とする。単調変換 $X = h(Y)$ とするとき、 Y の密度関数 $g(y)$ は、

$$g(y) = |h'(y)| f(h(y))$$

となる。

12.2.2 回帰分析への応用

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。

u_i の密度関数は、

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

となる。

Y_i の密度関数 $g(Y_i)$ は、

$$g(Y_i) = |h'(Y_i)| f(h(Y_i))$$

によって求められる。

この場合、 $h(Y_i) = Y_i - \alpha - \beta X_i$ なので、 $h'(Y_i) = 1$ となる。

したがって、 Y_i の密度関数は、

$$\begin{aligned} g(Y_i) &= |h'(Y_i)| f(h(Y_i)) \\ &= f(h(Y_i)) \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2} (Y_i - \alpha - \beta X_i)^2\right) \end{aligned}$$

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、

$$\begin{aligned} g(Y_1, Y_2, \dots, Y_n) &= \prod_{i=1}^n g(Y_i) \\ &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2\right) \end{aligned}$$

となる。これは α, β, σ^2 の関数となっている。

よって、尤度関数は、

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

となる。

対数尤度関数は、

$$\begin{aligned} \log l(\alpha, \beta, \sigma^2) &= -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) \\ &\quad - \frac{1}{2\sigma^2} \sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2 \end{aligned}$$

となる。

$\log l(\alpha, \beta, \sigma^2)$ を最大にするために,

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

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

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

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,

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

$$\hat{\alpha} = \bar{Y} - \hat{\beta} \bar{X}$$

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。

$\hat{\theta} = (\hat{\alpha}, \hat{\beta}, \hat{\sigma}^2)'$, $\theta = (\alpha, \beta, \sigma^2)'$ とする。 n が大きいとき,

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

ただし,

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

Y_i の密度関数 $g(Y_i; \theta)$ の対数は,

$$\begin{aligned} \log g(Y_i; \theta) &= -\frac{1}{2} \log(2\pi) - \frac{1}{2} \log(\sigma^2) \\ &\quad - \frac{1}{2\sigma^2} (Y_i - \alpha - \beta X_i)^2 \end{aligned}$$

となる。

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

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

$$\frac{\partial^2 \log g(Y_i; \theta)}{\partial \theta \partial \theta'}$$

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

$$= \begin{pmatrix} -\frac{1}{\sigma^2} & -\frac{X_i}{\sigma^2} & -\frac{u_i}{\sigma^4} \\ -\frac{X_i}{\sigma^2} & -\frac{X_i^2}{\sigma^2} & -\frac{X_i u_i}{\sigma^4} \\ -\frac{u_i}{\sigma^4} & -\frac{X_i u_i}{\sigma^4} & \frac{1}{2\sigma^4} - \frac{u_i^2}{\sigma^6} \end{pmatrix}$$

ただし, $u_i = Y_i - \alpha - \beta X_i$

期待値をとると,

$$\begin{aligned} E \left(\frac{\partial^2 \log g(Y_i; \theta)}{\partial \theta \partial \theta'} \right) &= E \begin{pmatrix} -\frac{1}{\sigma^2} & -\frac{X_i}{\sigma^2} & -\frac{u_i}{\sigma^4} \\ -\frac{X_i}{\sigma^2} & -\frac{X_i^2}{\sigma^2} & -\frac{X_i u_i}{\sigma^4} \\ -\frac{u_i}{\sigma^4} & -\frac{X_i u_i}{\sigma^4} & \frac{1}{2\sigma^4} - \frac{u_i^2}{\sigma^6} \end{pmatrix} \\ &= \begin{pmatrix} -\frac{1}{\sigma^2} & -\frac{X_i}{\sigma^2} & 0 \\ -\frac{X_i}{\sigma^2} & -\frac{X_i^2}{\sigma^2} & 0 \\ 0 & 0 & -\frac{1}{2\sigma^4} \end{pmatrix} \end{aligned}$$

となる。

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

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。

12.2.3 誤差項に系列相関がある場合

回帰モデル

$$\begin{aligned} Y_i &= \alpha + \beta X_i + u_i \\ u_i &= \rho u_{i-1} + \epsilon_i \quad i = 2, 3, \dots, n \end{aligned}$$

$\epsilon_2, \epsilon_3, \dots, \epsilon_n$ は互いに独立で、すべての i について $\epsilon_i \sim N(0, \sigma^2)$ を仮定する。

u_i を消去すると、

$$(Y_i - \alpha - \beta X_i) = \rho(Y_{i-1} - \alpha - \beta X_{i-1}) + \epsilon_i$$

または

$$(Y_i - \rho Y_{i-1}) = \alpha(1 - \rho) + \beta(X_i - \rho X_{i-1}) + \epsilon_i$$

と書き直すことが出来る。

$\theta = (\alpha, \beta, \sigma^2, \rho)$ とする。

$$\begin{aligned} \log f(Y_i; \theta) &= -\frac{1}{2} \log(2\pi\sigma^2) \\ &\quad - \frac{1}{2\sigma^2} \left((Y_i - \rho Y_{i-1}) - \alpha(1 - \rho) - \beta(X_i - \rho X_{i-1}) \right)^2 \end{aligned}$$

尤度関数は、

$$\begin{aligned} \log l(\theta) &= \sum_{i=2}^n \log f(Y_i; \theta) = -\frac{n-1}{2} \log(2\pi) - \frac{n-1}{2} \log(\sigma^2) \\ &\quad - \frac{1}{2\sigma^2} \sum_{i=2}^n \left((Y_i - \rho Y_{i-1}) - \alpha(1 - \rho) - \beta(X_i - \rho X_{i-1}) \right)^2 \end{aligned}$$

となる。

尤度関数をそれぞれ $\alpha, \beta, \sigma^2, \rho$ について微分し、ゼロとおく。

$$\begin{aligned} \frac{\partial \log l(\theta)}{\partial \alpha} &= \frac{1-\rho}{\sigma^2} \sum_{i=2}^n \left((Y_i - \rho Y_{i-1}) \right. \\ &\quad \left. - \alpha(1 - \rho) - \beta(X_i - \rho X_{i-1}) \right) = 0 \end{aligned}$$

$$\begin{aligned} \frac{\partial \log l(\theta)}{\partial \beta} &= \frac{1}{\sigma^2} \sum_{i=2}^n (X_i - \rho X_{i-1}) \left((Y_i - \rho Y_{i-1}) \right. \\ &\quad \left. - \alpha(1 - \rho) - \beta(X_i - \rho X_{i-1}) \right) = 0 \end{aligned}$$

$$\begin{aligned} \frac{\partial \log l(\theta)}{\partial \sigma^2} &= -\frac{n-1}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=2}^n \left((Y_i - \rho Y_{i-1}) \right. \\ &\quad \left. - \alpha(1 - \rho) - \beta(X_i - \rho X_{i-1}) \right)^2 = 0 \end{aligned}$$

$$\begin{aligned} \frac{\partial \log l(\theta)}{\partial \rho} &= \frac{1}{\sigma^2} \sum_{i=2}^n (Y_{i-1} - \alpha - \beta X_{i-1}) \left((Y_i - \alpha - \beta X_i) \right. \\ &\quad \left. - \rho(Y_{i-1} - \alpha - \beta X_{i-1}) \right) = 0 \end{aligned}$$

$(Y_i - \alpha - \beta X_i) - \rho(Y_{i-1} - \alpha - \beta X_{i-1})$ は $(Y_i - \rho Y_{i-1}) - \alpha(1 - \rho) - \beta(X_i - \rho X_{i-1})$ を書き直したものの。

4 つの連立方程式を解いて、最尤推定量 $\hat{\alpha}, \hat{\beta}, \hat{\sigma}^2, \hat{\rho}$ が得られる。

→ 下記のように収束計算によって求める。

(i) 初期段階では、 $\hat{\rho} = 0$ とする。

(ii) $X_i^* = X_i - \hat{\rho} X_{i-1}$

$$Y_i^* = Y_i - \hat{\rho} Y_{i-1}$$

(iii) $\begin{pmatrix} \hat{\alpha} \\ \hat{\beta} \end{pmatrix} = \begin{pmatrix} n-1 & \sum_{i=2}^n X_i^* \\ \sum_{i=2}^n X_i^* & \sum_{i=2}^n X_i^{*2} \end{pmatrix}^{-1} \begin{pmatrix} \sum_{i=2}^n Y_i^* \\ \sum_{i=2}^n X_i^* Y_i^* \end{pmatrix}$

$$(iv) \hat{\alpha} = \frac{\hat{\alpha}}{1 - \hat{\rho}}$$

$$(v) \hat{u}_i = Y_i - \hat{\alpha} - \hat{\beta} X_i$$

$$(vi) \hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=2}^n (\hat{u}_i - \hat{\rho} \hat{u}_{i-1})^2$$

$$(vii) \hat{\rho} = \frac{\sum_{i=2}^n \hat{u}_i \hat{u}_{i-1}}{\sum_{i=2}^n \hat{u}_{i-1}^2}$$

(viii) ステップ (ii) ~ (vii) を、収束するまで繰り返し計算する。

12.3 尤度比検定

n 個の確率変数 $X_1, X_2, \dots, X_n$ は互いに独立で、同じ確率分布 $f(x) \equiv f(x; \theta)$ とする。

尤度関数は、

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