

## 4 模型估計

我們將資料到  $t - 1$  期前的訊息集合表示成爲  $F_{t-1}$ ,  $\psi$  表示爲未知的參數, 則給定資料  $\psi$  的概似函數可表示爲:

$$\begin{aligned} f(\mathbf{y}|\psi) &= \prod_{t=1}^n \int f(\mathbf{y}_t|\mathbf{h}_t, \mathbf{B}) f(\mathbf{h}_t, \psi) d\mathbf{h}_t \\ &= \prod_{t=1}^n \int N_p(\mathbf{y}_t | 0, \boldsymbol{\Omega}_t) f(\mathbf{h}_t, \psi) d\mathbf{h}_t \end{aligned}$$

上式的積分沒有封閉解, 且維度高難以計算。以我們的實證資料爲例, 三個國家的電子指數及一個因子, 共計有 18 個參數要估計。正因爲沒有封閉解, 所以對隨機波動模型參數的估計, 沒有標準作法。文獻上的估計法有, 準最大概似法, 數值積分法, 以及 MCMC 法。我們選擇以 MCMC 的方法, 對後驗分配進行抽樣, 並以得到的統計量來描述後驗分配的性質。我們在下節簡單的介紹馬可夫鏈蒙地卡羅估計法。

### 4.1 馬可夫鏈蒙地卡羅估計法

當我們要求取一個函數的積分值時, 最簡單的想法即是利用蒙地卡羅積分,

$$\int_a^b f(x)p(x)dx \cong \frac{1}{n} \sum_{i=1}^n f(x_i)$$

其中  $x_1, x_2, \dots, x_n$  為來自  $p(x)$  的隨機變數。則當  $n$  趨近於無窮大時, 上式就會趨近於我們想要積分的函數積分。但蒙地卡羅積分法效率不高, 文獻上有許多改良的方法。且當  $p(x)$  也很複雜, 我們不容易抽取它的隨機變數時, 則我們可以尋求重要抽樣 (important sampling), 即並不一定要從  $p$  直接抽樣來計算。而是找一個我們已知如何抽樣且與類似的分配, 則

$$\int_b^a f(x)q(x)dx = \int_b^a f(x)\left(\frac{q(x)}{p(x)}\right)p(x)dx \cong \frac{1}{n} \sum_{i=1}^n \frac{f(x_i)q(x_i)}{p(x_i)}$$

但當目標函數爲高維度時蒙地卡羅積分的方法會更複雜收斂變慢, 也變的更難操作, 這時我們就尋求 MCMC 法。M-H 法基本上也不直接從  $p$  下手, 而是想造一個馬可夫鏈他的轉換機率 (transition

kernel) 的極限分配是我們的目標分配  $p$ ，對轉換機率適當假設之下，這個馬可夫鏈的極限分配，會趨近我們要的目標分配，而從這個馬可夫鏈所產生的隨機變數，也會是目標函數所產生的隨機變數。下面簡單介紹馬可夫鏈，與其收斂所需要的性質。

#### 4.1.1 馬可夫鏈

令  $\{X_t\}$  為一隨機過程，其狀態空間為  $\Theta$ ，為我們說此隨機過程具有馬可夫性質，如果其轉換機率的條件分配只跟上一期有關，也就是滿足

$$P(X_{t+1} = \phi | X_t = \theta, X_{t-1}, \dots) = P(X_{t+1} = \phi | X_t = \theta), \quad \phi, \theta \in \Theta.$$

其意思為，隨機變數  $X$  上期停留在狀態  $\theta$ ，下一期轉換到狀態  $\phi$  的機率。以下為了簡潔起見，直接表示為  $p(\phi|\theta)$ ，當一個馬可夫鏈具有極限分配如果：

$$\pi(\theta) = \sum_{\phi} \pi(\theta) p(\phi|\theta),$$

如果我們能夠找到一個適當的轉換機率  $p(\phi|\theta)$ ，它的極限分配就是我們想要的目標分配  $\pi(\theta)$ ，則給定任一起始點，則在疊代一段時間之後，停留在狀態  $\theta$  的機率就是  $\pi(\theta)$ 。或著說疊待夠久時，所得的數值，相當於從目標分配抽的的隨機變數。底下說明要在什麼條件之下，極限分配會存在，令  $r(\theta)$  表示下一期停留在同一狀態的機率，

$$p(\phi|\theta) = p^*(\phi|\theta) + r(\theta)\delta(\phi|\theta),$$

其中  $p^*(\theta|\theta) = 0$ ，且

$$\delta(\theta|\theta) = 1, \quad \text{又當 } \theta \neq \phi, \quad \delta(\phi|\theta) = 0,$$

因為下一期狀態要不就與這期一樣，要不就與這期不一樣，機率加總為一

$$1 = \sum_{\phi} p(\phi|\theta) = \sum_{\phi} p^*(\phi|\theta) + r(\theta).$$

又我們說一個轉換機率具可反轉性 (time reversibility), 如果滿足,

$$\pi(\theta) = p^*(\phi|\theta) = \pi(\phi)p^*(\theta|\phi),$$

上式意思是給定  $\theta$  的初始機率  $\pi(\theta)$ , 從狀態  $\theta$  轉到狀態  $\phi$  的機率, 與一該使停留在  $\phi$  最後轉到  $\theta$  的機率是相等的。

$$\begin{aligned} \sum_{\theta} \pi(\theta)p(\phi|\theta) &= \sum_{\theta} \pi(\theta)p^*(\phi|\theta) + \sum_{\theta} \pi(\theta)r(\theta)\delta(\phi|\theta) \\ &= \sum_{\theta} \pi(\phi)p^*(\theta|\phi) + \pi(\phi)r(\phi) \\ &= \pi(\phi) \left\{ \sum_{\theta} p^*(\theta|\phi) \right\} + \pi(\phi)r(\phi) \\ &= \pi(\phi)\{1 - r(\phi)\} + \pi(\phi)r(\phi) \\ &= \pi(\phi) \end{aligned}$$

## 4.2 Metropolis-Hastings 抽樣

從上面我們知道一個轉換機率是不是具有可反轉性質, 關係到此馬可夫鏈會不會收斂到我們想要的極限分配。令  $q(\phi|\theta)$  表一候選分配, 是一個已知且容易抽樣的分配, 且滿足,  $\sum_{\phi} q(\phi|\theta) = 1$ 。一般來說,  $q(\phi|\theta)$  並不一定具有可反轉性, 不失一般性我們假設,

$$\pi(\theta)q(\phi|\theta) > \pi(\phi)q(\theta|\phi),$$

這表示從狀態  $\theta$  轉到狀態  $\phi$  的機會比從  $\phi$  轉到  $\theta$  的機會要大, 為了要平衡兩邊狀態轉換的機率, 我們對左式乘上一個一個調整項,  $\alpha(\phi|\theta)$ , 使得

$$\pi(\theta)q(\phi|\theta)\alpha(\phi|\theta) = \pi(\phi)q(\theta|\phi),$$

則

$$\alpha(\phi|\theta) = \frac{\pi(\phi)q(\theta|\theta)}{\pi(\theta)q(\phi|\theta)}.$$

$\alpha(\phi|\theta)$  的作用為限制從  $\phi$  轉到  $\theta$  的次數，藉以達到可反轉性，所以  $\alpha$  又稱為移動機率 (probability of moving)。因為  $\phi$  轉到  $\theta$  的次數過少，所以我們不減低其次數， $\alpha(\theta|\phi) = 1$ 。而當前面的不等式符號相反時，算法一樣，只不過是將  $\phi$  與  $\theta$  相互對調而已。我們可以得到通式，

$$\alpha(\phi|\theta) = \min \left[ \frac{\pi(\phi)q(\theta|\theta)}{\pi(\theta)q(\phi|\theta)}, 1 \right].$$

這裡我們也可以看出，因為  $\pi$  出現在分子與分母，所以當我們計算  $\alpha$  時，其實只要知道  $\pi$  的同比例分配即可。又當我們的候選分配是對稱分配，即  $q(\phi|\theta) = q(\theta|\phi)$  時，接受率變成爲

$$\alpha(\phi|\theta) = \min \left[ \frac{\pi(\phi)}{\pi(\theta)}, 1 \right].$$

而這就是 Metropolis 當初的想法。M-H 的演算法如下，

1. 紿定初始值  $\theta^{(0)}$ ，
2. 從  $q(\theta^*|\theta^{t-1})$  抽出  $\theta^*$ ，
3. 計算接受率

$$\alpha(\phi|\theta) = \min \left[ \frac{\pi(\phi)q(\theta|\theta)}{\pi(\theta)q(\phi|\theta)}, 1 \right],$$

4. 從均勻分配抽出一個隨機變數  $u$ ，當  $u \leq \alpha$  我們令  $\theta^{(t)} = \theta^*$ ，否則停留在原值  $\theta^{(t)} = \theta^{(t-1)}$
5. 重複步驟二到步驟四

而經過遞迴而得的數列， $\{\theta^{(1)}, \theta^{(2)}, \dots, \theta^{(n)}\}$ ，要經過一段時間數列才會收斂到我們的目標分配，所以通常我們會捨棄前面  $k$  個值，只保留後面的。要捨棄多少個值沒有定論，一般來說如果發現產生的數列間的相關性非常大，則需捨棄較多的數值。在 M-H 法中，如何選擇候選分配是一門大學問，只要是定義域相同，對候選分配其實沒有什麼限制，然而接受率皆希望能越大越好，接受率大，則需要遞迴的次數也就不需要那麼多。不過這端賴經驗，與試誤法，一般理論上沒有特定的規則。

### 4.3 演算法

給定觀察值之下，參數與隱藏參數的後驗分配為

$$\pi(\beta, f_t, \boldsymbol{\theta}, \mathbf{h} | \mathbf{y})$$

我們將參數空間切割，分成幾個區塊，在固定其他參數之下，從條件分配中抽樣，進而反覆疊帶、更新。

模型估計的步驟簡述如下：

1. 設定  $(\boldsymbol{\theta}, \mathbf{h})$  的起始值。
2. 從條件分配  $\mathbf{B}, f_t | \mathbf{y}, \mathbf{h}$  抽取  $\mathbf{B}$  和  $f_t$ 。
3. 將模型轉換成  $p+k$  維的單變量模型，藉用 Chib et al. (2002) 的方法，從條件分配  $\boldsymbol{\theta}_j, \mathbf{h}_j | \mathbf{y}_j, \mathbf{B}, f_t$  抽取  $(\boldsymbol{\theta}_j, \mathbf{h}_j)$ ， $j = 1, 2, \dots, p+k$ 。
4. 回到步驟 2.

步驟 2 到步驟完成一個馬可夫鏈的轉換，一般蒙地卡羅法需要大量的遞迴次數，來確保後驗分配的收斂。抽樣的相關係數越高，要求的遞迴次數就越多。通常我們也捨棄模擬初始，明顯未收斂的值 (burn in)，只留下之後的模擬值。以下詳述各步驟的抽樣方法：

1. 要從條件分配  $\mathbf{B}, f_t | \mathbf{y}, \mathbf{h}_t$  抽取  $\mathbf{B}$  和  $f_t$ ，我們先給定  $f_t$  抽取  $\mathbf{B}$ ，再固定  $\mathbf{B}$ ，抽取  $f_t$ 。其中因為認定條件的關係，我們已將  $\mathbf{B}$  的第一項設定為 1，所以只需對係數未定的  $\beta$  做抽樣
  - (1)  $\beta$  的後驗分配為：

$$\begin{aligned} \pi(\beta | \mathbf{y}, \mathbf{h}_t) &\propto p(\beta) \prod_{t=1}^n p(\mathbf{y}_t | \mathbf{B}, \mathbf{h}_t) \\ &\propto p(\beta) \prod_{t=1}^n N_p(\mathbf{y}_t | 0, \mathbf{V}_t + \mathbf{B}\mathbf{D}_t\mathbf{B}') \end{aligned}$$

我們將以 M-H 法藉由多變量  $t$  分配,  $T(\mathbf{m}, \boldsymbol{\Sigma}, \nu)$  來抽取  $\beta$ 。而  $T(\mathbf{m}, \boldsymbol{\Sigma}, \nu)$  中的參數  $(\mathbf{m}, \boldsymbol{\Sigma})$  是數值極大化概似函數,  $\log\{\prod_{t=1}^n N_p(\mathbf{y} | 0, \boldsymbol{\Omega}_t)\}$  而來。<sup>1</sup>

$$\begin{aligned}\mathbf{m} = \arg \max l(\beta) &= \sum_{t=1}^n \log N_p(\mathbf{y} | 0, \boldsymbol{\Omega}) \\ &= \text{const} - \frac{1}{2} \sum_{t=1}^n \log |\boldsymbol{\Omega}_t| - \frac{1}{2} \sum_{t=1}^n \mathbf{y}'_t \boldsymbol{\Omega}_t^{-1} \mathbf{y}_t\end{aligned}$$

其中  $\mathbf{m}$  為上式的概似估計值,  $\boldsymbol{\Sigma}$  為負 Hessian 矩陣的反矩陣。 $\beta$  的先驗分配假設為常態, 則我們從  $T(\beta | \mathbf{m}, \boldsymbol{\Sigma}, \nu)$  抽出  $\beta^*$ , 接受  $\beta^*$  的機率為:

$$\alpha(\beta, \beta^* | \mathbf{y}, \mathbf{h}_t) = \min \left\{ 1, \frac{p(\beta^*) \prod_{t=1}^n N_p(\mathbf{y} | 0, \mathbf{V}_t + \mathbf{B}^* \mathbf{D}_t \mathbf{B}^{*'}) T(\beta | \mathbf{m}, \boldsymbol{\Sigma}, \nu)}{p(\beta) \prod_{t=1}^n N_p(\mathbf{y} | 0, \mathbf{V}_t + \mathbf{B} \mathbf{D}_t \mathbf{B}') T(\beta^* | \mathbf{m}, \boldsymbol{\Sigma}, \nu)} \right\}$$

如果  $\beta$  被拒絕, 則下一輪的  $\beta$  保持不變。

(2) 紿定了  $\beta$  我們可以從  $f_t | \mathbf{y}, \mathbf{B}, \mathbf{h}$  抽出  $f$ 。根據傳統貝氏的計算,

$$\begin{aligned}p(f_t | \mathbf{y}, \mathbf{h}_t, \mathbf{B}) &\propto p(f_t) f(\mathbf{y}_t | f_t, \mathbf{B}, \mathbf{h}_t) \\ &\propto \exp \left[ -\frac{1}{2} (\mathbf{y}_t - \mathbf{B} f_t)' \boldsymbol{\Omega}_t^{-1} (\mathbf{y}_t - \mathbf{B} f_t) \right] \times \exp \left[ -\frac{f_t' \mathbf{D}_t^{-1} f_t}{2} \right] \\ &\propto \exp \left[ -\frac{1}{2} (\mathbf{y}'_t \boldsymbol{\Omega}_t^{-1} \mathbf{y} - 2 \mathbf{y}' \boldsymbol{\Omega}_t^{-1} \mathbf{B} f_t + f_t' \mathbf{B}' \boldsymbol{\Omega}_t \mathbf{B} f_t + f_t' \mathbf{D}_t^{-1} f_t) \right] \\ &\propto \exp \left\{ -\frac{1}{2} [f_t' (\mathbf{B}' \boldsymbol{\Omega}_t^{-1} \mathbf{B} + \mathbf{D}_t^{-1}) f_t - 2 \mathbf{B}' \boldsymbol{\Omega}_t^{-1} \mathbf{y}] \right\} \\ &\propto \exp \left[ -\frac{1}{2} (f_t - \hat{f}_t)' \mathbf{F}^{-1} (f_t - \hat{f}_t) \right]\end{aligned}$$

<sup>1</sup>我們亦可提供一階導數, 來增加極大化的速度與準確度,

$$\begin{aligned}\frac{\partial l}{\partial \beta_{ij}} &= \frac{1}{2} \sum_{t=1}^n \left[ \tilde{y}'_t \boldsymbol{\Omega}_t^{-1} \frac{\partial \boldsymbol{\Omega}_t}{\partial \beta_{ij}} \boldsymbol{\Omega}_t^{-1} \tilde{y}_t - \text{tr} \left( \boldsymbol{\Omega}_t^{-1} \frac{\partial \boldsymbol{\Omega}_t}{\partial \beta_{ij}} \right) \right], \\ &= \sum_{t=1}^n \left[ \tilde{y}'_t \boldsymbol{\Omega}_t^{-1} \frac{\partial \mathbf{B}}{\partial \beta_{ij}} \mathbf{D}_t \mathbf{B}' \boldsymbol{\Omega}_t^{-1} \tilde{y}_t - \text{tr} \left( \boldsymbol{\Omega}_t^{-1} \mathbf{B} \mathbf{D}_t \frac{\partial \mathbf{B}'}{\partial \beta_{ij}} \right) \right].\end{aligned}$$

表 1: 混合常態

$s$	$\Pr(s = i)$	$m_i$	$v_i^2$
1	0.00730	-10.12999	5.79596
2	0.10556	-3.97281	2.61369
3	0.00002	-8.56686	5.17950
4	0.04395	2.77786	0.16735
5	0.34001	0.61942	0.64009
6	0.24566	1.79518	0.34023
7	0.25750	-1.08819	1.26261

所以  $f_t$  的後驗分配為平均數為  $\mathbf{F}_t \mathbf{B}' (\mathbf{V}_t^*)^{-1} \mathbf{y}_t$ , 變異數為  $\mathbf{F}_t = \left( \mathbf{B}' (\mathbf{V}_t^*)^{-1} \mathbf{B} + \mathbf{D}_t^{-1} \right)^{-1}$  的常態分配。

- 再給定  $\{\mathbf{y}_t, \mathbf{B}, f_t\}$ , 且因子與誤差的條件分配為相互獨立的常態分配, 我們可以將模型分解成  $p + k$  個常態狀態空間模型。令  $\boldsymbol{\alpha}_t = \mathbf{B} f_t$ ,

$$y_{jt} - \alpha_{jt} = \exp(h_{jt}/2) \varepsilon_{jt},$$

$$z_{jt} = \log(y_{jt} - \alpha_{jt})^2 = h_j + \log(\varepsilon_t)^2$$

其中,  $\log(\varepsilon_t)^2$  為取對數的卡方隨機變數。為了將上式轉為常態分配, 我們引用 Kim et al. (1998) 的方法, 以混和的常態分配來模擬取對數的卡方隨機變數。在這裡我們創造出一個指示變數  $s_t$ , 指示變數的作用是指明抽取何種常態分配的隨機變數。理論上以越多階的常態分配來模擬取對數的卡方分配會越準確, 但也越複雜。在可接受的誤差範圍之下, 我們以七個常態分配來模擬  $\log(\varepsilon_t)^2$ , 則在給定指示變數  $s_t$  之下,

$$\log(\varepsilon_t)|s_t \sim \mathbf{N}\left(m_{st}, v_{st}^2\right)^2,$$

$$\Pr(s_t = i) = q_i, \quad i \leq 7,$$

而指示變數的機率分配以及其所代表的常態分配如表 1。

在給定指示變數  $s_{jt}$  下,

$$z_{jt} | s_{jt}, h_{jt} \sim N(h_{jt} + m_{stj}, v_{stj}^2)$$

$$h_{jt} - \mu_j = \phi_j(h_{jt-1} - \mu_j) + \sigma_j \eta_{jt}, \quad j \leq p+k$$

現在我們說明如何對  $p+k$  個常態狀態模型中參數的抽樣。由於模型的因子與誤差的條件分配為相互獨立，使得，

$$p(\mathbf{s}, \boldsymbol{\theta}, \mathbf{h} | \mathbf{z}) = \prod_{j=1}^{k+p} p(\mathbf{s}_j, \boldsymbol{\theta}_j, \mathbf{h}_j | \mathbf{z}_j), \quad \theta_j = (\mu_j, \phi_j, \sigma_{\eta_j})$$

也就是說我們可以逐一對單變量中的參數做抽樣。我們將  $(\mathbf{s}_j, \boldsymbol{\theta}_j, \mathbf{h}_j | \mathbf{z}_j)$  分成三個區塊。

(1)  $\mathbf{s}_j$  的後驗分配為

$$\begin{aligned} Pr(\mathbf{s}_j | \mathbf{z}_j, \mathbf{h}_j) &\propto Pr(\mathbf{s}_j) N(\mathbf{z}_j | \mathbf{h}_j + \mathbf{m}_{st}, \mathbf{v}_{st}^2) \\ &= Pr(\mathbf{s}_j) \prod_{t=1}^n N(z_{jt} | h_{jt} + m_{stj}, v_{stj}^2) \end{aligned}$$

$\mathbf{s}_j$  的先驗分配即如表一。

(2)  $\boldsymbol{\theta}_j$  的後驗分配為

$$\begin{aligned} p(\boldsymbol{\theta}_j | \mathbf{z}_j, \mathbf{s}_j) &\propto p(\boldsymbol{\theta}_j) p(\mathbf{z}_j | \mathbf{s}_j, \boldsymbol{\theta}_j) \\ &= p(\boldsymbol{\theta}_j) p(z_{j1} | \mathbf{s}_j, \boldsymbol{\theta}_j) \prod_{t=2}^n N(z_{jt} | m_{stj} + \hat{h}_{t|t-1}, f_{t|t-1}), \end{aligned}$$

其中  $\{\hat{h}_{t|t-1}, f_{t|t-1}\}$  是根據 Kalman filter 遷迴所計算而來，遷迴公式(附錄一)如下：

$$\hat{h}_{t|t-1} = \mu + \phi(\hat{h}_{t|t-1} - \mu), \quad p_{t|t-1} = \phi^2 p_{t|t-1} + \sigma_{\eta}^2,$$

$$f_{t|t-1} = p_{t|t-1} + v_{st}^2, \quad k_t = p_{t|t-1} f_{t|t-1}^{-1},$$

$$\hat{h}_{t|t} = \hat{h}_{t|t-1} + k_t (z_j - m_{st} - \hat{h}_{t|t-1}).$$

對  $\theta_j$  的抽樣方法, 類似於抽取負荷矩陣  $\mathbf{B}$ , 同樣是以 M-H 法從  $T(\mathbf{m}, \mathbf{V}, \xi)$  抽出  $\theta^*$ , 而接受率為  $\alpha$ ,  $(\mathbf{m}, \mathbf{V})$  求取的方式仍是以數值極大化求解,  $\xi$  任意給定為 10。在常態假設之下,  $\theta$  後驗分配的概似函數可寫成,

$$\log g(\theta) \propto \frac{1}{2} \sum_{t=1}^N \log f_{t|t-1} - \frac{1}{2} \sum_{t=1}^N \frac{e_t^2}{f_{t|t-1}}$$

$$e_t = z_j - m_{s_t} - \hat{h}_{t|t-1}$$

而

$$\mathbf{m} = \arg \max_{\boldsymbol{\theta}} \log(l(\boldsymbol{\theta}))$$

$$\mathbf{V} = \left[ \frac{-\partial^2 \log(l(\boldsymbol{\theta}))}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}} \right]^{-1}$$

其中  $\mathbf{V}$  為負的 Hessian 的反矩陣, 則我們的 M-H 為從  $f_T(\mathbf{m}, \mathbf{V}, \xi)$  抽出  $\theta^*$  接受機率為

$$\alpha(\theta, \theta^* | z_j, s) = \min \left[ 1, \frac{g(\theta^*)}{g(\theta)} \frac{f_T(\theta | \mathbf{m}, \mathbf{V}, \xi)}{f_T(\theta' | \mathbf{m}, \mathbf{V}, \xi)} \right]$$

### (3) 狀態變數 $h_t$ 的抽樣

對狀態變數  $h_t$  的抽樣, 我們運用 de Jong 與 Shephard (1995) 的模擬平滑法 (signal simulant smoother), 有別其他方法, 這個方法最大的不同, 是它不是對狀態變數抽樣, 而是給定所有觀察值之下, 藉由對模型中誤差項的事後分配抽樣, 然後形成對狀態變數的模擬。在 kalman recursion 的計算之中, 我們保留  $e_t, f_t, k_t$ , 以向後遞迴的方式逐一抽出  $h_t$ 。首先定義  $n_t = f_{t|t-1}^{-1} + k_t^2 u_t$ ,  $d_t = f_{t|t-1}^{-1} e_t - r_t k_t$ , 令  $r_n = u_n = 0$ , 則其遞迴公式 (附錄二) 如下,

$$c_t = v_{s_t}^2 - v_{s_t}^4 n_t, \quad \zeta_t \sim N(0, c_t), \quad b_t = v_{s_t}^2 (n_t - \phi k_t u_t),$$

$$r_{t-1} = f_{t|t-1}^{-1} e_t + (\phi - k_t) r_{t-1} - b_t \frac{\zeta}{c_t},$$

$$u_{t-1} = f_{t|t-1}^{-1} + (\phi - k_t)^2 u_t + \frac{b_t^2}{c_t}$$

則狀態變數  $h_t = z_j - m_{s_t} - v_{s_t}^2 d_t - \zeta_t$ ,  $t = n, \dots, 1$ 。

## 4.4 模擬驗證

為了驗證上述演算法的正確性，我們依據選定的參數，模擬數據資料。下表列出參數的真實值與模型的估算值，其中樣本數 2000，模擬次數 12000 次，捨棄前面 2000 個值。表列為重複執行 30 次的平均值。真實值的選取為先對實際資料估計，以得到的估計值再整數化作為我們模擬真實設定的依據。估算的經驗中歸納幾點發現：

表 2: 模擬參數估計值

	真實值				估計值			
	$y_1$	$y_2$	$y_3$	$f$	$y_1$	$y_2$	$y_3$	$f$
$\mu$	1.500	1.000	0.000	1.500	1.5312 (0.237)	0.9777 (0.097)	-0.0397 (0.081)	1.4781 (0.054)
$\phi$	0.985	0.950	0.850	0.850	0.9786 (0.007)	0.9214 (0.029)	0.8633 (0.012)	0.8507 (0.019)
$\sigma_\eta$	0.150	0.200	1.000	0.250	0.1704 (0.022)	0.2575 (0.055)	0.1538 (0.029)	0.2679 (0.031)
$\beta$	1.000	1.200	0.800		1.0000 (0.035)	1.1998 (0.027)	0.8001	

表列為樣本數 2000，遞迴次數 12000 次，捨棄前面 2000 個值，重複執行 30 次的平均值。括弧內的數值為 RMSE。

- 程式以 Ox 語言編寫，在 CPU 1.8 GHz, 記憶體 1GB 的筆記型電腦上執行一次，大約耗時 10 小時。
- 大抵上估計值都算準確，不過通常  $\phi$  值皆會產生低估，但低估的程度在可以接受的範圍。另外，

$\sigma_\eta$  值皆會高估，且高估的程度與原來參數的真實大小值有關，真實的  $\sigma$  越大，高估的比例越大。

- $\mu$  與  $\beta$  的值相對比較容易收斂，其變異程度也較小。
- 改善偏誤的方法，我們發現以增加樣本數量的方式會比增加遞迴次數來的有效。