

(2)  $\sigma^2$  が未知のとき,  $\mu$  と  $\sigma^2$  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)  $\sigma^2$  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  $\mu$  と  $\log l(\mu)$  を最大にする  $\mu$  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  $\mu$  を求める。 $\mu$  の解を  $\hat{\mu}$  とすると， $\mu$  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、 $\mu$  の最尤推定量は、

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

となる。

$\widehat{\mu}$  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、

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

ただし、

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

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

(2)  $\sigma^2$  が未知のとき、 $\mu$  と  $\sigma^2$  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。

$\mu$  と  $\sigma^2$  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。

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

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

$$\widehat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \widehat{\mu})^2 \equiv \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

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,  $\mu, \sigma^2$  の最尤推定量は,

$$\widehat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i \equiv \bar{X}$$
$$\widehat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \widehat{\mu})^2 \equiv \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

となる。

$\sigma^2$  の最尤推定量  $\widehat{\sigma}^2$  は,  $\sigma^2$  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,

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

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

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

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、

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

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

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。

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

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

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

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

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

したがって,

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

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  $\lambda$  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,

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

となる。

$\log l(\lambda)$  を最大にする  $\lambda$  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  $\widehat{\lambda}$  は、

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

となる。

$\widehat{\lambda}$  の分布を求める。

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

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

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

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

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

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

したがって,

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

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、

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

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、 $\lambda$  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  $\widehat{\lambda}$  は、

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

となる。

$\widehat{\lambda}$  の分布を求める。

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

したがって、

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

を得る。

### 6.2.1 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。

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

$$= \begin{cases} F\left(\frac{y-b}{a}\right), & a > 0 \text{ のとき} \\ 1 - F\left(\frac{y-b}{a}\right), & a < 0 \text{ のとき} \end{cases}$$

分布関数と密度関数との関係は、

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

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。

## 6.2.2 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  $\alpha, \beta, \sigma^2$  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,

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

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

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

の連立方程式を解く。

上2つの式は  $\sigma^2$  に依存していない。 $\alpha$ ,  $\beta$  の最尤推定量は最小二乗推定量と同じになる。

すなわち,

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

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

$\sigma^2$  の最尤推定量は,

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

となり,  $s^2$  とは異なる。

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

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

ただし,

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

$Y_i$  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。

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

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

ただし,  $u_i = Y_i - \alpha - \beta X_i$

期待値をとると,

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

となる。

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

$$\begin{aligned}
&= \left( \begin{array}{ccc} \frac{n}{\sigma^2} & \frac{\sum_{i=1}^n X_i}{\sigma^2} & 0 \\ \frac{\sum_{i=1}^n X_i}{\sigma^2} & \frac{\sum_{i=1}^n X_i^2}{\sigma^2} & 0 \\ 0 & 0 & \frac{n}{2\sigma^4} \end{array} \right)^{-1} \\
&= \left( \begin{array}{ccc} \sigma^2 \left( \begin{array}{cc} n & \sum_{i=1}^n X_i \\ \sum_{i=1}^n X_i & \sum_{i=1}^n X_i^2 \end{array} \right) & 0 \\ 0 & \frac{2\sigma^4}{n} \end{array} \right)
\end{aligned}$$

したがって,

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

となる。

→ 最小二乗推定量の分布と同じ。

### 6.2.3 誤差項に系列相関がある場合

回帰モデル

$$Y_i = \alpha + \beta X_i + u_i$$

$$u_i = \rho u_{i-1} + \epsilon_i \quad i = 2, 3, \dots, n$$

$\epsilon_2, \epsilon_3, \dots, \epsilon_n$  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。

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

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

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

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

$(Y_i - \alpha - \beta X_i) - \rho(Y_{i-1} - \alpha - \beta X_{i-1})$  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、 $\widehat{\rho} = 0$  とする。

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

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

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

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

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

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

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

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

### 6.3 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，

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

となる。

$\theta$  の制約つき最尤推定量を  $\tilde{\theta}$ ，制約無し最尤推定量を  $\hat{\theta}$  とする。

制約の数を  $G$  個とする。

$\frac{l(\tilde{\theta})}{l(\hat{\theta})}$  を尤度比と呼ぶ

検定方法 1: 尤度比がある値より小さいときに、帰無仮説を棄却する。すなわち、

$$\frac{l(\tilde{\theta})}{l(\hat{\theta})} < c$$

となるときに、帰無仮説を棄却する。この場合、 $c$  を次のようにして求める必要がある。

$$\int \cdots \int \prod_{i=1}^n f(x_i; \tilde{\theta}) dx_1 \cdots dx_n = \alpha$$

ただし、 $\alpha$  は有意水準（帰無仮説が正しいときに、帰無仮説を棄却する確率）を表す。

検定方法 2 (大標本検定): または、 $n \rightarrow \infty$  のとき、

$$-2 \log \frac{l(\tilde{\theta})}{l(\hat{\theta})} \rightarrow \chi^2(G)$$

となる。

この検定を尤度比検定と呼ぶ。

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,  $\sigma^2$  が既知のとき, 帰無仮説  $H_0: \mu = \mu_0$ ,  $H_1: \mu \neq \mu_0$  の尤度比検定を行う。

$\sigma^2$  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  $\mu$  と  $\log l(\mu)$  を最大にする  $\mu$  は同じになる。

$\mu$  の最尤推定量は,

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

となる。

尤度比検定統計量は,

$$\begin{aligned}\frac{l(\mu_0)}{l(\bar{X})} &= \frac{\exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - \mu_0)^2\right)}{\exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - \bar{X})^2\right)} \\ &= \exp\left(-\frac{1}{2\sigma^2/n} (\bar{X} - \mu_0)^2\right) < c\end{aligned}$$

となる  $c$  を求める。

$H_0$  が正しいときに,  $\sqrt{n}(\bar{X} - \mu_0)/\sigma \sim N(0, 1)$  となるので,

$$P\left(\left|\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}}\right| > z_{\alpha/2}\right) = \alpha$$

すなわち,

$$P\left(\exp\left(-\frac{1}{2\sigma^2/n} (\bar{X} - \mu_0)^2\right) < \exp\left(-\frac{1}{2} z_{\alpha/2}^2\right)\right) = \alpha$$

と変形できる。したがって,

$$c = \exp\left(-\frac{1}{2}z_{\alpha/2}^2\right)$$

とすればよい。

**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,

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

となる。

$p$  の最尤推定量  $\hat{p}$  は,

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

である。

次の仮説検定を考える。

$$H_0 : p = p_0 \qquad H_1 : p \neq p_0$$

→ 制約数は 1 つ。 ( $G = 1$ )

尤度比は,

$$\frac{l(p_0)}{l(\hat{p})} = \frac{\prod_{i=1}^n p_0^{X_i} (1 - p_0)^{1-X_i}}{\prod_{i=1}^n \hat{p}^{X_i} (1 - \hat{p})^{1-X_i}}$$

したがって,  $n \rightarrow \infty$  のとき,

$$-2 \log \frac{l(p_0)}{l(\hat{p})} = -2 \log \frac{p_0}{\hat{p}} \sum_{i=1}^n X_i - 2 \log \frac{1 - p_0}{1 - \hat{p}} \sum_{i=1}^n (1 - X_i)$$

→  $\chi^2(1)$

$\chi^2(1)$  分布の上側 100  $\alpha\%$  点を  $\chi_\alpha^2(1)$  とするとき,

$$-2 \log \frac{l(p_0)}{l(\hat{p})} > \chi_\alpha^2(1)$$

のとき, 帰無仮説  $H_0 : p = p_0$  を棄却する。

**例 3 :** 回帰モデル

$$Y_i = \beta_1 X_{1i} + \beta_2 X_{2i} + \cdots + \beta_k X_{ki} + u_i$$

$$u_i \sim N(0, \sigma^2) \quad i = 1, 2, \dots, n$$

について,  $\beta_1, \dots, \beta_k$  に関する仮説の尤度比検定を行う。

例えば,

$$H_0 : \beta_1 = 0$$

$$H_0 : \beta_1 + \beta_2 = 1$$

$$H_0 : \beta_1 = \beta_2 = \beta_3 = 0$$

などのような仮説検定

$\theta = (\beta_1, \dots, \beta_k, \sigma^2)$  とする。

尤度関数は,

$$\begin{aligned} l(\theta) &= \prod_{i=1}^n f(Y_i; \theta) \\ &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (Y_i - \beta_1 X_{1i} - \dots - \beta_k X_{ki})^2\right) \end{aligned}$$

となる。

$H_0$  の制約つき最尤推定量を  $\tilde{\theta} = (\tilde{\beta}_1, \dots, \tilde{\beta}_k, \tilde{\sigma}^2)$  とする。この仮説に含まれる制約数を  $G$  とする。

制約なし最尤推定量を  $\widehat{\theta} = (\widehat{\beta}_1, \dots, \widehat{\beta}_k, \widehat{\sigma}^2)$  とする。

尤度比

$$\begin{aligned}
 \frac{l(\widetilde{\theta})}{l(\widehat{\theta})} &= \frac{(2\pi\widetilde{\sigma}^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\widetilde{\sigma}^2} \sum_{i=1}^n (Y_i - \widetilde{\beta}_1 X_{1i} - \dots - \widetilde{\beta}_k X_{ki})^2\right)}{(2\pi\widehat{\sigma}^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\widehat{\sigma}^2} \sum_{i=1}^n (Y_i - \widehat{\beta}_1 X_{1i} - \dots - \widehat{\beta}_k X_{ki})^2\right)} \\
 &= \frac{(\widetilde{\sigma}^2)^{-\frac{n}{2}} \exp\left(-\frac{n-G}{2}\right)}{(\widehat{\sigma}^2)^{-\frac{n}{2}} \exp\left(-\frac{n-k}{2}\right)} \\
 &= \left( \frac{\frac{1}{n-G} \sum_{i=1}^n \widetilde{u}_i^2}{\frac{1}{n-k} \sum_{i=1}^n \widehat{u}_i^2} \right)^{-n/2} \exp\left(-\frac{k-G}{2}\right) \\
 &= \exp\left(-\frac{k-G}{2}\right) \left(\frac{n-k}{n-G}\right)^{-n/2} \left(\frac{\sum_{i=1}^n \widetilde{u}_i^2}{\sum_{i=1}^n \widehat{u}_i^2}\right)^{-n/2}
 \end{aligned}$$

$$\begin{aligned}
&= \exp\left(-\frac{k-G}{2}\right) \left(\frac{n-k}{n-G}\right)^{-n/2} \\
&\quad \times \left(1 + \frac{\sum_{i=1}^n \tilde{u}_i^2 - \sum_{i=1}^n \widehat{u}_i^2}{\sum_{i=1}^n \tilde{u}_i^2}\right)^{-n/2} \\
&= \exp\left(-\frac{k-G}{2}\right) \left(\frac{n-k}{n-G}\right)^{-n/2} \\
&\quad \times \left(1 + \frac{G}{n-k} \frac{(\sum_{i=1}^n \tilde{u}_i^2 - \sum_{i=1}^n \widehat{u}_i^2)/G}{\sum_{i=1}^n \tilde{u}_i^2/(n-k)}\right)^{-n/2} \\
&< c
\end{aligned}$$

のとき仮説を棄却する。

$$\frac{(\sum_{i=1}^n \tilde{u}_i^2 - \sum_{i=1}^n \widehat{u}_i^2)/G}{\sum_{i=1}^n \tilde{u}_i^2/(n-k)} \sim F(G, n-k)$$

を利用すると  $c$  が求まる。

ただし、途中で以下を利用

$$\begin{aligned}\tilde{\sigma}^2 &= \frac{1}{n-G} \sum_{i=1}^n (Y_i - \tilde{\beta}_1 X_{1i} - \cdots - \tilde{\beta}_k X_{ki})^2 \\ &= \frac{1}{n-G} \sum_{i=1}^n \tilde{u}_i^2\end{aligned}$$

$$\begin{aligned}\hat{\sigma}^2 &= \frac{1}{n-k} \sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i} - \cdots - \hat{\beta}_k X_{ki})^2 \\ &= \frac{1}{n-k} \sum_{i=1}^n \hat{u}_i^2\end{aligned}$$

近似的には,

$$-2 \log \frac{l(\tilde{\theta})}{l(\hat{\theta})} = -2 \log \frac{(\tilde{\sigma}^2)^{-\frac{n}{2}} \exp\left(-\frac{n-G}{2}\right)}{(\hat{\sigma}^2)^{-\frac{n}{2}} \exp\left(-\frac{n-k}{2}\right)}$$

$$\begin{aligned}
 &= n \log\left(\frac{\tilde{\sigma}^2}{\sigma^2}\right) + (k - G) \\
 &\rightarrow \chi^2(G)
 \end{aligned}$$

例 4： 回帰モデル

$$Y_i = \alpha + \beta X_i + u_i$$

$$u_i = \rho u_{i-1} + \epsilon_i$$

$$\epsilon_i \sim N(0, \sigma^2) \quad i = 2, 3, \dots, n$$

について、 $H_0: \rho = 0$ ,  $H_1: \rho \neq 0$  の尤度比検定を行う。

$\theta = (\alpha, \beta, \sigma^2, \rho)$  とする。対数尤度関数は、

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

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

となる。

対数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。4本の連立方程式を解いて、制約なし最尤推定量  $\hat{\theta} = (\hat{\alpha}, \hat{\beta}, \hat{\sigma}^2, \hat{\rho})$  が得られる。

$\rho = 0$  と制約をおく。 $\theta = (\alpha, \beta, \sigma^2, 0)$  とする。対数尤度関数は、

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

となる。

上記の対数尤度関数をそれぞれ  $\alpha$ ,  $\beta$ ,  $\sigma^2$  について微分し、ゼロとおく。3本の連立方程式を解いて、 $\rho = 0$  の制約付き最尤推定量  $\tilde{\theta} = (\tilde{\alpha}, \tilde{\beta}, \tilde{\sigma}^2, 0)$  が得られる。

すなわち,

$$\frac{\max_{\alpha, \beta, \sigma^2} l(\alpha, \beta, \sigma^2, 0)}{\max_{\alpha, \beta, \sigma^2, \rho} l(\alpha, \beta, \sigma^2, \rho)} = \frac{l(\tilde{\alpha}, \tilde{\beta}, \tilde{\sigma}^2, 0)}{l(\hat{\alpha}, \hat{\beta}, \hat{\sigma}^2, \hat{\rho})} = \frac{l(\tilde{\theta})}{l(\hat{\theta})}$$

$\log l(\hat{\theta})$  は,  $\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=2}^n \left( (Y_i - \hat{\rho}Y_{i-1}) - \hat{\alpha}(1 - \hat{\rho}) - \hat{\beta}(X_i - \hat{\rho}X_{i-1}) \right)^2$  に注意して,

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

となる。

同様に,  $\log l(\tilde{\theta})$  は,  $\tilde{\sigma}^2 = \frac{1}{n-1} \sum_{i=2}^n (Y_i - \tilde{\alpha} - \tilde{\beta}X_i)^2$  に注意して,

$$\log l(\tilde{\theta}) = -\frac{n-1}{2} \log(2\pi) - \frac{n-1}{2} \log(\tilde{\sigma}^2)$$

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

となる。

したがって、尤度比検定統計量

$$-2 \log \frac{l(\tilde{\theta})}{l(\hat{\theta})} = (n-1) \log \frac{\tilde{\sigma}^2}{\hat{\sigma}^2}$$

は、 $n$ が大きくなると、 $\chi^2(1)$  分布に近づく。