

PENDUGAAN PARAMETER DERET WAKTU *HIDDEN* MARKOV HAMILTON *

BERLIAN SETIAWATY, YANA ADHARINI DAN HIRASAWA

Departemen Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Pertanian Bogor
Jl Meranti, Kampus IPB Darmaga, Bogor 16680 Indonesia

ABSTRAK. Pendugaan parameter untuk model deret waktu *Hidden* Markov Hamilton (1994) dilakukan menggunakan Metode *Maximum Likelihood* dan pendugaan ulang menggunakan metode *Expectation Maximization*. Dari kajian ini diperoleh algoritma untuk menduga parameter model.

Kata kunci: Rantai Markov, *Hidden* Markov, Deret waktu *Hidden* Markov, Metode *Expectation Maximization*.

1. PENDAHULUAN

Tulisan ini merupakan kajian tentang pendugaan parameter untuk deret waktu *Hidden* Markov, khususnya model Hamilton (1994). Pendugaan parameter menggunakan metode *Maximum Likelihood* dan pendugaan ulangnya menggunakan metode *Expectation Maximization* (Metode EM). Dari kedua metode tersebut kemudian diturunkan suatu algoritma yang dapat dipakai secara umum untuk menduga parameter model deret waktu *Hidden* Markov Hamilton (1994).

Tulisan ini dimulai dengan definisi model deret waktu *Hidden* Markov beserta sifat-sifatnya. Pada bagian 3 dibahas Pendugaan Parameter model dan terakhir pada bagian 4 dibahas pendugaan ulang parameter dan algoritmanya.

2. MODEL DERET WAKTU *HIDDEN* MARKOV

Pasangan proses stokastik $\{(X_k, Y_k) : k \in \mathbb{N}\}$ yang terdefinisi pada ruang peluang (Ω, \mathcal{F}, P) dan mempunyai nilai pada $S \times Y$ disebut model *hidden* Markov apabila $\{X_k\}$ adalah rantai Markov dengan *state* berhingga dan diasumsikan bahwa rantai Markov $\{X_k\}$ tidak diamati. Sehingga $\{X_k\}$ tersembunyi (*hidden*) di balik proses observasi $\{Y_k\}$. Banyaknya elemen dari S disebut ukuran (orde) dari model *hidden* Markov.

Pada bagian ini dibahas model *hidden* Markov Hamilton (1994) yang merupakan deret waktu yang memenuhi persamaan

$$Y_t = c(X_t) + \phi(X_t)Y_{t-1} + \varepsilon_t \quad (2.1)$$

di mana:

- $\{X_t\}$ adalah rantai Markov dengan ruang *state* $S = \{1, 2\}$ dan $\mathbf{P} = \begin{bmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{bmatrix}$ merupakan matriks peluang transisinya, di mana $p_{ij} = P\{X_t = j \mid X_{t-1} = i\}$.
- $\{Y_t\}$ adalah proses yang diamati dan bernilai skalar.
- $\{\varepsilon_t\}$ adalah barisan peubah acak yang saling bebas dan berdistribusi normal $N(0, \sigma^2)$.
- $c = (c_1, c_2)$ dan $\phi = (\phi_1, \phi_2) \in \mathfrak{R}^2$, dengan c_1, c_2, ϕ_1 , dan ϕ_2 adalah konstanta real.
- $c(X_t) = c_{X_t}$ dan $\phi(X_t) = \phi_{X_t}$.

Jadi model dicirikan oleh parameter $\theta = (c_1, c_2, \phi_1, \phi_2, \sigma^2, \mathbf{P})$. Dengan menggunakan metode EM akan diduga parameter $\theta = (c_1, c_2, \phi_1, \phi_2, \sigma^2, \mathbf{P})$ dari data Y .

Karena $\varepsilon_t \sim N(0, \sigma^2)$ bebas stokastik identik maka dapat diperoleh fungsi sebaran bagi ε_t sebagai berikut.

$$\begin{aligned} F_{\varepsilon_t}(y_t) &= P(\varepsilon_t \leq y_t) = \int_0^{y_t} \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(\varepsilon_t - 0)^2}{2\sigma^2}\right\} d\varepsilon_t \\ &= \int_0^{y_t} \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(\varepsilon_t)^2}{2\sigma^2}\right\} d\varepsilon_t. \end{aligned} \quad (2.2)$$

Berdasarkan persamaan (2.2) diturunkan fungsi sebaran bagi Y_t dengan cara sebagai berikut.

$$\begin{aligned} F_{Y_t}(y_t) &= P(Y_t \leq y_t) = P(c_{X_t} + \phi_{X_t} y_{t-1} + \varepsilon_t \leq y_t) \\ &= P(\varepsilon_t \leq y_t - c_{X_t} - \phi_{X_t} y_{t-1}) \\ &= \int_0^{y_t - c_{X_t} - \phi_{X_t} y_{t-1}} \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(\varepsilon_t)^2}{2\sigma^2}\right\} d\varepsilon_t. \end{aligned}$$

Misalkan $v = y_t - c_{X_t} - \phi_{X_t} y_{t-1}$, maka

$$F_{Y_t}(y_t) = \int_0^v \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(\varepsilon_t)^2}{2\sigma^2}\right\} d\varepsilon_t$$

dan

$$\begin{aligned} f_{Y_t}(y_t) &= \frac{\partial}{\partial y_t} F_{Y_t}(y_t) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(v)^2}{2\sigma^2}\right\} \cdot \frac{\partial v}{\partial y_t} \\ &= \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(y_t - c_{X_t} - \phi_{X_t} y_{t-1})^2}{2\sigma^2}\right\} \cdot 1 \\ &= \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(y_t - c_{X_t} - \phi_{X_t} y_{t-1})^2}{2\sigma^2}\right\}. \end{aligned}$$

(2.3)

Misalkan Y_t adalah medan- σ yang lengkap dan dibangun oleh $Y_1, Y_2, Y_3, \dots, Y_t$. Karena X_t merupakan rantai Markov 2 state maka terdapat 2 fungsi kerapatan peluang bagi Y_t . Kumpulan fungsi kerapatan tersebut dalam vektor (2×1) dilambangkan dengan η_t . Sehingga diperoleh:

$$\begin{aligned} \eta_t &= \begin{bmatrix} f(y_t | X_t = 1, Y_{t-1}; \theta) \\ f(y_t | X_t = 2, Y_{t-1}; \theta) \end{bmatrix} \\ &= \begin{bmatrix} \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(y_t - c_1 - \phi_1 y_{t-1})^2}{2\sigma^2}\right\} \\ \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(y_t - c_2 - \phi_2 y_{t-1})^2}{2\sigma^2}\right\} \end{bmatrix}. \end{aligned}$$

(2.4)

Misalkan $\hat{\xi}_{t|t-1}$ melambangkan vektor (2×1) di mana elemen ke- j pada vektor merepresentasikan $P\{X_t = j | Y_{t-1}; \theta\}$ dan \otimes melambangkan perkalian elemen per elemen vektor, maka

$$\begin{aligned} \hat{\xi}_{t|t-1} \otimes \eta_t &= \begin{bmatrix} P(X_t = 1 | Y_{t-1}; \theta) \\ P(X_t = 2 | Y_{t-1}; \theta) \end{bmatrix} \otimes \begin{bmatrix} f(y_t | X_t = 1, Y_{t-1}; \theta) \\ f(y_t | X_t = 2, Y_{t-1}; \theta) \end{bmatrix} \\ &= \begin{bmatrix} P\{X_t = 1 | Y_{t-1}; \theta\} \cdot f(y_t | X_t = 1, Y_{t-1}; \theta) \\ P\{X_t = 2 | Y_{t-1}; \theta\} \cdot f(y_t | X_t = 2, Y_{t-1}; \theta) \end{bmatrix} \\ &= \begin{bmatrix} P(X_t = 1 | Y_{t-1}; \theta) \cdot f(y_t | X_t = 1, Y_{t-1}; \theta) \\ P(X_t = 2 | Y_{t-1}; \theta) \cdot f(y_t | X_t = 2, Y_{t-1}; \theta) \end{bmatrix}. \end{aligned} \quad (2.5)$$

Berdasarkan persamaan (2.5) maka dapat dituliskan:

$$\begin{aligned} &P(X_t = j | Y_{t-1}; \theta) \cdot f(y_t | X_t = j, Y_{t-1}; \theta) \\ &= \frac{P(X_t = j, Y_{t-1}; \theta)}{P(Y_{t-1}; \theta)} \cdot \frac{P(y_t, X_t = j, Y_{t-1}; \theta)}{P(X_t = j, Y_{t-1}; \theta)} \\ &= \frac{P(y_t, X_t = j, Y_{t-1}; \theta)}{P(Y_{t-1}; \theta)} = P(y_t, X_t = j | Y_{t-1}; \theta) \end{aligned} \quad (2.6)$$

sehingga diperoleh

$$\begin{aligned} f(y_t | Y_{t-1}; \theta) &= \sum_{j=1}^2 P(y_t, X_t = j | Y_{t-1}; \theta) \\ &= \sum_{j=1}^2 P(X_t = j | Y_{t-1}; \theta) \cdot f(y_t | X_t = j, Y_{t-1}; \theta) \\ &= P(X_t = 1 | Y_{t-1}; \theta) f(y_t | X_t = 1, Y_{t-1}; \theta) \\ &\quad + P(X_t = 2 | Y_{t-1}; \theta) f(y_t | X_t = 2, Y_{t-1}; \theta) \\ &= \mathbf{1}' \left(\hat{\xi}_{t|t-1} \otimes \eta_t \right), \end{aligned} \quad (2.7)$$

di mana $\mathbf{1}' = [1 \ 1]$.

Jika persamaan (2.6) dibagi dengan persamaan (2.7) maka diperoleh

$$\begin{aligned}
\frac{P(y_t, X_t = j | Y_{t-1}; \theta)}{f(y_t | Y_{t-1}; \theta)} &= \frac{P(y_t, X_t = j, Y_{t-1}; \theta)}{P(Y_{t-1}; \theta)} \cdot \frac{P(Y_{t-1}; \theta)}{P(y_t, Y_{t-1}; \theta)} \\
&= \frac{P(y_t, X_t = j, Y_{t-1}; \theta)}{P(y_t, Y_{t-1}; \theta)} = \frac{P(X_t = j, y_t, Y_{t-1}; \theta)}{P(y_t, Y_{t-1}; \theta)} \\
&= P(X_t = j | y_t, Y_{t-1}; \theta) = P(X_t = j | Y_t; \theta).
\end{aligned} \tag{2.8}$$

Sehingga berdasarkan persamaan (2.6), (2.7) dan (2.8) diperoleh

$$\begin{aligned}
P(X_t = j | Y_t; \theta) &= \frac{P(y_t, X_t = j | Y_{t-1}; \theta)}{f(y_t | Y_{t-1}; \theta)} \\
\hat{\xi}_{t|t} &= \frac{\left(\hat{\xi}_{t|t-1} \otimes \eta_t \right)}{\mathbf{1}' \left(\hat{\xi}_{t|t-1} \otimes \eta_t \right)}. \tag{2.9} \\
\xi_{t+1|t}^{(i)} &= P(X_{t+1} = i | Y_t; \theta) \\
&= \sum_{j=1}^2 P(X_{t+1} = i, X_t = j | Y_t; \theta) \\
&= \sum_{j=1}^2 P(X_{t+1} = i | X_t = j, Y_t; \theta) \cdot P(X_t = j | Y_t; \theta) \\
&= \sum_{j=1}^2 P(X_{t+1} = i | S_t = j; \theta) \cdot P(X_t = j | Y_t; \theta) \\
&= \sum_{j=1}^2 p_{ij} \xi_{t|t}^{(j)}
\end{aligned}$$

dan

$$\xi_{t+1|t} = \begin{bmatrix} p_{11} \cdot \xi_{t|t}^{(1)} + p_{12} \cdot \xi_{t|t}^{(2)} \\ p_{21} \cdot \xi_{t|t}^{(1)} + p_{22} \cdot \xi_{t|t}^{(2)} \end{bmatrix} = \begin{bmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{bmatrix} \begin{bmatrix} \xi_{t|t}^{(1)} \\ \xi_{t|t}^{(2)} \end{bmatrix} = \mathbf{P} \cdot \xi_{t|t}. \tag{2.10}$$

Fungsi log *likelihood* $L(\theta)$ untuk data yang diamati Y_t dapat dihitung dengan cara

$$L(\theta) = \log \left(f(y_1 | Y_0; \theta) f(y_2 | Y_1; \theta) \cdots f(y_T | Y_{T-1}; \theta) \right) = \sum_{t=1}^T \log f(y_t | Y_{t-1}; \theta). \tag{2.11}$$

Salah satu pendekatan yang dapat digunakan untuk memilih nilai awal bagi $\hat{\xi}_{t|t-1}$ adalah dengan membuat $\hat{\xi}_{t|0}$ sama dengan vektor peluang tak bersyarat $\pi = [\pi_1 \quad \pi_2]^T$ yang memenuhi sifat *ergodic*, yaitu

$$\begin{aligned} \mathbf{P}\pi &= \pi \\ \pi_1 + \pi_2 &= 1 \end{aligned}$$

Sehingga diperoleh:

$$\hat{\xi}_{t|0} = \begin{bmatrix} \pi_1 \\ \pi_2 \end{bmatrix} = \begin{bmatrix} P(X_t = 1 | Y_0; \theta) \\ P(X_t = 2 | Y_0; \theta) \end{bmatrix} = \begin{bmatrix} \frac{1 - p_{22}}{2 - p_{11} - p_{22}} \\ \frac{1 - p_{11}}{2 - p_{11} - p_{22}} \end{bmatrix}.$$

Berdasarkan persamaan (2.7) diperoleh

$$\begin{aligned} f(y_t | Y_{t-1}; \theta) &= P(X_t = 1 | Y_{t-1}; \theta) \cdot f(y_t | X_t = 1, Y_{t-1}; \theta) \\ &\quad + P(X_t = 2 | Y_{t-1}; \theta) \cdot f(y_t | X_t = 2, Y_{t-1}; \theta) \\ &= P(X_t = 1 | Y_{t-1}; \theta) \frac{1}{\sqrt{2\pi\sigma}} \exp\left\{ \frac{-(x_t - c_1 - \phi_1 y_{t-1})^2}{2\sigma^2} \right\} \\ &\quad + P(X_t = 2 | Y_{t-1}; \theta) \frac{1}{\sqrt{2\pi\sigma}} \exp\left\{ \frac{-(x_t - c_2 - \phi_2 y_{t-1})^2}{2\sigma^2} \right\}. \end{aligned} \tag{2.12}$$

3. PENDUGAAN PARAMETER

Penduga kemungkinan maksimum bagi θ diperoleh dengan memaksimum-kan fungsi *log-likelihood*

$$\mathcal{L}(\theta) = \sum_{t=1}^T \log f(y_t | Y_{t-1}; \theta).$$

Berdasarkan persamaan (2.12) diperoleh

$$\begin{aligned} \frac{\partial f(y_t | Y_{t-1}; \theta)}{\partial c_1} &= P(X_t = 1 | Y_{t-1}; \theta) \frac{1}{\sqrt{2\pi\sigma}} \exp\left\{ \frac{-(y_t - c_1 - \phi_1 y_{t-1})^2}{2\sigma^2} \right\} \cdot \frac{(y_t - c_1 - \phi_1 y_{t-1})}{\sigma^2} \\ &= P(X_t = 1 | Y_{t-1}; \theta) f(y_t | X_t = 1, Y_{t-1}; \theta) \frac{(y_t - c_1 - \phi_1 y_{t-1})}{\sigma^2}. \end{aligned}$$

Untuk memperoleh nilai \hat{c}_1 yang memaksimum fungsi *log-likelihood* maka turunan pertama dari $\mathcal{L}(\theta)$ terhadap c_1 harus sama dengan nol.

$$\begin{aligned}
 \frac{\partial \mathcal{L}(\theta)}{\partial c_1} &= 0 \\
 \Leftrightarrow \sum_{t=1}^T \frac{1}{f(y_t | Y_{t-1}; \theta)} \cdot \frac{\partial f(y_t | Y_{t-1}; \theta)}{\partial c_1} &= 0 \\
 \Leftrightarrow \sum_{t=1}^T \left[\frac{P(X_t = 1 | Y_{t-1}; \theta) \cdot f(y_t | X_t = 1, Y_{t-1}; \theta)}{f(y_t | Y_{t-1}; \theta)} \cdot \frac{(y_t - c_1 - \phi_1 y_{t-1})}{\sigma^2} \right] &= 0 \\
 \Leftrightarrow \sum_{t=1}^T \frac{P(X_t = 1 | Y_{t-1}; \theta) \cdot f(y_t | X_t = 1, Y_{t-1}; \theta)}{f(y_t | Y_{t-1}; \theta)} \cdot (y_t - \phi_1 y_{t-1}) &= \\
 &= c_1 \sum_{t=1}^T \frac{P(X_t = 1 | Y_{t-1}; \theta) \cdot f(y_t | X_t = 1, Y_{t-1}; \theta)}{f(y_t | Y_{t-1}; \theta)}.
 \end{aligned}$$

Sehingga diperoleh

$$\hat{c}_1 = \frac{\sum_{t=1}^T \frac{P(X_t = 1 | Y_{t-1}; \hat{\theta}) \cdot f(y_t | X_t = 1, Y_{t-1}; \hat{\theta}) \cdot (y_t - \hat{\phi}_1 y_{t-1})}{f(y_t | Y_{t-1}; \hat{\theta})}}{\sum_{t=1}^T \frac{P(X_t = 1 | Y_{t-1}; \hat{\theta}) \cdot f(y_t | X_t = 1, Y_{t-1}; \hat{\theta})}{f(y_t | Y_{t-1}; \hat{\theta})}}. \quad (3.1)$$

Dengan cara yang sama diperoleh:

$$\hat{c}_2 = \frac{\sum_{t=1}^T \frac{P(X_t = 2 | Y_{t-1}; \hat{\theta}) \cdot f(y_t | X_t = 2, Y_{t-1}; \hat{\theta}) \cdot (y_t - \hat{\phi}_2 y_{t-1})}{f(y_t | Y_{t-1}; \hat{\theta})}}{\sum_{t=1}^T \frac{P(X_t = 2 | Y_{t-1}; \hat{\theta}) \cdot f(y_t | X_t = 2, Y_{t-1}; \hat{\theta})}{f(y_t | Y_{t-1}; \hat{\theta})}}. \quad (3.2)$$

Berdasarkan persamaan (2.12) diperoleh

$$\begin{aligned}
 \frac{\partial f(y_t | Y_{t-1}; \theta)}{\partial \phi_1} &= P(X_t = 1 | Y_{t-1}; \theta) \cdot \frac{1}{\sqrt{2\pi}\sigma} \exp \left\{ -\frac{(y_t - c_1 - \phi_1 y_{t-1})^2}{2\sigma^2} \right\} \cdot \frac{(y_t - c_1 - \phi_1 y_{t-1})}{\sigma^2} \cdot \frac{(y_{t-1})}{\sigma^2} \\
 &= P(X_t = 1 | Y_{t-1}; \theta) \cdot f(y_t | X_t = 1, Y_{t-1}; \theta) \cdot \frac{(y_t - c_1 - \phi_1 y_{t-1})}{\sigma^2} \cdot \frac{(y_{t-1})}{\sigma^2}.
 \end{aligned}$$

Untuk memperoleh nilai $\hat{\phi}_1$ yang memaksimum fungsi *log-likelihood* maka turunan pertama dari $\mathcal{L}(\theta)$ terhadap ϕ_1 harus sama dengan nol.

$$\begin{aligned} \frac{\partial \mathcal{L}(\theta)}{\partial \phi_1} &= \sum_{t=1}^T \frac{1}{f(y_t | \mathbf{Y}_{t-1}; \theta)} \cdot \frac{\partial f(y_t | \mathbf{Y}_{t-1}; \theta)}{\partial \phi_1} = 0 \\ \Leftrightarrow \sum_{t=1}^T \left[\frac{P(X_t = 1 | \mathbf{Y}_{t-1}; \theta) \cdot f(y_t | X_t = 1, \mathbf{Y}_{t-1}; \theta)}{f(y_t | \mathbf{Y}_{t-1}; \theta)} \cdot \frac{(y_t - c_1 - \phi_1 y_{t-1}) (y_{t-1})}{\sigma^2} \right] &= 0 \end{aligned}$$

memberikan

$$\begin{aligned} \sum_{t=1}^T \frac{P(X_t = 1 | \mathbf{Y}_{t-1}; \theta) f(y_t | X_t = 1, \mathbf{Y}_{t-1}; \theta) (y_{t-1}) (y_t - c_1)}{f(y_t | \mathbf{Y}_{t-1}; \theta)} &= \\ \phi_1 \sum_{t=1}^T \frac{P(X_t = 1 | \mathbf{Y}_{t-1}; \theta) f(y_t | X_t = 1, \mathbf{Y}_{t-1}; \theta) (y_{t-1})^2}{f(y_t | \mathbf{Y}_{t-1}; \theta)}. \end{aligned}$$

Sehingga diperoleh

$$\hat{\phi}_1 = \frac{\sum_{t=1}^T \frac{P(X_t = 1 | \mathbf{Y}_{t-1}; \hat{\theta}) f(y_t | X_t = 1, \mathbf{Y}_{t-1}; \hat{\theta}) (y_{t-1}) (y_t - \hat{c}_1)}{f(y_t | \mathbf{Y}_{t-1}; \hat{\theta})}}{\sum_{t=1}^T \frac{P(X_t = 1 | \mathbf{Y}_{t-1}; \hat{\theta}) f(y_t | X_t = 1, \mathbf{Y}_{t-1}; \hat{\theta}) (y_{t-1})^2}{f(y_t | \mathbf{Y}_{t-1}; \hat{\theta})}}. \quad (3.3)$$

Dengan cara yang sama diperoleh

$$\hat{\phi}_2 = \frac{\sum_{t=1}^T \frac{P(X_t = 2 | \mathbf{Y}_{t-1}; \hat{\theta}) f(y_t | X_t = 2, \mathbf{Y}_{t-1}; \hat{\theta}) (y_{t-1}) (y_t - \hat{c}_2)}{f(y_t | \mathbf{Y}_{t-1}; \hat{\theta})}}{\sum_{t=1}^T \frac{P(X_t = 2 | \mathbf{Y}_{t-1}; \hat{\theta}) f(y_t | X_t = 2, \mathbf{Y}_{t-1}; \hat{\theta}) (y_{t-1})^2}{f(y_t | \mathbf{Y}_{t-1}; \hat{\theta})}}. \quad (3.4)$$

Berdasarkan persamaan (2.12) diperoleh

$$\begin{aligned}
 \frac{\partial f(y_t | Y_{t-1}; \theta)}{\partial \sigma^2} &= \sum_{j=1}^2 \left[-P(X_t = j | Y_{t-1}; \theta) \frac{1}{2\sigma^3 \sqrt{2\pi}} \exp \left\{ \frac{-(y_t - c_j - \phi_j y_{t-1})^2}{2\sigma^2} \right\} \right. \\
 &\quad \left. + \left(P(X_t = j | Y_{t-1}; \theta) \frac{1}{\sigma \sqrt{2\pi}} \exp \left\{ \frac{-(y_t - c_j - \phi_j y_{t-1})^2}{2\sigma^2} \right\} \cdot \frac{(y_t - c_j - \phi_j y_{t-1})^2}{2\sigma^4} \right) \right] \\
 &= \sum_{j=1}^2 \left[P(X_t = j | Y_{t-1}; \theta) \frac{1}{\sigma \sqrt{2\pi}} \exp \left\{ \frac{-(y_t - c_j - \phi_j y_{t-1})^2}{2\sigma^2} \right\} \cdot \left(\frac{-1}{2\sigma^2} + \frac{(y_t - c_j - \phi_j y_{t-1})^2}{2\sigma^4} \right) \right] \\
 &= \sum_{j=1}^2 \left[P(X_t = j | Y_{t-1}; \theta) f(y_t | X_t = j, Y_{t-1}; \theta) \cdot \left(\frac{-1}{2\sigma^2} + \frac{(y_t - c_j - \phi_j y_{t-1})^2}{2\sigma^4} \right) \right] \\
 &= \sum_{j=1}^2 \left[P(X_t = j | Y_{t-1}; \theta) f(y_t | X_t = j, Y_{t-1}; \theta) \cdot \left(\frac{-\sigma^2}{2\sigma^4} + \frac{(y_t - c_j - \phi_j y_{t-1})^2}{2\sigma^4} \right) \right].
 \end{aligned}$$

Untuk memperoleh nilai $\hat{\sigma}^2$ yang memaksimum fungsi *log-likelihood* maka turunan pertama dari $\mathcal{L}(\theta)$ terhadap σ^2 harus sama dengan nol

$$\begin{aligned}
 \frac{\partial \mathcal{L}(\theta)}{\partial \sigma^2} &= 0 \\
 \Leftrightarrow \sum_{t=1}^T \frac{1}{f(y_t | Y_{t-1}; \theta)} \cdot \frac{\partial f(y_t | Y_{t-1}; \theta)}{\partial \sigma^2} &= 0 \\
 \Leftrightarrow \sum_{t=1}^T \sum_{j=1}^2 \left[\frac{P(X_t = j | Y_{t-1}; \theta) f(y_t | X_t = j, Y_{t-1}; \theta)}{f(y_t | Y_{t-1}; \theta)} \cdot \left(-\sigma^2 + (y_t - c_{s_t} - \phi_{s_t} y_{t-1})^2 \right) \right] &= 0
 \end{aligned}$$

memberikan

$$\begin{aligned}
 \sigma^2 \sum_{t=1}^T \sum_{j=1}^2 \frac{P(X_t = j | Y_{t-1}; \theta) f(y_t | X_t = j, Y_{t-1}; \theta)}{f(y_t | Y_{t-1}; \theta)} \\
 = \sum_{t=1}^T \sum_{j=1}^2 \frac{P(X_t = j | Y_{t-1}; \theta) f(y_t | X_t = j, Y_{t-1}; \theta) (y_t - c_{s_t} - \phi_{s_t} y_{t-1})^2}{f(y_t | Y_{t-1}; \theta)}.
 \end{aligned}$$

Sehingga diperoleh

$$\hat{\sigma}^2 = \frac{\sum_{t=1}^T \sum_{j=1}^2 \frac{P(X_t = j | Y_{t-1}; \hat{\theta}) f(y_t | X_t = j, Y_{t-1}; \hat{\theta}) (y_t - \hat{c}_{s_t} - \hat{\phi}_{s_t} y_{t-1})^2}{f(y_t | Y_{t-1}; \hat{\theta})}}{\sum_{t=1}^T \sum_{j=1}^2 \frac{P(X_t = j | Y_{t-1}; \hat{\theta}) f(y_t | X_t = j, Y_{t-1}; \hat{\theta})}{f(y_t | Y_{t-1}; \hat{\theta})}}. \tag{3.5}$$

Untuk menduga parameter P digunakan formula (3.6) berikut yang diperoleh dari Hamilton (1990).

$$\hat{p}_{ij} = \frac{\sum_{t=2}^T P(X_t = j, X_{t-1} = i | Y_T; \hat{\theta})}{\sum_{t=2}^T P(X_{t-1} = i | Y_T; \hat{\theta})} \quad (3.6)$$

di mana menurut Kim (1994)

$$\begin{aligned} & P(X_t = j, X_{t-1} = i | Y_T; \hat{\theta}) \\ &= P(X_t = j | Y_T; \hat{\theta}) \times P(X_{t-1} = i | X_t = j, Y_T; \hat{\theta}) \\ &\approx P(X_t = j | Y_T; \hat{\theta}) \times P(X_{t-1} = i | X_t = j, Y_T; \hat{\theta}) \\ &= \frac{P(X_t = j | Y_T; \hat{\theta}) \times P(X_{t-1} = i, s_t = j | Y_T; \hat{\theta})}{P(X_t = j | Y_T; \hat{\theta})} \\ &= \frac{P(X_t = j | Y_T; \hat{\theta}) \times P(X_{t-1} = i | Y_T; \hat{\theta}) \times P(X_t = i | X_{t-1} = i)}{P(X_t = j | Y_T; \hat{\theta})} \end{aligned} \quad (3.7)$$

dan

$$P(X_{t-1} = i | Y_T; \hat{\theta}) = \sum_{j=1}^2 P(X_t = j, X_{t-1} = i | Y_T; \hat{\theta}).$$

4. PENDUGAAN ULANG PARAMETER DAN ALGORITMA

Karena persamaan (3.1) sampai (3.7) tak linear, maka tidak mungkin untuk memperoleh $\hat{\theta}$ secara analitik sebagai fungsi dari $\{Y_1, Y_2, Y_3, \dots, Y_T\}$. Sehingga untuk mencari penduga kemungkinan maksimum digunakan algoritma iteratif dari metode EM.

4.1 Metode *Expectation Maximization* (Metode EM)

Algoritma EM dikembangkan oleh Baum and Petrie (1966) dengan ide dasar sebagai berikut.

Misalkan $\{P_\theta : \theta \in \Theta\}$ adalah koleksi ukuran peluang yang terdefinisi pada ruang (Ω, \mathcal{G}) dan kontinu absolut terhadap P_0 . Misalkan $Y \subset \mathcal{G}$. Definisikan fungsi *likelihood* untuk menentukan penduga parameter θ berdasarkan informasi Y sebagai

$$L(\theta) = E_0 \left[\frac{dP_\theta}{dP_0} \middle| Y \right]$$

dan penduga maksimum *likelihood* didefinisikan sebagai

$$\hat{\theta} \in \arg \max_{\theta \in \Theta} L(\theta).$$

Secara umum penduga maksimum likelihood $\hat{\theta}$ sulit dihitung secara langsung. Algoritma EM memberikan suatu metode iteratif untuk mengaproksimasi $\hat{\theta}$, dengan prosedur sebagai berikut.

Langkah 1: Set $p = 0$ dan pilih $\hat{\theta}_0$.

Langkah 2: [Langkah-E]

$$\text{Set } \theta^* = \hat{\theta}_p \text{ dan hitung } Q(\theta, \theta^*) = E_{\theta^*} \left[\log \frac{dP_\theta}{dP_{\theta^*}} \middle| Y \right].$$

Langkah 3: [Langkah-M]

$$\text{Tentukan } \hat{\theta}_{p+1} \in \arg \max_{\theta \in \Theta} Q(\theta, \theta^*).$$

Langkah 4: $p \leftarrow p + 1$

Ulangi langkah 2 sampai kriteria berhenti dipenuhi.

Catatan:

1. Barisan $\{\hat{\theta}_p : p \geq 0\}$ memberikan barisan $\{L(\hat{\theta}_p) : p \geq 0\}$ yang tak turun.
2. Menurut ketaksamaan Jensen,

$$Q(\hat{\theta}_{p+1}, \hat{\theta}_p) \leq \log L(\hat{\theta}_{p+1}) - \log L(\hat{\theta}_p).$$
3. $Q(\theta, \theta^*)$ disebut *pseudo-loglikelihood* bersyarat.

4.2 Pendugaan ulang parameter menggunakan metode EM

Dengan menggunakan metode EM diperoleh algoritma untuk menduga ulang parameter model. Algoritma tersebut sebagai berikut.

Langkah 1:

Tentukan banyaknya data (T) yang akan diamati serta tentukan juga nilai $(y_0, y_1, y_2, \dots, y_{T-1})$ dan matriks transisi

$$\mathbf{P} = \begin{bmatrix} P_{11} & P_{12} \\ P_{21} & P_{22} \end{bmatrix}.$$

Beri nilai awal bagi $\hat{\theta}$ yang dilambangkan dengan $\hat{\theta}^{(m)} = (\hat{c}_1, \hat{c}_2, \hat{\phi}_1, \hat{\phi}_2, \hat{\sigma}^2)$.

Langkah 2:

Cari fungsi kerapatan bersyarat bagi y_t untuk setiap $t = 1, 2, \dots, T$ dengan cara

$$\eta_t = \begin{bmatrix} f(y_t | X_t = 1, Y_{t-1}; \hat{\theta}^{(m)}) \\ f(y_t | X_t = 2, Y_{t-1}; \hat{\theta}^{(m)}) \end{bmatrix} = \begin{bmatrix} \frac{1}{\sqrt{2\pi\hat{\sigma}}} \exp\left\{ \frac{-(y_t - \hat{c}_1 - \hat{\phi}_1 y_{t-1})^2}{2\hat{\sigma}^2} \right\} \\ \frac{1}{\sqrt{2\pi\hat{\sigma}}} \exp\left\{ \frac{-(y_t - \hat{c}_2 - \hat{\phi}_2 y_{t-1})^2}{2\hat{\sigma}^2} \right\} \end{bmatrix}.$$

Langkah 3:

Penarikan kesimpulan optimal dan peramalan untuk setiap waktu t pada contoh dapat diperoleh melalui iterasi:

3.1. Tentukan nilai awal bagi $\hat{\xi}_{t|t-1}$ yang dilambangkan dengan $\hat{\xi}_{1|0}$.

3.2. Berikan nilai awal $i = 1$.

3.3. Untuk $t = i$, cari nilai dari

$$\begin{aligned} f(y_t | Y_{t-1}; \hat{\theta}^{(m)}) &= \mathbf{1}'(\hat{\xi}_{t|t-1} \otimes \eta_t) \\ &= P(X_t = 1 | Y_{t-1}; \hat{\theta}^{(m)}) \frac{1}{\sqrt{2\pi\hat{\sigma}}} \exp\left\{ \frac{-(y_t - \hat{c}_1 - \hat{\phi}_1 y_{t-1})^2}{2\hat{\sigma}^2} \right\} \\ &\quad + P(X_t = 2 | Y_{t-1}; \hat{\theta}^{(m)}) \frac{1}{\sqrt{2\pi\hat{\sigma}}} \exp\left\{ \frac{-(y_t - \hat{c}_2 - \hat{\phi}_2 y_{t-1})^2}{2\hat{\sigma}^2} \right\}, \end{aligned}$$

$$\hat{\xi}_{t|t} = \begin{bmatrix} P\{X_t = 1 | Y_{t-1}; \hat{\theta}^{(m)}\} \\ P\{X_t = 2 | Y_{t-1}; \hat{\theta}^{(m)}\} \end{bmatrix} = \frac{(\hat{\xi}_{t|t-1} \otimes \eta_t)}{\mathbf{1}'(\hat{\xi}_{t|t-1} \otimes \eta_t)},$$

$$\hat{\xi}_{t+1|t} = \begin{bmatrix} P\{X_{t+1} = 1 | Y_t; \hat{\theta}^{(m)}\} \\ P\{X_{t+1} = 2 | Y_t; \hat{\theta}^{(m)}\} \end{bmatrix} = \mathbf{P} \cdot \hat{\xi}_{t|t},$$

$i \leftarrow i + 1$.

3.4. Ulangi mulai dari langkah (3.3).

Stop jika $t = T$.

Lanjutkan ke langkah 4.

Langkah 4:

Cari nilai dari:

$$\hat{c}_i = \frac{\sum_{t=1}^T \frac{\hat{\xi}_{t+1|t}^{(j)} \cdot f(y_t | X_t = i, Y_{t-1}; \hat{\theta})}{f(y_t | Y_{t-1}; \hat{\theta})} \cdot (y_t - \phi_i y_{t-1})}{\sum_{t=1}^T \frac{\hat{\xi}_{t+1|t}^{(j)} \cdot f(y_t | X_t = i, Y_{t-1}; \hat{\theta})}{f(y_t | Y_{t-1}; \hat{\theta})}}, \quad i = 1, 2.$$

$$\hat{\phi}_i = \frac{\sum_{t=1}^T \frac{\hat{\xi}_{t+1|t}^{(j)} \cdot f(y_t | X_t = i, Y_{t-1}; \hat{\theta})}{f(y_t | Y_{t-1}; \hat{\theta})} \cdot (y_t - \hat{c}_i)(y_{t-1})}{\sum_{t=1}^T \frac{\hat{\xi}_{t+1|t}^{(j)} \cdot f(y_t | X_t = i, Y_{t-1}; \hat{\theta}) (y_{t-1})^2}{f(y_t | Y_{t-1}; \hat{\theta})}}, \quad i = 1, 2.$$

$$\hat{\sigma}^2 = \frac{\sum_{t=1}^T \sum_{j=1}^2 \frac{\hat{\xi}_{t+1|t}^{(j)} f(y_t | X_t = j, Y_{t-1}; \hat{\theta}) (y_t - \hat{c}_{X_t} - \hat{\phi}_{X_t} y_{t-1})^2}{f(y_t | Y_{t-1}; \hat{\theta})}}{\sum_{t=1}^T \sum_{j=1}^2 \frac{\hat{\xi}_{t+1|t}^{(j)} f(y_t | X_t = j, Y_{t-1}; \hat{\theta})}{f(y_t | Y_{t-1}; \hat{\theta})}}.$$

Langkah 5:

Beri nama parameter yang dihasilkan pada langkah 4 dengan

$$\hat{\theta}_{k+1} = (\hat{c}_1, \hat{c}_2, \hat{\phi}_1, \hat{\phi}_2, \hat{\sigma}^2), \quad k = 0, 1, 2, \dots, T-1.$$

Langkah 6:

Cari **P** yang baru, yaitu:

$$\hat{\xi}_{t|T}^{(j)} = \hat{\xi}_{t|t}^{(j)} \otimes \left\{ \mathbf{P}' \left[\hat{\xi}_{t+1|T}^{(j)} (\div) \hat{\xi}_{t+1|t}^{(j)} \right] \right\}$$

di mana (\div) merupakan operasi perkalian elemen per elemen vektor,

$$\begin{aligned} P(X_t = j, X_{t-1} = i | Y_T) \\ &\approx \frac{P(X_t = j | Y_T) \times P(X_{t-1} = i | Y_t) \times P(X_t = i | X_{t-1} = i)}{P(X_t = j | Y_t)} \\ &= \frac{\hat{\xi}_{t|T}^{(j)} \times \hat{\xi}_{t-1|t-1}^{(i)} \times p_{ij}}{\hat{\xi}_{t|t}^{(j)}}, \end{aligned}$$

$$P(X_{t-1} = i | Y_t; \hat{\theta}) = \sum_{j=1}^2 P(X_t = j, X_{t-1} = i | Y_T),$$

$$\hat{p}_{ij} = \frac{\sum_{t=2}^T P(X_t = j, X_{t-1} = i | Y_T; \hat{\theta})}{\sum_{t=2}^T P(X_{t-1} = i | Y_T; \hat{\theta})} = \frac{\sum_{t=2}^T \frac{\hat{\xi}_{t|T}^{(j)} \times \hat{\xi}_{t-1|t-1}^{(i)} \times p_{ij}}{\hat{\xi}_{t|t}^{(j)}}}{\sum_{t=2}^T \sum_{j=1}^2 \frac{\hat{\xi}_{t|T}^{(j)} \times \hat{\xi}_{t-1|t-1}^{(i)} \times p_{ij}}{\hat{\xi}_{t|t}^{(j)}}}.$$

Langkah 7:

Selama $k < T$, ulangi mulai dari langkah 2. Gunakan parameter yang sudah dihasilkan untuk mencari nilai harapan bagi nilai y yang akan datang.

$$E[Y_{t+1} | X_{t+1} = j, Y_t; \theta] = c_j + \phi_j y_t.$$

DAFTAR PUSTAKA

- [1]. Baum, L.E. and Petrie, T. 1966. Statistical inference for probabilistic functions of finite state Markov chains. *Annals of the Institute of Statistical Mathematics*, 37:1554-1563.
- [2]. Hamilton, J. D. 1990. Analysis of Time Series Subject to Changes in Regime. *Journal of Econometrics* 45: 39 -70.
- [3]. Hamilton, J. D. 1994. *Time Series Analysis*. Princeton University Press, New Jersey.
- [4]. Kim, C. J. 1994. Dynamic linear models with Markov-Switching. *Journal of Econometrics* 60: 1- 22.