

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	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	1.340	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 Time Series Analysis (時系列分析)

6.1 Introduction

1. Stationarity (定常性) :

Let y_1, y_2, \dots, y_T be time series data.

(a) Weak Stationarity (弱定常性) :

$$E(y_t) = \mu,$$

$$E((y_t - \mu)(y_{t-\tau} - \mu)) = \gamma(\tau), \quad \tau = 0, 1, 2, \dots$$

The first moment does not depend on time.

The second moment depends only on time difference.

(b) **Strong Stationarity (強定常性) :**

Let $f(y_{t_1}, y_{t_2}, \dots, y_{t_r})$ be the joint distribution of $y_{t_1}, y_{t_2}, \dots, y_{t_r}$.

$$f(y_{t_1}, y_{t_2}, \dots, y_{t_r}) = f(y_{t_1+\tau}, y_{t_2+\tau}, \dots, y_{t_r+\tau})$$

All the moments are same for all τ .

2. **Ergodicity (エルゴード性) :**

As time difference between two data is large, the two data become independent.

y_1, y_2, \dots, y_T is said to be ergodic in mean when \bar{y} converges in probability to $E(y_t)$.

3. **Auto-covariance Function (自己共分散関数) :**

$$E((y_t - \mu)(y_{t-\tau} - \mu)) = \gamma(\tau), \quad \tau = 0, 1, 2, \dots$$

$$\gamma(\tau) = \gamma(-\tau)$$

4. **Auto-correlation Function** (自己相関関数) :

$$\rho(\tau) = \frac{E((y_t - \mu)(y_{t-\tau} - \mu))}{\sqrt{\text{Var}(y_t)} \sqrt{\text{Var}(y_{t-\tau})}} = \frac{\gamma(\tau)}{\gamma(0)}$$

Note that $\text{Var}(y_t) = \text{Var}(y_{t-\tau}) = \gamma(0)$.

5. **Sample Mean** (標本平均) :

$$\hat{\mu} = \frac{1}{T} \sum_{t=1}^T y_t$$

6. **Sample Auto-covariance** (標本自己共分散) :

$$\hat{\gamma}(\tau) = \frac{1}{T} \sum_{t=\tau+1}^T (y_t - \hat{\mu})(y_{t-\tau} - \hat{\mu})$$

7. **Correlogram** (コレログラム, or 標本自己相関関数) :

$$\hat{\rho}(\tau) = \frac{\hat{\gamma}(\tau)}{\hat{\gamma}(0)}$$