

状态空间模型与卡门滤波器

State Space Models and Kalman Filters

林金龍

March 15, 2014

1 简介

有别于传统回归模型, 状态空间模型(state space model) 探讨影响可观察变量的状态变量行为, 例如在总体经济中, 恒常所得, 自然失业率, 潜在产出均为状态变量。藉由这些状态变量的推估, 我们可以探讨货币政策 (如泰勒法则) 如何建构; 也可以检验恒常所得假说是否成立。因此藉由状态空间模型的发展, 可以使我们对时间序列分析的进展有更深一步的了解。

2 模型

首先以local level model, 介绍状态空间模型的估算程序。基本上, 状态空间模型的估算是一代迭 (recursive) 的过程。首先我们想要先说明的是, 由我们所观察的时间序列数据转换成状态空间模型, 状态空间模型的代表法不是唯一, 原因在于我们不知时间序列数据的结构为何, 其均为缩减式 (reduce form), 所以必须对结构进行猜测, 故时间序列模型转成状态空间模型会有多种。

接着我们开始介绍 local level model, 模型如下所示:¹

$$y_t = \alpha_t + \epsilon_t, \epsilon_t \sim N(0, \sigma_\epsilon^2)$$

$$\alpha_{t+1} = \alpha_t + \eta_t, \eta_t \sim N(0, \sigma_\eta^2)$$

上两式中, ϵ_t 和 η_t 为mutually independent, 而且与 α_1 独立。 $\alpha_1 \sim N(a_1, P_1)$, $a_1, P_1, \sigma_\epsilon^2, \sigma_\eta^2$ 已知。 α 是状态变量, 因此我们无法从数据观察出来, 所以必须对其进行推估。在上述模型中, 有几点需要注意的是此模型所有参数均已知, α 的动态方程式类似一 random walk 模型, 但与 random walk 模型不同的是, α 并无法观察。

对 α 的推估有三种方式, 第一种为 forecasting, 即利用过去信息 (Y_{t-1}) 来进行推估。第二种为 filtering, 即利用过去到当期的所有信息 (Y_t) 来进行推估。第三种为 smoothing, 为利用全期的信息 (Y_n) 进行推估。²

¹我们称下列第一个方程式为observation equation; 第二个方程式为 state equation。

² Y_{t-1} 为过去的信息集合, Y_t 为过去到当期的信息集合, Y_n 为全期的信息集合。

在介绍估测方法之前, 我们先对 y_t 的一些统计性质作一介绍,

$$y \sim N(1a_1, \Omega), y = (y_1, \dots, y_n)', 1 = (1, \dots, 1)', \Omega = 11'P_1 + \Sigma$$

其中

$$\Sigma_{ij} = \begin{cases} (i-1)\sigma_\eta^2, & i < j \\ \sigma_\epsilon^2 + (i-1)\sigma_\eta^2, & i = j, \\ (j-1)\sigma_\eta^2, & i > j \end{cases} \quad i, j = 1, 2, \dots, n,$$

我们由上述可以知道, local level model 可以化作下式:

$$y_t = \alpha_1 + \sum_{j=1}^{t-1} \eta_j + \epsilon_t, \quad t = 1, \dots, n$$

在得知 y_t 的分配(常态分配) 之后, 我们便可以利用常态分配与条件常态分配的性质来对状态变量(α_t) 进行推估, 在此我们介绍filtering 和 smoothing 的估测过程。

2.1 Filtering

³ Filtering, 即利用过去到当期的所有信息 (Y_t) 来对 α 进行推估。我们的目标是当第 t 期 y_t 的信息进入之后, 求出 α 的条件期望值与条件变异数为何。

首先我们定义 α 的条件期望值 $a_{t+1} = E(\alpha_{t+1} | Y_t)$, α 的条件变异数 $P_{t+1} = \text{Var}(\alpha_{t+1} | Y_t)$ 。

由上述, 我们所定义的条件期望值

$$a_{t+1} = E(\alpha_{t+1} | Y_t) = E(\alpha_t + \eta_t | Y_t) = E(\alpha_t | Y_t),$$

$$P_{t+1} = \text{Var}(\alpha_{t+1} | Y_t) = \text{Var}(\alpha_t + \eta_t | Y_t) = \text{Var}(\alpha_t | Y_t) + \sigma_\eta^2,$$

即 $a_{t+1} = E(\alpha_t | Y_t)$; $P_{t+1} = \text{Var}(\alpha_t | Y_t) + \sigma_\eta^2$ 。接着我们定义预测误差 (forecasting error), $v_t = y_t - a_t$ 和预测变异数 (forecasting variance), $F_t = \text{Var}(v_t)$ 。因为 $v_t = y_t - a_t$, 表示在第 t 期下, v_t 的变动代表了 y_t 的变动, 即 v_t 所包含的讯息为第 t 期 y_t 所包含的讯息, 据此, 我

³以下我们探讨的filtering 称为 Kalman Filter。

们可以得到:⁴

$$E(\alpha_t|Y_t)=E(\alpha_t|Y_{t-1}, v_t)=E(\alpha_t|Y_{t-1})+\text{Cov}(\alpha_t, v_t)\text{Var}(v_t)^{-1}v_t, \text{ 其中}$$

$$\text{Cov}(\alpha_t, v_t) = E[\alpha_t(y_t - a_t)] = E[\alpha_t(\alpha_t + \epsilon_t - a_t)] = E[\alpha_t(\alpha_t - a_t)] = E[\text{Var}(\alpha_t|Y_{t-1})] = P_t;$$

$$\text{Var}(v_t) = F_t = \text{Var}(\alpha_t + \epsilon_t - a_t) = \text{Var}\alpha_t|Y_{t-1} + \text{Var}(\epsilon_t) = P_t + \sigma_\epsilon^2$$

因为 $a_t=E(\alpha_t|Y_{t-1})$, 所以我们由上可以得出 $E(\alpha_t|Y_t)=a_t+P_t/F_tv_t=a_t+K_tv_t$;

$$\text{Var}(\alpha_t|Y_t)=\text{Var}(\alpha_t|Y_{t-1}, v_t)=\text{Var}(\alpha_t|Y_{t-1})-\text{Cov}(\alpha_t, v_t)^2\text{Var}(v_t)^{-1} = P_t - P_t^2/F_t = P_t(1 - K_t)。$$

经由上述的计算过程, 我们可以得出变量之间彼此的关系如下:

$$v_t = y_t - a_t, \quad F_t = P_t + \sigma_\epsilon^2, \quad K_t = P_t/F_t,$$

$$a_{t+1} = a_t + K_tv_t, \quad P_{t+1} = P_t(1 - K_t) + \sigma_\eta^2$$

我们在模型中假设 $a_1, P_1, \sigma_\epsilon^2$ 与 σ_η^2 已知, 因此将这些数值带入, 迭代, 直到其收敛为止, 即可求出我们想要的估测值。

2.1.1 小结

总结以上进行的过程, 我们由观察的数据 $Y_t=(y_1, \dots, y_t)'$, 且 $a_1, P_1, \sigma_\epsilon^2$ 与 σ_η^2 已知, 可以得出下列的步骤:

step1:

$$F_1 = P_1 + \sigma_\epsilon^2, \quad K_1 = P_1/F_1, \quad v_1 = y_1 - a_1$$

⁴上述的期望值是利用以下的引理得出, 当 x, y , 和 z 为随机变量, 且三个变量为联合常态分配时, 根据标准的多变量常态回归理论, 我们可以得出下列条件期望值和条件变异数:

$$E(x|y, z) = E(x|y) + \Sigma_{xz}\Sigma_{zz}^{-1}z,$$

$$\text{Var}(x|y, z) = \text{Var}(x|y) - \Sigma_{xz}\Sigma_{zz}^{-1}\Sigma'_{xz}$$

step2:

$$\begin{aligned} a_2 = a_1 + K_1 v_1 &\implies P_2 = P_1(1 - K_1) + \sigma_\eta^2 \implies F_2 = P_2 + \sigma_\epsilon^2 \\ &\implies K_2 = P_2/F_2 \implies v_2 = y_2 - a_2 \end{aligned}$$

step3:

...

Recursive:

$$\implies (a_1, \dots, a_n), \quad (P_1, \dots, P_n), \quad (F_1, \dots, F_n)$$

2.2 Smoothing

在这一节, 我们探讨 Smoothing, 其为利用全期的信息 (Y_n) 进行对状态变量推估。我们的目标是当第全期 y_t 的信息都得知之后之后, 再次回推估 α 。我们先定义状态估计误差 (state estimation error), $x_t: x_t = \alpha_t - a_t$, 其变异数为: $\text{Var}(x_t) = P_t$ 。因为 $v_t = y_t - a_t = \alpha_t + \epsilon_t - a_t = x_t + \epsilon_t$, 且 $x_{t+1} = \alpha_{t+1} - a_{t+1} = \alpha_t + \eta_t - a_t - K_t v_t = x_t + \eta_t - K_t(x_t + \epsilon_t) = L_t x_t + \eta_t - K_t \epsilon_t$ 。

根据前述的作法, 我们可以得出 $P_{t+1} = \text{Var}(x_{t+1}) = \text{Cov}(x_{t+1}, \alpha_{t+1}) = \text{Cov}(x_{t+1}, \alpha_t + \eta_t) = L_t \text{Cov}(x_t, \alpha_t + \eta_t) + \text{Cov}(\eta_t, \alpha_t + \eta_t) - K_t \text{Cov}(\epsilon_t, \alpha_t + \eta_t) = L_t P_t + \sigma_\eta^2$ 。

2.2.1 Smoothed State

首先我们必须先导出纳入全期 (Y_n) 信息下, α_t 的条件期望值, 如前述, v_t 的变动代表 y_t 的变动, 因此我们可以得出全期下的条件期望值, 如下所述:⁵

$$\hat{\alpha}_t = E(\alpha_t | Y_n) = E(\alpha_t | Y_{t-1}, v_t, \dots, v_n)$$

$$= E(\alpha_t | Y_{t-1}) + \text{Cov}[\alpha_t, (v_t, \dots, v_n)'] \text{Var}[(v_t, \dots, v_n)']^{-1} (v_t, \dots, v_n)'$$

⁵导出条件期望值与条件变异数的公式, 参见附注3

$$\begin{aligned}
&= a_t + \begin{pmatrix} Cov(\alpha_t, v_t) \\ \vdots \\ Cov(\alpha_t, v_n) \end{pmatrix}' \begin{bmatrix} F_t & & 0 \\ & \ddots & \\ 0 & & F_t \end{bmatrix}^{-1} \begin{pmatrix} v_t \\ \vdots \\ v_n \end{pmatrix} \\
&= a_t + \sum_{j=t}^n Cov(\alpha_t, v_j) F_j^{-1} v_j
\end{aligned}$$

因为状态估计误差(state estimation error), x_t , 其变动代表 α_t 的变化, 因此上式的全期条件期望值, 式中的 $Cov(\alpha_t, v_j) = Cov(x_t, v_j), j=t, \dots, n$ 。所以我们可以导出 $Cov(x_t, v_t) = E(x_t(x_t + \epsilon_t)) = Var(x_t) = P_t$,

$$Cov(x_t, v_{t+1}) = E(x_t(x_{t+1} + \epsilon_{t+1})) = E[x_t(L_t x_t + \eta_t - K_t \epsilon_t)] = P_t L_t,$$

依据相同的方法, 我们可以得出 $Cov(x_t, v_{t+2}) = P_t L_t L_{t+1}, \dots, Cov(x_t, v_{t+n}) = P_t L_t L_{t+1} \dots L_{n-1}$ 。

因此我们可以导出:

$$\hat{\alpha}_t = a_t + \sum_{j=t}^n Cov(\alpha_t, v_j) F_j^{-1} v_j = a_t + P_t \frac{v_t}{F_t} + P_t L_t \frac{v_{t+1}}{F_{t+1}} + \dots = a_t + P_t r_{t-1}$$

其中 r_{t-1} 为预测误差 v_t 在 $t-1$ 期之后的加权和。我们由 r_{t-1} , 也可得出 r_t 的估计式, 因为在第 n 期之后, 我们没有观察值, 所以 $r_n = 0$, 将 r_t 代入 r_{t-1} , 可以导出 r_t 的递归公式: $r_{t-1} = F_t^{-1} + L_t r_t$ 。

$$\text{由 } \alpha_t = a_t + P_t r_{t-1}, r_{t-1} = F_t^{-1} + L_t r_t, t=n, \dots, 1.$$

根据 $r_n = 0$, 我们可以采 backward recursion 的方法, 利用观察值的全期信息, 对状态变量进行推估, 此种方法称为 state smoothing recursion。

2.2.2 Smoothed State Variance

根据前面的推估过程, 我们可以依照相同的逻辑来对状态变量的条件变异数进行推估, 如下所述:

$$\begin{aligned}
V_t = Var(\alpha_t | y) &= Var(\alpha_t | Y_{t-1}, v_t, \dots, v_n) = Var(\alpha_t | Y_{t-1}) - Cov[\alpha_t, (v_t, \dots, v_n)'] \\
&\quad \times Var[(v_t, \dots, v_n)']^{-1} Cov[\alpha_t, (v_t, \dots, v_n)']'
\end{aligned}$$

$$\begin{aligned}
&= P_t + \begin{pmatrix} Cov(\alpha_t, v_t) \\ \vdots \\ Cov(\alpha_t, v_n) \end{pmatrix}' \begin{bmatrix} F_t & & 0 \\ & \ddots & \\ 0 & & F_t \end{bmatrix}^{-1} \begin{pmatrix} Cov(\alpha_t, v_t) \\ \vdots \\ Cov(\alpha_t, v_n) \end{pmatrix} \\
&= P_t - \sum_{j=t}^n [Cov(\alpha_t, v_j)]^2 F_j^{-1}
\end{aligned}$$

根据前一节的作法, 我们可以求出 $Cov(\alpha_t, v_j), j=t, \dots, n$ 。并将其代入 V_t , 得出 V_t 如下式:

$$\begin{aligned}
V_t &= P_t - P_t^2 \frac{1}{F_t} - P_t^2 L_t^2 \frac{1}{F_{t+1}} - \dots - P_t^2 L_t^2 L_{t+1}^2 \dots L_{n-1}^2 \frac{1}{F_n} \\
&= P_t - P_t^2 N_{t-1}
\end{aligned}$$

其中 N_{t-1} 为预测误差变异数倒数的加权和。根据 N_{t-1} , 我们可以导出 N_t 的估计式, 相同的, 在第 n 期之后, 因为没有任何的观察值, 因此 $N_n=0$ 。将 N_t 代入 N_{t-1} 中, 我们得出递归公式: $N_{t-1}=F_t^{-1} + L_t^2 N_t$ 。

$$\text{由 } V_t = P_t + P_t^2 N_{t-1}, N_{t-1} = F_t^{-1} + L_t^2 N_t, t=n, \dots, 1.$$

根据 $N_n = 0$, 我们亦采 backward recursion 的方法, 利用观察值的全期信息, 对状态变量进行推估, 此种方法称为 state variance smoothing recursion。

2.2.3 小结

我们由 state smoothing recursion 与 state variance smoothing recursion, 给定适当的起始值, 经由迭代的程序, 可以推估出在全期的信息下, α_t 的条件期望值与条件变异数。

3 Missing observations

状态空间模型的一个优点是可以处理缺漏值的问题。假设在 local level 模型中, 我们观察到的 $y_j, j=\tau, \dots, \tau^* - 1$, 为缺漏值, 一个处理的方法是, 定义一组新的时间序

列数据 y_t^* , 其中 $y_t^*=y_t, t=1, \dots, \tau-1, y_t^*=y_{t+\tau^*-\tau}, t=\tau, \dots, n^*$ 。我们由此一新定义的时间序列数据, 进行如前述的 filtering 的推估过程。

另一个方法是, 依照原来的时间序列数据进行 filtering 的推估, 在 τ, \dots, τ^*-1 这段期间, 对 α 的条件期望值之估测值均为相同, 唯一的差异在于在这段期间内, 每个估测值的条件变异数会随时间的增加而加大。

4 起始值的设定

这节我们探讨起始值的设定问题, 因为状态空间模型的估算为一代迭过程(recursive procedure), 所以必须设定起始值的大小, 来得出最终的估算结果。当然起始值的设定是任意的, 如之前所设定的 a_1 与 P_1 。在这边我们探讨另一设定起始值的方法, 即我们会假设 α_1 具有diffuse prior density, 其所指的是 α_1 的期望值 a_1 为任意设定, 但将其变异数 P_1 设定为无穷大($P_1 \rightarrow \infty$)。经由此设定, 我们得出 a_2 与 P_2 如下:

$$a_2 = a_1 + \frac{P_1}{P_1 + \sigma_\epsilon^2}(y_1 - a_1)$$

$$P_2 = P_1 \left(1 - \frac{P_1}{P_1 + \sigma_\epsilon^2} + \sigma_\eta^2\right) = \frac{P_1}{P_1 + \sigma_\epsilon^2} \sigma_\epsilon^2 + \sigma_\eta^2$$

当 $P_1 \rightarrow \infty$ 时, 我们可以得出 $a_2=y_1, P_2 = \sigma_\epsilon^2 + \sigma_\eta^2$, 将 a_2 与 P_2 持续代迭, 便可以得出我们要的估算结果, 我们称此一过程为diffuse initialisation of the Kalman filter。明显地, 我们可以看出 P_1 的设定并不会影响到后续的推估过程。

上面介绍的为filtering 时的起始值设定, 当然, 当我们引入全期的数据进行smoothing 的推估时, 亦可做相同的起始值假设, 不再赘述。

除了探讨 a_1 与 P_1 的设定之外, σ_ϵ^2 与 σ_η^2 亦须进行设定, 在我们的模型中, 我们会利用MLE 法将其估计出来, 作为我们的起始值, 而这两个参数的估计在下节会进行说明。

5 估计

前述设定起始值时, 我们说明了 a_1 与 P_1 的设定, 通常利用diffuse prior 的方法进

行设定。我们开始讲述关于 σ_ϵ^2 与 σ_η^2 的设定,基本上此两参数的设定是利用MLE法所估出来的。首先我们说明概似函数的设定,考虑 y_t 的联合密度函数如下:

$$p(y_1, \dots, y_n) = p(y_1) \prod_{t=2}^n p(y_t | Y_{t-1})$$

因为之前说明的预测误差(v_t),其变动代表观察值(y_t)的变动,是故我们可以将上式转换成 v_t 的函数,如下所示:

$$p(v_1, \dots, v_n) = \prod_{t=1}^n p(v_t)$$

其中

$$p(v_1) = p(y_1), \quad p(v_t) = p(y_t | Y_{t-1}), t = 2, \dots, n$$

接着由 v_t 为 a_1 与观察值(y_t)的线性函数与其分配^{6 7}我们可以导出下列的概似函

⁶由filtering的公式中,我们可以得出 v_t 为 a_1 与观察值(y_t)的线性函数:

$$\begin{aligned} v_1 &= y_1 - a_1 \\ v_2 &= y_2 - a_1 - K_1(y_1 - a_1) \\ v_3 &= y_3 - a_1 - K_2(y_2 - a_1) - K_1(1 - K_2)(y_1 - a_1) \\ &\vdots \end{aligned}$$

⁷我们亦可导出 v_t 的分配:

$$v = C(y - 1a_1), v = (v_1, \dots, v_n)'$$

其中

$$C = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ c_{21} & 1 & 0 & \dots & 0 \\ c_{31} & c_{32} & 1 & \dots & 0 \\ & & & \ddots & \vdots \\ c_{n1} & c_{n2} & c_{n3} & \dots & 1 \end{bmatrix},$$

$$c_{i,i-1} = -K_{i-1},$$

$$c_{ij} = -(1 - K_{i-1})(1 - K_{i-2}) \cdots (1 - K_{j+1})K_j, \quad i = 2, \dots, n; j = 1, \dots, i - 2$$

数:

$$\log L = \log p(y) = -\frac{n}{2} \log(2\pi) - \frac{1}{2} \sum_{t=1}^n \left(\log F_t + \frac{v_t^2}{F_t} \right)$$

藉由 a_1 与 P_1 的设定, 我们藉由numerically 方式得出 σ_ϵ^2 与 σ_η^2 的估测值。

6 残差检定

我们的模型中假设残差 (ϵ_t, η_t) 是常态分配, 且为mutually independent。因此对于估计所得出的误差进行检定, 检验其是否为常态分配, 是否独立。关于常态的检定方面, 我们可以利用 QQ-plot 法来判断残差是否为常态分配。

在检定残差是否具序列相关上, 我们可以利用 Ljung-Box 统计量, ACF, PACF 等方法来检定其是否存在序列相关。

当然还有许多检定常态分配与序列相关的方法, 我们在此只是提出几种方法来说明, 其余的检定法, 可以参阅上学期所教授的相关课程。

7 延伸

现在进入Durbin and Koopman(2002) 书中第四章, 在本章中模型为一线性 Gaussian 状态空间模型, 设定如下:

$$y_t = Z_t \alpha_t + \epsilon_t, \epsilon_t \sim N(0, H_t),$$

$$\alpha_{t+1} = T_t \alpha_t + R_t \eta_t, \eta_t \sim N(0, Q_t), \quad t = 1, \dots, n,$$

$$\alpha_1 \sim N(a_1, P_1,)$$

我们并将上设状态空间模型的变量与参数之维度(Dimensions) 列出, 如下表:

由上我们可以得出:

$$v \sim N(0, C\Omega C'), \Omega = \text{Var}(y),$$

因为 $v \sim N(0, F)$, $F = C\Omega C'$, 我们称 $F = C\Omega C'$ 为对称矩阵的Cholesky 分解。

状态空间模型的变量与参数之维度

Vector		Matrix	
y_t	$p \times 1$	Z_t	$p \times m$
α_t	$m \times 1$	T_t	$m \times m$
ϵ_t	$p \times 1$	H_t	$p \times p$
η_t	$r \times 1$	R_t	$m \times r$
		Q_t	$r \times r$
a_1	$m \times 1$	P_1	$m \times m$

7.1 Filtering

我们可以依照前述 filtering 的做法, 得出代迭过程 (recursive procedure), 推导过程如前, 不再赘述, 在此我们列出 filtering 的变量如下:

$$v_t = y_t - Z_t a_t, \quad F_t = Z_t P_t Z_t' + H_t,$$

$$K_t = T_t P_t Z_t' F_t^{-1}, \quad L_t = T_t - K_t Z_t, \quad t = 1, \dots, n$$

$$a_{t+1} = T_t a_t - K_t v_t, \quad P_{t+1} = T_t P_t L_t' + R_t Q_t R_t',$$

其中 $L_t = T_t - K_t Z_t$, 给定适当的起始值, 则我们便可以进行代迭的过程, 得出我们想要知的估测值。

7.2 Smoothing

相同的, 在给定全期的信息下, 我们亦可依照前述 smoothing 的作法, 导出 state smoothing recursion 如下:

$$r_{t-1} = Z_t' F_t^{-1} + L_t' r_t, \quad N_{t-1} = Z_t' F_t^{-1} Z_t + L_t' N_t L_t,$$

$$\hat{\alpha}_t = a_t + P_t r_{t-1}, \quad V_t = P_t - P_t N_{t-1} P_t,$$

$t = n, \dots, 1$ 给定 $r_n = 0$ 与 $N_n = 0$ 之下, 我们便可依序代迭, 得出估测值。

8 相关软件

关于状态空间模型的估测有很多软件可以使用, 如R, Ox, ... 等, 我们非别介绍如下:

8.1 R packages about Kalman Filtering

KFM	This provides relatively flexible state space models via the <code>fkf()</code> function: state-space parameters are allowed to be time-varying and intercepts are included in both equations.
KFAS	provides a fast multivariate Kalman filter, smoother, simulation smoother and forecasting.
dlm	A package which also contains tools for converting other multivariate models into state space form.
MARSS	fits constrained and unconstrained multivariate autoregressive state-space models using an EM algorithm.

8.2 Ox

。关于 Ox 在状态空间模型的使用, Doornik(1998) 发表 *Econometrics Journal* 中的文章, 其文章中发展 SsfPack 套件, 应用在状态空间模型, 在此我们介绍其文章中关于状态空间模型的设定, 详细内容请参考 Doornik 的文章。⁸

我们说明文章中关于模型的设定, 并简单介绍一些用状态空间模型表示的例子。首先在文章中, 模型的设定如下:

$$\alpha_{t+1} = d_t + T_t \alpha_t + H_t \epsilon_t, \quad \alpha_1 \sim N(a, P), \quad t = 1, \dots, n,$$

⁸同学可以下列网址下载此文章:

<http://www.nuff.ox.ac.uk/economics/papers/1998/w6/ssf.pdf>

$$\theta_t = C_t + Z_t \alpha_t,$$

$$y_t = \theta_t + G_t \epsilon_t, \quad \epsilon_t \sim N(0, I)$$

在 SsfPack 套件中, 上述的模型被表示如下进行估测:

$$\begin{pmatrix} \alpha_{t+1} \\ y_t \end{pmatrix} = \delta_t + \Phi \alpha_t + u_t, u_t \sim N(0, \Omega_t), t = 1, \dots, n,$$

$$\delta_t = \begin{pmatrix} d_t \\ C_t \end{pmatrix}, \Phi_t = \begin{pmatrix} T_t \\ Z_t \end{pmatrix}, u_t = \begin{pmatrix} H_t \\ G_t \end{pmatrix} \epsilon_t, \Omega_t = \begin{pmatrix} H_t H_t' & H_t G_t' \\ G_t H_t' & G_t G_t' \end{pmatrix},$$

$$\alpha_1 \sim N(a, P)$$

其中 δ_t 为 $(m+N) \times 1$, Φ_t 为 $(m+N) \times m$, Ω_t 为 $(m+N) \times (m+N)$ 。在此模型中, 有 m 个状态变量 (state variable), N 个已观察变量 (observed variable), r 个残差 (distribrance)。在 SsfPack 套件中, 给定适当的起始值, 便可进行 filtering 或 smoothing 的估测。

接着我们举一些时间序列相关的例子, 用状态空间模型来表示:

1. Local trend model:

考虑 Local trend model, 如下所示:

$$\mu_{t+1} = \mu_t + \beta_t + \eta_t, \eta_t \sim NID(0, \sigma_\eta^2)$$

$$\beta_{t+1} = \beta_t + \zeta_t, \zeta_t \sim NID(0, \sigma_\zeta^2)$$

$$y_t = \mu_t + \epsilon_t, \epsilon_t \sim NID(0, \sigma_\epsilon^2)$$

我们可以得出下式:

$$\begin{pmatrix} \mu_{t+1} \\ \beta_{t+1} \\ y_t \end{pmatrix} = \begin{pmatrix} 1 & 1 \\ 0 & 1 \\ 1 & 0 \end{pmatrix} \begin{pmatrix} \mu_t \\ \beta_t \end{pmatrix} + \begin{pmatrix} \eta_t \\ \zeta_t \\ \epsilon_t \end{pmatrix}$$

其中

$$\alpha_t = (\mu_t, \beta_t)', \Phi = \begin{pmatrix} 1 & 1 \\ 0 & 1 \\ 1 & 0 \end{pmatrix}, \Omega_t = \begin{pmatrix} \sigma_\eta^2 & 0 & 0 \\ 0 & \sigma_\zeta^2 & 0 \\ 0 & 0 & \sigma_\epsilon^2 \end{pmatrix}$$

2. Local level model:

考虑 Local level model, 如下所示:

$$y_t = \alpha_t + \epsilon_t, \epsilon_t \sim (0, \sigma_\epsilon^2)$$

$$\alpha_{t+1} = \alpha_t + \eta_t, \eta_t \sim N(0, \sigma_\eta^2)$$

由上可以得出:

$$\begin{pmatrix} \alpha_{t+1} \\ y_t \end{pmatrix} = 0 + \begin{pmatrix} 1 \\ 1 \end{pmatrix} \alpha_t + \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} \epsilon_t \\ \eta_t \end{pmatrix}$$

其中,

$$\alpha_t = \alpha_t, \Phi = \begin{pmatrix} 1 \\ 1 \end{pmatrix}, \Omega = \begin{pmatrix} \sigma_\epsilon^2 & 0 \\ 0 & \sigma_\eta^2 \end{pmatrix}$$

3. ARMA(p,q) Process:

考虑 ARMA(1,1) Process, 如下所示:

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \xi_t + \theta_1 \xi_{t-1} + \dots + \theta_q \xi_{t-q}, \xi_t \sim NID(0, \sigma_\xi^2)$$

首先我们考虑其VAR(1) 的表现型式如下:

$$\alpha_{t+1} = \begin{pmatrix} \phi_1 & 1 & 0 & \dots & 0 \\ \phi_2 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & & \ddots & \\ \phi_{m-1} & 0 & 0 & \dots & 1 \\ \phi_m & 0 & 0 & \dots & 0 \end{pmatrix} \alpha_t + \begin{pmatrix} 1 \\ \theta_1 \\ \vdots \\ \theta_{m-2} \\ \theta_{m-1} \end{pmatrix} \xi_t, \xi_t \sim NID(0, \sigma_\xi^2)$$

$$m = \max(p, q + 1), y_t = (1, \dots, 0) \alpha_t$$

上式可以用Doornik 的文章的模型表示, 即为 $\alpha_{t+1} = T_\alpha + h\xi_t$, 可用Ssfpack 套件进行估测, 上式为 ARMA 模型表示法的一般化, 以下我们在举几个 ARMA 模型的例子, 以便同学了解。

✓ ARMA(1,1) Process:

由 $m = \max(p, q + 1) = \max(1, 2) = 2$, 可以将 ARMA(1,1) Process 表示如下:

$$\begin{pmatrix} \alpha_{1,t+1} \\ \alpha_{2,t+1} \end{pmatrix} = \begin{pmatrix} \phi_1 & 1 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} \alpha_{1,t} \\ \alpha_{2,t} \end{pmatrix} + \begin{pmatrix} 1 \\ \theta_1 \end{pmatrix} \xi_t$$

$$\alpha_{1,t+1} = \phi_1 \alpha_{1,t} + \alpha_{2,t} + \xi_t$$

$$\alpha_{2,t+1} = \theta_1 \xi_t$$

$$y_t = (1, 0)\alpha_t = \alpha_{1,t}$$

✓ ARMA(2,1) Process:

由 $m = \max(p, q + 1) = \max(2, 2) = 2$, 可以将 ARMA(2,1) Process 表示如下:

$$\begin{pmatrix} \alpha_{1,t+1} \\ \alpha_{2,t+1} \end{pmatrix} = \begin{pmatrix} \phi_1 & 1 \\ \phi_2 & 0 \end{pmatrix} \begin{pmatrix} \alpha_{1,t} \\ \alpha_{2,t} \end{pmatrix} + \begin{pmatrix} 1 \\ \theta_1 \end{pmatrix} \xi_t$$

$$\alpha_{1,t+1} = \phi_1 \alpha_{1,t} + \alpha_{2,t} + \xi_t$$

$$\alpha_{2,t+1} = \phi_2 \alpha_{1,t} + \theta_1 \xi_t$$

$$y_t = \alpha_{1,t}$$

✓ ARMA(3,2) Process:

由 $m = \max(p, q + 1) = \max(3, 3) = 3$, 可以将 ARMA(3,2) Process 表示如下:

$$\begin{pmatrix} \alpha_{1,t+1} \\ \alpha_{2,t+1} \\ \alpha_{3,t+1} \end{pmatrix} = \begin{pmatrix} \phi_1 & 1 & 0 \\ \phi_2 & 0 & 1 \\ \phi_3 & 0 & 0 \end{pmatrix} \begin{pmatrix} \alpha_{1,t} \\ \alpha_{2,t} \\ \alpha_{3,t} \end{pmatrix} + \begin{pmatrix} 1 \\ \theta_1 \\ \theta_2 \end{pmatrix} \xi_t$$

$$\alpha_{1,t+1} = \phi_1 \alpha_{1,t} + \alpha_{2,t} + \xi_t$$

$$\alpha_{2,t+1} = \phi_2 \alpha_{1,t} + \alpha_{3,t} + \theta_1 \xi_t$$

$$\alpha_{3,t+1} = \phi_3 \alpha_{1,t} + \theta_2 \xi_t$$

$$y_t = \alpha_{1,t}$$

9 参考文献

Durbin, J., and S. J. Koopman (2002), *Time Series Analysis by State Space Methods*, New York:Oxford University Press.

Koopman, S. J., Shephard, N., and J. A. Doornik (1998), “Statistical algorithms for models in state space using SsfPack 2.2,” *Econometrics Journal*, 1, 1-55.