

時系列解析 (11)

ー ボラティリティ、時変係数ARモデルー

東京大学 数理・情報教育研究センター


北川 源四郎

概要


1. 分散非定常モデル： 線形化・正規近似
2. 共分散非定常モデル：時変係数モデル
3. 非線形・非ガウス型状態空間モデル

分散・共分散非定常

地震波



日経225



非定常時系列のモデル

1. 平均非定常 トレンド, 季節調整

2. 分散非定常

- 線形・ガウスモデル（カルマンフィルタ）で推定するためには、近似が必要（線形化 + 正規近似）
- 非線形・非ガウス型状態空間モデルを使うと直接的なモデリングが可能

3. 共分散非定常

- 時変係数モデル

(線形モデルによる) 時変分散の推定

$$r_n = \sigma_n w_n, \quad w_n \sim N(0,1)$$


二乗

$$r_n^2 = \sigma_n^2 w_n^2$$

対数

$$\log r_n^2 = \log \sigma_n^2 + \log w_n^2$$

- 変換により分散変動の推定問題は **トレンド推定の問題に変換される**
- ただし、ノイズは正規分布ではない



(線形モデルによる) 時変分散の推定

分散変化のモデル (例)

$$\log \sigma_n^2 = \log \sigma_{n-1}^2 + \varepsilon_n$$

$$\log \sigma_n^2 = \alpha + \beta \log \sigma_{n-1}^2 + \varepsilon_n$$

ランダムウォーク型

(定数付き) AR型

時変分散のモデル (例)

$$\log \sigma_n^2 = \log \sigma_{n-1}^2 + \varepsilon_n$$

$$\log r_n^2 = \log \sigma_n^2 + \log w_n^2$$

状態空間表現

$$\log \sigma_n^2 = \log \sigma_{n-1}^2 + \varepsilon_n$$

$$\log r_n^2 = \log \sigma_n^2 + \log w_n^2$$






$x_n \equiv \log \sigma_n^2$, $y_n \equiv \log r_n^2$, $\delta_n \equiv \log w_n^2$ とおくと

$$x_n = x_{n-1} + \varepsilon_n$$

$$y_n = x_n + \delta_n$$

- 状態空間表現
- δ_n は正規分布には従わない
 - ✓ 正規近似 \longrightarrow カルマンフィルタ
 - ✓ 非正規分布 \longrightarrow 非ガウス型フィルタ

二種類のデータ変換



$\log w_n^2$ の分布：二重指数分布

$$y_n \sim N(0,1)$$

$$x_1 = y_1^2 \sim \chi_1^2 \quad (\text{カイ二乗分布})$$

$$g(x) = (2\pi x)^{-\frac{1}{2}} \exp\left\{-\frac{x}{2}\right\}$$

$$x = h(y) = y^2$$

$$y \begin{matrix} \xrightarrow{h} \\ \xleftarrow{h^{-1}} \end{matrix} x$$

$$f(y) = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{y^2}{2}\right\}$$

$$x = h(y) = y^2 \Rightarrow h^{-1}(x) = x^{\frac{1}{2}} \Rightarrow \frac{dh^{-1}}{dx} = \frac{1}{2} x^{-\frac{1}{2}}$$

$$\begin{aligned} g(x) &= \left| \frac{dh^{-1}}{dx} \right| \varphi(x | 0, 1) = 2 \times \frac{1}{2} x^{-\frac{1}{2}} (2\pi)^{-\frac{1}{2}} \exp\left\{-\frac{x}{2}\right\} \\ &= (2\pi x)^{-\frac{1}{2}} \exp\left\{-\frac{x}{2}\right\} \end{aligned}$$

$$w_1 = \log x_1$$

$$p(w) = \frac{1}{\sqrt{2\pi}} \exp\left\{\frac{w - e^w}{2}\right\}$$

(二重指数分布)

$$\begin{aligned} p(w) &= \left| \frac{d \log^{-1}}{dw} \right| g(h^{-1}(w)) \\ &= \left| \frac{d \log^{-1}}{dw} \right| (2\pi e^w)^{-\frac{1}{2}} \exp\left\{-\frac{e^w}{2}\right\} \\ &= (2\pi)^{-\frac{1}{2}} \exp\left\{\frac{w}{2} - \frac{e^w}{2}\right\} \end{aligned}$$

二重指数分布 (Gumbel分布)

$$y_n \sim N(0, 1)$$

$$s_2 = (y_1^2 + y_2^2) / 2 \sim \frac{1}{2} \chi_2^2 \quad (\text{自由度 } 2 \text{ の } \chi^2 \text{ 分布} = \text{指数分布})$$

$$g(s) = \exp\{-s\}$$

$$w_2 = \log s_2$$

$$\begin{aligned} p(w) &= \left| \frac{de^w}{dw} \right| g(h^{-1}(w)) \\ &= e^w \exp\{-e^w\} \\ &= \exp\{w - e^w\} \end{aligned}$$

$$w = h(s) = \log s$$

$$s \begin{array}{c} \xrightarrow{h} \\ \xleftarrow{h^{-1}} \end{array} w$$

$$h^{-1}(w) = e^w$$

$$p(w) = \exp\{w - e^w\} : \quad \text{二重指数分布}$$

注： $p(-w)$ はGumbel分布

二重指数分布の正規分布による近似

$$\log w_n^2 \sim \frac{1}{\sqrt{2\pi}} \exp \left\{ \frac{w}{2} - \frac{e^w}{2} \right\} \Rightarrow N(\zeta, \pi^2 / 2), \quad \zeta = -1.27036$$

$$\log w_n^2 \sim \exp \{ w - e^w \} \Rightarrow N(\gamma, \pi^2 / 6), \quad \gamma = -0.577216$$


γ Euler定数

log-ピリオドグラムの平滑化
Wahba (1980)

時変分散・ボラティリティ
Kitagawa & Gersch (1985)
Nelson (1988),
Harvey, Ruiz, Shepard (1994)


-1.27036 4.934802
-0.577216 1.644934
-0.270363 0.644934

二重指数分布と正規近似



$$\log(y_n^2)$$

$$g(w) = \frac{1}{\sqrt{2\pi}} \exp\left\{\frac{w - e^w}{2}\right\}$$



$$\log(y_{2m-1}^2 + y_{2m}^2)$$

$$g(w) = \exp\{w - e^w\}$$

- 正規近似が良くなる
- 分散が1/3
- データ数が1/2

分散変動(時変分散)モデル

$$\Delta^k t_m = v_m$$


$$z_m = t_m + w_m$$

$$h(w) = \exp\{w - e^w\} \sim N\left(-\gamma, \frac{\pi^2}{6}\right) \quad \chi_2^2\text{-型}$$


$$h(w) = \frac{1}{\sqrt{2\pi}} \exp\left\{\frac{1}{2}(w - e^w)\right\} \sim N\left(-\zeta, \frac{\pi^2}{2}\right) \quad \chi_1^2\text{-型}$$

時変分散の推定： MYE1F

χ_2^2 -型, トレンド次数=2
 $\tau^2 = 6.6 \times 10^{-6}$, $\sigma^2 = 9.71 \times 10^{-1}$
log-likelihood = -2195.731
AIC=4399.46



時変分散の推定とデータの等分散化




```
# an earthquake wave data  
data(MYE1F)
```

```
#  
tvvar(MYE1F, 2, 6.6e-06, 1.0e-06)
```


```
tau2      6.60000e-06  
sigma2    9.71228e-01  
log-likelihood -2195.731  
aic       4399.462
```

変換したデータ


MYE1F



時変分散



等分散化したデータ



AR型の分散変動モデル

ランダムウォークモデル

$$\log \sigma_n^2 = \log \sigma_{n-1}^2 + v_n$$

$$\log r_n^2 = \log \sigma_n^2 + \log w_n^2$$

AR 型モデル

$$\log \sigma_n^2 = \alpha + \beta \log \sigma_{n-1}^2 + \varepsilon_n$$

$$\log r_n^2 = \log \sigma_n^2 + \log w_n^2$$

時変スペクトル



時変係数 AR モデル

$$y_n = \sum_{j=1}^m a_{jn} y_{n-j} + w_n, \quad w_n \sim N(0, \sigma^2)$$

時変係数回帰モデル

時変係数AR モデルの推定

$$y_n = \sum_{j=1}^m a_{jn} y_{n-j} + w_n, \quad a_{nj} \text{ は時間とともに変動}$$

係数変化のモデル

$$\Delta^k a_{jn} = v_{jn}, \quad v_{jn} \sim N(0, \tau^2)$$

状態空間表現

$$\begin{aligned} x_n &= Fx_{n-1} + Gv_n & v_n &\sim N(0, Q) \\ y_n &= H_n x_n + w_n & w_n &\sim N(0, R) \end{aligned}$$

x_n, F, G, H_n, Q, R を定める

時変係数ARモデル

$$F^{(1)} = G^{(1)} = H^{(1)} = 1$$

$$F^{(2)} = \begin{bmatrix} 2 & -1 \\ 1 & 0 \end{bmatrix}, \quad G^{(1)} = \begin{bmatrix} 1 \\ 0 \end{bmatrix},$$

$$H^{(1)} = \begin{bmatrix} 1 & 0 \end{bmatrix}$$

$$F = F^{(k)} \otimes I_m, \quad G = G^{(k)} \otimes I_m$$

$$H_n = H^{(k)} \otimes (y_{n-1}, \dots, y_{n-m})$$

$$Q = \tau^2 \otimes I_m, \quad R = \sigma^2$$

$$x_n = (a_{1n}, \dots, a_{mn})^T \otimes (I, B, \dots, B^{k-1})$$

⊗ Kronecker 積

$$A \otimes B = \begin{bmatrix} a_{11} & \cdots & a_{1\ell} \\ \vdots & \ddots & \vdots \\ a_{m1} & \cdots & a_{m\ell} \end{bmatrix} \otimes \begin{bmatrix} b_{11} & \cdots & b_{1q} \\ \vdots & \ddots & \vdots \\ b_{p1} & \cdots & b_{pq} \end{bmatrix} = \begin{bmatrix} a_{11}B & \cdots & a_{1\ell}B \\ \vdots & \ddots & \vdots \\ a_{m1}B & \cdots & a_{m\ell}B \end{bmatrix}$$

$$F^{(1)} \otimes I_m = I_m, \quad F^{(2)} \otimes I_m = \begin{bmatrix} 2I_m & -I_m \\ I_m & O \end{bmatrix}$$

状態空間表現 ($k = 1$ の場合)

$$\begin{bmatrix} a_{1n} \\ \vdots \\ a_{mn} \end{bmatrix} = \begin{bmatrix} 1 & & \\ & \ddots & \\ & & 1 \end{bmatrix} \begin{bmatrix} a_{1,n-1} \\ \vdots \\ a_{m,n-1} \end{bmatrix} + \begin{bmatrix} 1 & & \\ & \ddots & \\ & & 1 \end{bmatrix} \begin{bmatrix} v_{1,n} \\ \vdots \\ v_{m,n} \end{bmatrix}$$

$$y_n = [y_{n-1}, \dots, y_{n-m}] \begin{bmatrix} a_{1n} \\ \vdots \\ a_{mn} \end{bmatrix} + w_n$$

$$Q = \begin{bmatrix} \tau^2 & & \\ & \ddots & \\ & & \tau^2 \end{bmatrix}, \quad R = \sigma^2$$

状態空間表現 ($k = 2$ の場合)

$$\begin{bmatrix} a_{1n} \\ \vdots \\ a_{mn} \\ \hline a_{1n-1} \\ \vdots \\ a_{mn-1} \end{bmatrix} = \begin{bmatrix} 2 & & -1 & & \\ & \ddots & & \ddots & \\ & & 2 & & -1 \\ \hline 1 & & & & \\ & \ddots & & & \\ & & 1 & & 1 \end{bmatrix} \begin{bmatrix} a_{1n-1} \\ \vdots \\ a_{mn-1} \\ \hline a_{1n-2} \\ \vdots \\ a_{mn-2} \end{bmatrix} + \begin{bmatrix} 1 & & & & \\ & \ddots & & & \\ & & & & 1 \end{bmatrix} \begin{bmatrix} v_{1,n} \\ \vdots \\ v_{m,n} \end{bmatrix}$$

$$y_n = [y_{n-1}, \dots, y_{n-m}, 0, \dots, 0] \begin{bmatrix} a_{1n} \\ \vdots \\ a_{mn} \\ \hline a_{1n-1} \\ \vdots \\ a_{mn-1} \end{bmatrix} + w_n \quad Q = \begin{bmatrix} \tau^2 & & & \\ & \ddots & & \\ & & & \\ & & & \tau^2 \end{bmatrix}, \quad R = \sigma^2$$

システムノイズの等分散仮定について

$Q = \text{diag}\{\tau^2, \dots, \tau^2\}$: の仮定は妥当か？

$$A(f, n) = 1 - \sum_{j=1}^m a_{nj} e^{-2\pi i j f}, \quad -\frac{1}{2} \leq f \leq \frac{1}{2}$$

AR係数のフーリエ変換

$$p_n(f) = \frac{\sigma^2}{|A(f, n)|^2}$$

ARモデルを白色化フィルタと
考えたときの周波数応答関数

$A(f, n)$ の時間変化の滑らかさに関する評価

$$\Delta^k A(f, n) = \sum_{j=1}^m \Delta^k a_{nj} e^{-2\pi i j f}$$

周波数領域 $-\frac{1}{2} \leq f \leq \frac{1}{2}$ で二乗積分

$$\int_{-\frac{1}{2}}^{\frac{1}{2}} |\Delta^k A(f, n)|^2 df = \sum_{j=1}^m (\Delta^k a_{nj})^2$$

各次数を同じ割合で加算しているので

$$\Delta_n^k a_{nj} = v_{nj}, \quad v_{nj} \sim N(0, \tau^2)$$

時変係数ARモデルのAIC





m	$k=1$	$k=2$	m	$k=1$	$k=2$
1	6492.5	6520.4	6	4831.9	4873.8
2	5527.7	5643.2	7	4821.6	4878.7
3	5070.0	5134.5	8	4805.1	4866.9
4	4820.0	4853.0	9	4813.4	4884.9
5	4846.0	4886.0	10	4827.1	4911.9

Rによる時変係数ARモデルの推定

```
data(MYE1F) # an earthquake wave data  
z <- tvar(MYE1F, trend.order = 2, ar.order = 8,  
span = 20, tau2.ini = 6.6e-06, delta = 1.0e-06)
```

z

tau2	1.60000e-06
sigma2	1.43071e+01
log-likelihood	-7284.520
aic	14589.041



時変係数 AR モデル

$$y_n = \sum_{j=1}^m a_{jn} y_{n-j} + w_n, \quad w_n \sim N(0, \sigma^2)$$

時変スペクトル

$$p_n(f) = \frac{\sigma_n^2}{\left| 1 - \sum_{j=1}^m a_{jn} e^{-2\pi i j f} \right|^2}$$


Rによる時変スペクトルの計算

```
z <- tvar(MYE1F, trend.order = 2, ar.order = 8,  
span = 20, tau2.ini = 6.6e-06, delta = 1.0e-06)
```

```
# 時変スペクトル
```

```
spec <- tvspc(z$arcoef, z$sigma2)
```

```
plot(spec, theta = 30, phi = 40, expand = 0.5)
```








係数の急激な変化について

- トレンドモデルによる変化はゆっくりした変化を仮定している
- 地震波などでは突然別のモデルに変化することがある。
- 対応 1
 - 変化点既知の場合
 - $k=1$ の場合： その時点で τ^2 を大きくすればよい
 - $k=2$ の場合： それだけでは屈折点となる
 - $x_{n|n-1}$ と $V_{n|n-1}$ を初期化するか $V_{n|n-1}$ の対角成分に大きな値を入れる
- 対応 2： 非ガウス型モデルを利用する（変化点未知でよい）

Rによる時変係数ARモデルの推定（構造変化を仮定）


```
z <- tvar(MYE1F, trend.order = 2, ar.order = 8,  
span = 40, outlier = c(630, 1026), tau2.ini = 6.6e-06,  
delta = 1.0e-06)
```

構造変化の時点




Rによる時変スペクトルの推定（構造変化を仮定）

```
# n=630と1026の2か所で構造変化があったと仮定
#
z <- tvar(MYE1F, trend.order = 2, ar.order = 8, span = 40,
          outlier = c(630, 1026), tau2.ini = 6.6e-06, delta = 1.0e-06)
#
# 時変係数ARモデルから時変スペクトルを計算
# 時変スペクトルを3次元表示
#
spec <- tvspc(z$arcoef, z$sigma2)
plot(spec, theta = 30, phi = 40, expand = 0.5)
```





時変係数と時変スペクトル




局所定常構造
時変係数AR

時変係数AR




時変スペクトル



本と同様の3次元プロット (未公開)

```
#####  
# 時変スペクトルの3次元表示  
#####  
# seismic data  
data(MYE1F)  
z <- tvar(MYE1F, trend.order = 2, ar.order = 8, span =  
20, outlier = c(630, 1026), tau2.ini = 6.6e-06, delta =  
1.0e-06)  
spec <-  
tvspc(z$arcoef, z$sigma2)  
#####  
  
# 最初のスペクトル(n=0)  
nf <- 201  
dt <- 2  
dy <- 0.2  
nf1 <- nf-dt  
t <- 1:nf  
tt <- 1:nf1  
plot(t,spec$z[,1],type="l", xlim=c(1,501),ylim=c(-2,18))  
y <- spec$z[,1] z  
<- y  
  
# 鳥瞰図(n=1,80)  
nrep <- 1:80  
for (i in nrep){  
  par(new=T)  
  t <- t+dt  
  for (j in 1:nf) z[j] <- spec$z[j,i]+dy*(i-1)  
  for (j in tt){  
    # z[j] <- max(spec$z[j,i]+dy*(i-1),y[j+dt])  
    z[j] <- max(z[j],y[j+dt])  
  }  
  y <- z  
  plot(t,y,type="l", xlim=c(1,501),ylim=c(-  
2,18),xaxt='n',yaxt="n")
```



スペクトルの滑らかさの制約

$$R_k = \int_{-\frac{1}{2}}^{\frac{1}{2}} \left| \frac{\Delta^k A(f, n)}{\partial f^k} \right|^2 df = (2\pi)^{2k} \sum_{j=1}^m j^{2k} a_{nj}^2$$

$$a_{jn} = u_{jn}^{(k)}, \quad u_{jn}^{(k)} \sim N(0, (j^k \lambda_k)^{-2})$$

$$a_{jn} = u_{jn}, \quad u_{jn} \sim N(0, (\lambda_0^2 + j^4 \lambda_2^2)^{-1})$$

$$\begin{aligned} \begin{bmatrix} a_{1n} \\ \vdots \\ a_{mn} \end{bmatrix} &= \begin{bmatrix} 1 & & & \\ & \ddots & & \\ & & 1 & \\ & & & \ddots \end{bmatrix} \begin{bmatrix} a_{1,n-1} \\ \vdots \\ a_{m,n-1} \end{bmatrix} + \begin{bmatrix} u_{1n} \\ \vdots \\ u_{mn} \end{bmatrix} & \begin{bmatrix} v_{1n} \\ \vdots \\ v_{mn} \end{bmatrix} \sim N \left(\begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix}, \begin{bmatrix} \tau^2 & & \\ & \ddots & \\ & & \tau^2 \end{bmatrix} \right) \\ \begin{bmatrix} y_n \\ 0 \\ \vdots \\ 0 \end{bmatrix} &= \begin{bmatrix} y_{n-1} & y_{n-2} & \cdots & y_{n-m} \\ 1 & & & \\ & \ddots & & \\ & & 1 & \end{bmatrix} \begin{bmatrix} a_{1n} \\ \vdots \\ a_{mn} \end{bmatrix} + \begin{bmatrix} w_n \\ u_{1n} \\ \vdots \\ u_{mn} \end{bmatrix} & \begin{bmatrix} w_n \\ u_{1n} \\ \vdots \\ u_{mn} \end{bmatrix} \sim N \left(\begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \begin{bmatrix} 1 & & & \\ & (\lambda_0^2 + \lambda_2^2)^{-1} & & \\ & & \ddots & \\ & & & (\lambda_0^2 + m^4 \lambda_2^2)^{-1} \end{bmatrix} \right) \end{aligned}$$

時系列解析 (12)

— 非線形・非ガウス型状態空間モデル —

東京大学 数理・情報教育研究センター

北川 源四郎

非線形・非ガウス型フィルタ


- 拡張カルマンフィルタ
- ガウス和フィルタ
- 非ガウス型フィルタ
- 粒子フィルタ
- アンサンブルカルマンフィルタ

非ガウス型モデリングの必要性


構造変化



非対称分布




異常値 (外れ値)



非線形性

$$x_n = f(x_{n-1}) + v_n$$

離散過程



状態空間モデルの拡張

線形・ガウス型

$$x_n = Fx_{n-1} + Gv_n$$

$$y_n = Hx_n + w_n$$

非線形・非ガウス型

$$x_n = f(x_{n-1}, v_n)$$

$$y_n = h(x_n, w_n)$$

関数：非線形
分布：非ガウス型

$$\begin{aligned}x_n &= f(x_{n-1}, v_n) \\ y_n &= h(x_n) + w_n\end{aligned}$$

x_n : 状態

y_n : 時系列

v_n : システムノイズ

$$v_n \sim q(v)$$

w_n : 観測ノイズ

$$w_n \sim r(w)$$

$$y_n = h(x_n, w_n)$$

ただし、 $h(x,w)$ の逆関数 $g(y,x)$ が存在して

- $w_n = g(y_n, x_n)$
- y で微分可能 ($\partial g / \partial y$ が存在)

$$\begin{aligned} \text{(例)} \quad y_n &= e^{x_n} w_n \\ w_n &= e^{-x_n} y_n \\ \frac{\partial g}{\partial y} &= e^{-x_n} \end{aligned}$$

- ボラティリティのモデリングなどで必要

非線形・非ガウス型状態空間モデル

非線形関数の例

$$x_n = f(x_{n-1}, v_n)$$

$$y_n = h(x_n, w_n)$$

$f(x)$ 非線形変換

$f(x, v)$ 積型

$h(x, w)$ 積型 (e^{xw} など)


$y=h(x, w)$ から $w=k(y, x)$ と
書ける必要がある。

$h(x)+w$ の方が簡単

非ガウス型分布の例

- ・ コーシー分布

$$p(x) = \frac{\sigma}{\pi} \frac{1}{(x - \mu)^2 + \sigma^2}$$



- ・ ピアソン分布族


$$p(x) = C \left((x - \mu)^2 + \sigma^2 \right)^{-b}$$

$$C = \frac{\tau^{2b-1} \Gamma(b)}{\Gamma(\frac{1}{2}) \Gamma(b - \frac{1}{2})}$$

- ・ 二重指数分布


- ・ 混合分布

$$p(x) = \alpha \varphi_1(x, \theta_1) + (1 - \alpha) \varphi_2(x, \theta_2)$$



状態推定

	カルマンフィルタ	非線形
予測	$x_{n n-1}, V_{n n-1}$	$p(x_n Y_{n-1})$
フィルタ	$x_{n n}, V_{n n}$	$p(x_n Y_n)$



非ガウス型予測の導出

$$p(x_n | Y_{n-1}) = \int_{-\infty}^{\infty} p(x_n, x_{n-1} | Y_{n-1}) dx_{n-1}$$

$$p(x) = \int_{-\infty}^{\infty} p(x, y) dy$$

$$\begin{aligned} p(x_n, x_{n-1} | Y_{n-1}) &= p(x_n | x_{n-1}, Y_{n-1}) p(x_{n-1} | Y_{n-1}) \\ &= p(x_n | x_{n-1}) p(x_{n-1} | Y_{n-1}) \end{aligned}$$

$$p(x, y) = p(y) p(x | y)$$

$$p(x_n | x_{n-1}, Y_{n-1}) = p(x_n | x_{n-1})$$

$$p(x_n | Y_{n-1}) = \int_{-\infty}^{\infty} p(x_n | x_{n-1}) p(x_{n-1} | Y_{n-1}) dx_{n-1}$$

非ガウス型フィルタの導出

$$\begin{aligned} p(x_n | Y_n) &= p(x_n | Y_{n-1}, y_n) \\ &= \frac{p(y_n, x_n | Y_{n-1})}{p(y_n | Y_{n-1})} \\ &= \frac{p(y_n | x_n, Y_{n-1}) p(x_n | Y_{n-1})}{p(y_n | Y_{n-1})} \\ &= \frac{p(y_n | x_n) p(x_n | Y_{n-1})}{p(y_n | Y_{n-1})} \end{aligned}$$

$$Y_n = \{y_1, \dots, y_n\} = \{Y_{n-1}, y_n\}$$

$$\begin{aligned} p(x | y) &= \frac{p(x, y)}{p(y)} \\ &= \frac{p(y | x) p(x)}{p(y)} \end{aligned}$$

$$p(y_n | x_n, Y_{n-1}) = p(y_n | x_n)$$

$$p(x_n | Y_n) = \frac{p(y_n | x_n) p(x_n | Y_{n-1})}{p(y_n | Y_{n-1})}$$

非ガウス型平滑化の導出

$$\begin{aligned} p(x_n, x_{n+1} | Y_N) &= p(x_{n+1} | Y_N) p(x_n | x_{n+1}, Y_N) \\ &= p(x_{n+1} | Y_N) p(x_n | x_{n+1}, Y_n) \\ &= p(x_{n+1} | Y_N) \frac{p(x_{n+1}, x_n | Y_n)}{p(x_{n+1} | Y_n)} \\ &= p(x_{n+1} | Y_N) \frac{p(x_{n+1} | x_n, Y_n) p(x_n | Y_n)}{p(x_{n+1} | Y_n)} \\ &= p(x_{n+1} | Y_N) \frac{p(x_{n+1} | x_n) p(x_n | Y_n)}{p(x_{n+1} | Y_n)} \end{aligned}$$

$$p(x, y) = p(y) p(x | y)$$

$$p(x_n | x_{n+1}, Y_N) = p(x_n | x_{n+1}, Y_n)$$

$$\begin{aligned} p(x | z) &= \frac{p(z, x)}{p(z)} \\ &= \frac{p(z | x) p(x)}{p(z)} \end{aligned}$$

$$p(x_{n+1} | x_n, Y_n) = p(x_{n+1} | x_n)$$

$$\begin{aligned} p(x_n | Y_N) &= \int_{-\infty}^{\infty} p(x_n, x_{n+1} | Y_N) dx_{n+1} \\ &= p(x_n | Y_n) \int_{-\infty}^{\infty} \frac{p(x_{n+1} | x_n) p(x_{n+1} | Y_N)}{p(x_{n+1} | Y_n)} dx_{n+1} \end{aligned}$$

一期先予測

$$p(x_n | Y_{n-1}) = \int_{-\infty}^{\infty} p(x_n | x_{n-1}) p(x_{n-1} | Y_{n-1}) dx_{n-1}$$

フィルタ

$$p(x_n | Y_n) = \frac{p(y_n | x_n) p(x_n | Y_{n-1})}{p(y_n | Y_{n-1})}$$

平滑化

$$p(x_n | Y_N) = p(x_n | Y_n) \int_{-\infty}^{\infty} \frac{p(x_{n+1} | x_n) p(x_{n+1} | Y_N)}{p(x_{n+1} | Y_n)} dx_{n+1}$$

分布の近似

0. 線形・正規モデル近似

カルマンフィルタ・平滑化

1. 正規分布近似


拡張カルマンフィルタ・平滑化

2. 区分線形（階段）近似

非ガウス型フィルタ・平滑化

3. 混合正規分布近似

ガウス和フィルタ・平滑化



予測

$$x_{n|n-1} = f_n(x_{n-1|n-1})$$

$$V_{n|n-1} = F_n V_{n-1|n-1} F_n^T + G_n Q_n G_n^T$$

フィルタ

$$K_n = V_{n|n-1} H_n^T (H_n V_{n|n-1} H_n^T + R_n)^{-1}$$

$$x_{n|n} = x_{n|n-1} + K_n (y_n - h_n(x_{n|n-1}))$$

$$V_{n|n} = (I - K_n H_n) V_{n|n-1}$$

$$F_n = \left[\frac{\partial f_n}{\partial x_n} \right]_{x_n = x_{n|n}}$$

$$G_n = \left[\frac{\partial g_n}{\partial x_n} \right]_{x_n = x_{n|n}}$$

$$H_n = \left[\frac{\partial h_n}{\partial x_n} \right]_{x_n = x_{n|n-1}}$$

密度関数の数値近似

密度関数	近似	記号
$p(x_n Y_{n-1})$	$\{d; t_0, \dots, t_d; p_1, \dots, p_d\}$	$p(t)$
$p(x_n Y_n)$	$\{d; t_0, \dots, t_d; f_1, \dots, f_d\}$	$f(t)$
$p(x_n Y_N)$	$\{d; t_0, \dots, t_d; s_1, \dots, s_d\}$	$s(t)$
$q(v_n)$	$\{2d+1; t_{-d}, \dots, t_d; q_{-d}, \dots, p_d\}$	$q(t)$

数値積分による実現

1次トレンドモデルの場合

$$t_n = t_{n-1} + v_n$$

$$y_n = t_n + w_n$$

一期先予測

$$p_i = p(t_i) = \int_{t_0}^{t_d} q(t_i - s) f(s) ds$$

$$= \sum_{j=1}^d \int_{t_{j-1}}^{t_j} q(t_i - s) f(s) ds$$

$$= \Delta t \sum_{j=1}^d q_{i-j} f_j$$

(数値積分：畳み込み積分)

フィルタ

$$f_i = f(t_i) = \frac{r(y_n - t_i) p(t_i)}{C}$$

$$= \frac{r(y_n - t_i) p_i}{C}$$

$$C = \int_{t_0}^{t_d} r(y_n - t) p(t) dt$$

$$= \sum_{j=1}^d \int_{t_{j-1}}^{t_j} r(y_n - t) p(t) dt$$

$$= \Delta t \sum_{j=1}^d r(y_n - t) p_j$$

各ステップの後で密度関数の全積分が1になるように規格化する

数値積分による実現(平滑化)

平滑化

$$\begin{aligned} s_i = s(t_i) &= f(t_i) \int_{t_0}^{t_d} \frac{q(t_i - u)s(u)}{p(u)} du \\ &= f(t_i) \sum_{j=1}^d \int_{t_{j-1}}^{t_j} \frac{q(t_i - u)s(u)}{p(u)} du \\ &= \Delta t \cdot f(t_i) \sum_{j=1}^d \frac{q_{i-j} s_j}{P_j} \end{aligned}$$

各ステップの後で密度関数の全積分が1になるように規格化する