

応用計量経済学(5)

横浜市立大学商学部

大阪大学国際公共政策研究科

松浦 克己

Colin McKenzie

第5章 系列相関

1 系列相関とは何か

$$y_t = a + b_1x_{1t} + b_2x_{2t} + \dots + b_kx_{kt} + e_t \quad 5.1)$$

のモデルを再び考えよう。このとき系列相関は無いという仮定

$E(e_t e_s) = \text{Cov}(e_t, e_s) = 0$ for $t \neq s$ が満たされていない場合の問題を考えてみよう。すなわち

$E(e_t e_s) \neq 0$ for $t \neq s$ という状況である。このようにある時点(t)と他のある時点(s)の誤差項が相関を持つとき、系列相関 (serial correlation, autocorrelation) があるという。そのようなモデルを系列相関のあるモデル (autocorrelated model) ということがある。

5.2) 式のように系列相関はある時点の行為が他の時点の行為に影響することを意味している。それはどのような場合に起きるのであろうか。

企業が設備投資を行うとしたとする。経済理論では企業は各期 (たとえば観察される四半期、あ

るいは年) 毎に利潤を最大化するように設備投資や人員の調整を行うことが想定されている。しかし実際には資金調達のために投資はずれ込むこともある。あるいは最適な生産計画が固定資本の投入を増やし労働投入を減少させることであっても、解雇は容易には進めることはできない。このようなケースはしばしば観察されるであろう。そのようなときは、前の期(直近、あるいは数期前の期)の企業の行動が当期に影響しているであろう¹⁾。

また政策のショックは当期だけではなく、時間のずれを持って影響することがある。たとえば通貨需要関数には金利が影響すると考えられるが、金利が変動しても家計や企業の通貨需要は調整コストのために、その影響は当期では吸収しきれずに、継続することがある²⁾。

もう一つの例は季節調整済みのデータを用いる場合である³⁾。たとえば次のような簡単な消費関数を考えよう。データは四半期データとする。

$$C_t = a + bY_t + e_t \quad 5.3)$$

C_t 、 Y_t は各期の実質消費と実質所得とする。 e_t

¹⁾ この例のもう一つの解釈は、5.1) 式で重要な説明変数が欠けているということである。すなわち、その欠けた変数の効果が当期だけではなく、来期にも影響しているようなケースである。

²⁾ この例のように系列相関はもっぱら時系列データで問題となる。クロスセクションデータでは通常この問題は取り上げられない。というのは時系列データではデータの並べ方に意味がある。具体的には90、91、92、...、99年というように時間の順序で並べられる。これを90、93、91、89というような並べ方はしない。他方でクロスセクションデータでは、通常並べ方に本質的な意味はない。たとえば都道府県データを北から南へ並べようが、「あいうえお」順で並べようが意味は変わらないはずである。そうするとtとsの順番も並べ方によって異なることになる。ただしクロスセクションデータの特殊な例外として空間的相関 (spatial correlation) と言われるものがあるが、ここでは取り上げない。

³⁾ 季節調整はかなり複雑な処理を原データに行うので、そのために原データと季節調整済みデータの統計的性質はかなり異なるものになることに留意した方がよい。

は誤差項で古典的仮定を充たすものとする。季節調整済みデータを何らかのウェイト (w_t) を利用し次のように作成したとする。

$$C_t^s = w_1 C_t + w_2 C_{t-1} + w_3 C_{t-2} + w_4 C_{t-3} \quad 5.4)$$

$$Y_t^s = w_1 Y_t + w_2 Y_{t-1} + w_3 Y_{t-2} + w_4 Y_{t-3} \quad 5.5)$$

ただし、 $w_1 + w_2 + w_3 + w_4 = 1$ の制約を仮定する。5.3) 式に5.4) 5.5) 式を代入し整理すると

$$\begin{aligned} C_t^s &= (w_1 + w_2 + w_3 + w_4) a \\ &+ b(w_1 Y_t + w_2 Y_{t-1} + w_3 Y_{t-2} + w_4 Y_{t-3}) \\ &+ (w_1 e_t + w_2 e_{t-1} + w_3 e_{t-2} + w_4 e_{t-3}) \\ &= a + b Y_t^s + u_t \end{aligned} \quad 5.6)$$

$$u_t = w_1 e_t + w_2 e_{t-1} + w_3 e_{t-2} + w_4 e_{t-3} \quad 5.7)$$

このとき

$$E(u_t u_{t-1}) = 0, E(u_t u_{t-2}) = 0,$$

$$E(u_t u_{t-3}) = 0, E(u_t u_{t-s}) = 0, s > 3$$

となる。

(見せかけの系列相関))

分散不均一の場合と同様、系列相関についても過小定式化の誤りや関数型の選択の誤りによる見せかけの系列相関 (spurious serial correlation) の問題に注意する必要がある。

たとえば真のモデルが

$$y_t = a + b_1 x_{1t} + b_2 x_{2t} + e_t \quad 5.8)$$

であったとする。過小定式化の誤りで

$$y_t = a + b_1 x_{1t} + u_t \quad 5.9)$$

を推計したとする。第4章でも説明したように5.9) 式の誤差項は以下ようになる。

$$u_t = b_2 x_{2t} + e_t$$

このとき x_{2t} が系列相関を持っていれば、 e_t に系列相関が無くとも u_t は系列相関を持つことになる⁴⁾。

関数型を誤るとき (たとえば真のモデルが対数関数であるのにレベルで推計したとき) も系列相関を生じる場合がある。

2 系列相関と推定量

モデルの定式化に誤りがないにもかかわらず、真の系列相関があるとしよう。そのとき推定量がどのような性質となるかを見てみよう。説明変数に被説明変数のラグ (y_{t-1} 、これをラグ付き内生変数、lagged value of the dependent variable という) を含まない次のケースを考えてみる。

$$y_t = a + b x_t + e_t$$

b の OLS 推定量 \hat{b} の期待値を $E(\hat{b})$ とする。 $E(e_t) = 0$ であるから

$$E(\hat{b}) = b + \frac{(x_t - \bar{x}) E(e_t)}{(x_t - \bar{x})^2} \quad 5.10)$$

となり、不偏性と一致性は保たれている。

分散は

$$\begin{aligned} V(\hat{b}) &= E(b - \hat{b})^2 = \frac{E((x_t - \bar{x}) e_t)^2}{(x_t - \bar{x})^2} \\ &= \frac{2}{(x_t - \bar{x})^2} + \frac{(x_t - \bar{x})(x_s - \bar{x}) E(e_t e_s)}{(x_t - \bar{x})^2} \\ &= \frac{2}{(x_t - \bar{x})^2} = V(b) \end{aligned} \quad 5.11)$$

となる。ここで $V(b)$ は系列相関のない場合の b の真の分散である。 $V(\hat{b})$ を推定するために $V(b)$ にある 2 に替えて OLS から得られる推定量 s^2 を利用したものを仮に $VE(\hat{b}) = s^2$ とする。しかし5.11) 式から明らかなように $VE(\hat{b})$ は真の分散の適切な推定量ではない。

従って系列相関が存在する場合 (説明変数にラグ付き内生変数がない場合) には、分散不均一の場合と同様にそれをを用いた t 検定や F 検定などもバイアスを持つことになる。また区間予測も行えないことになる。

系列相関だけではなく、分散不均一もある場合の $y_t = a + b x_t + e_t$ の問題を考える (ここでもラグ付き内生変数は含まれないものとする)。分散は、

⁴⁾ 過小定式化の場合、推定量が不偏性と一致性を持たないことは第3章で説明したとおりである。

$$V(\hat{\theta}) = E(\hat{\theta} - b)^2 = \frac{E\left(\sum_{t=1}^n (x_t - \bar{x})e_t\right)^2}{\left(\sum_{t=1}^n (x_t - \bar{x})^2\right)}$$

$$= \frac{\sum_{t=1}^n (x_t - \bar{x})^2 E(e_t^2) + \sum_{s \neq t} (x_t - \bar{x})(x_s - \bar{x}) E(e_t e_s)}{\left(\sum_{t=1}^n (x_t - \bar{x})^2\right)} \quad 5.12)$$

となり、 $\hat{\theta}$ はやはり有効推定量ではなくなる。

次にラグ付き内生変数を説明変数に含む場合を考えてみよう。

$$y_t = a + by_{t-1} + e_t \quad 5.13a)$$

$$E(\hat{\theta}) = b + E\left[\frac{(y_{t-1} - \bar{y}_{-1})e_t}{(y_{t-1} - \bar{y}_{-1})^2}\right] b \quad 5.13b)$$

ここで \bar{y}_{-1} は y_{t-1} の平均値とする。5.13b)より $\hat{\theta}$ は b の不偏推定量ではないということがわかる⁵⁾。

また b はやはり有効推定量ではなくなる。

これから

$$\text{plim}\hat{\theta} = b + \frac{\text{plim}\left(\frac{1}{n} \sum_{t=1}^n (y_{t-1} - \bar{y}_{-1})e_t\right)}{\text{plim}\left(\frac{1}{n} \sum_{t=1}^n (y_{t-1} - \bar{y}_{-1})^2\right)} \quad 5.13c)$$

となる。推定量が一致性を持つかどうかは5.13b)式の右辺第2項の分子に依存する。このケースは後述するが、一致性は持たないことが知られている。したがってラグ付き内生変数を持つモデルが系列相関を有するときは、OLSを用いることはできない。

3 系列相関のパターン⁶⁾

1) ARモデル

系列相関としてよく想定されるのは

$$e_t = \rho e_{t-1} + u_t \quad 5.14)$$

という1階の自己回帰モデル (first order autoregressive model, AR(1)) である。なおここで u_t は通常の仮定を充たすものとする。また e_t は分散均一であるとする。

は e_t と e_{t-1} の相関を示す未知のパラメータである ($\text{Cor}(e_t, e_{t-1}) = \rho$)。収束のために $-1 < \rho < 1$ を想定する⁷⁾。 $\rho > 0$ であれば正の系列相関 (positive autocorrelation) を持ち、 $\rho < 0$ であれば負の系列相関 (negative autocorrelation) を持つという。

e_t の分散を考えると

$$V(e_t) = V(\rho e_{t-1} + u_t)$$

$$= \rho^2 V(e_{t-1}) + V(u_t) + 2\rho \text{Cov}(e_{t-1}, u_t)$$

となる。

仮定により $\text{Cov}(e_{t-1}, u_t) = 0$, $V(u_t)$ は一定であるから、それを σ_u^2 とする。

$$V(e_t) = \sigma_e^2 = \rho^2 \sigma_e^2 + \sigma_u^2$$

となるので、結局

$$\sigma_e^2 = \frac{\sigma_u^2}{1 - \rho^2} \quad 5.15)$$

を得る。これから系列相関の程度が大きいほど推定された分散は過小評価されることになる。

また5.14)式はすべての t に対して成り立つので

$$e_{t-1} = \rho e_{t-2} + u_{t-1}$$

となる。これを5.14)式に代入すると

$$e_t = (\rho e_{t-2} + u_{t-1}) + u_t = \rho^2 e_{t-2} + u_t + \rho u_{t-1}$$

同様の代入計算を繰り返すと

$$e_t = \rho^k e_{t-k} + u_t + \rho u_{t-1} + \dots + \rho^{k-1} u_{t-k+1}$$

となる。その結果から

$$\text{Cov}(e_t, e_{t-k}) = \rho^k \sigma_e^2 \quad 5.16)$$

$$\text{Cov}(e_t, e_{t-k}) = \frac{\text{Cov}(e_t, e_{t-k})}{V(e_t)V(e_{t-k})} = \frac{\rho^k \sigma_e^2}{\sigma_e^2 \sigma_e^2} = \rho^k \quad 5.17)$$

となるので、時間が経過するにつれ相関は弱くなる (AR(1)モデルであるから、 ρ は時間を通じて

⁵⁾ 5.13a)式において e_t が系列相関を持たない場合でも、OLS推定量は不偏性を持たない。

⁶⁾ 系列相関のパターンとしては、本章で取り上げるAR、MA、ARMA以外にARCH等がある。しかし、別の見方をするとARCHは分散不均一性のパターンでもある。

⁷⁾ $|\rho| > 1$ であれば、発散する。 $|\rho| < 1$ を定常性の条件 (stationarity condition) ということがある。 $\rho = 1$ であれば e_t は単位根 (unit root) を持つという。この定常性と単位根の問題については章を改めて詳述する。

一定である)。

ここで次のような5.13a) 式の問題を考えよう。
便宜上 $a = 0$ と仮定する。

$$y_{t-1} = e_{t-1} + be_{t-2} + b^2e_{t-3} + \dots + b^{k-1}e_{t-k} \dots$$

両辺に e_t を乗じ5.17) 式を用いると

$$\begin{aligned} \text{plim} \left(\frac{1}{n} \sum_{t=1}^n (y_{t-1} - \bar{y}_{-1}) e_t \right) &= \frac{\sigma_e^2}{1-b} + b \frac{\sigma_e^2}{1-b^2} + \dots \\ &+ \dots + b^{k-1} \frac{\sigma_e^2}{1-b^k} \dots = \frac{\sigma_e^2}{1-b} \quad 0 \end{aligned}$$

となるので、5.13c) 式は、 $\text{plim}(\hat{\beta}) = b$ である。従ってラグ付き内生変数を説明変数に持つモデルが系列相関を有するときは、そのOLS推定量は一致性を持たない場合がある。特に上記のケースのように説明変数と誤差項が相関する場合は、一致性を失うことになる。

季節調整を行わない時系列の原データを用いるとき、それが四半期データであれば前年同期(4四半期前)、月次データであれば12ヶ月前と相関すると考えるのは不思議ではない(たとえばボーナス期の消費は前年のボーナス期の消費と関連するだろう)。すなわち以下のような例である。

$$e_t = e_{t-4} + u_t \quad 5.18a)$$

$$e_t = e_{t-12} + u_t \quad 5.18b)$$

このように直近の期とは系列相関を持たないが、離れた期と相関を持つことがある。原データを利用して分析するときは、この点に留意する必要がある。

$V(u_t) = \sigma_u^2$ とし、5.18a) 式の場合

$$E(e_t) = 0$$

$$V(e_t) = \sigma_u^2 / (1 - b^4) \quad \text{for all } t$$

$$\text{Cov}(e_t, e_{t-s}) = \sigma_u^2 \cdot s/4 / (1 - b^2)$$

(sが4の倍数の時)

$$= 0$$

(otherwise)

5.18b) 式の場合

$$E(e_t) = 0$$

$$V(e_t) = \sigma_u^2 / (1 - b^{12}) \quad \text{for all } t$$

$$\text{Cov}(e_t, e_{t-s}) = \sigma_u^2 \cdot s/12 / (1 - b^2)$$

(sが12の倍数の時)

$$= 0$$

(otherwise)

となる。

更に系列相関はAR(1)モデルのようにある特定の期とだけに存在するのみならず、多期間にわたり存在することがある、またその誤差項の相関の程度も期によって異なることがある。すなわち

$$e_t = \rho e_{t-1} + \rho^2 e_{t-2} + \dots + \rho^p e_{t-p} + u_t \quad 5.19)$$

という場合である。これをp次のARモデル (AR(p)) と表記する) という。

2) MAモデル

系列相関のもう一つのパターンは移動平均プロセス (MA, moving average process, moving average disturbance) といわれるものである。

5.14) 式に変えて

$$e_t = u_t + \rho u_{t-1} \quad 5.20)$$

を想定するものである。ここでも u_t は標準的仮定を充たすものとする ($V(u_t) = \sigma_u^2$)。1階の系列相関を想定するのでこれをMA(1)という。このとき e_t について以下の性質を得ることができる。

$$E(e_t) = 0$$

$$V(e_t) = \sigma_u^2 (1 + \rho^2)$$

$$\text{Cov}(e_t, e_{t-s}) = \rho \sigma_u^2 \quad s = 1 \quad 5.21)$$

$$= 0 \quad s > 1$$

$$\text{Corr}(e_t, e_{t-s}) = \frac{\rho}{1 + \rho^2} \quad s = 1$$

$$= 0 \quad s > 1$$

この5.21) 式のうちの相関 ($\text{Corr}(e_t, e_{t-1})$) をとすると

$$= \frac{\rho}{1 + \rho^2} \quad 5.22)$$

である。MA(1)の場合通常 $|\rho| < 1.0$ と仮定する⁸⁾。そうすると5.22) より $|\rho| < 0.5$ となる。

このMA(1)モデルを一般化すると

$$e_t = u_t + \rho_1 u_{t-1} + \rho_2 u_{t-2} + \dots + \rho_q u_{t-q} \quad 5.23)$$

となる。これをq次のMAモデル、MA(q)という。MA(2)であれば以下のようなのである。

$$e_t = u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2}$$

$$V(e_t) = \sigma_u^2 (1 + \theta_1^2 + \theta_2^2)$$

$$\text{Cov}(e_t, e_{t-1}) = \theta_1 \sigma_u^2$$

$$\text{Cov}(e_t, e_{t-2}) = \theta_2 \sigma_u^2$$

$$\text{Cov}(e_t, e_{t-s}) = 0 \quad s > 2$$

ここで $\text{Corr}(e_t, e_{t-i}) = \rho_i$ とする。

$$\rho_1 = \frac{\theta_1 (1 + \theta_2)}{1 + \theta_1^2 + \theta_2^2} \quad (5.24)$$

$$\rho_2 = \frac{\theta_2}{1 + \theta_1^2 + \theta_2^2}$$

を得る。5.23) 式のケースでは5.24) 式の相関は、代入計算を繰り返すことにより、 $\rho_0 = 1$ とし、以下のようになる⁹⁾。

$$\rho_k = \frac{\sum_{t=0}^{q-k} \theta_t \theta_{t+k}}{\sum_{t=0}^q \theta_t^2} \quad k = 0, 1, \dots, q \quad (5.25)$$

3) ARMAモデル

ARモデルとMAモデルを結合させた自己移動平均モデル (autoregressive moving average, ARMA) が利用されることもある。

5.14) 式と5.20) 式を併せた

$$e_t = \phi_1 e_{t-1} + u_t + \theta_1 u_{t-1} \quad (5.26)$$

である (AR、MAの次数が各々1であるので、ARMA(1, 1) と表記する。p次とq次であればARMA(p, q) と表記する)。ここでも u_t は標準的仮定を充たすものとする。

データについてARMAでもAR部分で定常性、MA部分で反転可能性が満たされていることが求められる。データの定常性が満たされているとき、ARMA(1, 1) の期待値は次式で与えられる。

$$E(e_t) = 0$$

分散は以下のようなのである。

$$r_0 = V(e_t) = E(e_t)^2 = E(e_{t-1} + u_t + \theta_1 u_{t-1})^2$$

$$= V(e_{t-1}) + 2 E(e_{t-1} u_t) + \sigma_u^2 + \theta_1^2 \sigma_u^2$$

このとき、 $E(e_{t-1} u_t) = 0$ 、また仮定により u_t は u_{t-1} 、 e_{t-1} と相関を持たないので、結局

$$r_0 = V(e_t) = \left(\frac{1 + \theta_1^2 + \theta_2^2}{1 - \theta_1^2} \right) \sigma_u^2$$

となる。共分散は以下の通りである。

$$r_1 = \text{Cov}(e_t, e_{t-1}) = \left(\frac{\theta_1 (1 + \theta_2)}{1 - \theta_1^2} \right) \sigma_u^2$$

$$\rho_0 = r_0 / \sigma_u^2$$

$$r_k = \rho_k r_0 \quad k \geq 2$$

従って自己相関は次の通りである。

$$\text{Corr}(e_t, e_{t-1}) = r_1 / r_0 = \frac{\theta_1 (1 + \theta_2)}{1 + \theta_1^2 + \theta_2^2} \quad (5.27)$$

$$\text{Corr}(e_t, e_{t-k}) = \rho_k \text{Corr}(e_t, e_{t-1}) \quad k \geq 2$$

4) 自己相関、偏自己相関

観察されるサンプル (y_1, \dots, y_n) について自己の標本共分散 (c_j) を標本分散 (c_0) で標準化したもの ($d_j = c_j / c_0$) を標本自己相関 (auto correlation) あるいは標本コレログラム (correlogram) という。 c_0 と c_j は下記のように定義する。

$$c_0 = (1/n) \sum_{t=1}^n (y_t - \bar{y})^2$$

$$c_j = (1/n) \sum_{t=1}^n (y_t - \bar{y})(y_{t-j} - \bar{y})$$

系列相関が全くないという帰無仮説が正しければ

$$d_t = c_t / c_0 \rightarrow 0$$

は標準正規分布に従う。

サンプルの相関を計るもう一つの尺度は標本偏自己相関 (partial autocorrelation) である。 $e_{t-1} = e_{t-2} + u_{t-1}$ を考えると、 e_{t-2} は e_{t-1} を通じて e_t に

⁸⁾ MAモデルはある条件を充たせばARモデルとして表現することができる。これはMAモデルの反転可能性の条件 (invertibility condition) と呼ばれている。MA(1)の場合 $|\theta_1| < 1$ は反転可能性の条件となる。

⁹⁾ q次までの相関を考えているので、 $k = 0, 1, \dots, q$ である。

影響することが分かる。そのルート以外に e_{t-2} が直接に e_t に影響している可能性がある。一般的に、 k 期離れたラグが途中の期($k-1$ 等)を通じた影響だけでなく、その固有の要因で e_t に影響することがある。これを標本偏自己相関という。これを $\hat{\rho}_{kk}$ と書くと次のような公式で与えられる。

$$\hat{\rho}_{kk} = d_j \quad k = 1$$

$$= \frac{d_k - \sum_{j=1}^{k-1} \hat{\rho}_{k-1,j} d_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\rho}_{k-1,j} d_j} \quad k > 1 \quad (5.28)$$

ただし $\hat{\rho}_{kj} = \hat{\rho}_{k-1,j} - \hat{\rho}_{kk} \hat{\rho}_{k-1,kj}$, $j = 1, 2, \dots, k-1$ 。この検定はサンプル n が十分に多いものとして

$$t = \hat{\rho}_{kk} / \sqrt{1/n} \text{で行う。} \quad (5.29)$$

これは系列相関が疑われる場合のAR、MA、ARMAのいずれに該当するかを考察する上で便利な役割を果たす。AR(p)の場合、偏自己相関はラグ p まではゼロではないが、ラグ $p+1$ 以降はゼロになる。しかし自己相関はずっとゼロではなく時間が経つにつれ小さくなる。それに対してMA(q)の場合自己相関はラグ q まではゼロではないが、ラグ $q+1$ 以降はゼロになる。ただし偏自己相関はずっとゼロではないが、時間が経つにつれ小さくなる。ARMAモデルの場合偏自己相関と自己相関はゼロにならない。この性質は標本自己相関と標本偏自己相関に反映されるはずである。

標本自己相関が有意であり、かつ標本偏自己相関が有意でなければARモデルを選択する(又は多くの標本自己相関が有意であり、かつほとんどの標本偏自己相関が有意でなければARモデルを選択する)。逆に標本自己相関が非有意でかつ標本偏自己相関が有意であればMAモデルを選択する。(又はほとんどの標本自己相関が非有意でかつ多くの標本偏自己相関が有意であればMAモデルを選択する)。

さらに多くの標本自己相関と多くの標本偏自己

相関が共に有意であれば、ARMAを選択する。しかし場合によってAR、MA、ARMAモデルの識別が非常に困難なケースがあることには留意しておく必要がある。

4 系列相関の検定

最初にラグ付き内生変数を含まないAR(1)の系列相関の検定について考えてみる(MAモデルについても基本的に同様である)。

1) Durbin Watsonテスト(DW test)

1階の系列相関の検定に最もよく使われるのは、Durbin Watsonテスト(DWテスト、その統計量を d 、DWと書くことが多い)である。

$$y_t = a + bx_t + e_t \quad e_t = e_{t-1} + u_t \quad (5.30)$$

において、以下の仮説検定を考える。

$$H_0: \rho = 0$$

$$H_0: \rho < 0$$

(5.30)式の回帰モデルのOLS残差を \hat{e}_t とし、Durbin Watsonテストの統計量は以下で与えられる。

$$d = \frac{\sum_{t=2}^n (\hat{e}_t - \hat{e}_{t-1})^2}{\sum_{t=1}^n \hat{e}_t^2} \quad (5.31)$$

ここで d が $4 > d > 0$ という条件を充たすことを証明することができる。(5.31)式の分子を書き換えると

$$\sum_{t=2}^n (\hat{e}_t - \hat{e}_{t-1})^2 = \sum_{t=2}^n \hat{e}_t^2 + \sum_{t=2}^n \hat{e}_{t-1}^2 - 2 \sum_{t=2}^n \hat{e}_t \hat{e}_{t-1}$$

である。相関係数の $\hat{\rho}$ は

$$\hat{\rho} = \frac{\sum_{t=2}^n \hat{e}_t \hat{e}_{t-1}}{\sum_{t=1}^n \hat{e}_t^2}$$

$$d \approx 2 -$$

と近似することができる。系列相関がないとき、すなわち

$$\rho = 0 \text{であれば、} \hat{\rho} \approx 0 \text{となるので} d \approx 2 \text{となる。}$$

正(負)

の系列相関であれば $\hat{\rho} > 0$ ($\hat{\rho} < 0$)となる。したがって、正(負)の系列相関が存在す

るときは $0 < d < 2$ ($2 < d < 4$)となる ($-1 < < 1$ の定常性の条件を充たす必要がある)。

ただし、 t 値や F 値と異なり、DWテストの臨界値は説明変数 x_t に依存する。そのために一般的な分布表を作成することができない。そこでDurbin Watsonは標本数とパラメータの数を利用した臨界値 (d_T) の上限 (d_u) と下限 (d_l) を提示している ($d_l < d_T < d_u$)。それを利用することで1階の系列相関の有無を検定することができる。これを用いると正の系列相関の検定 (すなわち $H_0: = 0$ 、 $H_1: > 0$) は次のとおりである。

$d < d_l$ $H_0: = 0$ を棄却。
 $H_1: > 0$ を採択。
 $d_u < d$ $H_0: = 0$ を棄却できない。
 $d_l < d < d_u$ 判断を下すことができない
 (inconclusive)

負の系列相関について (すなわち $H_0: = 0$ 、 $H_1: < 0$) は次のとおりである。

$d > 4 - d_l$ $H_0: = 0$ を棄却。
 $H_1: < 0$ を採択。
 $d < 4 - d_u$ $H_0: = 0$ を棄却できない。
 $4 - d_u < d < 4 - d_l$ 判断を下すことができない
 (inconclusive)

系列相関の符号についての事前情報がない場合 (すなわち $H_0: = 0$ 、 $H_1: \neq 0$) 検定は次のとおりである。

$d < d_l$ $H_0: = 0$ を棄却。

$H_1: \neq 0$ を採択。
 判断を下すことができない
 (inconclusive)

$d_l < d < d_u$

$d_u < d < 4 - d_u$

$4 - d_u < d < 4 - d_l$

$d > 4 - d_l$

$H_0: = 0$ を棄却できない。
 判断を下すことができない
 (inconclusive)

$H_0: = 0$ を棄却。

$H_1: \neq 0$ を採択。

このようにDW統計量には、系列相関の有無について判断を下すことができない領域が存在する。またこの検定統計量が用いられるのは、ラグ付き内生変数を含まないこと¹⁰⁾、説明変数は非確率変数であること、モデルに定数項を含むことという制約がある。

これらの制約にも関わらず、DW統計量の実際上有用な点はモデルを推計したとき

$d = R^2$

であれば、モデルの定式化に誤りがある (すなわち過小定式化などにより見せかけの系列相関がある) というシグナルになることである¹¹⁾。

第1章から第4章で様々な推計結果を掲載したが、それらの表にあるDurbin Watson statがDurbin Watsonの統計量である。

2) Qテスト

系列相関の検定に使われるものにBox PierceのQテストとLjung Boxテストがある。これは高

¹⁰⁾ ラグ付き内生変数を含む場合、DurbinはDurbin's h 統計量を提示している。

$$y_t = a + b_1 x_t + b_2 y_{t-1} + e_t$$

$$e_t = \rho e_{t-1} + u_t$$

のモデルにおいて

$h = (1 - 0.5d) n / (1 - n\hat{\rho}^2)$ が標準正規分布に従うことを利用するものである。ここで n はサンプル数 $\hat{\rho}_2$ は b_2 のOLS推定量 $\hat{\rho}_2$ は $\hat{\rho}_2$ の分散のOLS推定量、 d はAR(1)を仮定するときのダービンワトソン統計量である。

なお、 $1 - n\hat{\rho}^2 > 0$ の制約を充たしている必要がある。高次の系列相関があるときはDurbin's alternativeという統計量も提案されているが省略する。

¹¹⁾ 四半期データを用いたときの、 $\hat{e}_t = \hat{e}_{t-4} + \hat{u}_t$ の検定がWallisによって示されている。これはDurbin-Watsonの応用で、帰無仮説 $H_0: = 0$ について

$$d = \frac{\sum_{t=1}^n (\hat{e}_t - \hat{e}_{t-4})^2}{\sum_{t=1}^n \hat{e}_t^2}$$

の統計量を用いて検定する。統計量の臨界値の上限と下限はKmenta [1997] に掲載されている。

次の系列相関やARMAプロセスの検定に用いられる（ただしラグ付き内生変数はモデルに含まれないものとする）。

その統計量Qは

$$Q = n \sum_{j=1}^p r_j^2 \quad (5.32)$$

$$\text{ただし } r_j = \frac{\sum_{t=j+1}^n \hat{e}_t \hat{e}_{t-j}}{\sum_{t=1}^n \hat{e}_t^2}$$

回帰モデルのOLS残差を e_t とする。

系列相関はないという帰無仮説の下で、Q統計量は自由度pの χ^2 分布に従う。小標本の場合は(5.32)式を以下のように修正して用いる。

$$Q = n(n+2) \sum_{j=1}^p r_j^2 / (n-j) \quad (5.33)$$

QはLjung Boxテストと呼ばれている。(5.33)式も系列相関はないという帰無仮説の下で自由度pの χ^2 分布に従う。

なおQ統計量（又はQ統計量）は次数の取り方に依存するので、本来高次の系列相関があるにも関わらず、それよりも低い次数で、検定した場合結果を誤ることがあることに留意する必要がある。逆に本来低次の系列相関があるにも関わらず、それよりも高い次数で検定した場合でも同じように結果を誤ることもある。

3) LM検定

ラグ付き内生変数をモデルに含む場合や、高次の系列相関を含む場合やARMA等に関するより一般的な検定方法が、Breusch Godfreyのラグランジュ乗数テスト(LM)によって示されている。

$$y_t = a + bx_t + e_t \quad (5.34a)$$

$$e_t = \alpha_1 e_{t-1} + \alpha_2 e_{t-2} + \dots + \alpha_p e_{t-p} + u_t \quad (5.34b)$$

ただし u_t は標準的仮定を充たすものとする。このケ-スを考えよう。系列相関がないという帰無仮説は

$$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_p = 0$$

である。(5.34b)式にある e_t が観測可能であれば(5.34b)式をOLSで推定し、 H_0 をF検定で検定す

れば良い。しかし e_t が観測可能ではないので推定する必要がある。

そのために(5.34a)式をOLSで推計し、その残差 e_t を求める。その上で

$$\hat{e}_t = a + b x_t + \alpha_1 \hat{e}_{t-1} + \alpha_2 \hat{e}_{t-2} + \dots + \alpha_p \hat{e}_{t-p} + v_t \quad (5.35a)$$

$$v_t = u_t + (\alpha_1 (e_{t-1} - \hat{e}_{t-1})) + (\alpha_2 (e_{t-2} - \hat{e}_{t-2})) + \dots + \alpha_p (e_{t-p} - \hat{e}_{t-p}) \quad (5.35b)$$

の補助回帰を行う。(5.35a)式の決定係数を R^2 、サンプル数をnとする。帰無仮説の下でnが十分大きいとき、 nR^2 が自由度pの χ^2 分布に従う。

もう一つの検定はF検定を利用することである。帰無仮説が正しいと $v_t = u_t$ となるので、(5.35a)式の誤差項は標準的線形回帰モデルの仮定を充たす。(5.35a)式から得られる残差平方和を制約のないモデルの残差平方和 RSS_u とする。

$$\alpha_1 = \alpha_2 = \dots = \alpha_p = 0 \text{ の制約をつけたモデル}$$

$$e_t = a + b x_t + u_t \quad (5.36)$$

の残差平方和を RSS_r とする。F統計量は

$$F = \frac{(RSS_r - RSS_u)/p}{RSS_u/(n-2-p)} \quad (5.37)$$

である（これは除外変数テストの一例である）。このとき除かれた残差は非確率説明変数ではないので、小標本ではF分布の正確な性質を知ることができない。しかし大標本のケ-スではF分布に従う。

$RSS_u/(n-k-p)$ は u_t の分散推定量で、nが十分大きいとき RSS_r/n で置き換えることができる。F統計量として(5.37)式に代えて

$$F = \frac{(RSS_r - RSS_u)/p}{RSS_r/n} \quad (5.38)$$

を用いる。OLSの正規方程式より、 x_t は e_t を説明することはないので、(5.36)式の総平方和は RSS_r となる。このとき

$$F = nR^2/p \text{ が知られている。これを書き換えて } pF = nR^2 \quad (5.39)$$

となる。これを自由度pの²検定すればよい。

$$\frac{1}{n} \left(\sum_{t=q+1}^n (x_t - \bar{x})(x_{t-q} - \bar{x}) + \sum_{t=q+1}^n (x_{t-q} - \bar{x})(x_t - \bar{x}) \right) \quad (5.40)$$

5 系列相関がある場合の推定

系列相関がある場合の問題を見てみよう。系列相関はあるが、ラグ付き内生変数や確率変数を含まず、説明変数と誤差項に相関はないケースがまず考えられる。このとき前述の通りOLSの推定量は一致性は持つが有効性は持たない。t検定やF検定を行うことができない。したがってこのケースでは、一致性は持つので分散（標準誤差）の修正が問題となる。

もう一つはARモデルやMAモデルなどの推定方法である。

もう一つはラグ付き内生変数などを含むためにOLS推定量が一致性も持たない場合である。この場合は操作変数法（Instrumental Variables Method, IV）や二段階最小自乗法（Two Stage Least Squares, 2SLS）によることになる。IVや2SLSについては章を改めて紹介する。

1) Newey Westの一致性のある推定

誤差項に系列相関がある場合、あるいは分散不均一が存在する場合、もしくは系列相関と分散不均一が共に存在する場合、その分散の推定量をNewey - Westは提案した。これは係数についてはOLSの推定量を用いるが、その推定量の真の分散（たとえば5.11）式や5.12）式）を推定し、仮説検定を行うものである。

ここでも

$$y_t = a + bx_t + e_t$$

を考える。Newey - Westの修正は以下による。

$$Q = \hat{e}_t'(x_t - \bar{x})(x_t - \bar{x}) + \sum_{q=1}^L W_q \sum_{t=q+1}^n \hat{e}_t \hat{e}_{t-q}$$

ここで、

$$w_q = 1 - q/(L + 1) \quad R = (x_t - \bar{x})(x_t - \bar{x})$$

5.12) 式の分散を $VE(\hat{\beta}) = \text{sew}(\hat{\beta})^2 = Q/R^2$ として推定する。t検定は

$$\frac{\hat{\beta} - b}{\text{sew}(\hat{\beta})}$$

が行う。

なおL = 0であれば、第4章で見た分散不均一に関するWhiteの一致性のある推定量と同一となる¹²⁾¹³⁾。Newey - Westの方法はWhiteの推定方法のより一般的なものといえる。

2) ARモデルの推定

系列相関のある場合の推定方法について、最も簡単なAR(1)モデルについて見てみよう（高次の系列相関のある場合もこの延長である）。

$$y_t = a + bx_t + e_t \quad (5.41)$$

$$e_t = e_{t-1} + u_t \quad (5.42)$$

となる。t = 2のケースについては5.41)式に5.42)式を代入し整理すると

$$y_t - y_{t-1} = (1 - \alpha) + \beta(x_t - x_{t-1}) + u_t$$

を得る。ここで

$$y_t^* = y_t - y_{t-1}, \quad a^* = (1 - \alpha), \quad x_t^* = x_t - x_{t-1}$$

とおくと、

$$y_t^* = a^* + \beta x_t^* + u_t \quad (5.43)$$

となる。仮定により u_t は互いに相関しないので、 $u_t \sim N(0, \sigma^2)$ である。

5.43)式による推計は一般化最小自乗法（generalized least squares, GLS）の一つの例である¹⁴⁾¹⁵⁾。

¹²⁾ Newey Westの一致性のある推定についてはDavidson and MacKinnon[1993] Greene[1997]参照。

¹³⁾ EviewsはLを

$L = \text{floor}(4(n/100)^{1/9})$ として自動的に選択する。

Qを計算するためにEviewsは先に定義した w_q を利用するが、別の計算ソフトの場合 w_q の選択は違う形で行われている。

が既知の場合はその値を用いて y_t^* 、 x_t^* を計算できるが、 a 、 b が未知の場合は a と b を同時に推定する。

もう一つ用いられるのは最尤法である。 e_t 、 u_t が正規分布に従うとする。

$$\text{Log}L = 0.5 \text{Log} (1 - \rho^2) - 0.5 n \text{log} (2 \pi \sigma_u^2) - \sum_{t=1}^n u_t^2 / 2 \sigma_u^2 \quad (5.44)$$

を最大化する。ここで

$$u_t = y_t - y_{t-1} - (1 - \rho) a - b(x_t - x_{t-1}) \quad t > 1$$

$$u_1 = y_1 - a - b x_1$$

となる。このときパラメータ a 、 b と ρ は同時に推定される。

四半期データの場合作用 (5.42) 式の代わりに

$$e_t = e_{t-4} + u_t$$

を使用することがある。最尤法で推定すると対数尤度関数は

$$\text{Log}L = 0.5 \text{Log} (1 - \rho^4) - 0.5 n \text{log} (2 \pi \sigma_u^2) - \sum_{t=1}^n u_t^2 / 2 \sigma_u^2 \quad (5.45)$$

ここで

$$u_t = y_t - y_{t-4} - (1 - \rho) a - b(x_t - x_{t-4}) \quad t > 4$$

$$u_t = y_t - a - b x_t \quad t = 1, 2, 3, 4$$

となる。

3) MAモデル、ARMAモデルの推定

MAモデル、ARMAモデルの推定は必ずしも容

易ではない。MAモデルの対数尤度は次の通りである¹⁴⁾。

$$y_t = a + b x_t + e_t$$

$$e_t = u_t + \rho u_{t-1}$$

において

$$\text{Log}L = -(n/2) \text{Log} (\sigma_e^2) + 1/2 \text{Log} |w| - (1/2 \sigma_e^2) \sum_{t=1}^n u_t^2 \quad (5.46)$$

ただし w^2 は e_t の分散共分散行列である。このとき

$$\text{Log} |w| = \text{Log} [(1 - \rho^{2n+2}) / (1 - \rho^2)]$$

であることが知られている。 u_t を計算するために $u_0 = 0$ とし、

$$u_1 = y_1 - a - b x_1$$

$$u_2 = y_2 - a - b x_2 - \rho u_1$$

⋮

$$u_n = y_n - a - b x_n - \rho u_{n-1}$$

となる。 y_t^* 、 x_t^* と z_t^* を次のように定義すると

$$y_0^* = 0, \quad y_t^* = y_t - \rho y_{t-1}^* \quad t > 0$$

$$x_0^* = 0, \quad x_t^* = x_t - \rho x_{t-1}^* \quad t > 0$$

$$z_0^* = 0, \quad z_t^* = 1 - \rho z_{t-1}^* \quad t > 0$$

u_t は $u_t = y_t^* - a z_t^* - b x_t^*$ となる。

実際の推定に当たっては、(5.46) 式を推計することは困難なので、(5.46) の第2項を無視して

$$\text{Log}L = -(n/2) \text{Log} (\sigma_e^2) - (1/2 \sigma_e^2) \sum_{t=1}^n u_t^2 \quad (5.47)$$

14) $t = 1$ のケースでは、(5.41) 式の両辺に $1 - \rho^2$ を乗じると、
 $y_1 (1 - \rho^2) = a (1 - \rho^2) + b x_1 (1 - \rho^2) + e_1 (1 - \rho^2)$

を得る。ここで、

$$y_1^* = y_1 (1 - \rho^2) \quad a^* = a (1 - \rho^2)$$

$$x_1^* = x_1 (1 - \rho^2) \quad e_1^* = e_1 (1 - \rho^2)$$

とおくと、

$$y_1^* = a^* + b x_1^* + e_1^*$$

となる。このとき

$$E[e_1^*] = E[e_1] (1 - \rho^2) = 0$$

$$V[e_1^*] = (1 - \rho^2) V[e_1] = (1 - \rho^2) \frac{\sigma_e^2}{(1 - \rho^2)}$$

$t = 2$ のケースのみを推計するのは Cochrane-Orcutt 法と言われる。

15) (5.43) 式を次のように考える。

$$Y_t = (1 - \rho) a + b_1 x_t - \rho b x_{t-1} + y_{t-1} + u_t = a + b_1 x_t + b_2 x_{t-1} + b_3 y_{t-1} + u_t$$

このとき、 $b_2 + \rho b_1 - b_3 = 0$ の制約 (common factor restriction) がかかっている。この非線形制約が成立しているかどうかを、Wald検定で確かめることが望ましい。

16) 詳しくは山本拓 [1988] の第4章3、4節、Davidson and MacKinnon [1993] のCh10-7を参照。

を用いる。

なお5.46)式はMA(q)とARMAモデルにも適用される。

ARとMAの次数については、十分高い次数から選択し順次非有意な次数を除いてゆけばよいというのが一つの選び方である。ARMAの次数の選択(又はARとMAの次数の選択)についてはAICやSICの情報量基準を用いることも行われる(AICとSICについて第3章を参照されたい)。

6 Eviewsによる推定

輸入関数を例として、系列相関の問題を考えることにしたい。季節調整を行っていない月次の輸入数量指数(IMPNUMBERと表記する)を被説明変数としよう。輸入に影響するものとして国内生産を考える(具体的にはその代理変数として鉱工業生産指数IIPを考える)。国内生産が高まれば輸入需要は増加するので、その符号は正が期待さ

れる。為替レートとしては実効為替レートを取り上げる(JILTUKOU)。円高になれば実効為替レートは高くなり、輸入は増えると考えられるので、その符号は正が期待される。ただしJカーブ効果が働いているようであれば負が期待される。価格効果として輸入物価指数/国内卸売物価指数(SOUTAI)を考える。相対価格が上昇すれば輸入品の競争力が落ちるので、この符号は負が期待される(推計期間は93年1月から98年3月までである)。


$$\text{IMPNUMBER}_t = a + b_1 \text{IIP}_t + b_2 \text{JILTUKOU}_t + b_3 \text{SOUTAI}_t + e_t$$

をOLSで推計するEviewsのプログラムは次の通りである(方程式の名前をeq5_1としている)。

```
equation eq5_1 Js IMPNUMBER C IIP  
JILTUKOU SOUTAI
```

結果は次のようであった。

図5.1 残差のグラフ(系列相関)



$$\text{IMPNUMBER}_i = 120.13 + 0.81\text{IIP}_i - 0.57\text{JILTUKOU}_i - 29.51\text{SOUTAI}_i + \epsilon_i$$

$$(1.30) (4.00) \quad (-1.64) \quad (-0.63)$$

5.48)

AdjR² = 0.408 (R² = 0.436) SER = 9.57

DW = 0.941 期間：93年1月 - 98年3月

なおカッコ内はt値である。

(時系列データを用いた分析ではDW統計量を報告するのが通例である)

定数項以外の説明変数が3個、サンプルは63個である。このケースでdは約1.49、duは約1.69である(5%有意水準)。この例では非常に強い正の系列相関がある。残差をプロットすると明らかに正の系列相関がうかがわれる(図5.1参照)。

月次データであるので、比較的長い16次までのラグをとってQテストを行ってみよう。Qテストは

View/Residual Tests/Correlogram Q Statisticsを選択し、Lag Specificationのダイアログにラグの次数(この場合16)を入れる。結果は表5.1に

示すとおりである。Q統計量は極めて高く、p値は0.000であり系列相関はないという帰無仮説は強く棄却されている。なお、表に示されるAutocorrelation (AC) Partial Correlation (PAC) の点線は $\pm 2/\sqrt{n}$ で計算された2*標準誤差におおむね対応し、約5%の有意水準を示す。この点線の範囲内であれば系列相関はないという帰無仮説は棄却されない。

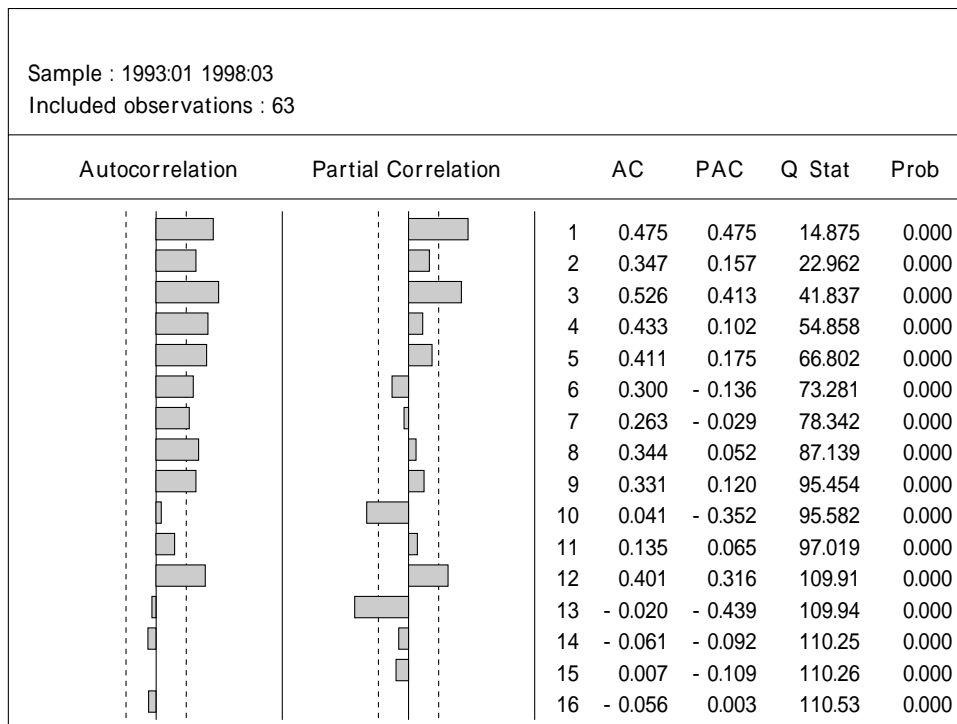
ACは9期までの各ラグと12期とも有意に0とは乖離している。PACは1~3期、9、10、12、13期で有意に0から乖離している。これからかなり複雑な系列相関(例えばARMA)のパターンがうかがわれる。

このような複雑なARMA構造は、経済データでは希である。モデルの定式化に誤りがあり、見せかけの系列相関の疑いがある。そこで説明変数に在庫率(ZAIKORI)を加えた推計を試みた。結果は次の通りである。

表5.1 Qテストとコレログラム

Sample : 1993:01 1998:03 Included observations : 63						
Autocorrelation	Partial Correlation	AC	PAC	Q Stat	Prob	
		1	0.514	0.514	17.419	0.000
		2	0.445	0.246	30.711	0.000
		3	0.598	0.432	55.095	0.000
		4	0.388	-0.065	65.551	0.000
		5	0.395	0.104	76.582	0.000
		6	0.351	-0.113	85.421	0.000
		7	0.258	-0.012	90.293	0.000
		8	0.289	0.012	96.528	0.000
		9	0.361	0.249	106.43	0.000
		10	0.078	-0.379	106.91	0.000
		11	0.128	0.069	108.20	0.000
		12	0.384	0.308	120.02	0.000
		13	0.009	-0.327	120.02	0.000
		14	0.017	-0.131	120.05	0.000
		15	0.065	-0.114	120.41	0.000
		16	-0.095	0.010	121.19	0.000

表5.2 Qテストとコレログラム



$$\text{IMPNUMBER}_t = 26.54 + 1.492\text{IIP}_t + 0.46\text{ZAIKORI}_t$$

(0.26) (3.93) (2.10)

$$- 0.55\text{JILTUKOU}_t - 0.54\text{SOUTAI}_t + \varepsilon_t \quad (5.49)$$

(-1.64) (-1.16)

AdjR² = 0.44 (R² = 0.476) SER = 9.30

DW = 1.015 期間 : 93年1月 - 98年3月

Q統計量は表5.2に掲げるとおりである。在庫率を説明変数に加えても、なお複雑な系列相関構造となっている。

次にLM検定を行ってみる。LM検定は

View/Residual Tests/Serial Correlation LM Test を選択し、やはりLag Specificationのダイアログにラグの次数を入れる。ラグの次数を16と選んだ結果は表5.3に示すとおりである。Obs*R squaredがLM統計量である。45.57でp値は0.000113であるから、系列相関はないという帰無仮説はここでも棄却されている（なおF統計量も

報告されているが、ラグの係数が全て0であるという制約を検定するものであり、厳密な分布に従うものではない。比較のために計算されているだけであるから、論文で報告する必要はない。

さらに説明変数として円ドルレート (YEN-DOLL) を加えてみる。実効為替レートを説明変数に含むので、円ドルレートを更に加える必要は無いとも考えられる。円高になればYENDOLLの値が小さくなるので、係数の符号は負が期待される。しかし各国の企業が市場に応じて価格設定を変えている (pricing to market) ならばドル建ての輸入とドル以外の通貨による輸入で異なる効果を持つことも考えられる¹⁷⁾。

$$\text{IMPNUMBER}_t = a + b_1\text{IIP}_t + b_2\text{ZAIKORI}_t + b_3\text{JILTUKOU}_t + b_4\text{YENDOLL}_t + b_5\text{SOUTAI}_t + \varepsilon_t$$

を推計するコマンドは次の通りである。

$$\text{equation eq5_3 } \text{ls IMPNUMBER C IIP}$$

¹⁷⁾ 厳密にはドルを除いた為替レートを考える必要があるが、ここでは便宜ドルを含む実効為替レートを取り上げる。

域となり、系列相関があるとも無いとも決定を下
 せない。そこでQテストとLMテストを試みる。
 結果は表5.4、5.5に掲げるとおりであるACか
 ら12次のAR項、PACから12次のMA項で系列相
 関があることがわかる(Durbin Watson
 テストは1次の系列相関を検定するもので、この
 ような高次の系列相関を検定するものではなかつ
 たことを思い出してほしい)。

LM検定は38.22でありp値は0.0014であるから
 系列相関はないという帰無仮説は強く棄却されて

いる。

なおここでWald検定の例を示しておくことに
 する。輸入に与える実効為替レートと円ドルレ
 ートの効果は正反対であるならば、実効為替レ
 ートと円ドルレートの係数は同一であろう¹⁸⁾。すなわ
 ち

$$b_3 = b_4, \text{ あるいは } b_3 - b_4 = 0$$

の制約が成立しているはずである。これを
 Eviewsで行ってみよう。

View/Coefficient Tests/Wald Coefficient Re-

表5.4 Qテストとコレログラム

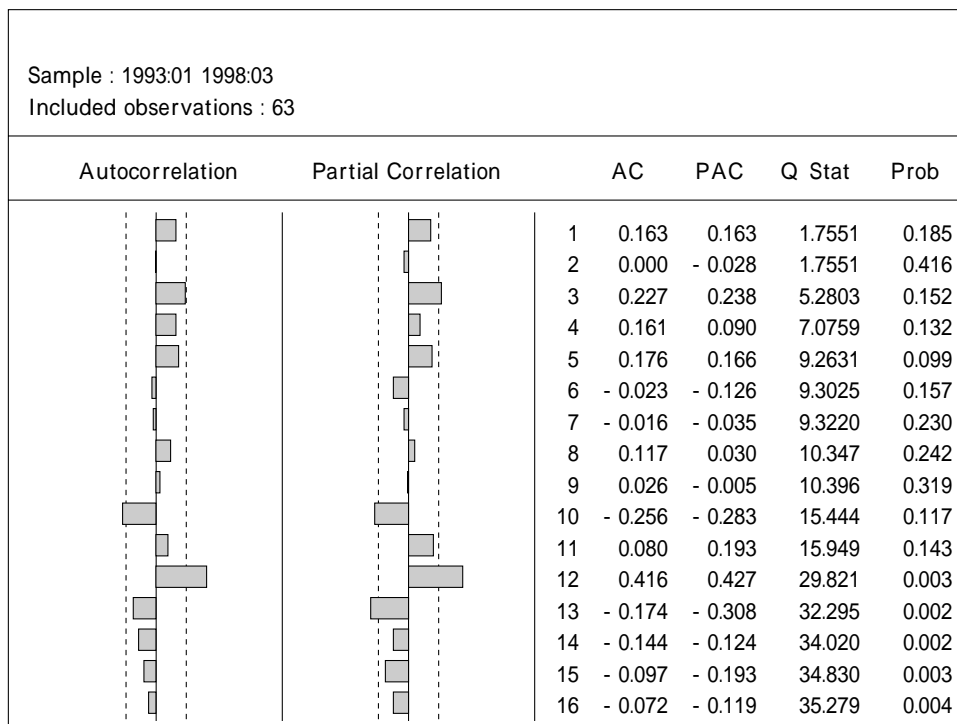


表5.5 LMテスト2

Breusch Godfrey Serial Correlation LM Test:

F statistic	3.953553	Probability	0.000191
Obs*R squared	38.22465	Probability	0.001406

Test Equation:

Dependent Variable: RESID

Method: Least Squares

(一部OUTPIUTを省略)

¹⁸⁾ この二つの変数の定義より円高になると円ドルレートは小さくなるが、実効為替レートは円高では大きくなる。効果が同じと
 という意味は円高のような変化の効果が同じということなので、制約は $b_3 = -b_4$ となる。

strictions
 を選択する。ダイアログに制約式
 $\alpha(4) - \alpha(5) = 0$
 を書き入れる（Eviewsは説明変数の順番を $\alpha(1)$ 、 $\alpha(2)$ 、 $\alpha(3)$..として認識する。この例ではJIL-TUKOUは説明変数の4番目、YENDOLLは説明変数の5番目である）。結果は図5.2に示すとおりである。EviewsではF統計量と χ^2 統計量が示される（この例では制約が1個であるから両者は同一である）。統計量は0.135、p値は0.713であるから帰無仮説は棄却されない。

円ドルレートと実効為替の効果が同一ならば、 $b_3 = -b_4$ 、あるいは $b_3 + b_4 = 0$ の制約が成立している。これはEviewsでは次のようにWald検定で行うことができる（表5.6）。

$\alpha(4) + \alpha(5) = 0$
 統計量は29.91、p値は0.000であるから、 $b_3 + b_4$

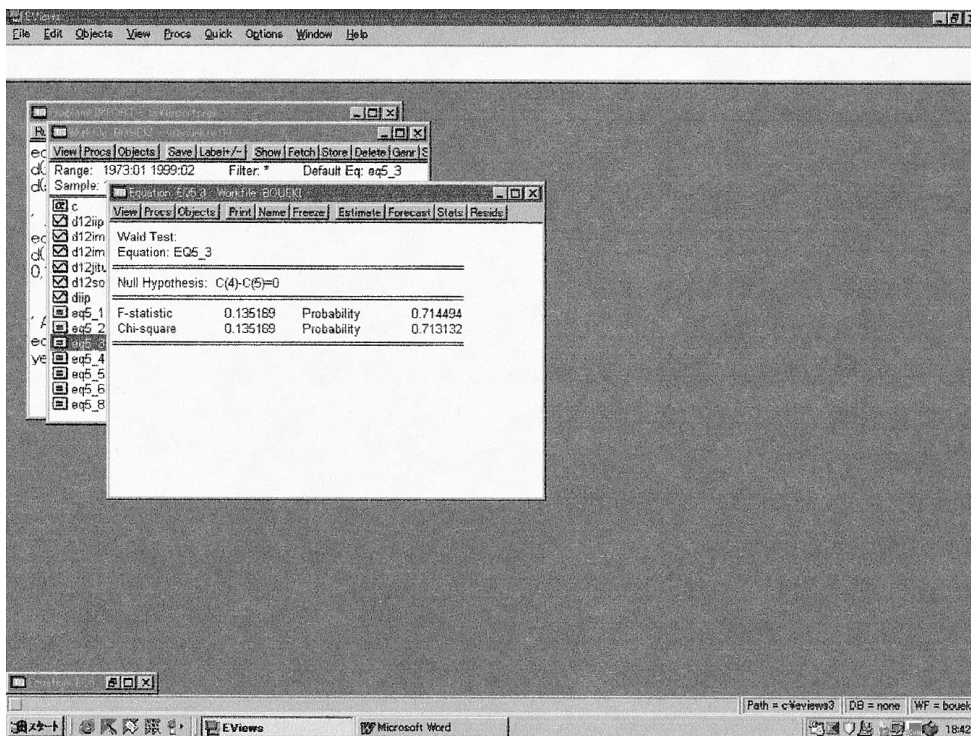
$= 0$ の帰無仮説は強く棄却されている。

このことから我が国の輸入市場は、ドル建てについてみると円安（ドル高、YENDOLLの値が大きくなる）では速やかな輸入の減少をもたらしているが、実効為替レートでみると円高（バスケットの通貨安、JILUKOUの値が大きくなる）も速やかな輸入の減少をもたらす、その効果が異なることが分かる。なお上記のWald検定を行うに際し、系列相関がないという前提が暗黙の裡におかれている。

5.48)、5.49)と5.50)の各式の推定結果から分かるように、重要な説明変数を落とすことによって強いかつ複雑な系列相関が生じる場合がある。ただしここでは5.50)式で見られる系列相関を真の系列相関として議論を進める¹⁹⁾。

次に系列相関のあることがLM検定で確かめられたので、Newey Westの一致性のある推定の例

図5.2 WALDテスト



¹⁹⁾ 5.50)式によると円高の効果は今期だけに生じると仮定する。この効果が完全に生じるまで時間がかかるのであれば5.50)式の特定化が間違っている。この問題について章を改めて詳述する。

表5.6 Waldテスト

Wald Test:

Equation: EQ5_3

Null Hypothesis: $\alpha(4) + \alpha(5) = 0$

F statistic	29.90863	Probability	0.000001
Chi square	29.90863	Probability	0.000000

表5.7 Newey Westの一致性のある推計

Dependent Variable: IMPNUMBER

Method: Least Squares

Sample (adjusted): 1993:01-1998:03

Included observations: 63 after adjusting endpoints

Newey West HAC Standard Errors & Covariance (lag truncation = 3)

Variable	Coefficient	Std. Error	t Statistic	Prob.
C	92.04623	104.0232	0.884863	0.3799
IIP	1.375849	0.345929	3.977254	0.0002
ZAİKORI	0.576975	0.175536	3.286932	0.0017
JILTUKOU	-0.873089	0.347340	-2.513644	0.0148
YENDOLL	-0.977469	0.199609	-4.896911	0.0000
SOUTAI	18.10679	41.07153	0.440860	0.6610
R squared	0.683691	Mean dependent var		96.28730
Adjusted R squared	0.655945	S.D. dependent var		12.43226
S.E. of regression	7.292297	Akaike info criterion		6.901907
Sum squared resid	3031.123	Schwarz criterion		7.106015
Log likelihood	-211.4101	F statistic		24.64070
Durbin Watson stat	1.604122	Prob (F statistic)		0.000000

をみてる。そのプログラムは次の通りである。

```
equation eq5_4 ls (n) IMPNUMBER C IIP
ZAİKORI JILTUKOU YENDOLL SOUTAI
(n) がNewey Westの一致性のある推定を行う
ためのオプションである。
```

結果は表5.7に掲げるとおりである。分散とt統計値の修正を行うだけであるから、パラメータの値や決定係数などの統計量は5.49)式と変わるところはない。

ここまでは季節調整を行っていない原輸入数量指数を使って分析してきた。そこでは12ヶ月前と

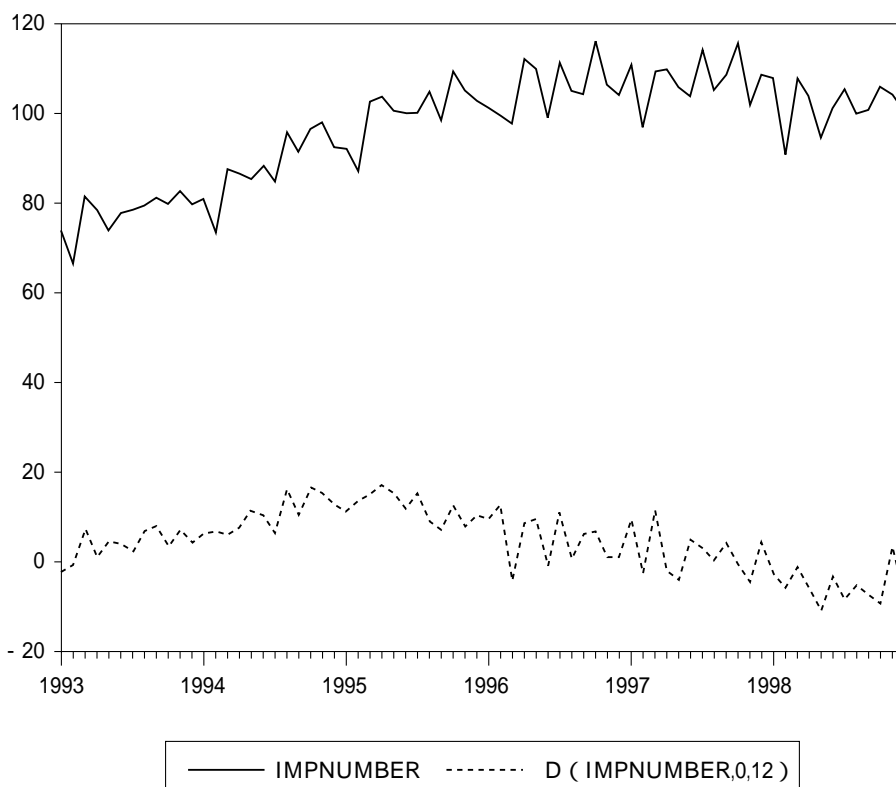
強い相関を持つことが疑われる(12次のAR項、12次のMA項はその可能性を示唆している)。季節変動を考慮する方法はいくつかがあるがここで12ヶ月前のデータとの階差をとり、両者の動きを比べてみよう。階差の取り方はEviewsでは2通りある。

```
series IMPN12=IMPNUMBER - IMPNUMBER(-12)
D(IMPNUMBER,0,12)
```

前者はラグをとり、 ${}_{12}y_t = y_t - y_{t-12}$ を計算するものである(ここではIMPN12と名付けて保存している)。

20) ラグオペレータ(L)は次のように定義する。 $Ly_t = y_{t-1}$ と $L^s y_t = y_{t-s}$ 。これを用いると以下のように表される。nを階差、sを季節変動(seasonal difference)とし、 $(1-L)y_t$ と $(1-L)^n(1-L^s)y_t$ を計算するコマンドはそれぞれD(y, n, 0)とD(y, n, s)となる。

図5.3 原データと階差をとったデータの動き



後者はDで階差をとることを指示し（階差をとる変数、季節階差、階差の数）を指示するものである²⁰⁾。IMPNUMBERとD(IMPNUMBER,0,12)をグラフ化したのが図5.3である。図から原データであるIMPNUMBERには周期的な変動があることがうかがえる。

そこで12期の階差をとったモデルを次に分析しよう。

$${}_{12}\text{IMPNUMBER}_t = a + b_1 {}_{12}\text{IIP}_t + b_2 {}_{12}\text{ZAIKORI}_t + b_3 {}_{12}\text{JILTUKOU}_t + b_4 {}_{12}\text{YENDOLL}_t + b_5 {}_{12}\text{SOUTAI}_t + e_t$$

を推計するコマンドは以下の通りである。

```
equation eq5_5 Js D(IMPNUMBER,0,12)
C D(IIP,0,12) D(ZAIKORI,0,12)
D(JILTUKOU,0,12) D(YENDOLL,0,12)
D(SOUTAI,0,12)
```

結果は表5.8に掲げるとおりである（なお階差をとっているので変化幅を分析するモデルとなって

おり、水準を説明する5.50)式とはもはや異なる経済モデルであることに留意する必要がある。被説明変数が違うので、R²等でモデルの当てはまり具合を比較するのは不適切である。

DWは1.717であるから、系列相関の有無については判断は下せない。QテストとLM検定を行おう。階差をとっているので12次までのラグを見る。

Qテスト（表5.8）では系列相関はないという帰無仮説は棄却されない。またLM検定統計量（表5.9）は20.198であり、p値は0.063であるから、帰無仮説は5%水準で棄却されない。

なお、このモデルをAR(1)、あるいはMA(1)で推計するには

```
equation eq5_6 Js D(IMPNUMBER,0,12)
C D(IIP,0,12) D(ZAIKORI,0,12)
D(JILTUKOU,0,12) D(YENDOLL,0,12)
D(SOUTAI,0,12) AR(1)
```

表5.8a Qテストとコレログラム

Date : 05/12/99 Time : 14:50						
Sample : 1993:01 1998:03						
Included observations : 63						
Autocorrelation	Partial Correlation	AC	PAC	Q Stat	Prob	
		1 0.136	0.136	1.2140	0.271	
		2 -0.003	-0.022	1.2146	0.545	
		3 0.212	0.219	4.2816	0.233	
		4 -0.047	-0.115	4.4348	0.350	
		5 0.012	0.052	4.4443	0.487	
		6 0.100	0.040	5.1637	0.523	
		7 -0.195	-0.196	7.9318	0.339	
		8 0.088	0.162	8.5070	0.386	
		9 0.250	0.184	13.240	0.152	
		10 -0.030	-0.010	13.308	0.207	
		11 0.181	0.156	15.899	0.145	
		12 -0.080	-0.262	16.410	0.173	

表5.8b 階差をとったモデルの推計

Dependent Variable: D(IMPNUMBER, 0, 12)

Method: Least Squares

Sample (adjusted) 1993:01-1998:03

Included observations: 63 after adjusting endpoints

Variable	Coefficient	Std. Error	t Statistic	Prob.
C	4.344512	0.561654	7.735213	0.0000
D(IMP, 0, 12)	1.271700	0.219176	5.802187	0.0000
D(ZAIKORI, 0, 12)	0.033550	0.109414	0.306629	0.7602
D(JILTUKOU, 0, 12)	-0.547483	0.112827	-4.852417	0.0000
D(YENDOLL, 0, 12)	-0.424744	0.085273	-4.980978	0.0000
D(SOUTAI, 0, 12)	-55.31297	18.10942	-3.054376	0.0034
R squared	0.643531	Mean dependent var		6.177778
Adjusted R squared	0.612262	S.D. dependent var		6.067030
S.E. of regression	3.777857	Akaike info criterion		5.586584
Sum squared resid	813.5156	Schwarz criterion		5.790692
Log likelihood	-169.9774	F statistic		20.58033
Durbin - Watson stat	1.717375	Prob (F statistic)		0.000000

表5.9 LMテスト3

Breusch Godfrey Serial Correlation LM Test:

F statistic	1.769586	Probability	0.083356
Obs*R squared	20.19788	Probability	0.063434

Test Equation:

Dependent Variable: RESID

Method: Least Squares

Variable	Coefficient	Std. Error	t Statistic	Prob.
C	0.562892	0.727675	0.773549	0.4432
D(IIP, 0, 12)	-0.059239	0.261016	-0.226955	0.8215
D(ZAIKORI, 0, 12)	-0.037406	0.130654	-0.286301	0.7760
D(JILTUKOU, 0, 12)	0.148264	0.181231	0.818096	0.4176
D(YENDOLL, 0, 12)	0.179200	0.166667	1.075196	0.2880
D(SOUTAI, 0, 12)	-0.386211	18.44072	-0.454766	0.6515
RESID (- 1)	0.239484	0.150504	1.591217	0.1186
RESID (- 2)	0.025090	0.161030	0.155810	0.8769
RESID (- 3)	0.250894	0.149027	1.683545	0.0992
RESID (- 4)	0.070718	0.169178	0.418009	0.6779
RESID (- 5)	0.073159	0.167013	0.438044	0.6634
RESID (- 6)	0.221079	0.182753	1.209717	0.2327
RESID (- 7)	-0.179354	0.167107	-1.073288	0.2889
RESID (- 8)	0.183930	0.168009	1.094760	0.2794
RESID (- 9)	0.409237	0.178827	2.288454	0.0269
RESID (- 10)	0.036932	0.181682	0.203277	0.8398
RESID (- 11)	0.185161	0.202811	0.912973	0.3661
RESID (- 12)	-0.370845	0.218846	-1.694546	0.0971
R squared	0.320601	Mean dependent var	1.82E - 15	
Adjusted R squared	0.063940	S.D. dependent var	3.622322	
S.E. of regression	3.504605	Akaike info criterion	5.580989	
Sum squared resid	552.7015	Schwarz criterion	6.193313	
Log likelihood	-157.8012	F statistic	1.249120	
Durbin Watson stat	2.085869	Prob (F statistic)	0.268513	

equation eq5_7 Is D(IMPNUMBER 0,12) D(IIP 0,12) D(ZAIKORI 0,12) D(JILTUKOU 0,12) D(YENDOLL 0,12) D(SOUTAI 0,12) MA(1) としてやればよい。このように分析者が考える次数を加えてやればよい (AR(3)を考えるのであれば、AR(1)、AR(2)、AR(3)と定式化する。MA(2)を考えるのであればMA(1)、MA(2)とする (なお計量の教科書ではAR(p)、MA(q)というときAR(1)からAR(p)、MA(1)からMA(q)の全てのラグを含むが、Eviewsのプログラムの表記はこれ

とは若干異なることに留意されたい)。参考までにAR(1)の結果を掲げておく (表5.10)。下欄にARが定常性を満たしているかどうか、INVERTED AR Roots (反転可能であったかどうか) の形で示されている。この場合0.22 < 1であるから定常性を満たしている。(反転不能であればEstimated AR process is noninvertibleと表示される)。AR(1)の係数は統計的に有意ではない。最後にARMAモデルの例を掲げておく。5.50) 式の結果では12次のAR項、12次のMA項が示唆されていた。この推計プログラムは次の通りであ

表5.10 AR(1)モデルの推定

Dependent Variable: D (IMPNUMBER 0 ,12)
 Method: Least Squares
 Sample (adjusted) 1993: 01 1998: 03
 Included observations : 63after adjusting endpoints
 Convergence achieved after 7 iterations

Variable	Coefficient	Std. Error	t Statistic	Prob.
C	4.378128	0.704811	6.211780	0.0000
D(IIP, 0, 12)	1.383855	0.260039	5.321726	0.0000
D(ZAIKORI, 0, 12)	-0.018913	0.133558	-0.141610	0.8879
D(JILTUKOU, 0, 12)	-0.525707	0.135708	-3.873821	0.0003
D(YENDOLL, 0, 12)	-0.351130	0.105363	-3.332559	0.0015
D(SOUTAI, 0, 12)	-64.87948	21.30726	-3.044947	0.0035
AR (1)	0.219393	0.142315	1.541602	0.1288
R squared	0.653690	Mean dependent var		6.177778
Adjusted R squared	0.616586	S.D. dependent var		6.067030
S.E. of regression	3.756733	Akaike info criterion		5.589415
Sum squared resid	790.3303	Schwarz criterion		5.827541
Log likelihood	-169.0666	F statistic		17.61750
Durbin Watson stat	1.973934	Prob (F statistic)		0.000000
Inverted AR Roots	22			

る。

equation eq5_8 Is IMPNUMBER C IIP
 ZAIKORI JILTUKOU YENDOLL SOUTAI
 AR(12) MA(12)
 ここではAR(1) = AR(2) = ... = AR(11) = 0 とMA

(1) = MA(2) = ... = MA(11) = 0 が仮定されている。
 すなわち12次の項のみが分析対象となっている。
 結果を見ると (表5.11) MAは反転可能であるが、
 ARの推計値に1.0や -1.00が含まれており、定常
 性に問題があることが示唆されている²¹⁾。

²¹⁾ ARMAを推定するのに色々な問題があるが一つは識別問題 (identification problem) である。この例では誤差項の過程は $e_t = e_{t-1} + u_t + u_{t-1}$ となり、 $e_t = u_t$ であればこの過程と $e_t = u_t$ を識別することができない。推定結果をみると $e_t = u_t$ が成り立たないか、その状態に近いことがうかがわれる。

表5.11 AR(12)MA(12)モデルの推計

Dependent Variable: IMPNUMBER
 Method: Least Squares
 Sample (adjusted) 1993: 011998: 03
 Included observations: 63after adjusting endpoints
 Convergence achieved after70iterations
 Backcast: 1992: 011992: 12

Variable	Coefficient	Std. Error	t Statistic	Prob.
C	502.6149	1028.534	0.488671	0.6270
IIP	1.120080	0.273624	4.093505	0.0001
ZAİKORI	-0.047022	0.150526	-0.312387	0.7559
JILTUKOU	-0.417238	0.128774	-3.240088	0.0020
YENDOLL	-0.388099	0.101032	-3.841359	0.0003
SOUTAI	-45.83807	23.28594	-1.968487	0.0541
AR (12)	0.985839	0.038383	25.68458	0.0000
MA (12)	-0.832435	0.044706	-18.62029	0.0000
R squared	0.935511	Mean dependent var		96.28730
Adjusted R squared	0.927303	S.D. dependent var		12.43226
S.E. of regression	3.352030	Akaike info criterion		5.375176
Sum squared resid	617.9858	Schwarz criterion		5.647320
Log likelihood	-161.3180	F statistic		113.9795
Durbin Watson stat	1.990884	Prob (F statistic)		0.000000
Inverted AR Roots	1.00	.86 - .50i	.86 + .50i	.50 + .86i
		.50 - .86i	-.00 - 1.00i	-.50 + .86i
		-.50 - .86i	-.86 - .50i	-.86 + .50i
				-1.00
Inverted MA Roots	.98	.85 + .49i	.85 - .49i	.49 + .85i
		.49 - .85i	-.00 + .98i	-.49 - .85i
		-.49 + .85i	-.85 - .49i	-.85 - .49i

参考文献

系列関連の問題は、計量経済学の教科書では例外なく触られている。

本章の理解を深める上では、以下のものが参考となろう。

山本拓 [1988] 『経済の時系列分析』創文社の第2章～第4章は、AR、MAモデルに詳しい。

Kmenta, J [1997] *Elements of Econometrics*, Michigan Ch8 3

Hill, R., Griffiths, W and G. Judge [1997] *Undergraduate ECONOMETRICS*, John Wiley & SonsのCh11は、DW統計などを分かりやすく説明している。

Davidson, R and J. MacKinnon [1993] *Estimation and Inference in Econometrics*, Oxford University Press Ch10

Johnston, J and J. DiNardo [1997] *ECONOMETRIC METHOD*, McGraw Hill Ch6 6～6.9, Ch7 .1～7.2

Greene, W [1997] *ECONOMETRIC ANALYSIS (3rd)*, PrnticeHall CH13

はAR、MAやNewey Westなどについても詳しい。