

4 系列相関： DW について

4.1 DW について

最小自乗法の仮定の一つに、「攪乱項 u_1, u_2, \dots, u_n はそれぞれ独立に分布する」というものがあつた。ダービン・ワトソン比 (DW) とは、誤差項の系列相関、すなわち、 u_i と u_{i-1} との間の相関の有無を検定するために考案された。

⇒ 時系列データのときのみ有効

u_1, u_2, \dots, u_n の系列について、それぞれの符号が、 $+++-----++----++$ のように、プラスが連続で続いた後で、マイナスが連続で続くというような場合、 u_1, u_2, \dots, u_n は正の系列相関があると言う。また、 $+ - + - + - + - +$ のように交互にプラス、マイナスになる場合、 u_1, u_2, \dots, u_n 負の系列相関があると言う。

特徴： u_1, u_2, \dots, u_i から u_{i+1} の符号が予想できる。⇒ 「 u_1, u_2, \dots, u_n はそれぞれ独立に分布する」という仮定に反する。

すなわち、ダービン・ワトソン比とは、回帰式が

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

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

のときに、 $H_0: \rho = 0, H_1: \rho \neq 0$ の検定である。ただし、 $\epsilon_1, \epsilon_2, \dots, \epsilon_n$ は互いに独立とする。

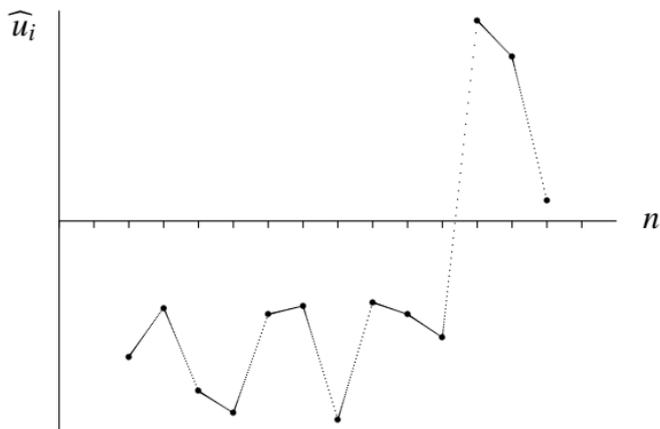


図 4： 正の系列相関

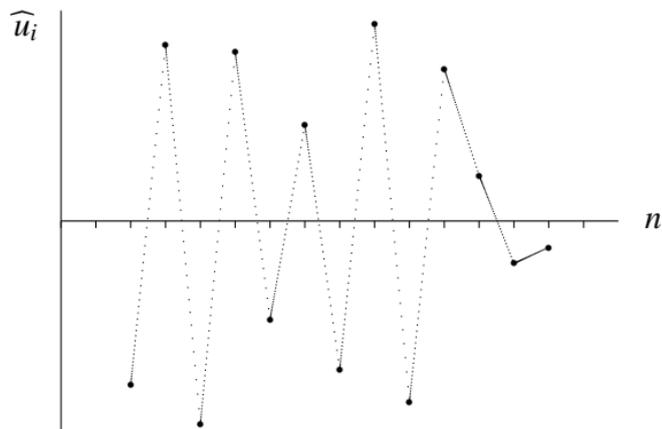


図 5： 負の系列相関

ダービン・ワトソン比の定義は次の通りである。

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

DW は近似的に、次のように表される。

$$\begin{aligned} DW &= \frac{\sum_{i=2}^n (\widehat{u}_i - \widehat{u}_{i-1})^2}{\sum_{i=1}^n \widehat{u}_i^2} = \frac{\sum_{i=2}^n \widehat{u}_i^2 - 2 \sum_{i=2}^n \widehat{u}_i \widehat{u}_{i-1} + \sum_{i=2}^n \widehat{u}_{i-1}^2}{\sum_{i=1}^n \widehat{u}_i^2} \\ &= \frac{2 \sum_{i=1}^n \widehat{u}_i^2 - (\widehat{u}_1^2 + \widehat{u}_n^2)}{\sum_{i=1}^n \widehat{u}_i^2} - 2 \frac{\sum_{i=2}^n \widehat{u}_i \widehat{u}_{i-1}}{\sum_{i=1}^n \widehat{u}_i^2} \approx 2(1 - \widehat{\rho}), \end{aligned}$$

以下の2つの近似が用いられる。

$$\begin{aligned} \frac{\widehat{u}_1^2 + \widehat{u}_n^2}{\sum_{i=1}^n \widehat{u}_i^2} &\approx 0, \\ \frac{\sum_{i=2}^n \widehat{u}_i \widehat{u}_{i-1}}{\sum_{i=1}^n \widehat{u}_i^2} &= \frac{\sum_{i=2}^n \widehat{u}_i \widehat{u}_{i-1}}{\sum_{i=2}^n \widehat{u}_{i-1}^2 + \widehat{u}_n^2} \approx \frac{\sum_{i=2}^n \widehat{u}_i \widehat{u}_{i-1}}{\sum_{i=2}^n \widehat{u}_{i-1}^2} = \widehat{\rho}, \end{aligned}$$

すなわち、 $\widehat{\rho}$ は \widehat{u}_i と \widehat{u}_{i-1} の回帰係数である。 $u_i = \rho u_{i-1} + \epsilon_i$ において、 u_i, u_{i-1} の代わりに $\widehat{u}_i, \widehat{u}_{i-1}$ に置き換えて、 ρ の推定値 $\widehat{\rho}$ を求める。

1. DW の値が 2 前後のとき，系列相関なし ($\hat{\rho} = 0$ のとき， $DW \approx 2$)。
2. DW が 2 より十分に小さいとき，正の系列相関と判定される。
3. DW が 2 より十分に大きいとき，負の系列相関と判定される。

正確な判定には，データ数 n とパラメータ数 k に依存する。表 1 を参照せよ。
 k' は定数項を除くパラメータ数を表すものとする。

See <http://www.stanford.edu/~clint/bench/dwcrit.htm> for the DW table.

Table 1: ダービン・ワトソン統計量の 5% 点の上限と下限

n	$k' = 1$		$k' = 2$		$k' = 3$		$k' = 4$		$k' = 5$		$k' = 6$		$k' = 7$		$k' = 8$		$k' = 9$		$k' = 10$		k'	
	dl	du	dl	du		dl																
6	0.610	1.400	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—
7	0.700	1.356	0.467	1.896	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—
8	0.763	1.332	0.559	1.777	0.367	2.287	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—
9	0.824	1.320	0.629	1.699	0.455	2.128	0.296	2.588	—	—	—	—	—	—	—	—	—	—	—	—	—	—
10	0.879	1.320	0.697	1.641	0.525	2.016	0.376	2.414	0.243	2.822	—	—	—	—	—	—	—	—	—	—	—	—
11	0.927	1.324	0.758	1.604	0.595	1.928	0.444	2.283	0.315	2.645	0.203	3.004	—	—	—	—	—	—	—	—	—	—
12	0.971	1.331	0.812	1.579	0.658	1.864	0.512	2.177	0.380	2.506	0.268	2.832	0.171	3.149	—	—	—	—	—	—	—	—
13	1.010	1.340	0.861	1.562	0.715	1.816	0.574	2.094	0.444	2.390	0.328	2.692	0.230	2.985	0.147	3.266	—	—	—	—	—	—
14	1.045	1.350	0.905	1.551	0.767	1.779	0.632	2.030	0.505	2.296	0.389	2.572	0.286	2.848	0.200	3.111	0.127	3.360	—	—	—	—
15	1.077	1.361	0.946	1.543	0.814	1.750	0.685	1.977	0.562	2.220	0.447	2.471	0.343	2.727	0.251	2.979	0.175	3.216	0.111	3.438	—	—
16	1.106	1.371	0.982	1.539	0.857	1.728	0.734	1.935	0.615	2.157	0.502	2.388	0.398	2.624	0.304	2.860	0.222	3.090	0.155	3.304	0.09	—
17	1.133	1.381	1.015	1.536	0.897	1.710	0.779	1.900	0.664	2.104	0.554	2.318	0.451	2.537	0.356	2.757	0.272	2.975	0.198	3.184	0.13	—
18	1.158	1.391	1.046	1.535	0.933	1.696	0.820	1.872	0.710	2.060	0.603	2.257	0.502	2.461	0.407	2.668	0.321	2.873	0.244	3.073	0.17	—
19	1.180	1.401	1.074	1.536	0.967	1.685	0.859	1.848	0.752	2.023	0.649	2.206	0.549	2.396	0.456	2.589	0.369	2.783	0.290	2.974	0.22	—
20	1.201	1.411	1.100	1.537	0.998	1.676	0.894	1.828	0.792	1.991	0.691	2.162	0.595	2.339	0.502	2.521	0.416	2.704	0.336	2.885	0.26	—
21	1.221	1.420	1.125	1.538	1.026	1.669	0.927	1.812	0.829	1.964	0.731	2.124	0.637	2.290	0.546	2.461	0.461	2.633	0.380	2.806	0.30	—
22	1.239	1.429	1.147	1.541	1.053	1.664	0.958	1.797	0.863	1.940	0.769	2.090	0.677	2.246	0.588	2.407	0.504	2.571	0.424	2.735	0.34	—
23	1.257	1.437	1.168	1.543	1.078	1.660	0.986	1.785	0.895	1.920	0.804	2.061	0.715	2.208	0.628	2.360	0.545	2.514	0.465	2.670	0.39	—
24	1.273	1.446	1.188	1.546	1.101	1.656	1.013	1.775	0.925	1.902	0.837	2.035	0.750	2.174	0.666	2.318	0.584	2.464	0.506	2.613	0.43	—
25	1.288	1.454	1.206	1.550	1.123	1.654	1.038	1.767	0.953	1.886	0.868	2.013	0.784	2.144	0.702	2.280	0.621	2.419	0.544	2.560	0.47	—
26	1.302	1.461	1.224	1.553	1.143	1.652	1.062	1.759	0.979	1.873	0.897	1.992	0.816	2.117	0.735	2.246	0.657	2.379	0.581	2.513	0.50	—
27	1.316	1.469	1.240	1.556	1.162	1.651	1.084	1.753	1.004	1.861	0.925	1.974	0.845	2.093	0.767	2.216	0.691	2.342	0.616	2.470	0.54	—
28	1.328	1.476	1.255	1.560	1.181	1.650	1.104	1.747	1.028	1.850	0.951	1.959	0.874	2.071	0.798	2.188	0.723	2.309	0.649	2.431	0.57	—

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

$-1 < \rho < 1$ なので (証明略), 近似的に $0 \leq DW \leq 4$ となる。

- $0 \leq DW \leq dl$ $\rightarrow u_i$ に正の系列相関
- $dl \leq DW \leq du$ $\rightarrow u_i$ に正の系列相関と判定できない
- $du \leq DW \leq 4 - du$ $\rightarrow u_i$ に系列相関なし
- $4 - du \leq DW \leq 4 - dl$ $\rightarrow u_i$ に負の系列相関と判定できない
- $4 - dl \leq DW \leq 4$ $\rightarrow u_i$ に負の系列相関

数値例： 今までと同じ数値例で， DW を計算する。

i	Y_i	X_i	$X_i Y_i$	X_i^2	\widehat{Y}_i	\widehat{u}_i
1	6	10	60	100	6.8	-0.8
2	9	12	108	144	8.1	0.9
3	10	14	140	196	9.4	0.6
4	10	16	160	256	10.7	-0.7
合計	ΣY_i	ΣX_i	$\Sigma X_i Y_i$	ΣX_i^2	$\Sigma \widehat{Y}_i$	$\Sigma \widehat{u}_i$
	35	52	468	696	35	0
平均	\bar{Y}	\bar{X}				
	8.75	13				

$$\begin{aligned}
 DW &= \frac{\sum_{i=2}^n (\widehat{u}_i - \widehat{u}_{i-1})^2}{\sum_{i=1}^n \widehat{u}_i^2} \\
 &= \frac{(-0.8 - 0.9)^2 + (0.9 - 0.6)^2 + (0.6 - (-0.7))^2}{(-0.8)^2 + 0.9^2 + 0.6^2 + (-0.7)^2} = \frac{4.67}{2.30} = 2.03
 \end{aligned}$$

推定結果の表記方法： 回帰モデル：

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

の推定の結果, $\widehat{\alpha} = 0.3, \widehat{\beta} = 0.65, s_{\widehat{\alpha}} = \sqrt{10.0005} = 3.163, s_{\widehat{\beta}} = \sqrt{0.0575} = 0.240,$
 $\frac{\widehat{\alpha}}{s_{\widehat{\alpha}}} = 0.095, \frac{\widehat{\beta}}{s_{\widehat{\beta}}} = 2.708, s^2 = 1.15$ (すなわち, $s = 1.07$), $R^2 = 0.786, \bar{R}^2 = 0.679,$
 $DW = 2.03$ を得た。

これらをまとめて,

$$Y_i = \begin{array}{c} 0.3 \\ (0.095) \end{array} + \begin{array}{c} 0.65 \\ (2.708) \end{array} X_i,$$

$$R^2 = 0.786, \bar{R}^2 = 0.679, s = 1.07, DW = 2.03,$$

ただし, 係数の推定値の下の括弧内は t 値を表すものとする。

または,

$$Y_i = \underset{(3.163)}{0.3} + \underset{(0.240)}{0.65} X_i,$$

$$R^2 = 0.786, \quad \bar{R}^2 = 0.679, \quad s = 1.07, \quad DW = 2.03,$$

ただし, 係数の推定値の下の括弧内は標準誤差を表すものとする。

のように書く。 $s = \sqrt{1.15} = 1.07$ に注意。

4.2 系列相関のもとで回帰式の推定

回帰式が

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

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

のときの推定を考える。ただし、 $\epsilon_1, \epsilon_2, \dots, \epsilon_n$ は互いに独立とする。

u_i を消去すると、

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

となり、

$$Y_i^* = (Y_i - \rho Y_{i-1}), X_i^* = (X_i - \rho X_{i-1})$$

を新たな変数として、

$$Y_i^* = \alpha' + \beta X_i^* + \epsilon_i,$$

に最小二乗法を適用する。 $\epsilon_1, \epsilon_2, \dots, \epsilon_n$ は互いに独立とするなので、最小二乗法を適用が可能となる。ただし、 $\alpha' = \alpha(1 - \rho)$ の関係が成り立つことに注意。

より一般的に、回帰式が

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

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

のときの推定を考える。ただし、 $\epsilon_1, \epsilon_2, \dots, \epsilon_n$ は互いに独立とする。

u_i を消去すると、

$$(Y_i - \rho Y_{i-1}) = \beta_1(X_{1i} - \rho X_{1,i-1}) + \beta_2(X_{2i} - \rho X_{2,i-1}) + \dots + \beta_k(X_{ki} - \rho X_{k,i-1}) + \epsilon_i,$$

となり、

$$Y_i^* = (Y_i - \rho Y_{i-1}), X_{1i}^* = (X_{1i} - \rho X_{1,i-1}), X_{2i}^* = (X_{2i} - \rho X_{2,i-1}), \dots, X_{ki}^* = (X_{ki} - \rho X_{k,i-1})$$

を新たな変数として、

$$Y_i^* = \beta_1 X_{1i}^* + \beta_2 X_{2i}^* + \dots + \beta_k X_{ki}^* + \epsilon_i$$

最小二乗法を適用する。 $\epsilon_1, \epsilon_2, \dots, \epsilon_n$ は互いに独立とするなので、最小二乗法を適用が可能となる。

ρ の求め方について (その 1): DW は近似的に $DW \approx 2(1 - \hat{\rho})$ と表されるので、 DW から ρ の推定値 $\hat{\rho}$ を逆算して、

$$Y_i^* = (Y_i - \widehat{\rho}Y_{i-1}), X_{1i}^* = (X_{1i} - \widehat{\rho}X_{1,i-1}), X_{2i}^* = (X_{2i} - \widehat{\rho}X_{2,i-1}), \dots, X_{ki}^* = (X_{ki} - \widehat{\rho}X_{k,i-1})$$

を新たな変数として,

$$Y_i^* = \beta_1 X_{1i}^* + \beta_2 X_{2i}^* + \dots + \beta_k X_{ki}^* + \epsilon_i,$$

に最小二乗法を適用する。

ρ の求め方について (その 2): 収束計算によって求める。 → コクラン・オーカット法

1. $Y_i = \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i, \quad i = 1, 2, \dots, n$

を最小二乗法で推定する。 → $\widehat{\beta}_1, \dots, \widehat{\beta}_k, \widehat{u}_i$ を得る。

2. $\widehat{u}_i = \rho \widehat{u}_{i-1} + \epsilon_i, \quad i = 2, 3, \dots, n$

を最小二乗法で推定する。 → $\widehat{\rho}$ を得る。

3. $\rho^{(m-1)} = \widehat{\rho}$ とおく。

4. $Y_i^* = (Y_i - \rho^{(m-1)}Y_{i-1})$, $X_{1i}^* = (X_{1i} - \rho^{(m-1)}X_{1,i-1})$, $X_{2i}^* = (X_{2i} - \rho^{(m-1)}X_{2,i-1})$, \dots ,
 $X_{ki}^* = (X_{ki} - \rho^{(m-1)}X_{k,i-1})$ を計算する。

$$Y_i^* = \beta_1 X_{1i}^* + \beta_2 X_{2i}^* + \dots + \beta_k X_{ki}^* + \epsilon_i, \quad i = 2, 3, \dots, n$$

を最小二乗法で推定する。 $\rightarrow \widehat{\beta}_1, \dots, \widehat{\beta}_k$ を得る。

5. $\widehat{u}_i = Y_i - \widehat{\beta}_1 X_{1i} - \widehat{\beta}_2 X_{2i} - \dots - \widehat{\beta}_k X_{ki}$, $i = 1, 2, \dots, n$
を計算する。

6. ステップ 2 に戻り, $m = 1, 2, \dots$ について繰り返す。

収束先を $\beta_1, \beta_2, \dots, \beta_k, \rho$ の推定値とする。

5 不均一分散 (不等分散)

回帰式が

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

の場合を考える。 X_i が外生変数、 Y_i は内生変数、 u_i は互いに独立な同一の分布を持つ攪乱項(最小二乗法に必要な仮定)とする。「独立な同一の分布」の意味は「攪乱項 u_1, u_2, \dots, u_n はそれぞれ独立に平均ゼロ、分散 σ^2 の分布する」である。分散が時点に依存する場合、代表的には、分散が他の変数(例えば、 z_i)に依存する場合、すなわち、 u_i の平均はゼロ、分散は $\sigma_*^2 z_i^2$ の場合は、最小二乗法の仮定に反する。そのため、単純には、 $Y_i = \alpha + \beta X_i + u_i$ に最小二乗法を適用できない。以下のような修正が必要となる。

$$\frac{Y_i}{z_i} = \alpha \frac{1}{z_i} + \beta \frac{X_i}{z_i} + \frac{u_i}{z_i} = \alpha \frac{1}{z_i} + \beta \frac{X_i}{z_i} + u_i^*$$

このとき、新たな攪乱項 u_i^* は平均ゼロ、分散 σ_*^2 の分布となる(すなわち、「同

一の」分布)。

$$E(u_i^*) = E\left(\frac{u_i}{z_i}\right) = \left(\frac{1}{z_i}\right)E(u_i) = 0$$

u_i の仮定 $E(u_i) = 0$ が使われている。

$$V(u_i^*) = V\left(\frac{u_i}{z_i}\right) = \left(\frac{1}{z_i}\right)^2 V(u_i) = \sigma_*^2$$

u_i の仮定 $V(u_i) = \sigma_*^2 z_i^2$ が最後に使われている。

よって、 $\frac{Y_i}{z_i}, \frac{1}{z_i}, \frac{X_i}{z_i}$ を新たな変数として、最小二乗法を適用することができる。

不均一分散の検定について

$$\widehat{u}_i^2 = \gamma z_i + \epsilon_i$$

を推定し、 γ の推定値 $\widehat{\gamma}$ の有意性の検定を行う (通常の t 検定)。

z_i は回帰式に含まれる変数でもよい。例えば、 u_i の平均はゼロ、分散は $\sigma_*^2 X_i^2$ の

場合、各変数を X_i で割って、

$$\frac{Y_i}{X_i} = \alpha \frac{1}{X_i} + \beta + \frac{u_i}{X_i} = \alpha \frac{1}{X_i} + \beta + u_i^*$$

を推定すればよい。 β は定数項として推定されるが、意味は限界係数(すなわち、傾き)と同じなので注意すること。

6 推定量の求め方

6.1 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、 $\widehat{\mu} \equiv \bar{x}$ 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、

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

となり、 $\widehat{\mu} \equiv \bar{X}$ を得る ($\widehat{\mu}$ 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,

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

の連立方程式を α, β について解く。

6.2 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 を与えたもとの、 $\prod_{i=1}^n f(x_i; \theta)$ 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、 $\widehat{\theta} = \widehat{\theta}(X_1, X_2, \dots, X_n)$ を最尤推定量と呼ぶ。

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

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、

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

ただし、

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

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

θ がベクトル ($k \times 1$) の場合, n が大きいとき,

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

ただし,

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

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、

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

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) 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,

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

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

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, μ, σ^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。

σ^2 の最尤推定量 $\widehat{\sigma}^2$ 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,

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

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, μ , σ^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 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 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 $\widehat{\lambda}$ 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 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 $\widehat{\lambda}$ は、

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

となる。

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

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

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

σ^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,

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

となる。

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

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

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。