

時系列の状態空間モデル

樋口さぶろお <https://hig3.net>

龍谷大学大学院 理工学研究科 数理情報学専攻

理論物理学特論 L11 (2022-12-07 Wed)

最終更新: Time-stamp: "2022-12-13 Tue 10:19 JST hig"

今日の目標

- 確率過程の自己回帰移動平均モデル $ARMA(m, k)$ を説明できる.
- 時系列モデルの状態空間モデルを説明できる



L10-Q1

Quiz 解答: 移動平均 実は問題の $x(t)$ はこうやって作ってました. 周期が 4 だから, 4 次の移動平均でトレンドをだいたい回復できるでしょ.

t	0	1	2	3	4	5	6	7	8	
トレンド	0.0	0.2	0.4	0.6	0.8	1.0	1.2	1.4	1.6	
周期	2.0	-2.0	2.0	-2.0	2.0	-2.0	2.0	-2.0	2.0	-
ノイズ	-0.2	0.2	0.2	0.2	0.2	-0.2	0.2	-0.2	0.2	
x	1.8	-1.6	2.6	-1.2	3.0	-1.2	3.4	-0.8	3.8	
y_3		0.9	-0.1	1.5	0.2	1.7	0.5	2.1	1.0	
y_4			0.0	0.8	0.9	1.1	1.2	1.5		

L10-Q2

Quiz 解答: コレログラム 1-a, 2-c, 3-b

L10-Q3

Quiz 解答: 自己回帰モデル AR(2) の例

- ① モデルの定義より $X_2 = \phi_1 X_1 + \phi_2 X_0 + \epsilon_2 = \epsilon_2$.

② モデルの定義より

$$X_3 = \phi_1 X_2 + \phi_2 X_1 + \epsilon_3 \phi_1 (\phi_1 X_1 + \phi_2 X_0 + \epsilon_2) + \phi_2 X_1 + \epsilon_3 = \phi_1 \epsilon_2 + \epsilon_3.$$

$$E[(\phi_1 \epsilon_2 + \epsilon_3)^2] = \phi_1^2 \sigma^2 + 2 \cdot \phi_1 \cdot 0 + \sigma^2.$$

③ モデルの定義より

$$X_4 = \phi_1 X_3 + \phi_2 X_2 + \epsilon_4 = \phi_1^2 \epsilon_2 + \phi_1 \epsilon_3 + \phi_2 \epsilon_2 + \epsilon_4.$$

$$E[X_3] = E[X_4] = 0 \text{ より,}$$

$$\text{Cov}[X_3, X_4] = E[X_3 X_4] = \phi_1^3 E[\epsilon_2^2] + \phi_1 \phi_2 E[\epsilon_2^2] + \phi_1 E[\epsilon_3^2] =$$

$$(\phi_1^3 + \phi_1 \phi_2 + \phi_1) \sigma^2.$$

ここまで来たよ

10 時系列の MA モデル

- k 次の移動平均モデル $MA(k)$

11 時系列の状態空間モデル

- 状態空間モデル
- 状態空間モデルの例

移動平均の定義

定義 (移動平均)

時系列 $\{X_t\}$.

k 次の後方移動平均 $Y_{t,k} = \frac{1}{k}(X_{t-k+1} + \cdots + X_{t-1} + X_t)$.

移動平均モデルの定義のアイデア

$$X_t = \phi_1 Y_{t-1,1} + \phi_2 Y_{t-1,2} + \cdots + \phi_k Y_{t-1,k} + \epsilon_t$$

としては?

漸化式を解いていくと、けっきょくすべて $\epsilon_{t'}$ $t-k-1 \leq t' \leq t-1$ に帰着する.

k 次の移動平均モデル $MA(k)$

定義 (k 次の移動平均モデル $MA(k)$)

$t = 0, 1, 2, \dots$: 時刻

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

$\theta_k \in \mathbb{R}$: パラメタ

$X_t (t \geq 1)$ は次のように定まる.

$$X_t = \beta_0 + \theta_0 \epsilon_t + \theta_1 \epsilon_{t-1} + \dots + \theta_k \epsilon_{t-k}. \quad (t \geq k)$$

ただし $\theta_0 = 1$. ϵ_t は次を満たす.

$$E[\epsilon_t] = 0 \quad (\text{WN1})$$

$$E[\epsilon_t \epsilon_s] = \sigma^2 \delta_{ts} \quad (\text{WN2})$$

$$E[X_t \epsilon_s] = 0 \quad (t < s) \quad (\text{PI})$$

移動平均モデル $MA(k)$ の母平均値・母自己共分散



$$E[X_t] = \beta_0.$$

$$\begin{aligned} V[X_t] &= V[\theta_0\epsilon_t + \theta_1\epsilon_{t-1} + \cdots + \theta_k\epsilon_{t-k}] \\ &= \theta_0^2 V[\epsilon_t] + \theta_1^2 V[\epsilon_{t-1}] + \cdots + \theta_k^2 V[\epsilon_{t-k}] \\ &= (\theta_0^2 + \theta_1^2 + \cdots + \theta_k^2)\sigma^2. \end{aligned}$$

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

移動平均モデル $MA(k)$ のサンプルパスとコレログラム

$MA(1)$, $\theta_1 = 0.9$.



青網掛けは、Bartlett's formula による信頼区間。この外に出ると、帰無仮説 $r = 0$ が有意水準 $\alpha = 0.05$ で棄却される。

L10-Q4

Quiz(移動平均モデル MA(1) の例)

1 次の移動平均モデル MA(1) モデルを考える (授業中に使った記号で).
 $\beta_0 = 0$ とする.

- ① 確率変数 X_2 を, ϵ_t, θ_1 で表そう.
- ② 母期待値 $E[X_2^2]$ を σ と θ_1 で表そう.
- ③ 母自己共分散 $\text{Cov}[X_2, X_3]$ を σ と θ_1 で表そう.
- ④ 母自己共分散 $\text{Cov}[X_2, X_4]$ を求めよう.

m, k 次の自己回帰移動平均モデル $ARMA(m, k)$

X_t の漸化式の右辺が, ϵ_t に加え, $AR(m)$ と $MA(k)$ の和であるモデル.

階差数列

時系列の階差を繰り返すと, 定常になって, $ARMA$ で解析できることがある.

階差 difference \leftrightarrow 和分 (離散和のこと) integrated

m, d, k 次の自己回帰和分移動平均モデル $ARIMA(m, d, k)$

d 階階差が $ARMA(m, k)$ にしたがる時系列, $ARMA$ を和分した時系列.

Code example for ARMA(2,2)

Listing 1: arma

```

1 from statsmodels.tsa.arima_process import ArmaProcess
2 ar=[1,-phi1,-phi2] # 1は必ず含める マイナスをつける
3 ma=[1,theta1,theta2] # [theta_0,theta_1,theta_2] 1は必ず
4 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
5 x=MA.generate_sample(nsample=50) # 時間の長さ=50

```

ar, ma は、漸化式の L のラグ多項式の係数のリスト。

定義 (ラグ演算子)

ラグ演算子 L を $LX_t = X_{t-1}$ で定める。

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2}$$

$$(1 - \phi_1 L^1 - \phi_2 L^2)X_t = (1 + \theta_1 L^1 + \theta_2 L^2)\epsilon_t$$

ここまで来たよ

- ⑩ 時系列の MA モデル
 - k 次の移動平均モデル $MA(k)$

- ⑪ 時系列の状態空間モデル
 - 状態空間モデル
 - 状態空間モデルの例

時系列の隠れた変数

琵琶湖の漁の毎年の漁獲量は時系列. 過去の漁獲量 (kg) のデータを見て, AR(2) っぽい, とか, ϕ_1, ϕ_2, σ^2 はいくつ? とか推定することはできる. し
か~し.

- 実は背後に, 琵琶湖の生息するナマズの総数とか, モロコの総数とか, もっと言えば, 水温とか水草の量とか, 観測できないより本質的な時系列があるのでは?
 - ▶ 被食者捕食者の増減の話とかやったよね?/やります. 微分方程式, 数理モデル
- ホワイトノイズ ϵ_t っていうけど, 今年はたまたま稚魚が育たなかつたっていうノイズと, 今年はコロナで漁船の整備ができなかった (?) っていうノイズは別なのでは?

システムと観測を分けて, もっと精密に考えたい!

定義 (状態空間モデル (の簡単な場合))

- 観測できない量
 - ▶ \mathbf{X}_t : 状態ベクトル (2次元「状態空間」の元)
 - ▶ \mathbf{v}_t : システムノイズベクトル (2次元)
 - ▶ w_t : 観測ノイズ (1次元) $V[w_t] = \sigma_w^2$.
 - ▶ \mathbf{v}_t, w_t は互いに独立なホワイトノイズ
- 観測できる量
 - ▶ Y_t : 観測値 (1次元)
- 定数
 - ▶ F, G : 2×2 行列
 - ▶ H : 1×2 行列

$$\text{システム (状態) モデル } \mathbf{X}_t = F\mathbf{X}_{t-1} + G\mathbf{v}_t$$

$$\text{観測モデル } Y_t = H\mathbf{X}_t + w_t$$

状態空間 = \mathbf{X}_t の観測できない空間
状態ベクトルは,

$$\begin{aligned}\mathbf{X}_t &= F\mathbf{X}_{t-1} + G\mathbf{v}_t \\ &= F(F\mathbf{X}_{t-2} + G\mathbf{v}_{t-1}) + G\mathbf{v}_{t-1} \\ &= \dots = F^t\mathbf{X}_0 + \sum_{t'=0}^t F^{t-t'}G\mathbf{v}_{t'}\end{aligned}$$

のように漸化式で計算される。

観測値 Y_t は漸化式で結ばれておらず、各時刻ごとに \mathbf{X}_t から

$$Y_t = H\mathbf{X}_t + w_t$$

で計算される。

ここまで来たよ

10 時系列の MA モデル

- k 次の移動平均モデル $MA(k)$

11 時系列の状態空間モデル

- 状態空間モデル
- 状態空間モデルの例

例: 琵琶湖の漁獲量

$$F = \begin{pmatrix} 1.01 & 0.3 \\ -0.5 & 0.98 \end{pmatrix}, \mathbf{X}_t = \begin{pmatrix} \text{なまずの個体数} \\ \text{モロコの個体数} \end{pmatrix},$$

$$G = \begin{pmatrix} 1 & 2 \\ 100 & 200 \end{pmatrix}, \mathbf{v}_t = \begin{pmatrix} \text{正規分布 (水草の量)} \\ \text{正規分布 (水温)} \end{pmatrix}$$

$$Y_t = \text{漁獲量 (kg)}, H = (1000 \quad 10), w_t = \text{正規分布 (漁船の数)}$$

例:AR(m)

AR(2)

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \epsilon_t.$$

は2次元の状態空間で表せる.

$$\begin{pmatrix} X_t \\ X_{t-1} \end{pmatrix} = \begin{pmatrix} \phi_1 & \phi_2 \\ 1 & 0 \end{pmatrix} \begin{pmatrix} X_{t-1} \\ X_{t-2} \end{pmatrix} + \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} \text{正規ノイズ} \\ \text{正規ノイズ} \end{pmatrix},$$

$$Y_t = (1 \quad 0) \begin{pmatrix} X_t \\ X_{t-1} \end{pmatrix} + 0 \cdot \text{正規ノイズ}$$

AR(3) 3次元の状態空間で表せる.

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \phi_3 X_{t-3} + \epsilon_t,$$

$$X_{t-1} = 1 \cdot X_{t-1},$$

$$X_{t-2} = +1 \cdot X_{t-2},$$

$$Y_t = X_t + 0 \cdot \epsilon'_t$$

例: ローカルレベルモデル (ランダムウォークプラスノイズモデル)

$$X_t = X_{t-1} + \text{乱数},$$

$$Y_t = X_t + \text{別の乱数}$$

ランダムウォークだが, 観測者によるウォーカーの位置の測定値 Y_t は正確ではない. その前提で, 正確な位置 X_t を求めたい.

L11-Q1

Quiz(AR(4) の状態空間モデル)

4 次の自己回帰モデル AR(4) モデルを状態空間モデルとして考える (授業の記号で).

- ① 状態ベクトルを書こう.
- ② システムモデル, 観測モデルに現れる行列の, F, G, H を書こう.

状態空間モデルの特徴

- パラメタが多い
- AR(m) や親戚の MA, ARMA, ARIMA, SARIMA などのモデルを統一的に表せる.
- これでないと表せないモデルもある.
- 制御工学でよく扱われて、解法が整備されている. Y_1, \dots, Y_t から状態推定する.
- 問題の分類
 - ▶ 平滑化 過去の状態 $X_{t'}$ ($t' < t$) を推定する
 - ▶ フィルタ 現在の状態 $X_{t'}$ ($t' = t$) を推定する
 - ▶ 予測 将来の状態 $X_{t'}$ ($t' > t$) を推定する
- 効率のよい解法カルマンフィルタがある
- HMM=Hidden Markov model 隠れマルコフモデルは、状態空間ベクトル \mathbf{X}_t を離散値にしたバージョン

状態空間モデルを使う手続き

- ① 与えられた Y_t を見る
- ② (原理から考えて) モデルを書く
- ③ F, G, H が未知ならそれを**パラメタ推定**する
- ④ 与えられた学習データ $\{Y_t\}_{t=0, \dots, T}$ から X_t を**状態推定** (予測, フィルタ, 平滑化) する.
- ⑤ テストデータ Y_t と, X_t から求めた \hat{y}_t を比較して, 性能を評価する

カルマンフィルタを備える, 状態空間モデルのライブラリ

<https://www.statsmodels.org/dev/generated/statsmodels.tsa.statespace.structural.UnobservedComponents.html>

状態空間モデルの扱いやすい場合 1: 正規ノイズ

- $\mathbf{v}_t, \mathbf{w}_t$ が正規分布にしたがうと仮定する. このとき, 正規分布の加法的性から, X_t, Y_t などがすべて正規分布にしたがい, それらの母平均値, 母共分散の間の関係式をつかって解析できる.

状態空間モデルの扱いやすい場合 2: 隠れマルコフモデル

- 「 X_t が離散型確率変数の場合」を考えたい. $X_t = 1, 2, \dots, n$.
- システムモデルは「 X_t が確率的に時間発展する」ことを表すので, マルコフ連鎖で書くのが自然. M は推移確率行列.

計算科学 B, 確率モデル及び実習

$$P(X_t = 1) = M_{11}P(X_{t-1} = 1) + M_{12}P(X_{t-1} = 2) + \dots + M_{1n}P(X_{t-1} = n)$$

$$P(X_t = 2) = M_{21}P(X_{t-1} = 1) + M_{22}P(X_{t-1} = 2) + \dots + M_{2n}P(X_{t-1} = n)$$

$$\vdots$$

$$P(X_t = n) = M_{n1}P(X_{t-1} = 1) + M_{n2}P(X_{t-1} = 2) + \dots + M_{nn}P(X_{t-1} = n)$$

- 観測できない (隠れた) $X = 1, 2, \dots, n$ という状態があり, ある法則で時間発展する. 観測される Y_t の値は X から決まる.