

6 関数型について

線型：

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

この場合，

$$\beta = \frac{dY_i}{dX_i}$$

なので， β は， X_i が一単位上昇（下落）したとき， Y_i は何単位上昇（下落）するのかを表す。すなわち， β は限界係数と呼ばれる。

成長率：

$$100 \times \frac{Y_i - Y_{i-1}}{Y_{i-1}} = \alpha + \beta X_i + u_i,$$

として，成長率を被説明変数として用いる場合もある。 $100 \times \frac{Y_i - Y_{i-1}}{Y_{i-1}}$ という変数をあらかじめ作っておき，これをこれまでの Y_i として扱う。

注意：

$Y_i = \alpha + \beta X_i + u_i$ と $100 \times \frac{Y_i - Y_{i-1}}{Y_{i-1}} = \alpha + \beta X_i + u_i$ では、得られる決定係数の大きさが全く異なる。単純に、 R^2 や \bar{R}^2 による比較はこの場合出来ない。
 $\Rightarrow s^2$ で比較すればよい。

対数線型：

$$\log(Y_i) = \alpha + \beta \log(X_i) + u_i,$$

この場合、

$$\beta = \frac{d \log(Y_i)}{d \log(X_i)} = \frac{\frac{dY_i}{Y_i}}{\frac{dX_i}{X_i}} = \frac{100 \frac{dY_i}{Y_i}}{100 \frac{dX_i}{X_i}}$$

となる。

2つ目の等号では、 $\frac{d \log(Y_i)}{dY_i} = \frac{1}{Y_i}$ が利用される。

3つ目の等号の分子 $100 \frac{dY_i}{Y_i}$ や分母 $100 \frac{dX_i}{X_i}$ は上昇率を表す。

したがって、 β は、 X_i が1%上昇(下落)したとき、 Y_i は何%上昇(下落)するのかを表す。 β は弾力性と呼ばれる。

例：コブ＝ダグラス型生産関数：

$$Q_i = \beta_1 K_i^{\beta_2} L_i^{\beta_3}$$

ただし、 Q_i は生産量、 K_i は資本、 L_i は労働である。この場合、対数変換によって、

$$\log(Q_i) = \beta'_1 + \beta_2 \log(K_i) + \beta_3 \log(L_i) + u_i,$$

として、 $\log(Q_i)$, $\log(K_i)$, $\log(L_i)$ のデータをあらかじめ変換しておき、最小二乗法で $\beta'_1, \beta_2, \beta_3$ を推定する。また、生産関数には一次同次の制約 $\beta_2 + \beta_3 = 1$ を置く場合が多い。この場合は、

$$\begin{aligned} \log(Q_i) &= \beta'_1 + \beta_2 \log(K_i) + \beta_3 \log(L_i) \\ &= \beta'_1 + \beta_2 \log(K_i) + (1 - \beta_2) \log(L_i) + u_i \\ &= \beta'_1 + \beta_2 (\log(K_i) - \log(L_i)) + \log(L_i) + u_i, \end{aligned}$$

となるので、

$$\log(Q_i) - \log(L_i) = \beta'_1 + \beta_2 (\log(K_i) - \log(L_i)) + u_i,$$

を最小二乗法で推定し、 β'_1, β_2 を求めることになる。この場合も同様に、各変数をあらかじめ、 $\log(Q_i) - \log(L_i)$, $\log(K_i) - \log(L_i)$ としてデータを作っておく必要がある。

二次式：

$$Y_i = \alpha + \beta X_i + \gamma X_i^2 + u_i,$$

⇒ 平均費用と生産量との関係等

逆数：

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

⇒ 賃金上昇率と失業率との関係 (フィリップス曲線)

遅れのある変数： 習慣的効果を考慮に入れたモデル：

$$Y_i = \alpha + \beta X_i + \gamma Y_{i-1} + u_i,$$

ラグ付き内生変数が説明変数に用いられる。

X_i の Y_i への効果は、短期効果、長期効果の2つある。 β は短期効果を表す係数である。長期効果とは、 $Y_i = Y_{i-1}$ となるときの、 X_i から Y_i への影響を示す効果である。

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

として、 Y_i について解くと、

$$Y_i = \frac{\alpha}{1-\gamma} + \frac{\beta}{1-\gamma} X_i + \frac{1}{1-\gamma} u_i,$$

となり、 $\frac{\beta}{1-\gamma}$ が X_i の Y_i への長期効果を表す係数となる。

問題点：

1. 最小二乗法の仮定の一つに、説明変数は確率変数ではないという仮定がある。ラグ付き内生変数を説明変数に加えることによって、この仮定が満たされなくなる。最小二乗推定量は最小分散線型不偏推定量ではなくなる。
2. Y_i と X_i とは、経済理論的に考えると、相関が高いはず。 Y_i と Y_{i-1} は相関が高い。当然、 Y_{i-1} と X_i も高い相関を示す。
⇒ 多重共線性の可能性が高い。
3. DW 統計量は意味をなさない。 $(DW$ については、後述)

遅れのある変数の解釈 (部分調整モデル)： X_i が与えられたときの Y の最適水準を Y_i^* とする。

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

現実の水準 Y_i は、最適水準 Y_i^* と前期の水準 Y_{i-1} との差の一定割合と前期の水準 Y_{i-1} との和で与えられるとする。調整関数を考える。

$$Y_i - Y_{i-1} = \lambda(Y_i^* - Y_{i-1}) + u_i,$$

ただし、 u_i は互いに独立で同一な分布の誤差項、 $0 < \lambda < 1$ とする。

よって、

$$Y_i = \lambda\alpha + \lambda\beta X_i + (1 - \lambda)Y_{i-1} + u_i,$$

を得る。

Y_{i-1} と u_i との相関はない。

しかし、 Y_{i-1} が説明変数の一つに入っている (説明変数間が確率変数でないという仮定に反する)。

推定量は不偏推定量ではないが、一致推定量である (証明略)。

7 系列相関：DW について

7.1 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。

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。

$$\frac{\widehat{u}_1^2 + \widehat{u}_n^2}{\sum_{i=1}^n \widehat{u}_i^2} \approx 0,$$

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

すなわち、 $\hat{\rho}$ は \hat{u}_i と \hat{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 \hat{u}_i, \hat{u}_{i-1} に置き換えて、 ρ の推定値 $\hat{\rho}$ 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と表2を参照せよ。

表1と表2で、 k' は定数項を除くパラメータ数を表すものとする。

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	$\sum Y_i$ 35	$\sum X_i$ 52	$\sum X_i Y_i$ 468	$\sum X_i^2$ 696	$\sum \widehat{Y}_i$ 35	$\sum \widehat{u}_i$ 0
平均	\bar{Y} 8.75	\bar{X} 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, $s = 1.07$), $R^2 = 0.786$, $\overline{R}^2 = 0.679$,
 $DW = 2.03$ を得た。これらをまとめて,

$$Y_i = \underset{(0.095)}{0.3} + \underset{(2.708)}{0.65} X_i,$$

$$R^2 = 0.786, \quad \overline{R}^2 = 0.679,$$

$$s = 1.07, \quad DW = 2.03,$$

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,

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

$$R^2 = 0.786, \quad \overline{R}^2 = 0.679,$$

$$s = 1.07, \quad DW = 2.03,$$

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。

図 4： 正の系列相関

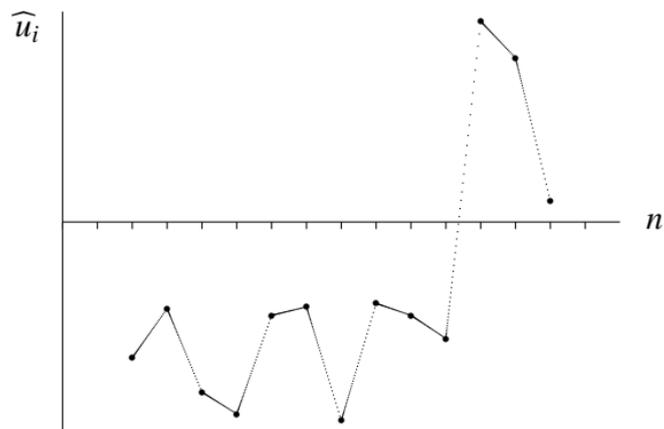


図 5： 負の系列相関

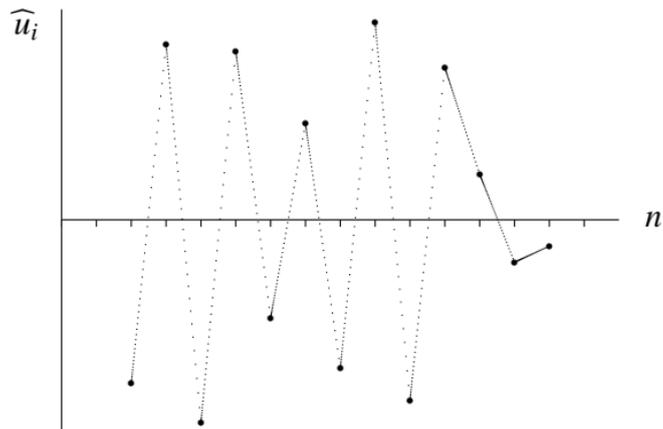


Table 1: ダービン・ワトソン統計量の 5% 点の上限と下限

(1) $k' = 1$

n	A		B		C		D		E	
	下限	上限	下限	上限	下限	上限	下限	上限	下限	上限
	0	dl	dl	du	du	$4 - du$	$4 - du$	$4 - dl$	$4 - dl$	4
15	0	1.08	1.08	1.36	1.36	2.64	2.64	2.92	2.92	4
20	0	1.20	1.20	1.41	1.41	2.59	2.59	2.80	2.80	4
25	0	1.29	1.29	1.45	1.45	2.55	2.55	2.71	2.71	4
30	0	1.35	1.35	1.49	1.49	2.51	2.51	2.65	2.65	4

(2) $k' = 2$

n	A		B		C		D		E	
	下限	上限	下限	上限	下限	上限	下限	上限	下限	上限
	0	dl	dl	du	du	$4 - du$	$4 - du$	$4 - dl$	$4 - dl$	4
15	0	0.95	0.95	1.54	1.54	2.46	2.46	3.05	3.05	4
20	0	1.10	1.10	1.54	1.54	2.46	2.46	2.90	2.90	4
25	0	1.21	1.21	1.55	1.55	2.45	2.45	2.79	2.79	4
30	0	1.28	1.28	1.57	1.57	2.43	2.43	2.72	2.72	4

(3) $k' = 3$

n	A		B		C		D		E	
	下限	上限	下限	上限	下限	上限	下限	上限	下限	上限
	0	dl	dl	du	du	$4 - du$	$4 - du$	$4 - dl$	$4 - dl$	4
15	0	0.95	0.95	1.54	1.54	2.46	2.46	3.05	3.05	4
20	0	1.10	1.10	1.54	1.54	2.46	2.46	2.90	2.90	4
25	0	1.21	1.21	1.55	1.55	2.45	2.45	2.79	2.79	4
30	0	1.28	1.28	1.57	1.57	2.43	2.43	2.72	2.72	4

Table 2: 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																		
6	0.610	1.400	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—
7	0.700	1.356	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—	—
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	—
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	0.61	—
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	0.64	—
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	0.67	—
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	0.70	—
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	0.73	—
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	0.75	—
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	0.78	—
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	0.80	—
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	0.83	—
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	0.85	—
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	0.87	—
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	0.89	—
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	0.98	—
50	1.503	1.585	1.462	1.628	1.421	1.674	1.378	1.721	1.335	1.766	1.291	1.822	1.246	1.875	1.201	1.930	1.156	1.986	1.110	2.044	1.06	—
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	1.10	—