

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' = 11		k' = 12		k' = 13			
	dl	du	dl	du	dl	du	dl	du	dl	du	dl	du	dl	du	dl	du	dl	du	dl	du	dl	du	dl	du	dl	du	dl	du
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	1.440	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	1.970	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	0.098	3.503	—	—	—	—	—	—
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	0.138	3.378	0.087	3.557	—	—	—	—
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	0.177	3.265	0.123	3.441	0.078	3.603	—	—
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	0.220	3.159	0.160	3.335	0.111	3.496	—	—
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	0.263	3.063	0.200	3.234	0.145	3.395	—	—
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	0.307	2.976	0.240	3.141	0.182	3.300	—	—
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	0.349	2.897	0.281	3.057	0.220	3.211	—	—
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	0.391	2.826	0.322	2.979	0.259	3.129	—	—
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	0.431	2.761	0.362	2.908	0.297	3.053	—	—
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	0.470	2.702	0.400	2.844	0.335	2.983	—	—
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	0.508	2.649	0.438	2.784	0.373	2.919	—	—
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	0.544	2.600	0.475	2.730	0.409	2.860	—	—
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	0.578	2.555	0.510	2.680	0.445	2.805	—	—
29	1.341	1.483	1.270	1.563	1.198	1.650	1.124	1.743	1.050	1.841	0.975	1.944	0.900	2.052	0.826	2.164	0.753	2.278	0.681	2.396	0.612	2.515	0.544	2.634	0.479	2.754	—	—
30	1.352	1.489	1.284	1.567	1.214	1.650	1.143	1.739	1.071	1.833	0.998	1.931	0.926	2.034	0.854	2.141	0.782	2.251	0.712	2.363	0.643	2.477	0.577	2.592	0.513	2.708	—	—
31	1.363	1.496	1.297	1.570	1.229	1.650	1.160	1.735	1.090	1.825	1.020	1.920	0.950	2.018	0.879	2.120	0.810	2.226	0.741	2.333	0.674	2.443	0.608	2.553	0.545	2.665	—	—
32	1.373	1.502	1.309	1.574	1.244	1.650	1.177	1.732	1.109	1.819	1.041	1.909	0.972	2.004	0.904	2.102	0.836	2.203	0.769	2.306	0.703	2.411	0.638	2.518	0.576	2.625	—	—
33	1.383	1.508	1.321	1.577	1.258	1.651	1.193	1.730	1.127	1.813	1.061	1.900	0.994	1.991	0.927	2.085	0.861	2.181	0.796	2.281	0.731	2.382	0.667	2.484	0.606	2.588	—	—
34	1.393	1.514	1.333	1.580	1.271	1.652	1.208	1.728	1.144	1.808	1.079	1.891	1.015	1.978	0.950	2.069	0.885	2.162	0.821	2.257	0.758	2.355	0.695	2.454	0.634	2.553	—	—
35	1.402	1.519	1.343	1.584	1.283	1.653	1.222	1.726	1.160	1.803	1.097	1.884	1.034	1.967	0.971	2.054	0.908	2.144	0.845	2.236	0.783	2.330	0.722	2.425	0.662	2.521	—	—
36	1.411	1.525	1.354	1.587	1.295	1.654	1.236	1.724	1.175	1.799	1.114	1.876	1.053	1.957	0.991	2.041	0.930	2.127	0.868	2.216	0.808	2.306	0.748	2.398	0.689	2.492	—	—
37	1.419	1.530	1.364	1.590	1.307	1.655	1.249	1.723	1.190	1.795	1.131	1.870	1.071	1.948	1.011	2.029	0.951	2.112	0.891	2.197	0.831	2.285	0.772	2.374	0.714	2.464	—	—
38	1.427	1.535	1.373	1.594	1.318	1.656	1.261	1.722	1.204	1.792	1.146	1.864	1.088	1.939	1.029	2.017	0.970	2.098	0.912	2.180	0.854	2.265	0.796	2.351	0.739	2.438	—	—
39	1.435	1.540	1.382	1.597	1.328	1.658	1.273	1.722	1.218	1.789	1.161	1.859	1.104	1.932	1.047	2.007	0.990	2.085	0.932	2.164	0.875	2.246	0.819	2.329	0.763	2.413	—	—
40	1.442	1.544	1.391	1.600	1.338	1.659	1.285	1.721	1.230	1.786	1.175	1.854	1.120	1.924	1.064	1.997	1.008	2.072	0.952	2.150	0.896	2.228	0.840	2.309	0.785	2.391	—	—
45	1.475	1.566	1.430	1.615	1.383	1.666	1.336	1.720	1.287	1.776	1.238	1.835	1.189	1.895	1.139	1.958	1.089	2.022	1.038	2.088	0.988	2.156	0.938	2.225	0.887	2.296	—	—
50	1.503	1.585	1.462	1.628	1.421	1.674	1.378	1.721	1.335	1.771	1.291	1.822	1.246	1.875	1.201	1.930	1.156	1.986	1.110	2.044	1.064	2.103	1.019	2.163	0.973	2.225	—	—
55	1.528	1.601	1.490	1.641	1.452	1.681	1.414	1.724	1.374	1.768	1.334	1.814	1.294	1.861	1.253	1.909	1.212	1.959	1.170	2.010	1.129	2.062	1.087	2.116	1.045	2.170	—	—
60	1.549	1.616	1.514	1.652	1.480	1.689	1.444	1.727	1.408	1.767	1.372	1.808	1.335	1.895	1.298	1.894	1.260	1.939	1.222	1.984	1.184	2.031	1.145	2.079	1.065	2.127	—	—
65	1.567	1.629	1.536	1.662	1.503	1.696	1.471	1.731	1.438	1.767	1.404	1.805	1.370	1.843	1.336	1.882	1.301	1.923	1.266	1.964	1.231	2.006	1.195	2.049	1.160	2.093	—	—
70	1.583	1.641	1.554	1.672	1.525	1.703	1.494	1.735	1.464	1.768	1.433	1.802	1.401	1.838	1.369	1.874	1.337	1.910	1.305	1.948	1.272	1.987	1.239	2.026	1.206	2.066	—	—
75	1.598	1.652	1.571	1.680	1.543	1.709	1.515	1.739	1.487	1.770	1.458	1.801	1.428	1.834	1.399	1.867	1.369	1.901	1.339	1.935	1.308	1.970	1.277	2.006	1.247	2.043	—	—
80	1.611	1.662	1.586	1.688	1.560	1.715	1.534	1.743	1.507	1.772	1.480	1.801	1.453	1.831	1.425	1.861	1.397	1.893	1.369	1.925	1.340	1.957	1.312	1.990	1.283	2.024	—	—
85	1.623	1.671	1.600	1.696	1.575	1.721	1.550	1.747	1.525	1.774	1.500	1.801	1.474	1.829	1.448	1.857	1.422	1.886	1.396	1.916	1.369	1.946	1.342	1.977	1.315	2.008	—	—
90	1.635</																											

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

$-1 < \rho < 1$ 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。 → コ克蘭・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 最尤法について

標本 X_1, X_2, \dots, X_n の密度関数 :

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

θ は未知母数 $\implies \widehat{\theta}_n(x_1, x_2, \dots, x_n)$ によって推定

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

のように、 θ の関数として考える。

$l(\theta)$: 尤度関数

尤度関数を最大にする θ を $\widehat{\theta}_n$ とする。

$\widehat{\theta}_n \equiv \widehat{\theta}_n(X_1, X_2, \dots, X_n) \implies$ 最尤推定量

$\widehat{\theta}_n(x_1, x_2, \dots, x_n) \implies$ 最尤推定値

すなわち,

$$\frac{\partial l(\theta)}{\partial \theta} = 0$$

を解くことによって, 最尤推定量 $\hat{\theta}_n \equiv \hat{\theta}_n(X_1, X_2, \dots, X_n)$ が得られる。

最尤推定量の性質 :

小標本について (n が小さいとき) :

- 一般に, 最尤推定量は不偏性を持っていないが, 適当な変換によって, 不偏推定量を作ることが出来る場合が多い。
- 有効推定量が存在すれば (すなわち, クラメール・ラオの不等式の等号を満たすような推定量が存在するならば), 最尤推定量は有効推定量に一致する。
- 十分統計量が存在すれば, 最尤推定量は十分統計量の関数となる。

大標本について (n が大きいとき) :

$n \rightarrow \infty$ のとき,

$$\sqrt{n}(\widehat{\theta}_n - \theta) \rightarrow N(0, \sigma^2)$$

となる。 \Rightarrow 一致性, 漸近的正規性, 漸近的有効性

ただし,

$$\sigma^2 = \sigma^2(\theta) = \frac{1}{\mathbb{E} \left[\left(\frac{\partial \log f(X; \theta)}{\partial \theta} \right)^2 \right]}$$

すなわち, $n \rightarrow \infty$ のとき,

$$\frac{\sqrt{n}(\widehat{\theta}_n - \theta)}{\sigma(\theta)} = \frac{\widehat{\theta}_n - \theta}{\sigma(\theta)/\sqrt{n}} \rightarrow N(0, 1)$$

となる。

したがって, 厳密ではないが, n が大きいとき,

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

と近似できる。

すなわち、 $n \rightarrow \infty$ のとき、 $\widehat{\theta}_n$ の分散はクラメール・ラオの不等式の下限 $\frac{\sigma^2(\theta)}{n}$ に近づくことを意味する。

⇒ 漸近的に有効推定量

さらに、分母の θ を最尤推定量 $\widehat{\theta}_n$ で置き換えて、 $n \rightarrow \infty$ のとき、

$$\frac{\widehat{\theta}_n - \theta}{\sigma(\widehat{\theta}_n) / \sqrt{n}} \rightarrow N(0, 1)$$

となる。

実際には、 n が大きいとき、

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

と近似して用いる。

例：

X_1, X_2, \dots, X_n は互いに独立で、すべて同一の正規分布 (すなわち、平均 μ , 分散 σ^2 ですべて同一の分布) に従うものとする。 μ, σ^2 の最尤推定量を求める。

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

対数をとる。(最大化しやすくなる場合が多い)

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

対数尤度関数 $\log l(\mu, \sigma^2)$ を μ と σ^2 について微分して、ゼロと置く。

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

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

この2つの連立方程式を解く。

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

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

μ, σ^2 の最尤推定量は,

$$\bar{X}, \quad S^{**2} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

となる。

$E(\bar{X}) = \mu$ なので, μ の最尤推定量 \bar{X} は不偏推定量である。

$E(S^{**2}) = \frac{n-1}{n} \sigma^2 \neq \sigma^2$ なので, σ^2 の最尤推定量 S^{**2} は不偏推定量でない。

例：

X_1, X_2, \dots, X_n は互いに独立で、すべて同一のベルヌイ分布ですべて同一の分布) に従うものとする。すなわち、 X の確率関数は $P(X = x) = f(x; p) = p^x(1-p)^{1-p}$, $x = 0, 1$, となる。 p の最尤推定量を求める。

$$f(x_1, x_2, \dots, x_n; p) = \prod_{i=1}^n f(x_i; p) = \prod_{i=1}^n p^{x_i}(1-p)^{1-x_i} = p^{\sum_i x_i}(1-p)^{n-\sum_i x_i} = l(p)$$

対数をとる。

$$\log l(p) = \left(\sum_i x_i \right) \log(p) + \left(n - \sum_i x_i \right) \log(1-p)$$

対数尤度関数 $\log l(p)$ を p について微分して、ゼロと置く。

$$\frac{\partial \log l(p)}{\partial p} = \frac{\sum_i x_i}{p} - \frac{n - \sum_i x_i}{1-p} = \frac{\sum_i x_i - np}{p(1-p)} = 0$$

この方程式を解く。

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

p の最尤推定量は,

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

となる。

$E(\bar{X}) = p$ なので, p の最尤推定量 \bar{X} は不偏推定量である。

X がベルヌイ分布 $f(x; p)$ のとき, $E(X) = p$ に注意。