

平成 28 年度 計量経済理論
講義ノート 6 定常時系列解析

このノートでは簡単な一変量の時系列モデルとその分析方法を解説する。まず、系列相関とそれを調べる統計的手法を紹介し、時系列の代表的なモデルである自己回帰移動平均モデルとその統計的分析法を解説する。また、自己回帰モデルを用いた予測法にも触れる。

6.1 時系列データ

時系列データとは、各年の我が国の GDP データのように、時間を追って観測されるデータである。経済において主たるものは GDP を始め、金利や貿易その他のマクロデータである。また、近年はデータ整備の技術進歩に伴って、株価や為替レートの高頻度データの蓄積が進んでおり、これらも時系列データである。

$\{y_t\}_{t=1}^T$ を時系列データとする。時系列データでは、 y_t と y_{t-j} は相関しているかもしれない。そのような相関を系列相関あるいは自己相関という。時系列分析は、その動学的性質を分析の対象とする。

y_{t-j} を y_t の j 次のラグといい、それらの共分散 $cov(y_t, y_{t-j})$ を自己共分散という。

定常性 同時分布が時間を通じて変わらないことを（強）定常性という。

例えば、 y_t と y_{t-j} の同時分布が t に依存しないということである。特に、定常な時系列においては、

- $E(y_t) = \mu$ (平均が t に依存していない)。
- $var(y_t) = \gamma_0$ (分散が t に依存していない)。
- $cov(y_t, y_{t-j}) = \gamma_j$ (共分散が t に依存していない)。なお、 γ_j を j 次の自己共分散という。

が成り立ち、このように平均と自己共分散が j のみに依存し t に依存していない場合、弱定常または共分散定常であるという。定常なら弱定常であるが、逆は必ずしも成り立たない。また、平均が 0 で 1 次以上の自己共分散がすべて 0 の弱定常な時系列をホワイトノイズという。

定常性が満たされない例で、経済学上重要なものは、

- トレンドがある場合、
- 確率的トレンドがある場合 (単位根など)、
- 構造変化がある場合、

などである。定常性がない時系列を非定常時系列という。非定常時系列の分析は、この講義では取り扱わないが、経済時系列の解析においては非常に重要なトピックである。

6.2 自己共分散と自己相関係数

自己共分散と自己相関係数は変数の系列相関を表現する基本的なパラメーターである。

$\gamma_j = cov(y_t, y_{t-j})$ を j 次の自己共分散として、
 j 次の自己相関係数は、

$$\rho_j = \frac{Cov(y_t, y_{t-j})}{\sqrt{var(y_t)}\sqrt{var(y_{t-j})}} = \frac{\gamma_j}{\gamma_0} \quad (1)$$

である。

自己相関を調べることは時系列解析の第一歩である。横軸に j をとり、縦軸に ρ_j をとるグラフをピリオドグラムという。

推定 自己共分散は、標本自己共分散

$$\hat{\gamma}_j = \frac{1}{T} \sum_{t=j+1}^T (y_t - \bar{y})(y_{t-j} - \bar{y}) \quad (2)$$

によって推定できる。ここで、 $\bar{y} = \sum_{t=1}^T y_t / T$ である。

また自己相関係数は、標本自己相関係数

$$\hat{\rho}_j = \frac{\hat{\gamma}_j}{\hat{\gamma}_0} \quad (3)$$

によって推定できる。

これらの推定量は、ある条件のもとで、一致性と漸近正規性を持つ。しかし、その証明、漸近分散の式はかなり複雑なので、ここでは取り扱わない。

一方で、もし、 y_t が i.i.d. であるなら、 $\rho_0 = 1$ 、他の自己相関係数はすべて 0 であり、また

$$\sqrt{T}\hat{\rho}_j \rightarrow_d N(0, 1) \quad (4)$$

となる。推定された自己相関係数でピリオドグラムを描くとき、合わせて $\pm 1/\sqrt{T}$ や $\pm 1.96/\sqrt{T}$ の横線を書くことがよくある。それは、上の結果を用いて帰無仮説 $\rho_j = 0$ を検定する際の棄却域を示している。すなわち、 $\pm 1.96/\sqrt{T}$ の線を超えているなら、系列相関があると結論付ける。

系列相関の検定 上の方法によって、各 j に対して $\rho_j = 0$ を検定することが可能である。一方、最初のいくつかの相関係数をまとめて系列相関の有無を検定することもできる。頻繁に使われるのは以下の二つの検定統計量である。

$$\text{Box-Pierce 検定統計量: } Q = T \sum_{k=1}^p \hat{\rho}_k^2, \quad (5)$$

$$\text{Ljung-Box 検定統計量: } Q = T(T+2) \sum_{k=1}^p \frac{\hat{\rho}_k^2}{T-k}, \quad (6)$$

なお、 p は研究者が適当に選ぶ。これは、 p 次までの自己相関を見て、もし、どれかの自己相関が大きければ、検定統計量が大きくなるという性質を使って、検定するものである。

これらの二つの検定統計量は y_t が i.i.d. であるという帰無仮説のもとで、 χ_p^2 の分布を持つ。

これらの検定は、いくつもの自己相関をまとめて検定するという意味で、ふろしき検定やかばん検定と呼ばれる。

6.3 自己回帰移動平均モデル

時系列構造を表現するために最もよく使われるモデルは、自己回帰移動平均モデル (Autoregressive and moving average model, ARMA model) である。まず自己回帰の部分について述べ、次に移動平均を説明し、最後にそれらを合わせた ARMA モデルを紹介する。

自己回帰モデル 現在の値が過去の値とホワイトノイズから決まるモデルを自己回帰モデルという。その最も単純なものが下の1次の自己回帰モデル (AR(1) モデル) で、過去一期分のみに依存している場合である。

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + u_t \quad (7)$$

ここで、 α_0 と α_1 はパラメーターであり、 $u_t \sim i.i.d.(0, \sigma^2)$ は誤差項で、ノイズ、イノベーション等と呼ばれる。

これは、分散均一を仮定した回帰モデルと見ることができる。分散均一は強い仮定かもしれないが、理論分析を簡単にする。分散不均一を表現するモデルには ARCH や GARCH 等のモデルがあり、マクロ時系列分析や金融時系列分析において広く使われているが、少し難しいためこの講義では取り扱わない。

AR(1) のラグ次数を一般化した

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + u_t \quad (8)$$

を AR(p) モデルという。

定常性の条件 AR モデルで表現できる時系列が弱定常性を持つための条件は、

$$1 - \alpha_1 x - \alpha_2 x^2 - \dots - \alpha_p x^p = 0 \quad (9)$$

という方程式の解の絶対値がすべて 1 より大きいことである。

AR(1) の場合、定常性の条件は、

$$|\alpha_1| < 1 \quad (10)$$

である。

AR(2) の場合は、 $\alpha_1 + \alpha_2 < 1$, $\alpha_2 - \alpha_1 < 1$, $-1 < \alpha_2 < 1$ となる。

一般の AR(p) モデルの場合に定常性の条件を求めることも可能だが、その条件は複雑な式になる。

自己回帰モデルの平均と分散 定常な AR(1) モデルの平均と分散は次のようにして求めることができる。 $E(y_t) = \mu$ とする。

AR(1) の式の両辺の期待値をとると、

$$E(y_t) = \alpha_0 + \alpha_1 E(y_{t-1}) + E(u_t) \quad (11)$$

となるが、 $E(y_t) = E(y_{t-1}) = \mu$ かつ $E(u_t) = 0$ なので

$$\mu = \alpha_0 + \alpha_1 \mu \quad (12)$$

となり、期待値

$$\mu = \frac{\alpha_0}{1 - \alpha_1} \quad (13)$$

が得られる。

AR(1) の式から (12) を引くと

$$y_t - \mu = \alpha_1(y_{t-1} - \mu) + u_t \quad (14)$$

となり、この両辺に u_t をかけて期待値をとると、

$$E\{(y_t - \mu)u_t\} = \alpha_1 E\{(y_{t-1} - \mu)u_t\} + E\{u_t^2\} = \sigma^2 \quad (15)$$

となる。

同じく両辺に $(y_t - \mu)$ をかけて期待値をとると、

$$E\{(y_t - \mu)^2\} = \alpha_1 E\{(y_{t-1} - \mu)(y_t - \mu)\} + E\{u_t(y_t - \mu)\} \quad (16)$$

となり、上の結果を代入して

$$\gamma_0 = \alpha_1 \gamma_1 + \sigma^2 \quad (17)$$

が得られる。さらに、AR(1) の式に $(y_{t-1} - \mu)$ をかけて期待値をとると、

$$E\{(y_t - \mu)(y_{t-1} - \mu)\} = \alpha_1 E\{(y_{t-1} - \mu)^2\} + E\{u_t(y_{t-1} - \mu)\} \quad (18)$$

となるが、これは、

$$\gamma_1 = \alpha_1 \gamma_0 \quad (19)$$

となる。以上の結果より、

$$\gamma_0 = \frac{\sigma^2}{1 - \alpha_1^2}, \quad (20)$$

$$\gamma_1 = \frac{\alpha_1 \sigma^2}{1 - \alpha_1^2} \quad (21)$$

となる。同様に、

$$\gamma_j = \alpha_1^j \gamma_0 = \frac{\alpha_1^j \sigma^2}{1 - \alpha_1^2} \quad (22)$$

であることを示すことができる。

AR(p) モデルの場合も同じように平均と自己共分散を計算することができる。

また AR(1) モデルの自己相関は、

$$\rho_j = \frac{\gamma_j}{\gamma_0} = \alpha_1^j \quad (23)$$

である。

移動平均モデル 以下のように、現在の値が現在と過去 q 期のイノベーションに依存して決まるモデルを移動平均モデル (MA(q) モデル) という。

$$y_t = \theta_0 + \epsilon_t - \theta_1 \epsilon_{t-1} - \dots - \theta_q \epsilon_{t-q} \quad (24)$$

ここで、 $\epsilon_t \sim i.i.d.(0, \sigma^2)$ とする。

移動平均モデルが常に弱定常であることは、次のように簡単に示すことができる。

MA(q) モデルに従う y_t の期待値は、

$$\mu = E(y_t) = E(\theta_0 + \epsilon_t - \theta_1 \epsilon_{t-1} - \dots - \theta_q \epsilon_{t-q}) = \theta_0 \quad (25)$$

であり、分散は、

$$\gamma_0 = E(y_t - \theta_0)^2 = E(\epsilon_t^2) + \theta_1^2 E(\epsilon_{t-1}^2) + \dots + \theta_q^2 E(\epsilon_{t-q}^2) = (1 + \theta_1^2 + \dots + \theta_q^2) \sigma^2 \quad (26)$$

である。また 1 次の自己共分散は、

$$\gamma_1 = E(y_t y_{t-1}) - \mu^2 = (-\theta_1 + \theta_1 \theta_2 + \dots + \theta_{q-1} \theta_q) \sigma^2 \quad (27)$$

のようになる。なお、($q+1$) 次以上の自己共分散は 0 である。

MA モデルで注意しなくてはならないのは、識別性の問題である。AR モデルの場合は、モデルのパラメータ (係数とイノベーションの分散) が与えられれば自己共分散の系列が決まり、逆に自己共分散の系列を決めるとモデルのパラメータが一意に決まる。この意味で、AR モデルのパラメータは識別性をもつという。それに対して、MA モデルの場合はそうならない。例えば、MA(1) モデルに基づいて計算すると、自己共分散は、

$$\gamma_0 = (1 + \theta_1^2) \sigma^2, \quad \gamma_1 = -\theta_1 \sigma^2 \quad (28)$$

それ以上の自己共分散は 0 となる。逆に、 γ_0, γ_1 を定めたときに、ある θ_1 と σ^2 の組み合わせと、 $1/\theta_1$ と $\theta_1^2 \sigma^2$ の組み合わせは同じ自己共分散をもたらすことが分かる。(つまり (28) を θ_1 と σ^2 について解くと解が二つある) それゆえ、データから観測できる自己共分散をみても、MA モデルのパラメーターの値を一意に決めることができない。しかし、 $|\theta_1| \leq 1$ とすると、唯一に決めることができる。通常は、この識別性の条件を仮定する。一般に、

$$1 - \theta_1 x - \theta_2 x^2 - \dots - \theta_q x^q = 0 \quad (29)$$

の方程式の解の絶対値がすべて 1 以上 (1 を含む) であれば、識別可能であることが知られている。

AR モデルと MA モデルの関係 定常な AR モデルは、MA(∞) モデルで表現することができる。例えば、AR(1) モデルは、

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + u_t \quad (30)$$

$$= \alpha_0 + \alpha_1 (\alpha_0 + \alpha_1 y_{t-2} + u_{t-1}) + u_t \quad (31)$$

$$= \alpha_0 + \alpha_1 \alpha_0 + \alpha_1^2 (\alpha_0 + \alpha_1 y_{t-3} + u_{t-2}) + u_t + \alpha_1 u_{t-1} \quad (32)$$

$$\dots \quad (33)$$

$$= \frac{\alpha_0}{1 - \alpha_1} + \sum_{j=0}^{\infty} \alpha_1^j u_{t-j} \quad (34)$$

となる。

また追加的な条件を置けば、MA モデルも AR(∞) モデルで表現できる。その条件を、反転可能性の条件という。それは、

$$1 - \theta_1 x - \theta_2 x^2 - \dots - \theta_q x^q = 0 \quad (35)$$

の方程式の解の絶対値がすべて 1 より大きい (1 を含まない) ということである。識別可能性との違いは、解の絶対値が 1 である場合が許されるかどうかである。例えば、MA(1) のとき、 $|\theta_1| < 1$ のとき反転可能であり、

$$y_t = \frac{\theta_0}{1 - \theta_1} - \sum_{j=1}^{\infty} \theta_1^j y_{t-j} + \epsilon_t \quad (36)$$

となる。MA(1) で $|\theta_1| = 1$ のとき、識別可能ではあるが、反転可能ではない。

自己回帰移動平均モデル AR モデルと MA モデルを組み合わせたものを自己回帰移動平均モデル (ARMA(p, q) モデル) という。 p, q はそれぞれ、自己回帰部分と移動平均部分のラグの次数である。モデルは、

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + \epsilon_t - \theta_1 \epsilon_{t-1} - \dots - \theta_q \epsilon_{t-q} \quad (37)$$

とかける。 $\epsilon_t \sim i.i.d.(0, \sigma^2)$ と仮定する。

定常性の条件は、AR モデルと同じで、方程式

$$1 - \alpha_1 x - \alpha_2 x^2 - \dots - \alpha_p x^p = 0 \quad (38)$$

の解の絶対値がすべて 1 より大きいことである。また、反転可能性の条件は、MA モデルと同じで、

$$1 - \theta_1 x - \theta_2 x^2 - \dots - \theta_q x^q = 0 \quad (39)$$

の解の絶対値がすべて 1 より大きいことである。

6.4 自己回帰モデルの推定

AR モデルは、OLS で推定できる。

つまり、定数項を含む AR(p) モデルは、

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + u_t \quad (40)$$

であるが、この係数 $\alpha = (\alpha_0, \dots, \alpha_p)'$ の推定量は、 $x_t = (1, y_{t-1}, \dots, y_{t-p})'$ と表記すると、 α の OLS 推定量は

$$\hat{\alpha} = \left(\sum_{t=p+1}^T x_t x_t' \right)^{-1} \sum_{t=p+1}^T x_t y_t \quad (41)$$

である。時系列が定常で誤差項が $\epsilon_t \sim i.i.d.(0, \sigma^2)$ なら、 $\hat{\alpha}$ は一致で漸近正規な推定量である。ただし、通常の線形回帰の場合と異なり、不偏性は持たない。これらの証明はこの講義では取り扱わない。

なお MA モデルや ARMA モデルについては、通常イノベーションに正規分布を仮定した最尤法を使って推定する。複雑なのでここでは取り扱わないが、EViews 等の統計ソフトではプログラムが実装されており、簡単に推定できる。

ラグの選び方 ARモデルでは、どこまでの次数のラグをモデルに含めるかによって、推定結果や（以下で扱う）予測が変わってしまう。経済モデルからラグの長さが決まる場合もあるが、通常はラグの長さは先験的に明らかではない。

良く使用されるラグの選び方は、情報量基準によるものである。代表的な情報基準としては、赤池情報量基準 (AIC) やベイズ情報量基準 (BIC) 等がある。

AIC は、

$$AIC(p) = \log \left(\frac{\sum_{t=p+1}^T \hat{u}_t(p)^2}{T} \right) + (p+1) \frac{2}{T} \quad (42)$$

である。ここで、 $\hat{u}_t(p) = y_t - \hat{\alpha}_0 - \hat{\alpha}_1 y_{t-1} - \dots - \hat{\alpha}_p y_{t-p}$ であり、 $\hat{\alpha}_j$ は OLS 推定量である。AIC の第一項はフィットの良さを測る指標である。線形回帰分析の章で説明したとおり、説明変数の数（ここでは $p+1$ ）を増やしていけば自動的にフィットは良くなってしまふ。そこで、第二項を加えることによって、説明変数のを増やし過ぎに対する罰則（ペナルティー）を与えている。色々な p に対して推定を行って AIC を計算し、それが最小化になる p を選ぶ。

また BIC は

$$BIC(p) = \log \left(\frac{\sum_{t=p+1}^T \hat{u}_t(p)^2}{T} \right) + (p+1) \frac{\log T}{T} \quad (43)$$

である。AIC と同じように、BIC と最小化する p を選ぶ。

AIC と BIC のどちらを使用するかは状況や目的による。もし、真のモデルが AR(p) モデルの場合は、BIC で p を一貫性をもって推定できる。

ここでは、 T で割っているが、Ng and Perron (2000) によると、 $T - p_{\max}$ で割るのが適切であろうとのことである。 p_{\max} は、考慮する最大の p の値である。ただしこの場合、 p_{\max} を前もって決める必要がある。

AIC や BIC の厳密な定義は、使用する統計ソフトによって違うことがあるので、注意が必要である。

6.5 予測

次に、ARモデルを使用して、 h 期先の y の値を予測する方法を解説する。

まず、AR(1) で、パラメーターの値がわかっている場合を考える。

$$y_{T+h} = \alpha_0 + \alpha_1 y_{T+h-1} + u_{T+h} \quad (44)$$

$$= \alpha_0 + \alpha_0 \alpha_1 + \alpha_1^2 y_{T+h-2} + u_{T+h} + \alpha_1 u_{T+h-1} \quad (45)$$

$$\dots \quad (46)$$

$$= \frac{(1 - \alpha_1^h) \alpha_0}{1 - \alpha_1} + \alpha_1^h y_T + \sum_{j=0}^{h-1} \alpha_1^j u_{T+h-j} \quad (47)$$

であるので、 $E_T(\cdot)$ を T 期までの情報での条件付き期待値とすると、

$$E_T(y_{T+h}) = \frac{(1 - \alpha_1^h) \alpha_0}{1 - \alpha_1} + \alpha_1^h y_T \quad (48)$$

となる。これを y_{T+h} の T 期までの情報に基づいた予測値として使う。

この予測誤差の分散は、

$$\text{var}_T(y_{T+h}) = \sigma^2 \sum_{j=0}^{h-1} \alpha_1^{2j} = \sigma^2 \frac{1 - \alpha_1^{2h}}{1 - \alpha_1^2} \quad (49)$$

である。

なお、 $h \rightarrow \infty$ とすると、予測値は、

$$\frac{\alpha_0}{1 - \alpha_1} \quad (50)$$

となり、 y_t の（条件付きでない）期待値に一致する。また予測誤差の分散は、

$$\sigma^2 \frac{1}{1 - \alpha_1^2} \quad (51)$$

で有界であり、同じく y_t の（条件付きでない）分散に一致する。つまり、はるか先の y_t の値を予測する際には、それまでに観察された y_t の値は役に立たず、単に、 y_t の期待値を使用することと同じになる。

一般に AR(p) モデルの場合も同じように議論できる。

パラメーターの値がわかっていない場合には、パラメーターを推定値で置き換え、

$$\frac{(1 - \hat{\alpha}_1^h) \hat{\alpha}_0}{1 - \hat{\alpha}_1} + \hat{\alpha}_1^h y_T \quad (52)$$

で予測を行う。予測誤差には、パラメーターの推定誤差も考慮する必要がある。しかし、 T が十分に大きい場合には、一致性により、推定誤差の予測誤差への影響は軽微であることが分かるので、予測誤差の分散を単に

$$\hat{\sigma}^2 \frac{1 - \hat{\alpha}_1^{2h}}{1 - \hat{\alpha}_1^2} \quad (53)$$

として推定することもよく行われる。ただし、 $\hat{\sigma}^2 = \frac{1}{T} \sum_{t=2}^T (y_t - \hat{\alpha}_0 - \hat{\alpha}_1 y_{t-1})^2$ とする。

MA モデルや ARMA モデルの場合も同様の議論が成り立つが、予測には、 ϵ_t の値を推定する必要があり、若干面倒になる。