

第9章「SVモデルとカルマン・フィルター」

1. Stochastic Volatility モデル

時点 t における収益率を x_t とするとき，次のモデルを SV (Stochastic Volatility: 確率的ボラティリティー) モデルという．

SV モデル (Stochastic Volatility Model):

$$x_t = \sigma_t \varepsilon_t, \quad \log \sigma_t^2 = \gamma + \phi \log \sigma_{t-1}^2 + \eta_t, \quad (1)$$

$$\{\varepsilon_t\} \sim \text{NID}(0, 1), \quad \{\eta_t\} \sim \text{NID}(0, \sigma_\eta^2)$$

ここで， $\{\varepsilon_t\}$ と $\{\eta_t\}$ は互いに独立．したがって， $\{\varepsilon_t\}$ と $\{\sigma_t\}$ も互いに独立．SV モデルは Taylor モデルとも呼ばれる．

2. SV モデルの推定

SV モデルにはパラメータ $\gamma, \phi, \sigma_\eta^2$ が含まれている．これらを推定するために，SV モデルを次のように表現する．

$$\log x_t^2 = \mu + \log \sigma_t^2 + \xi_t, \quad \log \sigma_t^2 = \gamma + \phi \log \sigma_{t-1}^2 + \eta_t, \quad (2)$$

ここで， $\mu = E(\log \varepsilon_t^2)$ ， $\xi_t = \log \varepsilon_t^2 - E(\log \varepsilon_t^2)$ ．パラメータ μ は次のように正確に計算可能．まず， ε_t^2 が自由度 1 の χ^2 分布に従うことから， $\varepsilon_t^2 = W$ とおくととき， $\log W$ の積率母関数 (mgf) は

$$\begin{aligned} m(\theta) &= E(e^{\theta \log W}) = E(W^\theta) \\ &= \int_0^\infty \frac{1}{\sqrt{2\pi}} w^{\theta-1/2} e^{-w/2} dw = \frac{2^{\theta+1/2} \Gamma(\theta+1/2)}{\sqrt{2\pi}} \int_0^\infty \frac{w^{\theta-1/2} e^{-w/2} dw}{2^{\theta+1/2} \Gamma(\theta+1/2)} \\ &= \frac{2^{\theta+1/2} \Gamma(\theta+1/2)}{\sqrt{2\pi}} \end{aligned}$$

となる．したがって，

$$\begin{aligned} \mu &= \frac{d}{d\theta} [\log m(\theta)]_{\theta=0} \\ &= \frac{d}{d\theta} [(\theta+1/2) \log 2 + \log \Gamma(\theta+1/2) - \log \sqrt{2\pi}]_{\theta=0} \\ &= \log 2 + \frac{\Gamma'(1/2)}{\Gamma(1/2)} = \log 2 + \psi(1/2) \\ &= -1.270363 \end{aligned}$$

(注) $\psi(x) = d \log \Gamma(x) / dx$ であり，digamma 関数と呼ばれる．

さらに ,

$$\begin{aligned}\sigma_{\xi}^2 &= V(\xi) = \frac{d^2}{d\theta^2} [\log m(\theta)]_{\theta=0} \\ &= \frac{d}{dx} [\psi(x)]_{x=1/2} = \psi'(1/2) = \frac{\pi^2}{2} \\ &= 4.9348\end{aligned}$$

(注) $\psi'(x) = d\psi(x)/dx$ は trigamma 関数と呼ばれる .

SV モデルの性質

- (a) 収益率 $\{x_t\}$ の条件付き分布は nonnormal
- (b) 厳密な尤度関数を導出することは不可能
- (c) $\log x_t^2$ は ARMA(1,1) モデル

$$\log x_t^2 = \phi \log x_{t-1}^2 + \mu(1 - \phi) + \gamma + \eta_t + \xi_t - \phi\xi_{t-1}$$

に従う . ここで , η_t は normal , しかし ξ_t は nonnormal.

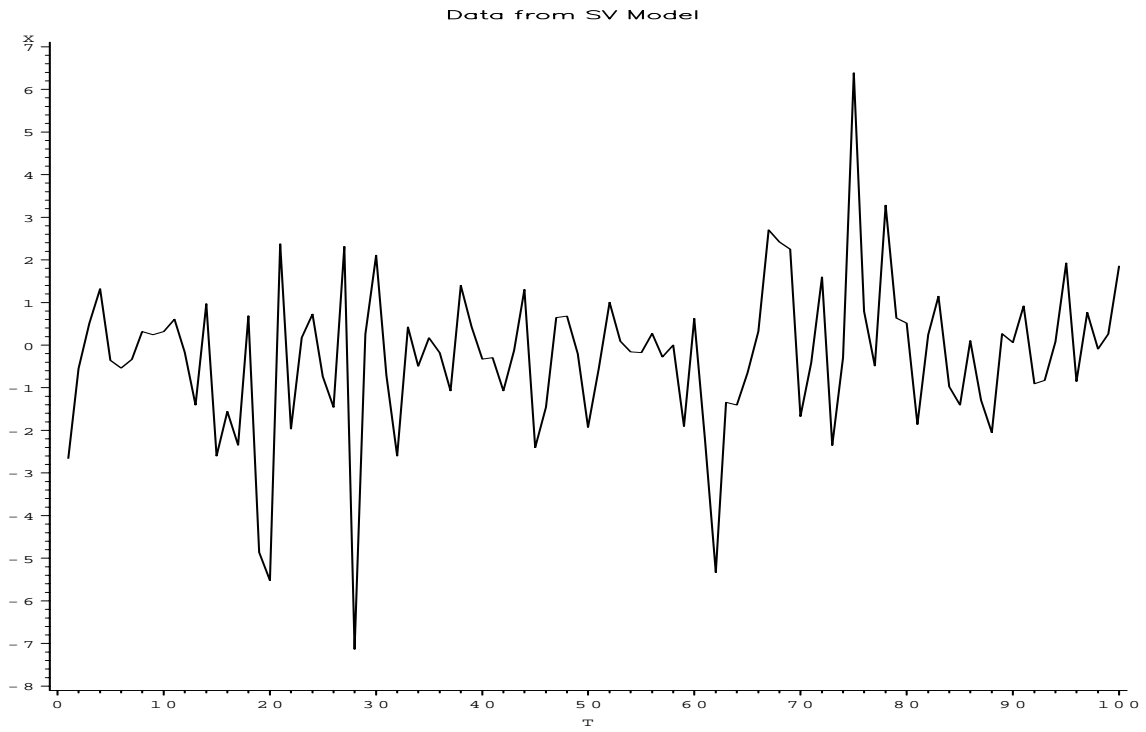
例 1 : コンピュータで生成した SV モデルからの 100 個のデータの系列 $\{x_t\}$ と , それを変換した系列 $\{\log x_t^2\}$ が次のページに図示されている . $\{x_t\}$ は ,

$$x_t = \sigma_t \varepsilon_t, \quad \log \sigma_t^2 = \phi \log \sigma_{t-1}^2 + \eta_t, \quad \phi = 0.6$$

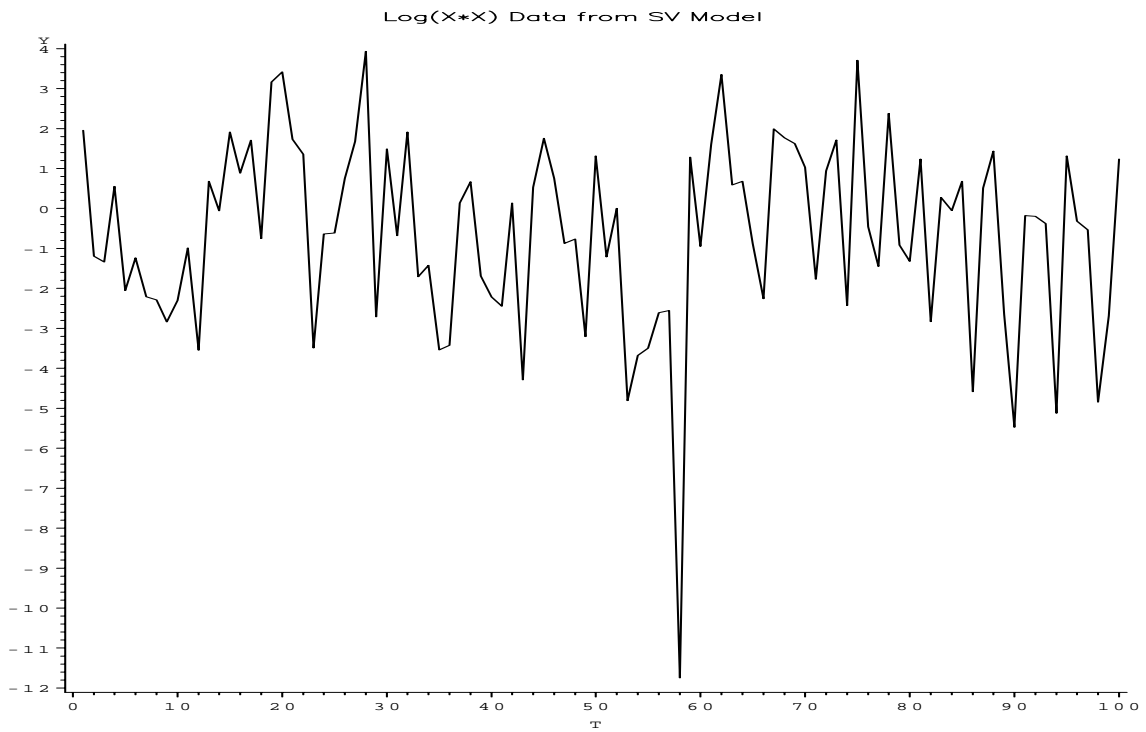
$$\{\varepsilon_t\} \sim \text{NID}(0, 1), \quad \{\eta_t\} \sim \text{NID}(0, \sigma_{\eta}^2), \quad \sigma_{\eta}^2 = 1$$

から生成されたものである . 前述のように , $\{\log x_t^2\}$ は ARMA(1,1) に従うが , 誤差項は non-normal である . 図の系列にも normal の場合には見られないような outlier が存在する .

SV Model からの収益率データ



$\{\log x_t^2\}$ に変換されたデータ



非正規性を無視した最尤推定

Name of variable = Y = 原系列の 2 乗の対数値

Mean of working series = -0.65155

Standard deviation = 2.389239

Number of observations = 100

Autocorrelations

Lag	Covar	Corr	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
0	5.70846	1.00000												*****									
1	0.64595	0.11316									.	**	.										
2	0.7962	0.13948									.	***	.										
3	0.38575	0.06757									.	*	.										
4	0.56572	0.09910									.	**	.										
5	0.5304	0.09291									.	**	.										
6	0.09337	0.01636									.		.										
7	-0.2401	-0.04206									.	*	.										
8	0.26546	0.04650									.	*	.										
9	-0.5944	-0.10413									.	**	.										
10	-0.5146	-0.09014									.	**	.										
11	-0.4924	-0.08626									.	**	.										
12	-0.0574	-0.01006									.		.										
13	-0.0949	-0.01663									.		.										
14	-0.5001	-0.08761									.	**	.										
15	-0.4605	-0.08067									.	**	.										
16	-0.0828	-0.01451									.		.										
17	-0.1128	-0.01977									.		.										
18	0.08756	0.01534									.		.										
19	-0.2946	-0.05161									.	*	.										
20	-0.6611	-0.11581									.	**	.										
21	-1.0407	-0.18231									.	****	.										
22	-0.1692	-0.02964									.	*	.										
23	-0.3377	-0.05916									.	*	.										
24	0.16488	0.02888									.	*	.										

Maximum Likelihood Estimation

Parameter	Estimate	Approx.			Lag
		Std Error	T Ratio		
MU	-0.64809	0.34482	-1.88		0
MA1,1	0.62323	0.36748	1.70		1
AR1,1	0.74190	0.31523	2.35		1

Constant Estimate = -0.1672691

Variance Estimate = 5.69998245

SV モデルは最尤推定が困難であるので，GMM (Generalized Method of Moments) や擬似最尤推定 (Quasi ML) などの方法が提案されている．ここでは，次節で状態空間モデルを使った擬似最尤推定を考える．

3 . 状態空間モデル (State Space Model)

観測値 y_t が

$$\text{観測方程式: } y_t = \beta_t + \varepsilon_t$$

$$\text{状態方程式: } \beta_t = \delta + \rho\beta_{t-1} + \eta_t$$

と表されるものとする．ここで，

- (a) β_t は観測不可能な確率変数 (状態変数) である．
- (b) 誤差項 ε_t と η_t は互いに独立である．
- (c) $\{\varepsilon_t\} \sim \text{NID}(0, \sigma^2)$, $\{\eta_t\} \sim \text{NID}(0, \lambda\sigma^2)$

このモデルを状態空間モデルあるいは Signal plus Noise Model という．状態空間モデルには，パラメータ $\delta, \rho, \lambda, \sigma^2$ が含まれているが，これらが既知ならば，状態変数 β_t は各時点ごとに逐次的に推定することができる．そのためのアルゴリズムはカルマン・フィルターと呼ばれる．今，

$$\beta(t|s) = E(\beta_t | y_s, \dots, y_1): \text{時点 } s \text{ までのデータに基づく } \beta_t \text{ の条件付き期待値}$$

とすると，カルマン・フィルターは次のように計算される (第 3 章で述べた射影の考え方を使えば導出できる) ．

$$\begin{aligned} \beta(t|t-1) &= \delta + \rho\beta(t-1|t-1) \\ \beta(t|t) &= \beta(t|t-1) + \frac{P(t|t-1)}{1 + P(t|t-1)}(y_t - \beta(t|t-1)) \\ P(t|t-1) &= \rho^2 P(t-1|t-1) + \lambda \\ P(t|t) &= \frac{P(t|t-1)}{1 + P(t|t-1)} \end{aligned}$$

ここで， $P(t|s) = E(\beta(t|s) - \beta_t)^2 / \sigma^2$ ($\beta(t|s)$ の MSE) である．

カルマン・フィルターの導出

第 3 章で述べた射影の考え方をを使う．まず，

$$\beta(t|t-1) = \Pi(\delta + \rho\beta_{t-1} + \eta_t | y_{t-1}, \dots, y_1) = \delta + \rho\beta(t-1|t-1)$$

を得る．次に，再帰的射影 (recursive projection) に関する定理 (p.23 定理 4)

$$\Pi(y|\Omega, x) = \Pi(y|\Omega) + \Pi(y - \Pi(y|\Omega) | x - \Pi(x|\Omega))$$

により ,

$$\begin{aligned}
\beta(t|t) &= \Pi(\beta_t|y_t, y_{t-1}, \dots, y_1) \\
&= \Pi(\beta_t|y_{t-1}, \dots, y_1) + \Pi[\beta_t - \Pi(\beta_t|y_{t-1}, \dots, y_1)|y_t - \Pi(y_t|y_{t-1}, \dots, y_1)] \\
&= \beta(t|t-1) + \Pi[\beta_t - \beta(t|t-1)|\beta_t - \beta(t|t-1) + \varepsilon_t]
\end{aligned}$$

を得る . ここで ,

$$\Pi[\beta_t - \beta(t|t-1)|\beta_t - \beta(t|t-1) + \varepsilon_t] = a_0 + a_1[\beta_t - \beta(t|t-1) + \varepsilon_t]$$

とすると , a_0, a_1 は次の正規方程式をみたす .

$$E[\beta_t - \beta(t|t-1) - a_0 - a_1\{\beta_t - \beta(t|t-1) + \varepsilon_t\}] = 0$$

$$E[\{\beta_t - \beta(t|t-1) - a_0 - a_1\{\beta_t - \beta(t|t-1) + \varepsilon_t\}\}(\beta_t - \beta(t|t-1) + \varepsilon_t)] = 0$$

このことから ,

$$a_0 = 0, \quad a_1 = \frac{V(\beta_t - \beta(t|t-1))}{V(\beta_t - \beta(t|t-1) + \varepsilon_t)} = \frac{\sigma^2 P(t|t-1)}{\sigma^2 P(t|t-1) + \sigma^2}$$

となる . したがって ,

$$\begin{aligned}
\beta(t|t) &= \beta(t|t-1) + a_1[\beta_t - \beta(t|t-1) + \varepsilon_t] \\
&= \beta(t|t-1) + \frac{P(t|t-1)}{1 + P(t|t-1)}(y_t - \beta(t|t-1))
\end{aligned}$$

を得る . 次に ,

$$\begin{aligned}
\sigma^2 P(t|t-1) &= E(\beta_t - \beta(t|t-1))^2 \\
&= E[(\rho(\beta_{t-1} - \beta(t-1|t-1)) + \eta_t)^2] \\
&= \sigma^2 [\rho^2 P(t-1|t-1) + \lambda]
\end{aligned}$$

であり ,

$$\begin{aligned}
\sigma^2 P(t|t) &= E(\beta_t - \beta(t|t))^2 \\
&= E\left[\left\{\beta_t - \beta(t|t-1) - \frac{P(t|t-1)}{1 + P(t|t-1)}(y_t - \beta(t|t-1))\right\}^2\right] \\
&= E\left[\left\{\beta_t - \beta(t|t-1) - \frac{P(t|t-1)}{1 + P(t|t-1)}(\beta_t - \beta(t|t-1) + \varepsilon_t)\right\}^2\right] \\
&= E\left[\left\{\frac{1}{1 + P(t|t-1)}(\beta_t - \beta(t|t-1) - P(t|t-1)\varepsilon_t)\right\}^2\right] \\
&= \sigma^2 \left[\frac{P(t|t-1) + P^2(t|t-1)}{(1 + P(t|t-1))^2}\right] \\
&= \sigma^2 \frac{P(t|t-1)}{1 + P(t|t-1)}
\end{aligned}$$

を得る.

パラメータの推定

$\{y_t\}$ の条件付き分布は

$$y_t | y_{t-1}, \dots, y_1 \sim N(\beta(t|t-1), \sigma^2(1 + P(t|t-1)))$$

であるから, 対数尤度関数は

$$L(\delta, \rho, \lambda, \sigma^2) = \text{const.} - \frac{1}{2} \sum_{t=1}^T \log\{\sigma^2(1 + P(t|t-1))\} - \frac{1}{2\sigma^2} \sum_{t=1}^T \frac{(y_t - \beta(t|t-1))^2}{1 + P(t|t-1)} \quad (3)$$

で与えられる. これを最大化することにより推定可能.

Plackett アルゴリズム: カルマン・フィルターの原形
回帰モデル

$$y_n = \mathbf{X}_n \beta + u, \quad \mathbf{X}_n : n \times k \quad (n > k)$$

における β の LSE $\hat{\beta}$ をデータの入手とともに update する計算式

$$\begin{aligned} \hat{\beta}_n &= (\mathbf{X}'_n \mathbf{X}_n)^{-1} (\mathbf{X}'_n y_n) \\ &= (\mathbf{X}'_{n-1} \mathbf{X}_{n-1} + \mathbf{x}_n \mathbf{x}'_n)^{-1} (\mathbf{X}'_{n-1} y_{n-1} + \mathbf{x}_n y_n) \\ &= \hat{\beta}_{n-1} + \mathbf{P}_n \mathbf{x}_n (y_n - \mathbf{x}'_n \hat{\beta}_{n-1}) \end{aligned}$$

$$\mathbf{P}_n = \mathbf{P}_{n-1} - \frac{\mathbf{P}_{n-1} \mathbf{x}_n \mathbf{x}'_n \mathbf{P}_{n-1}}{1 + \mathbf{x}'_n \mathbf{P}_{n-1} \mathbf{x}_n}$$

・ SV モデルの場合

状態空間モデル

$$\log x_t^2 = \mu + \log \sigma_t^2 + \xi_t, \quad \log \sigma_t^2 = \phi \log \sigma_{t-1}^2 + \eta_t \quad (4)$$

を考える. これは, (2) の SV モデルで $\gamma = 0$ としたものである. この場合,

$$\mu = -1.270363, \quad \sigma_\xi^2 = V(\xi_t) = \pi^2/2$$

であるから, 未知のパラメータは ϕ と $\lambda = V(\eta_t)/\sigma_\xi^2 = \sigma_\eta^2 \sigma_\xi^2 /$ である. これらは, (3) の尤度関数の最大化により求めることができる. ただし,

$$y_t \rightarrow \log x_t^2 - \mu, \quad \beta_t \rightarrow \log \sigma_t^2$$

と置きかえる. (4) の誤差項 $\{\xi_t\}$ や $\{\eta_t\}$ は正規分布に従わないので, 尤度関数は擬似であるが, 推定量の漸近的特性は正規分布の場合と同様である.