



時系列分析 1

時系列分析の基礎

担当： 長倉 大輔
(ながくらだいすけ)

時系列分析の基礎


- 時系列データとは？

時系列データとは、時間の推移とともに観測されるデータの事です。例えば、為替レート、株価、国内総生産(GDP)、インフレ率などのようなデータです。観測される**順番**に意味のある事が大きな特徴です。


- 時系列分析とは？

時系列分析とは時系列データを分析するための手法です。


TOPIX



実効為替レート



鉍工業生産指数



時系列分析とは？

■ 時系列分析の応用

時系列分析の応用には分析の目的にもよりますが、おおざっぱに言って

1. データの特徴を捉える。
2. 経済理論などの検証
3. 時系列変数の予測

などが挙げられます。

時系列分析の基礎

■ 時系列データの表し方

観測点を t で表し、その時点における観測値を y_t などと表します。時点 $t=1, \dots, T$ までのデータの集合

$$\{ y_1, y_2, \dots, y_T \}$$

は $\{ y_t \}_{t=1}^T$ などと表されます。

時系列分析の基礎

■ 時系列データの種類

時系列データそのものは**原系列**とよばれます。原系列データに様々な変換を施して、新たな時系列データを作る事ができます。

■ よく使われる変換

原系列への変換としてよく使われる変換に**対数変換**と**階差をとる**という2つの変換があります。対数変換とは $\log y_t$ のように y_t の対数をとる事、階差をとるとは $y_t - y_{t-1}$ のように1時点離れたデータとの差を取る事です。

時系列分析の基礎

- 対数差分による変化率
(通常の変化率の定義)

$$\frac{y_t - y_{t-1}}{y_{t-1}}$$

- (対数差分による変化率)


$$\log y_t - \log y_{t-1}$$

変化率が小さい時


$$\log y_t - \log y_{t-1} = \log \frac{y_t}{y_{t-1}} = \log \left(1 + \frac{y_t - y_{t-1}}{y_{t-1}} \right) \approx \frac{y_t - y_{t-1}}{y_{t-1}}$$

が成り立ちます。

TOPIXの変化率



TOPIX (対数差分による)変化率



時系列分析の基礎

■ 基本統計量

データの性質を要約する統計量を基本統計量といいます。時系列データに関する基本統計量として代表的なものには

1. **期待値**
2. **分散**
3. **標準偏差(ボラティリティ)**
4. **自己共分散**
5. **自己相関係数**

などがあります。

時系列分析の基礎

■ 期待値と分散

y_t の期待値は $E(y_t)$ 、分散は $\text{var}(y_t)$ と表されます。

それぞれ、通常の期待値や分散と同じ定義
(つまり分散は $\text{var}(y_t) = E[(y_t - \mu_t)^2]$ と定義されます。
ここで $\mu_t = E(y_t)$ です)。解釈の仕方も同じ。

注) μ_t に下付き文字 t がついている事に注意。
一般には y_t と y_{t-1} の期待値、分散は**異なります**。

時系列分析の基礎

■ 自己共分散

時点 t における k 次の自己共分散 γ_{kt} は次のように定義されます。

$$\gamma_{kt} = \text{cov}(y_t, y_{t-k}) = E[(y_t - \mu_t)(y_{t-k} - \mu_{t-k})]$$

ここで $\mu_t = E(y_t)$, $\mu_{t-k} = E(y_{t-k})$ です。

つまり、**時点 t より k 時点前の y_t との共分散**です。

また $k=0$ の時(つまり 0 次の自己共分散) γ_{0t} は定義により y_t の分散と等しくなります。

時系列分析の基礎

■ 自己相関係数

時点 t における k 次の自己相関係数、 ρ_{kt} 、は**時点 t より k 時点前のデータとの相関係数**、すなわち

$$\rho_{kt} = \frac{\text{cov}(y_t, y_{t-k})}{\sqrt{\text{var}(y_t) \text{var}(y_{t-k})}} = \frac{\gamma_{kt}}{\sqrt{\gamma_{0t} \gamma_{0,t-k}}}$$

と定義されます。

自己相関係数は $k = 0$ の時に 1、 $k > 0$ の時に $|\rho_{kt}| \leq 1$ が成り立ちます。

定常性

■ 定常性

時系列分析において最も重要な概念が**定常性**です。
ある時系列データが**定常**であるとは次の事を意味します。

全ての t について

$$E(y_t) = \mu \quad \text{および} \quad \gamma_{kt} = \gamma_k、$$


ここで γ_k とは k にのみ依存した値(つまり k の関数)を表しています。

定常性

■ 定常性の意味

1. 一般には y_t と y_s ($t \neq s$) の期待値や自己共分散は異なる。
2. しかし、これらを推定するためのデータ y_t は1つの時系列に付き1つしか観測されない(例えば2008年の11月6日のTOPIXの終値は一度しか観測されない)。
3. y_t の1つの観測値より、 y_t がたくさん観測された時に平均的にとるであろう値である、期待値を精度良く推定する事はほぼ不可能。
4. 定常性の仮定をおく事により期待値の推定に(同じ期待値を持つ) y_t, y_{t-1}, \dots を用いる事ができるようになる。
5. ほとんどの場合にデータが定常性の仮定を満たすようにデータを変換する事ができる(例: 対数階差)。


TOPIX




TOPIX 変化率




実効為替レート




為替レートの変化率



鉍工業生產指數



鉱工業生産指数の変化率



定常性

■ 強定常性

先ほどの定常性は厳密に言うと、**弱定常性**といわれるものです。定常性にはもうひとつ**強定常性**とよばれるものがあります。これは以下のように定義されます。

(強定常性)

全ての t と k について $(y_t, y_{t+1}, \dots, y_{t+k})$ の同時分布が等しい。

通常の実験においては弱定常性で十分ですが、場合によっては強定常性を仮定する事があります。

定常性

例題1

弱定常過程において、

$$\gamma_k = \gamma_{-k}$$

を確認して下さい。

推定

- 平均、分散、自己共分散、自己相関の推定
(標本平均)

$$\bar{y} = \frac{1}{T} \sum_{t=1}^T y_t$$

- (標本自己共分散)

$$\hat{\gamma}_k = \frac{1}{T} \sum_{t=k+1}^T (y_t - \bar{y})(y_{t-k} - \bar{y})$$

推定


(標本自己相関)

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0}$$

- (標本)コレログラム

縦軸に(標本)自己相関、横軸に次数 k をとって図を描いたものを(標本)コレログラムといいます。

TOPIX 変化率のコレログラム



定常過程の例

■ ホワイトノイズ

ε_t が全ての t において

$$(1) \quad E(\varepsilon_t) = 0$$


$$(2) \quad \gamma_k = E(\varepsilon_t \varepsilon_{t-k}) = \begin{cases} \sigma^2, & k = 0 \\ 0, & k \neq 0 \end{cases}$$

を満たす時、 ε_t を**ホワイトノイズ**(白色雑音)とといいます。
 ε_t が分散 σ^2 のホワイトノイズである事を

$$\varepsilon_t \sim \text{W.N.}(\sigma^2)$$

のように書きます。

ホワイトノイズ



定常過程の例


- 自己回帰過程 (autoregressive (AR) process)

$$y_t = c + \phi y_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim \text{W.N.}(\sigma^2)$$


のように y_t が決定される時、 y_t を自己回帰過程 (AR過程) といいます。

ϕ が $|\phi| < 1$ の時にAR過程は定常となります。


AR過程 $\phi = 0.5$



AR過程 $\phi = 0.9$



AR過程 $\phi = 0.99$




定常過程の例

- 移動平均過程
(moving average (MA) process)


$$y_t = c + \theta \varepsilon_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim \text{W.N.}(\sigma^2)$$

のように y_t が決定される時、 y_t を移動平均過程 (MA過程) といいます。


MA過程($\theta = 0.5$)



MA過程($\theta = 0.9$)



MA過程($\theta = 0.99$)



定常過程

例題2

$$y_t = \mu + \varepsilon_t, \quad \varepsilon_t \sim \text{W.N.}(\sigma^2)$$

が弱定常過程である事を確認して下さい。

定常過程

例題3

$$y_t = \theta \varepsilon_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim \text{W.N.}(\sigma^2)$$

が弱定常過程である事を確認して下さい。

自己相関の検定

■ 自己相関の推定

定常性を仮定すると、自己共分散、自己相関は

$$\hat{\gamma}_k = \frac{1}{T} \sum_{t=k+1}^T (y_t - \bar{y})(y_{t-k} - \bar{y})$$

および

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0}$$

によって推定する事ができます。

自己相関の検定

■ 自己相関の検定

通常の統計分析同様、推定の後には**検定**をすることを考えます。

ここでは自己相関 ρ_k が 0 かどうかの検定を考えましょう。

帰無仮説は $H_0: \rho_k = 0$ 、対立仮説は $H_1: \rho_k \neq 0$ です。

自己相関の検定

- 自己相関の検定

$\hat{\rho}_k$ を用いて検定します。

そのためには帰無仮説のもとでの $\hat{\rho}_k$ の漸近分布を知る必要があります。

y_t が i.i.d. であれば、 $\hat{\rho}_k$ の分布は漸近的に

$$\hat{\rho}_k \sim N(0, 1/T)$$

となる事が知られています。

自己相関の検定

- 自己相関の検定

よって有意水準5%で検定するのであれば、 $\hat{\rho}_k$ が

$$|\hat{\rho}_k| > \frac{1.96}{\sqrt{T}}$$

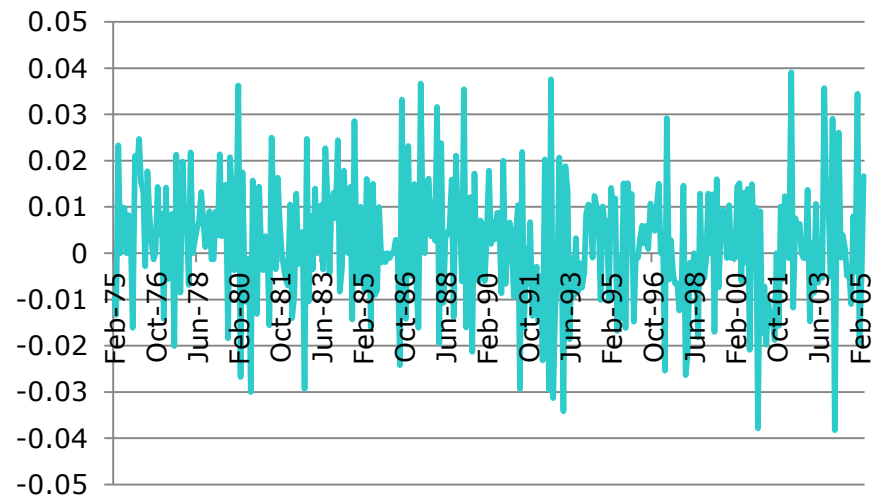
を満たす時に帰無仮説 $H_0: \rho_k = 0$ を**棄却**します
(つまり ρ_k は 0 ではないと結論する！)。

自己相関の検定

■ 自己相関の検定の例

鉱工業指数の変化率に対して、自己相関の有無を検定してみましょう。

鉱工業生産指数の変化率




自己相関の検定

■ 自己相関の検定の例

まず、変化率の自己相関係数を計算します。
以下はそのコレログラムです。

鉱工業指数の変化率のコレログラム



自己相関の検定

- 自己相関の検定の例

ρ_k の具体的な値は以下のようにになります。

1	2	3	4	5
-0.305	0.123	0.170	0.062	0.017
6	7	8	9	10
0.083	-0.001	0.090	0.036	-0.049

標本数は $T = 363$ であるので ρ_k の絶対値が

$$1.96 / \sqrt{T} = 1.96 / \sqrt{363} \approx 0.103$$

より大きければ有意水準 5% で $\rho_k = 0$ を棄却。

自己相関の検定

- 自己相関の検定の例

ρ_k の具体的な値は以下のようにになります。

1	2	3	4	5
-0.305	0.123	0.170	0.062	0.017
6	7	8	9	10
0.083	-0.001	0.090	0.036	-0.049

標本数は $T = 363$ であるので ρ_k の絶対値が

$$1.96 / \sqrt{T} = 1.96 / \sqrt{363} \approx 0.103$$

より大きければ有意水準 5% で $\rho_k = 0$ を棄却。

自己相関の検定

- 自己相関の検定の例

よって、最初の3つの自己相関(3次までの自己相関)は有意(に0と異なる)。


4次から10次までの自己相関は有意ではない。
→本当の値は0かもしれない。

自己相関の検定

■ 自己相関の検定の例

以下のようにコレログラムに臨界値を示すとわかりやすい。

鉱工業指数の変化率のコレログラム



自己相関の検定

- 自己相関の検定のまとめ
以上の流れをまとめておきましょう。
- (1) 自己相関を推定する。
 - (2) コレログラムを書く。
 - (3) 自己相関を検定する。
 - (4) コレログラムに臨界値を示す線を書きこむ。
 - (5) 結果を解釈する。

自己相関の検定

■ かばん検定

先ほどは個々の自己相関が0かどうかの検定を考えたが、まとめて m 次までの自己相関がすべて0かどうかを検定するという方法があります。

このような検定を**かばん検定**と呼びます。

自己相関の検定

- かばん検定の注意点

かばん検定の帰無仮説は

「 m 次までの全ての自己相関が 0 である」

というものです。よって対立仮説は

「 m 次までの自己相関のうち少なくとも 1 つは 0 でない」

となる事に注意が必要です。

自己相関の検定

- Ljung – Box 統計量

代表的なかばん検定統計量に **Ljung – Box 統計量** があります。その検定統計量は

$$Q(m) = T(T + 2) \sum_{k=1}^m \frac{\hat{\rho}_k^2}{T - k}$$

によって定義されます。

自己相関の検定

■ Ljung – Box 統計量

$Q(m)$ は 帰無仮説

$$H_0: \rho_1 = \rho_2 = \rho_3 = \dots = \rho_m = 0,$$

のもとで(より正確には y_t が i.i.d.であれば)

$$Q(m) \sim \chi^2(m)$$

となります。よって $Q(m)$ と $\chi^2(m)$ の95%点を比べて、 $Q(m)$ の方が大きい場合に帰無仮説を**棄却**します。

自己相関の検定

■ Ljung – Box 統計量の例

鉱工業指数の変化率のデータの Ljung – Box 統計量を計算してみましょう。

($m = 10$ までの Ljung – Box 統計量)

m	1	2	3	4	5	6	7	8	9	10
$Q(m)$	34.20	39.76	50.40	51.80	51.91	54.46	54.46	57.46	57.94	58.84
P値	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000

自己相関の検定

■ Ljung – Box 統計量の例

鉱工業指数の変化率のデータの Ljung – Box 統計量を計算してみましょう。

($m = 10$ までの Ljung – Box 統計量)

m	1	2	3	4	5	6	7	8	9	10
$Q(m)$	34.20	39.76	50.40	51.80	51.91	54.46	54.46	57.46	57.94	58.84
P値	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000

$m = 10$ までのすべての P 値が 0。

⇒ 少なくとも 10 次までの自己相関のどれか 1 つが 0 ではない。

自己相関の検定

■ Ljung – Box 統計量の問題点

Ljung – Box 統計量のひとつの問題点は m の選択が難しい事にあります。

m が小さすぎる \Rightarrow 高次の相関を見逃す可能性

m が大きすぎる \Rightarrow 検出力の低下の可能性

実際には、複数の m に対して $Q(m)$ を計算して総合的に判断するのが一般的。