

# カルマンフィルタ

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 L12 (2022-12-14 Wed)

最終更新: Time-stamp: "2022-12-14 Wed 14:29 JST hig"

## 今日の目標

- 時系列モデルのカルマンフィルタを説明できる



## L10-Q4

## Quiz 解答: 移動平均モデル MA(1) の例

- ①  $X_2 = \epsilon_2 + \theta_1 \epsilon_1.$
- ②  $E[(\epsilon_2 + \theta_1 \epsilon_1)^2] = \sigma^2(1 + \theta_1)^2.$
- ③  $E[(\epsilon_2 + \theta_1 \epsilon_1)(\epsilon_3 + \theta_1 \epsilon_2)] = \sigma^2 \theta_1.$
- ④ 0.

## L11-Q1

## Quiz 解答: AR(4) の状態空間モデル

$$\textcircled{1} \mathbf{X}_t = \begin{bmatrix} x_t \\ x_{t-1} \\ x_{t-2} \\ x_{t-3} \end{bmatrix}$$

②  $\boldsymbol{x}_t = F\boldsymbol{x}_{t-1} + G\boldsymbol{v}_t, y_t = H\boldsymbol{V}x_t + 0 \cdot w_t$  とすると

$$F = \begin{bmatrix} \phi_1 & \phi_2 & \phi_3 & \phi_4 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, G = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}, H = [1 \quad 0 \quad 0 \quad 0].$$

## 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)  $V[w_t] = \sigma^2$ .
  - ▶  $\mathbf{v}_t, w_t$  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
  - ▶  $F, G$ :  $2 \times 2$  行列
  - ▶  $H$ :  $1 \times 2$  行列

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

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

# カルマンフィルタ

- 状態空間モデルで, パラメタ  $F, G, \sigma_v^2, \sigma^2$  を既知として, 観測された  $Y_1, \dots, Y_t$  から, 状態  $X_{t'}$  を推定する方法.
  - ▶ 平滑化  $t' < t$
  - ▶ フィルタ  $t' = t$
  - ▶ 予測  $t' > t$
- 雑音として, 正規ホワイトノイズを仮定:  $v_t \sim N(0, \sigma_v^2 E)$   
 $w_t \sim N(0, \sigma^2)$ .
- 計算時間が少ない, 消費メモリーが少ない
- オンラインなアルゴリズム ( $\leftrightarrow$  バッチなアルゴリズム)
  - ▶  $Y_1, \dots, Y_{t-1}$  からの推測結果を持っているところに, データ  $Y_t$  が追加されたとき, 全てのデータからの計算し直しではなく, 現在の推測結果からの (少ない計算での) 修正が行える.
- Python library pykalman <https://pykalman.github.io/>
- 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>

## 相手にする分布

### 状態の周辺事後分布

$$f(x_{t'}|y_{1:t}) \stackrel{\text{略記}}{=} (t'|t)$$

- $y_{1:t}$  は  $(y_1, \dots, y_t)$  の略記.
- 周辺と言う名は  $t'$  以外の  $x_{t''}$  について周辺化した (和を取った) から.

### 分布の間の漸化式

	$x_0$	$x_1$	$x_2$	$x_3$	$x_4$
$y_{1:0} = \emptyset$	(0 0)	(1 0)	(2 0)	(3 0)	(4 0)
$y_{1:1}$	(0 1)	(1 1)	(2 1)	(3 1)	(4 1)
$y_{1:2}$	(0 2)	(1 2)	(2 2)	(3 2)	(4 2)
$y_{1:3}$	(0 3)	(1 3)	(2 3)	(3 3)	(4 3)
$y_{1:4}$	(0 4)	(1 4)	(2 4)	(3 4)	(4 4)

## 単純化: ローカルレベルモデル

## 定義 (直線上を歩く AirTag をつけた猫)

- 観測できない量
  - ▶  $x_t$ : 猫の位置
  - ▶  $v_t \sim N(0, \sigma_v^2)$ : 猫の気まぐれな移動
  - ▶  $w_t \sim N(0, \sigma^2)$ : AirTag の誤差
- 観測できる量
  - ▶  $y_t$ : AirTag の位置表示

システム (状態) モデル  $x_t = F \cdot x_{t-1} + v_t$

観測モデル  $y_t = H \cdot x_t + w_t$

定数  $F = H = 1$

## ベイズ推定の復習と準備

L12-Q1

## Quiz(正規分布のベイズ推定)

確率変数  $X$  の確率密度関数 ('事前分布') を

$$f_X(x) = \frac{1}{\sqrt{2\pi C}} e^{-\frac{(x-m)^2}{2C}}$$

とする.

確率変数  $Y$  は  $Y = X + \epsilon$ ,  $\epsilon \sim N(0, \sigma^2)$  で定まる.

- ①  $X = x_0$  という条件のもとで,  $Y$  の条件付き分布を求めよう.
- ②  $Y$  として,  $y_0$  が得られたという条件のもとで,  $X$  の条件付き分布 ('事後分布') を求めよう.



## L12-Q2

## Quiz(正規分布の母平均値のベイズ推定)

真の値  $x$  を測定器で測定して値  $y$  を得る.

測定器の出力  $y$  は, 母平均値を  $x$ , 母分散を  $\sigma^2$  とする正規分布にしたがう.

- ① 1 個の測定値  $y_1$  を得たとき, 真の値の (ベイズで言う事後) 分布を答えよう.
- ② さらにもう 1 個の測定値  $y_2$  を得たとき, 真の値の (ベイズ更新後の事後) 分布を答えよう.



ノイズが正規分布なので、(いちばん最初の事前分布が正規なら) 次の分布はすべて正規分布になる。

正規分布の加法性

$$\text{略記 } f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi \cdot \sigma^2}} e^{-\frac{1}{2 \cdot \sigma^2} (x - \mu)^2}.$$

$$\text{フィルタ分布 } f(x_t | y_{1:t}) = \frac{1}{\sqrt{2\pi \cdot C_t}} e^{-\frac{1}{2 \cdot C_t} (x_t - m_t)^2}$$

$$\text{一期先予測分布 } f(x_t | y_{1:t-1}) = \frac{1}{\sqrt{2\pi \cdot \hat{C}_t}} e^{-\frac{1}{2 \cdot \hat{C}_t} (x_t - \hat{m}_t)^2}$$

$$\text{一期先予測尤度 } f(y_t | y_{1:t-1})$$

$C_t, \hat{C}_t, m_t, \hat{m}_t$  を漸化式で計算して、 $f(x_t | y_{1:t})$  を求めていける。

## 状態の更新

フィルタ分布  $f(x_{t-1}|y_{1:t-1}) = \frac{1}{\sqrt{2\pi \cdot C_{t-1}}} e^{-\frac{1}{2 \cdot C_{t-1}}(x_{t-1} - m_{t-1})^2}$  を持っているときに、システムモデルの式を使って、一期先予測分布

$f(x_t|y_{1:t-1}) = \frac{1}{\sqrt{2\pi \cdot \hat{C}_t}} e^{-\frac{1}{2 \cdot \hat{C}_t}(x_t - \hat{m}_t)^2}$  を求める計算

$$\begin{aligned} f(x_t|y_{1:t-1}) &= \int dx_{t-1} f(x_t|x_{t-1}) f(x_{t-1}|y_{1:t-1}) \\ &= \int dx_{t-1} f(x_t - Fx_{t-1}; 0, \sigma_v^2) f(x_{t-1}; m_{t-1}, C_{t-1}) \\ &\stackrel{\text{平方完成}}{=} f(x_t; \hat{m}_t, \hat{C}_t), \end{aligned}$$

$\hat{m}_t = E[Fx_{t-1} + v_t] = m_{t-1}$ ,  $\hat{C}_t = V[Fx_{t-1} + v_t] = C_{t-1} + \sigma_v^2$   
 分布の間の漸化式で言うと、横向き矢印  $(t-1|t-1) \rightarrow (t|t-1)$

## フィルタリング I

ここで正規分布のベイズ推定を使う

一期先予測分布  $f(x_t|y_{1:t-1}) = \frac{1}{\sqrt{2\pi \cdot \hat{C}_t}} e^{-\frac{1}{2 \cdot \hat{C}_t} (x_t - \hat{m}_t)^2}$  を持っているときに、最新データ  $y_t$  が来たので、これを考慮してベイズ更新して、フィルタ分布  $f(x_t|y_{1:t})$  を求める計算.

$$\begin{aligned} f(x_t|y_{1:t}) &= f(x_t|y_{1:t-1}) \frac{f(y_t|x_t)}{f(y_t|y_{1:t-1})} \\ &= f(x_t; m_t, C_t) \end{aligned}$$

分布の間の漸化式で言うと、下向きの矢印

$(t|t-1)$

↓

$(t|t)$

## フィルタリング II

$$C_t^{-1} = \hat{C}_t^{-1} + (\sigma^2)^{-1} = (C_{t-1} + \sigma_v^2)^{-1} + (\sigma^2)^{-1}$$

$$\begin{aligned} m_t &= \frac{\hat{C}_t^{-1}}{\hat{C}_t^{-1} + (\sigma^2)^{-1}} \hat{m}_t + \frac{(\sigma^2)^{-1}}{\hat{C}_t^{-1} + (\sigma^2)^{-1}} y_t \\ &= \frac{(C_{t-1} + \sigma_v^2)^{-1}}{(C_{t-1} + \sigma_v^2)^{-1} + (\sigma^2)^{-1}} m_{t-1} + \frac{(\sigma^2)^{-1}}{(C_{t-1} + \sigma_v^2)^{-1} + (\sigma^2)^{-1}} y_t \\ K_t &= \frac{(\sigma^2)^{-1}}{(C_{t-1} + \sigma_v^2)^{-1} + (\sigma^2)^{-1}} \\ &= \hat{m}_t + \frac{\hat{C}_t}{\sigma^2 + \hat{C}_t} (y_t - \hat{m}_t) \end{aligned}$$

$K_t$  はカルマンゲイン (カルマン利得). 新着データ  $y_t$  で得られる情報の比率を表す.

## (一般次元の) カルマンフィルタリング

 $(m_{t-1}, C_{t-1})$  から  $(m_t, C_t)$  を得る手続きシステムの状態の更新  $\hat{m}_t = Gm_{t-1}$ 

$$\hat{C}_t = GC_{t-1}G^t + V$$

カルマンゲインの計算

$$f_t = F\hat{m}_t Q_t =$$

$$F\hat{C}_t F^t + W$$

$$K_t = \hat{C}_t F^t Q_t^{-1}$$

ベイズ更新

$$m_t = \hat{m}_t + K_t(y_t - f_t)$$

$$C_t = (I - K_t F)\hat{C}_t$$

## 予測分布

(長期) 予測分布の更新

$((t+k)$ の予測) =  $\int dx_{t+k-1}$  システムの状態更新  $\times$   $((t+k-1)$ の予測)

$$f(x_{t+k}|y_{1:t}) = \int dx_{t+k-1} f(x_{t+k}|x_{t+k-1}) f(x_{t+k-1}|y_{1:t})$$

右向き矢印  $(t+k-1|t) \rightarrow (t+k|t)$ 

	$x_0$	$x_1$	$x_2$	$x_3$	$x_4$
$y_{1:0} = \emptyset$	(0 0)	(1 0)	(2 0)	(3 0)	(4 0)
$y_{1:1}$	(0 1)	(1 1)	(2 1)	(3 1)	(4 1)
$y_{1:2}$	(0 2)	(1 2)	(2 2)	(3 2)	(4 2)
$y_{1:3}$	(0 3)	(1 3)	(2 3)	(3 3)	(4 3)
$y_{1:4}$	(0 4)	(1 4)	(2 4)	(3 4)	(4 4)

## 平滑化

平滑化分布の更新 ( $t' < t$ )  
 フィルタリング分布  $\times$  補正

$$f(x_{t'}|y_{1:t}) = f(x_{t'}|y_{1:t'}) \times \int dx_{t'+1} \frac{f(x_{t'+1}|x_{t'})}{f(x_{t'+1}|y_{1:t})} f(x_{t'+1}|y_{1:t})$$

左向き矢印 ( $t'|t$ )  $\leftarrow$  ( $t' + 1|t$ )

	$x_0$	$x_1$	$x_2$	$x_3$	$x_4$
$y_{1:0} = \emptyset$	(0 0)	(1 0)	(2 0)	(3 0)	(4 0)
$y_{1:1}$	(0 1)	(1 1)	(2 1)	(3 1)	(4 1)
$y_{1:2}$	(0 2)	(1 2)	(2 2)	(3 2)	(4 2)
$y_{1:3}$	(0 3)	(1 3)	(2 3)	(3 3)	(4 3)
$y_{1:4}$	(0 4)	(1 4)	(2 4)	(3 4)	(4 4)

## 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

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

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

⋮

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

- 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.