

# L14 自己回帰モデルAR(m), 移動平均モデルMA(k)

## 多変量解析☆演習

### 今日の目標

- 確率過程(母ナントカ)を時系列データ(標本ナントカ)と対比して説明できる.
- 確率過程のひとつである自己回帰モデルAR(m)を説明できる.
- 確率過程のひとつである移動平均モデルMA(m)を説明できる.

## L13の補足

### L13のQuizの略解

データ  $\{X_t\}_{t=0,1,\dots,L-1}$  の周期性を知るには, 離散フーリエ変換も使える. フーリエ変換

$$\tilde{X}_s = \sum_{t=0}^{L-1} e^{-\frac{2\pi st}{L}} X_t$$

で,  $|\tilde{X}_s|^2$  が大きいなら, 周期  $L/s$  の成分の寄与が大きい.

フーリエ解析

## 時系列の母ナントカ

### 時系列データは確率過程の標本

時系列データは確率変数の標本と思える. 為替相場が, 同じルール, 同じ状況でパラレルワールドでスタートしても別の値動きをしよう. どんな母ナントカの標本と思えるだろう?

#### 確率過程(の特別なケース)

時刻  $t$  に対する連続型確率変数の列  $\{X_t\}_{t=0,1,\dots}$  を確率過程という. 大注意:  $X_t$  は独立でも同分布でもない! 1回サイコロを振ると(標本抽出すると),  $X_0, X_1, \dots$  がぜんぶでてくる.

### 単回帰でどう?

時系列データを見ると, 次のように単回帰分析したくなるかも.

- $t$  を説明変数(いままでの  $x$ )
- $X$  を目的変数(いままでの  $y$ )

$$X_t = \beta_0 + \beta_1 \times t + \epsilon_t,$$

$$\epsilon_t \text{は独立同分布, } \epsilon_t \sim N(0, \sigma^2), .$$

これで済む場合もあるけど、つまらなくて単純。トレンドは $\beta_0 + \beta_1 t$ , 周期なし,  $X_t$ は独立。

$$\begin{aligned} \text{Cov}[X_1, X_2] &= \text{Cov}[\epsilon_1, \epsilon_2] \quad \text{確率変数以外は共分散に関係しない} \\ &= 0 \end{aligned}$$

以下では、もっと複雑で面白い場合を扱う。

ここでは、 $t$ でなく  $x_{[t-1]}$  を説明変数にする(ようなもの)

## 1次の自己回帰モデルAR(1) auto regression

### 1次の自己回帰モデルAR(1)

- $\{\epsilon_t\}_{t=1, \dots}$ : 連続型確率変数の列
- $\{X_t\}_{t=0, 1, \dots}$ : 連続型確率変数の列
- $\phi_1$ : 定数

$$X_t = \phi_1 \cdot X_{t-1} + \epsilon_t. \quad (t \geq 1)$$

ただし,  $\epsilon_t$   $t = 0, 1, 2, \dots$ は,

- WN1  $E[\epsilon_t] = 0$
- WN1a  $E[\epsilon_t \epsilon_t] = \sigma^2$   $\sigma$
- WN1b  $E[\epsilon_t \epsilon_s] = 0$  ( $t \neq s$ ) 独立
- $E[X(t) \epsilon_s] = 0$  ( $t > s$ )

$\epsilon_t$ の「互いに無関係さ」に対しては、独立同分布,  $\epsilon_t \sim N(0, \sigma^2)$ のような分布ベースの強い仮定ではなく、母共分散が0という母期待値ベースの弱い仮定を置いている。WN1, WN2 を満たす $\epsilon_t$ を、ホワイトノイズ, white noise, 白色雑音という。

例1: 感染症の患者数

例2:  $\phi_1 = 1$ : ランダムウォーク

確率モデル及び演習

## AR(1)の生成

漸化式のりで計算できる。

$$\begin{aligned}
X_t &= \phi_1 X_{t-1} + \epsilon_t \\
&= \phi_1 (\phi_1 X_{t-2} + \epsilon_{t-1}) + \epsilon_t \\
&= \phi_1 (\phi_1 (\phi_1 X_{t-3} + \epsilon_{t-2}) + \epsilon_{t-1}) + \epsilon_t \\
&= \dots \\
&= \phi_1^t X_0 + \phi_1^{t-1} \epsilon_1 + \phi_1^{t-2} \epsilon_2 + \dots + \phi_1^0 \epsilon_t \\
&= \phi_1^t X_0 + \sum_{k=0}^{t-1} \phi_1^k \epsilon_{t-k}
\end{aligned}$$

## 時系列の定常性

ここに、一般論、時系列が定常であることの定義を挿入

時系列の(弱い意味での)定常性

時系列  $\{X_t\}$  が(弱い意味で)定常であるとは、次の両方を満たすこと。

- $E[X_t]$  が  $t$  によらないこと。
- $\text{Cov}[X_t, X_{t-s}]$  が  $t$  によらないこと。

分布や高次のモーメントは  $t$  に依存してもよい(依存しない  $\Leftrightarrow$  強い意味での定常性)

$x_t = \phi_1^t X_0 + \sum_{k=0}^{t-1} \phi_1^k \epsilon_{t-k}$  は、 $|\phi_1| \leq 1$  なら  $t \rightarrow +\infty$  で定常になる望みがある。

## AR(1)の母平均値, 母共分散

$$\begin{aligned}
E[X_t] &= E[\phi_1^t X_0 + \sum_{k=0}^{t-1} \phi_1^k \epsilon_{t-k}] \\
&= \phi_1^t E[X_0]
\end{aligned}$$

$$\begin{aligned}
V[X_t] &= V[\phi_1^t X_0 + \sum_{k=0}^{t-1} \phi_1^k \epsilon_{t-k}] \\
&= V[\phi_1^t X_0] + \sum_{k=0}^{t-1} \phi_1^k V[\epsilon_{t-k}] \\
&= \phi_1^t V[X_0] + \sum_{k=0}^{t-1} \phi_1^k \sigma^2 \\
&= \phi_1^t V[X_0] + \frac{1 - \phi_1^t}{1 - \phi_1} \sigma^2
\end{aligned}$$

$|\phi_1| < 1, t \rightarrow +\infty$  で、定常の望みあり、 $V[X_t]$  も一定。以下、簡単のため  $E[X_0] = E[X_t] = 0$  と仮定。



$$\begin{aligned}
\text{Cov}[X_t, X_{t-s}] &= \mathbf{E}[X_t X_{t-s}] \\
&= \mathbf{E}\left[\left(\phi_1^t X_0 + \sum_{k=0}^{t-1} \phi_1^k \epsilon_{t-k}\right) \left(\phi_1^{t-s} X_0 + \sum_{\ell=0}^{t-s-1} \phi_1^\ell \epsilon_{t-s-\ell}\right)\right]
\end{aligned}$$

展開すると 0 にならないのは,  $\mathbf{E}[X_0 X_0]$ ,  $\mathbf{E}[\epsilon_k \epsilon_k] = \sigma^2$ のみ.

$$\begin{aligned}
\text{Cov}[X_t, X_{t-s}] &= \phi_1^{2t-s} \mathbf{E}[X_0 X_0] + (\phi_1^{2t-2s-2} + \phi_1^{2t-2s-4} + \dots + \phi_1^0) \phi_1^s \sigma^2 \\
&= \phi_1^{2t-s} \mathbf{E}[X_0 X_0] + \frac{1 - (\phi_1^2)^{t-s}}{1 - \phi_1^2} \phi_1^s \sigma^2 \\
&\rightarrow \begin{cases} \frac{\phi_1^s \sigma^2}{1 - \phi_1^2} & (|\phi_1| < 1) \\ \approx t & (|\phi_1| = 1) \\ \approx t \phi_1^{2t} & (|\phi_1| > 1) \end{cases}
\end{aligned}$$

$|\phi_1| < 1$ のとき定常. このとき, ラグ $s$ の自己相関係数は  $r(s) = \frac{\phi_1^s \sigma^2}{1 - \phi_1^2}$  ( $|\phi_1| < 1$ ) つまり等比数列. そうなってるやつあったでしょ? あれから $\phi_1$ が読み取れる.

## AR(1)の自己相関係数とコレログラム



## $m$ 次の自己回帰モデルAR( $m$ )

### $m$ 次の自己回帰モデルAR( $m$ )

#### $m$ 次の自己回帰モデルAR( $m$ )

- $\{\epsilon_t\}_{t=1,\dots}$ : 連続型確率変数の列
- $\{X_t\}_{t=0,1,\dots}$ : 連続型確率変数の列
- $\phi_0 = 1, \phi_1, \dots, \phi_m$  定数

$$X_t = \phi_1 \cdot X_{t-1} + \dots + \phi_m \cdot X_{t-m} + \epsilon_t. \quad (t \geq 1)$$

$m$ 個前の時刻の $X_{t-s}$ から影響する.

## Quiz L14-1

### [Quiz L14-1](#)

## AR(1)の生成

母集団からの標本抽出=確率過程のシミュレーション

## シミュレーション及び実習(確率の現れないシミュレーション)

## ARMAはAR(1)

を一般化したモデル.

```
from statsmodels.tsa.arima_process import ArmaProcess
ar=[1,-0.9,0.5] # [a0,-a1,-a2,-a3,..]. a1以降は符号を逆にする
ma=[1] # 現時点ではこうする
AR=ArmaProcess(ar,ma) # 自己回帰モデルを計算するオブジェクト
x=AR.generate_sample(nsample=50) # 時間の長さ=50
```

これは,  $\phi_1 = 0.9, \phi_2 = -0.5$  という例.

リストxが $x_0, x_1, x_2, \dots, x_{49}$ に代入される.

手でやるならこう.

```
x=[2] # x1
t=1
phi1=1.0
for t in range(1,100,1):
    xnext=x[t-1]*phi1 + stats.norm(loc=0,scale=1).rvs(size=1)[0]
    x.append(xnext)
```

字下げした部分がブロック. Cでいうなら,

```
double x[101];
double xnext;
int t;
x[0]=2;
phi1=1.0;
for(t=1; t<=100; t+=1){
    xnext=x[t-1]*phi1+乱数();
    x[t]=xnext;
}
```

## AR(m)モデルの推定と時系列の予測

```
from statsmodels.tsa import ar_model
model = ar_model.AR(x) # modelは ARモデルでの予測を行うオブジェクト. xは時系列を収めた Series
result = model.fit(maxlag=12, ic='aic') # mが最大12までの範囲でよく予測するmと係数を探せ. 基準はAIC(魔法)
result.k_ar # k_ar とは mのこと
result.fittedvalues # xと同じ範囲を予測した時系列
result.predict(t1,t2) # t1からt2までの期間を予測した時系列
```

## k次の移動平均モデルMA(k)

## k次の移動平均モデルMA(k)

## k次の移動平均モデルMA(k)

- $\{\epsilon_t\}_{t=1,\dots}$ : 連続型確率変数の列
- $\{X_t\}_{t=0,1,\dots}$ : 連続型確率変数の列
- $\theta_0 = 1, \theta_1, \dots$ : 定数

$$X_t = \beta_0 + \epsilon_t + \theta_1 \epsilon_{t-1} + \dots + \theta_k \epsilon_k \quad (t \geq k)$$

ただし,  $\epsilon_t$   $t = 0, 1, 2, \dots$ は,

- WN1  $E[\epsilon_t] = 0$
- WN1a  $E[\epsilon_t \epsilon_t] = \sigma^2$   $\sigma$
- WN1b  $E[\epsilon_t \epsilon_s] = 0$  ( $t \neq s$ ) 独立
- $E[X(t) \epsilon_s] = 0$  ( $t < s$ )


## 移動平均モデルMA(k)の母平均値・母共分散

$$E[X_t] = 0$$

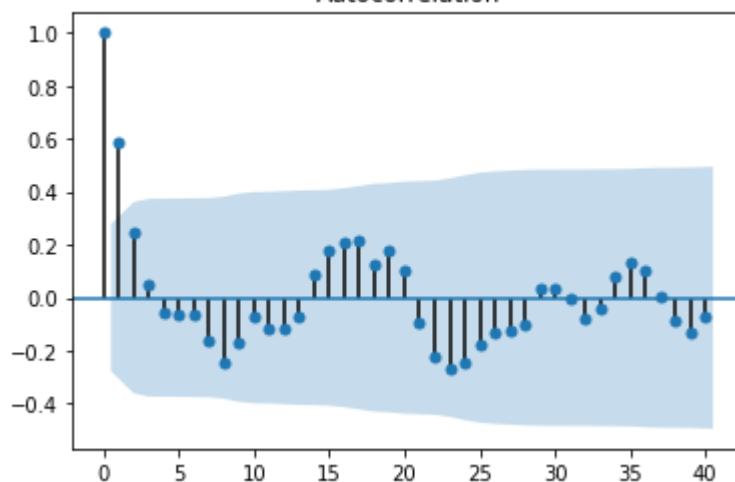
$$\begin{aligned} V[X_t] &= V[\epsilon_t + \theta_1 \epsilon_{t-1} + \dots + \theta_k \epsilon_k] \\ &= V[\epsilon_t] + \theta_1^2 V[\epsilon_{t-1}] + \dots + \theta_k^2 V[\epsilon_k] \\ &= (1 + \theta_1^2 + \dots + \theta_k^2) \sigma^2 \end{aligned}$$

$$\begin{aligned} \text{Cov}[X_t, X_{t-s}] &= E[(\epsilon_t + \theta_1 \epsilon_{t-1} + \dots + \theta_k \epsilon_{t-k})(\epsilon_{t-s} + \theta_1 \epsilon_{t-s-1} + \dots + \theta_k \epsilon_{t-s-k})] \\ &= \dots \\ &= \begin{cases} 0 & (k < s) \\ (\theta_0 \theta_s + \theta_1 \theta_{s+1} + \dots + \theta_{k-s} \theta_k) \sigma^2 & (k \geq s) \end{cases} \end{aligned}$$

## コレログラム



Autocorrelation



## Quiz L14-2

### [Quiz L14-2](#)

## MA(k)の生成

```
from statsmodels.tsa.arima_process import ArmaProcess
ar=[1] #
ma=[1,0.5,0.2] # [theta_0,theta_1,theta_2]
MA=ArmaProcess(ar,ma) # 自己回帰移動平均モデルを計算するオブジェクト
x=MA.generate_sample(nsample=50) # 時間の長さ=50
```

## バリエーション

- $m, \ell$ 次の自己回帰移動平均モデルARMA( $m, \ell$ ) 漸化式の右辺が, AR( $m$ )とMA( $\ell$ )の和になっているもの.
- $m, k$ 次の自己回帰和分移動平均モデルARIMA( $m, k$ ).  
階差がARMA( $m, k$ )にしたがう時系列. それ自身は非定常でありうる.
- $\vdots$