

PENDUGAAN PARAMETER MODEL *HIDDEN MARKOV* *

BERLIAN SETIAWATY DAN LINDA KRISTINA

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

ABSTRAK. Pendugaan parameter untuk model *Hidden Markov* Elliott et. al. (1995) dilakukan menggunakan Metode *Maximum Likelihood* dan pendugaan ulang menggunakan metode *Expectation Maximization* yang melibatkan perubahan ukuran. Dari metode tersebut diperoleh algoritma untuk menduga parameter model.

Kata kunci: Rantai Markov, model *Hidden Markov*, perubahan ukuran, metode *Expectation Maximization*.

1. PENDAHULUAN

Tulisan ini merupakan kajian pustaka tentang pendugaan parameter untuk model *Hidden Markov* Elliott, et. al. (1995). Pendugaan parameter menggunakan metode *Maximum Likelihood* dan pendugaan ulangnya menggunakan metode *Expectation Maximization* (Metode EM) yang melibatkan perubahan ukuran. Dari kedua metode tersebut kemudian diturunkan suatu algoritma yang dapat dipakai secara umum untuk menduga parameter model *Hidden Markov* Elliott, et. al. (1995).

Tulisan ini dimulai dengan definisi model *Hidden Markov* beserta karakteristiknya. Pada bagian 3 dibahas Pendugaan Parameter model dan terakhir pada bagian 4 diturunkan algoritmanya.

*Tulisan ini merupakan bagian dari hasil penelitian yang didanai oleh Hibah Penelitian PHK A2 Departemen Matematika IPB tahun 2006

2. MODEL HIDDEN MARKOV

2.1 Definisi

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 tulisan ini dibahas model *hidden* Markov Elliot, et. al. (1995) yang berbentuk:

$$\begin{aligned} X_{k+1} &= AX_k + V_{k+1} \\ Y_{k+1} &= c(X_k) + \sigma(X_k)\omega_{k+1} \end{aligned}$$

di mana $\{X_k\}$ adalah rantai Markov yang homogen dengan ruang state $S = \{e_1, e_2, \dots, e_N\}$, dengan e_i vektor satuan di \mathbb{R}^N dan $A = (a_{ji})_{N \times N}$ merupakan matriks transisinya, dengan

$$a_{ji} = P(X_k = e_j \mid X_{k-1} = e_i) \quad i, j = 1, 2, \dots, N$$

$\{\omega_k\}$ adalah barisan peubah acak yang bebas stokastik identik dengan sebaran $N(0,1)$ dan

$$c(X_k) = \langle c, X_k \rangle \quad \text{dan} \quad \sigma(X_k) = \langle \sigma, X_k \rangle$$

dengan

$$\begin{aligned} c &= (c_1, c_2, \dots, c_N) \in \mathbb{R}^N, \quad \sigma = (\sigma_1, \sigma_2, \dots, \sigma_N) \in \mathbb{R}^N \\ \langle \cdot, \cdot \rangle &= \text{perkalian dalam di } \mathbb{R}^N. \end{aligned}$$

Asumsikan $\sigma_i > 0$, untuk $i = 1, 2, \dots, N$.

Misalkan $\{\mathcal{F}_k\}_k$ adalah filtrasi lengkap yang dibangun oleh $\{X_k\}_k$, $\{Y_k\}$ adalah filtrasi lengkap yang dibangun oleh $\{Y_k\}$ dan $\{\mathcal{G}_k\}_k$ adalah filtrasi lengkap yang dibangun oleh $\{X_k\}_k$ dan $\{Y_k\}$.

Catatan 2.1.1 Karena $\omega_k, k \in \mathbb{N}$ adalah peubah acak yang bebas stokastik identik, maka ω_k bebas dari \mathcal{G}_k . Akibatnya ω_k juga bebas dari \mathcal{F}_k .

2.2 Nilai Harapan Bersyarat

Untuk sebarang $t \in \mathbb{N}$, berlaku

$$\begin{aligned}
P(Y_{k+1} \leq t | \mathbf{Y}_k) &= \sum_{i=1}^N P(Y_{k+1} \leq t, X_k = e_i | \mathbf{Y}_k) \\
&= \sum_{i=1}^N P(Y_{k+1} \leq t | X_k = e_i, \mathbf{Y}_k) \cdot P(X_k = e_i | \mathbf{Y}_k) \\
&= \sum_{i=1}^N P(Y_{k+1} \leq t | X_k = e_i) \cdot P(X_k = e_i | \mathbf{Y}_k) \\
&= \sum_{i=1}^N P(c(X_k) + \sigma(X_k)\omega_{k+1} \leq t | X_k = e_i) \cdot P(X_k = e_i | \mathbf{Y}_k) \\
&= \sum_{i=1}^N P(c_i + \sigma_i\omega_{k+1} \leq t) \cdot P(X_k = e_i | \mathbf{Y}_k) \\
&= \sum_{i=1}^N P(\sigma_i\omega_{k+1} \leq t - c_i) \cdot P(X_k = e_i | \mathbf{Y}_k).
\end{aligned}$$

Misalkan $\hat{X}_k := E[X_k | \mathbf{Y}_k]$ dan $\phi_i(x) = \frac{1}{\sqrt{2\pi\sigma_i}} e^{-\frac{1}{2\sigma_i}x^2}$ (fungsi kepadatan $N(0, \sigma_i)$)

maka

$$\begin{aligned}
\langle \hat{X}_k, e_i \rangle &= \langle E[X_k | \mathbf{Y}_k], e_i \rangle = \left\langle \sum_{j=1}^N e_j \cdot P(X_k = e_j | \mathbf{Y}_k), e_i \right\rangle \\
&= \sum_{j=1}^N P(X_k = e_j | \mathbf{Y}_k) \langle e_j, e_i \rangle = P(X_k = e_i | \mathbf{Y}_k).
\end{aligned}$$

Sehingga diperoleh

$$P(Y_{k+1} \leq t | \mathbf{Y}_k) = \sum_{i=1}^N P(\sigma_i\omega_{k+1} \leq t - c_i) \cdot P(X_k = e_i | \mathbf{Y}_k) = \sum_{i=1}^N \langle \hat{X}_k, e_i \rangle \int_{-\infty}^{t-c_i} \phi_i(x) dx. \quad (2.1)$$

Jadi fungsi kepadatan bersyarat dari Y_{k+1} diketahui \mathbf{Y}_k adalah

$$\sum_{j=1}^N \langle \hat{X}_k, e_j \rangle \phi_j(t - c_j).$$

Adapun sebaran gabungan dari X_k dan Y_{k+1} diketahui \mathbf{Y}_k adalah

$$\begin{aligned}
P(X_k = e_i, Y_{k+1} \leq t | \mathbf{Y}_k) &= P(Y_{k+1} \leq t | X_k = e_i, \mathbf{Y}_k) \cdot P(X_k = e_i | \mathbf{Y}_k) \\
&= P(c_i + \sigma_i\omega_{k+1} \leq t) \cdot P(X_k = e_i | \mathbf{Y}_k) = \langle \hat{X}_k, e_i \rangle \int_{-\infty}^{t-c_i} \phi_i(x) dx.
\end{aligned}$$

Sehingga diperoleh fungsi kepadatan gabungan bersyarat dari

X_k dan Y_{k+1} diketahui \mathbf{Y}_k adalah $\langle \hat{X}_k, e_i \rangle \phi_i(t - c_i)$.

Berdasarkan aturan Bayes, diperoleh

$$E[\langle X_k, e_i \rangle | \mathbf{Y}_{k+1}] = P(X_k = e_i | Y_{k+1}, \mathbf{Y}_k) = \frac{P(X_k = e_i, Y_{k+1} | \mathbf{Y}_k)}{P(Y_{k+1} | \mathbf{Y}_k)} = \frac{\langle \hat{X}_k, e_i \rangle \phi_i(t - c_i)}{\sum_{j=1}^N \langle \hat{X}_k, e_j \rangle \phi_j(t - c_j)}. \text{ Ak}$$

ibatnya didapat

$$E[X_k | Y_{k+1}] = E\left[\sum_{i=1}^N \langle X_k, e_i \rangle e_i | Y_{k+1}\right] = \sum_{i=1}^N E[\langle X_k, e_i \rangle | Y_{k+1}] e_i = \frac{\sum_{i=1}^N \langle \hat{X}_k, e_i \rangle \phi_i(y_{k+1} - c_i) e_i}{\sum_{j=1}^N \langle \hat{X}_k, e_j \rangle \phi_j(y_{k+1} - c_j)}.$$

Teorema 2.2.1 (Elliot et. al. 1995)

$$\hat{X}_{k+1} = E[X_{k+1} | Y_{k+1}] = \frac{\sum_{i=1}^N \langle \hat{X}_k, e_i \rangle \phi_i(y_{k+1} - c_i) A e_i}{\sum_{j=1}^N \langle \hat{X}_k, e_j \rangle \phi_j(y_{k+1} - c_j)}.$$

Catatan 2.2.2 Dari persamaan di atas diperoleh bahwa penduga \hat{X}_{k+1} bergantung pada \hat{X}_k secara tidak linear.

2.3 Perubahan Ukuran Pada Model *Hidden Markov*

Misalkan $\omega(\cdot)$ adalah peubah acak yang terdefinisi pada (Ω, \mathcal{F}, P) dengan fungsi kepadatan $\phi(\omega)$ dan c, σ adalah konstanta yang diketahui. Diketahui $Y(\cdot) = c + \sigma \omega(\cdot)$.

Akan dikonstruksi ukuran peluang baru \bar{P} pada (Ω, \mathcal{F}) sedemikian sehingga:

- a. $\frac{d\bar{P}}{dP} = \lambda$
- b. Di bawah \bar{P} peubah acak y mempunyai fungsi kepadatan ϕ .

Karena

$$\begin{aligned} \bar{P}(Y \leq t) &= \int_{-\infty}^t \phi(y) dy = \int_{\Omega} I_{\{Y \leq t\}} d\bar{P} = \int_{\Omega} I_{\{Y \leq t\}} \lambda dP = \int_{\Omega} I_{\{\omega \leq \frac{t-c}{\sigma}\}} \lambda(\omega) \phi(\omega) d\omega \\ &= \int_{-\infty}^{\frac{t-c}{\sigma}} \lambda(\omega) \phi(\omega) d\omega = \int_{-\infty}^t \lambda(\omega) \phi(\omega) \frac{1}{\sigma} dy \end{aligned}$$

maka diperoleh $\phi(y) = \frac{\lambda(\omega)\phi(\omega)}{\sigma}$ atau $\lambda(\omega) = \frac{\sigma\phi(y)}{\phi(\omega)}$.

Pada (Ω, \mathcal{F}, P) proses observasi $\{Y_k\}$ mempunyai bentuk

$$Y_{k+1} = \langle c, X_k \rangle + \langle \sigma, X_k \rangle \omega_{k+1}$$

di mana $\{\omega_k\}$ bebas stokastik identik menyebar $N(0,1)$. Misalkan $\phi(\cdot)$ adalah fungsi kepadatan peluang $N(0,1)$ dan

$$\lambda_l = \frac{\langle \sigma, X_{l-1} \rangle \phi(y_l)}{\phi(\omega_l)}, \quad l \in \mathbb{N}; \quad \Lambda_0 = 1; \quad \Lambda_k = \prod_{l=1}^k \lambda_l, \quad k \geq 1.$$

Definisikan ukuran peluang \bar{P} pada (Ω, \mathcal{F}) sebagai berikut $\frac{d\bar{P}}{dP}\Big|_{G_k} = \Lambda_k$.

Eksistensi Λ_k dijamin oleh Teorema Radon-Nikodym dan eksistensi \bar{P} dijamin oleh Teorema Perluasan Kolmogorov (Wong and Hajek, 1985).

Lemma 2.3.1 (Elliot et. al. 1995) Di bawah \bar{P} , $\{Y_k\}$ adalah barisan peubah acak yang bebas stokastik identik menyebar $N(0,1)$.

Sebaliknya, dimulai dengan ukuran peluang \bar{P} pada (Ω, \mathcal{F}) , di mana di bawah \bar{P} berlaku:

- a. $\{X_k\}$ adalah rantai Markov dengan matriks transisi A sehingga $X_{k+1} = AX_k + V_{k+1}$, dengan $\bar{E}[V_{k+1} | \mathcal{F}_k] = 0$
- b. $\{Y_k\}$ adalah barisan peubah acak yang bebas stokastik identik menyebar $N(0,1)$ dan bebas dari X_k ,

akan dikonstruksi P dari \bar{P} sehingga di bawah P berlaku:

$$\omega_{k+1} = \frac{Y_{k+1} - \langle c, X_k \rangle}{\langle \sigma, X_k \rangle}, \quad k \in \mathbb{N} \quad (\langle \sigma, X_k \rangle \neq 0)$$

adalah barisan peubah acak yang bebas stokastik identik dan menyebar $N(0,1)$.

Untuk mengkonstruksi P dari \bar{P} , definisikan

$$\bar{\lambda}_l = \frac{1}{\lambda_l} = \frac{\phi(\omega_l)}{\langle \sigma, X_{l-1} \rangle \phi(y_l)}, \quad l \in \mathbb{N}; \quad \bar{\Lambda}_0 = 1; \quad \bar{\Lambda}_k = \prod_{l=1}^k \bar{\lambda}_l, \quad k \geq 1; \quad \frac{d\bar{P}}{dP}\Big|_{G_k} = \bar{\Lambda}_k.$$

Lemma 2.3.2 Di bawah P , $\{\omega_k\}$ adalah barisan peubah acak yang bebas stokastik identik menyebar $N(0,1)$.

Catatan 2.3.3 Untuk selanjutnya kita akan bekerja pada ruang peluang $(\Omega, \mathcal{F}, \bar{P})$.

3. PENDUGAAN PARAMETER

Sifat statistik model *Hidden* Markov ditentukan secara lengkap oleh himpunan parameter

$$\theta = \{(a_{ji}), 1 \leq i, j \leq N; c_i, 1 \leq i \leq N; \sigma_i, 1 \leq i \leq N\}.$$

Pada bagian ini dibahas proses pendugaan parameter tersebut menggunakan Algoritma EM (*Expectation maximization algorithm*).

3.1 Pendugaan Rekursif

Definisi 3.1.1 (Elliot et. al. 1995) Barisan peubah acak $\{\phi_k\}$ disebut *adapted*-G, atau *adapted* terhadap filtrasi $\{G_k\}$, apabila untuk setiap k , ϕ_k terukur-G_k.

Definisi 3.1.2 Jika $\{H_k\}$ adalah barisan peubah acak yang *adapted* terhadap $\{G_k\}$, definisikan $\gamma_k(H_k) := \bar{E}[\Lambda_k H_k | Y_k]$ dan $\hat{H}_k := E[H_k | Y_k]$.

Menurut Teorema Bayes bersyarat

$$\hat{H}_k := E[H_k | Y_k] = \frac{\bar{E}[\Lambda_k H_k | Y_k]}{\bar{E}[\Lambda_k | Y_k]} = \frac{\gamma_k(H_k)}{\gamma_k(1)},$$

sehingga

$$\hat{X}_0 = E[X_0 | Y_0] = \frac{\gamma_0(X_0)}{\gamma_0(1)} = \gamma_0(X_0)$$

karena $\gamma_0(1) = 1$.

Catatan 3.1.3 Pada proses pendugaan rekursif, $\gamma_0(X_0) = E[X_0]$ diambil sebagai nilai awal.

Lemma 3.1.4. (Elliot et. al. 1995)

Misalkan $\{H_k\}$ adalah barisan peubah acak bernilai skalar, maka

- a. $\gamma_k(H_k) = \langle \gamma_k(H_k X_k), \bar{1} \rangle$
- b. $\gamma_k(1) = \langle \gamma_k(X_k), \bar{1} \rangle$.

Catatan 3.1.5 Dari persamaan di atas diperoleh bahwa pendugaan $\gamma_{k+1}(H_{k+1})$ bergantung pada $\gamma_k(H_k X_k)$.

Definisi 3.1.6 Barisan peubah acak $\{\phi_k\}$ disebut *predictable* terhadap filtrasi $\{G_k\}$, apabila untuk setiap k , ϕ_k terukur-G_{k-1}.

Teorema 3.1.7 Misalkan $\{H_k\}$ adalah proses bernilai skalar yang *adapted* terhadap filtrasi $\{G_k\}$ dan mempunyai bentuk

- a. H_0 terukur-F₀
- b. $H_{k+1} = H_k + \alpha_{k+1} + \langle \beta_{k+1}, V_{k+1} \rangle + \delta_{k+1} f(y_{k+1}), \quad k \geq 1$

di mana

- $V_{k+1} = X_{k+1} - A X_k$
- f adalah fungsi bernilai skalar
- α, β, δ adalah proses yang *predictable*-G

- β adalah proses bernilai vektor berdimensi- N
maka

$$\begin{aligned} \gamma_{k+1}(H_{k+1}X_{k+1}) &:= \gamma_{k+1,k+1}(H_{k+1}) \\ &= \sum_{i=1}^N \left\{ \langle \gamma_k(H_k X_k), \Gamma^i(y_{k+1}) \rangle a_i + \gamma_k(\alpha_{k+1} \langle X_k, \Gamma^i(y_{k+1}) \rangle) a_i \right. \\ &\quad \left. + \gamma_k(\delta_{k+1} \langle X_k, \Gamma^i(y_{k+1}) \rangle) f(y_{k+1}) a_i + (\text{diag}(a_i) - a_i a_i^T) \gamma_k(\beta_{k+1} \langle X_k, \Gamma^i(y_{k+1}) \rangle) \right\} \\ &\quad \text{di } \phi\left(\frac{y_k - c_{(\cdot)}}{\sigma_{(\cdot)}}\right) \\ \text{manakita } a_i &= Ae_i \text{ dan } \Gamma^{(\cdot)}(y_k) := \frac{\sigma_{(\cdot)}}{\sigma_{(\cdot)}\phi(y_k)} e_{(\cdot)}. \end{aligned}$$

3.2 Penduga Parameter

3.2.1 Penduga untuk State

Teorema 3.2.1 (Elliott et. al. 1995)

$$\gamma_{k+1}(X_{k+1}) = \sum_{i=1}^N \langle \gamma_k(X_k), \Gamma^i(y_{k+1}) \rangle a_i. \quad (3.1)$$

Bukti:

Dengan mengambil $H_k = H_0 = 1$, $\alpha_k = 0$, $\beta_k = 0$ dan $\delta_k = 0$ pada Teorema 3.1.7

$$\text{diperoleh } \gamma_{k+1}(X_{k+1}) = \sum_{i=1}^N \langle \gamma_k(X_k), \Gamma^i(y_{k+1}) \rangle a_i.$$

Catatan 3.2.2 Persamaan (3.1) menunjukkan bahwa $\gamma_{k+1}(X_{k+1})$ bergantung pada $\gamma_k(X_k)$ secara linear.

3.2.2 Penduga untuk Number of Jumps

Jika rantai Markov melompat dari state e_r pada waktu ke- k , ke state e_s pada waktu ke- $k+1$, $1 \leq r, s \leq N$, maka $\langle X_k, e_r \rangle \langle X_{k+1}, e_s \rangle = 1$, sehingga banyaknya lompatan (*number of jumps*) dari state e_r ke state e_s pada waktu ke- $k+1$ adalah

$$\begin{aligned} J_{k+1}^{rs} &:= \sum_{n=1}^{k+1} \langle X_{n-1}, e_r \rangle \langle X_n, e_s \rangle \\ &= J_k^{rs} + \langle X_k, e_r \rangle \langle X_{k+1}, e_s \rangle \\ &= J_k^{rs} + \langle X_k, e_r \rangle \langle AX_k + V_{k+1}, e_s \rangle \\ &= J_k^{rs} + \{ \langle X_k, e_r \rangle \langle AX_k, e_s \rangle + \langle X_k, e_r \rangle \langle V_{k+1}, e_s \rangle \} \\ &= J_k^{rs} + \{ \langle X_k, e_r \rangle a_{sr} + \langle X_k, e_r \rangle \langle V_{k+1}, e_s \rangle \}. \end{aligned}$$

Teorema 3.2.2 (Elliott et. al. 1995)

$$\gamma_{k+1,k+1}(\mathbf{J}_{k+1}^{rs}) = \sum_{i=1}^N \left\langle \gamma_{k,k}(\mathbf{J}_k^{rs}), \Gamma^i(y_{k+1}) \right\rangle a_i + \left\langle \gamma_k(X_k), \Gamma^r(y_{k+1}) \right\rangle a_{sr} e_s. \quad (3.2)$$

Bukti: Dengan mengambil

$H_{k+1} = \mathbf{J}_{k+1}^{rs}$, $H_0 = 0$, $\alpha_{k+1} = \langle X_k, e_r \rangle a_{sr}$, $\beta_{k+1} = \langle X_k, e_r \rangle e_s$ dan $\delta_{k+1} = 0$ pada Teorema 3.1.7 diperoleh

$$\begin{aligned} \gamma_{k+1,k+1}(\mathbf{J}_{k+1}^{rs}) &= \sum_{i=1}^N \left\{ \left\langle \gamma_k(\mathbf{J}_k^{rs} X_k), \Gamma^i(y_{k+1}) \right\rangle a_i + \gamma_k \left(\langle X_k, e_r \rangle a_{sr} \langle X_k, \Gamma^i(y_{k+1}) \rangle \right) a_i \right. \\ &\quad \left. + 0 + (\text{diag}(a_i) - a_i a_i^T) \gamma_k \left(\langle X_k, e_r \rangle e_s \langle X_k, \Gamma^i(y_{k+1}) \rangle \right) \right\}. \end{aligned}$$

Sedangkan

$$\begin{aligned} \sum_{i=1}^N \gamma_k \left(\langle X_k, e_r \rangle a_{sr} \langle X_k, \Gamma^i(y_{k+1}) \rangle \right) a_i &= \sum_{i=1}^N \gamma_k \left(\langle X_k, e_r \rangle \langle X_k, \Gamma^i(y_{k+1}) \rangle \right) a_{sr} a_i \\ &= \gamma_k \left(\langle X_k, \Gamma^r(y_{k+1}) \rangle \right) a_{sr} a_r \end{aligned}$$

dan

$$\begin{aligned} \sum_{i=1}^N (\text{diag}(a_i) - a_i a_i^T) \gamma_k \left(\langle X_k, e_r \rangle e_s \langle X_k, \Gamma^i(y_{k+1}) \rangle \right) &= \sum_{i=1}^N \gamma_k \left(\langle X_k, e_r \rangle \langle X_k, \Gamma^i(y_{k+1}) \rangle \right) (\text{diag}(a_i) - a_i a_i^T) e_s \\ &= \gamma_k \left(\langle X_k, \Gamma^r(y_{k+1}) \rangle \right) (\text{diag}(a_r) - a_r a_r^T) e_s \\ &= \gamma_k \left(\langle X_k, \Gamma^r(y_{k+1}) \rangle \right) (a_{sr} e_s - a_{sr} a_r). \end{aligned}$$

Sehingga

$$\begin{aligned} \gamma_{k+1,k+1}(\mathbf{J}_{k+1}^{rs}) &= \sum_{i=1}^N \left\langle \gamma_k(\mathbf{J}_k^{rs} X_k), \Gamma^i(y_{k+1}) \right\rangle a_i + \gamma_k \left(\langle X_k, \Gamma^r(y_{k+1}) \rangle \right) a_{sr} e_s \\ &= \sum_{i=1}^N \left\langle \gamma_{k,k}(\mathbf{J}_{k+1}^{rs}), \Gamma^i(y_{k+1}) \right\rangle a_i + \left\langle \gamma_k(X_k), \Gamma^r(y_{k+1}) \right\rangle a_{sr} e_s. \end{aligned}$$

3.2.3 Penduga untuk *Occupation Time*

Banyaknya kejadian rantai Markov berada pada state e_r , $1 \leq r \leq N$ sampai waktu ke- k didefinisikan sebagai berikut.

$$O_{k+1}^r := \sum_{n=1}^{k+1} \langle X_{n-1}, e_r \rangle = O_k^{rs} + \langle X_k, e_r \rangle.$$

Teorema 3.2.3 (Elliott et. al. 1995)

$$\gamma_{k+1,k+1}(O_{k+1}^r) = \sum_{i=1}^N \left\langle \gamma_{k,k}(O_k^r), \Gamma^i(y_{k+1}) \right\rangle a_i + \left\langle \gamma_k(X_k), \Gamma^r(y_{k+1}) \right\rangle a_r. \quad (3.3)$$

Bukti: Dengan mengambil

$H_{k+1} = O_{k+1}^{rs}$, $H_0 = 0$, $\alpha_{k+1} = \langle X_k, e_r \rangle$, $\beta_{k+1} = 0$ dan $\delta_{k+1} = 0$ pada Teorema 3.1.7 diperoleh

$$\begin{aligned}\gamma_{k+1,k+1}(O_{k+1}^r) &= \sum_{i=1}^N \left\langle \gamma_k(O_k^r X_k), \Gamma^i(y_{k+1}) \right\rangle a_i + \gamma_k(\langle X_k, e_r \rangle \langle X_k, \Gamma^i(y_{k+1}) \rangle) a_i \\ &= \sum_{i=1}^N \left\langle \gamma_k(O_k^r X_k), \Gamma^i(y_{k+1}) \right\rangle a_i + \gamma_k(\langle X_k, \Gamma^r(y_{k+1}) \rangle) a_r \\ &= \sum_{i=1}^N \left\langle \gamma_{k,k}(O_k^r), \Gamma^i(y_{k+1}) \right\rangle a_i + \langle \gamma_k(X_k), \Gamma^r(y_{k+1}) \rangle a_r.\end{aligned}$$

3.2.4 Penduga untuk Proses Observasi

Untuk menduga parameter $\sigma = (\sigma_1, \sigma_2, \dots, \sigma_N)^T$ dan $c = (c_1, c_2, \dots, c_N)^T$ pada proses observasi $y_{k+1} = \langle c, X_k \rangle + \langle \sigma, X_k \rangle \omega_{k+1}$, definisikan

$$\begin{aligned}\tau_{k+1}^r(f) &:= \sum_{l=1}^{k+1} \langle X_{l-1}, e_r \rangle f(y_l) \quad 1 \leq r \leq N \\ &= \tau_k^r(f) + \langle X_k, e_r \rangle f(y_{k+1})\end{aligned}$$

di mana $f(y) = y$ atau $f(y) = y^2$.

Teorema 3.2.4 (Elliott et. al. 1995)

$$\gamma_{k+1,k+1}(\tau_{k+1}^r(f)) = \sum_{i=1}^N \left\langle \gamma_{k,k}(\tau_k^r(f)), \Gamma^i(y_{k+1}) \right\rangle a_i + \langle \gamma_k(X_k), \Gamma^r(y_{k+1}) \rangle f(y_{k+1}) a_r. \quad (3.4)$$

Bukti:

Dengan mengambil

$H_{k+1} = \tau_{k+1}^r(f)$, $H_0 = 0$, $\alpha_{k+1} = 0$, $\beta_{k+1} = 0$ dan $\delta_{k+1} = \langle X_k, e_r \rangle$ pada Teorema 3.1.7 diperoleh

$$\begin{aligned}\gamma_{k+1,k+1}(\tau_{k+1}^r(f)) &= \sum_{i=1}^N \left\langle \gamma_k(\tau_k^r(f) X_k), \Gamma^i(y_{k+1}) \right\rangle a_i + \gamma_k(\langle X_k, e_r \rangle \langle X_k, \Gamma^i(y_{k+1}) \rangle) f(y_{k+1}) a_i \\ &= \sum_{i=1}^N \left\langle \gamma_k(\tau_k^r(f) X_k), \Gamma^i(y_{k+1}) \right\rangle a_i + \gamma_k(\langle X_k, \Gamma^r(y_{k+1}) \rangle) f(y_{k+1}) a_r \\ &= \sum_{i=1}^N \left\langle \gamma_{k,k}(\tau_k^r(f)), \Gamma^i(y_{k+1}) \right\rangle a_i + \langle \gamma_k(X_k), \Gamma^r(y_{k+1}) \rangle f(y_{k+1}) a_r.\end{aligned}$$

3.3 Expectation Maximization Algorithm (Algoritma 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 $Y \subset G$. 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 3.3.1

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.

Model *Hidden Markov* yang akan diduga parameternya berbentuk

$$\begin{aligned} X_{k+1} &= AX_k + V_{k+1} \\ y_{k+1} &= \langle c, X_k \rangle + \langle \sigma, X_k \rangle \omega_{k+1} \quad k \in \aleph \end{aligned}$$

di mana V_{k+1} adalah martingale *increments* dan ω_k adalah peubah acak yang bebas stokastik identik menyebar $N(0,1)$. Parameter model diberikan oleh himpunan

$$\theta = \{(a_{ji}), 1 \leq i, j \leq N; c_i, 1 \leq i \leq N; \sigma_i, 1 \leq i \leq N\}$$

di mana $\sum_{i=1}^N a_{ji} = 1, 1 \leq i \leq N$.

Akan ditentukan himpunan parameter baru

$$\hat{\theta}(k) = \{(\hat{a}_{ji}(k)), 1 \leq i, j \leq N; \hat{c}_i(k), 1 \leq i \leq N; \hat{\sigma}_i(k), 1 \leq i \leq N\}$$

di mana $\sum_{i=1}^N \hat{a}_{ji}(k) = 1, 1 \leq i \leq N$ yang memaksimumkan *pseudolog-likelihood* bersyarat.

Untuk mengubah parameter a_{ji} menjadi $\hat{a}_{ji}(k)$ pada rantai Markov X , misalkan

$$\lambda_k = \prod_{r,s=1}^N \left[\frac{\hat{a}_{sr}(k)}{a_{sr}} \right]^{\langle X_k, e_s \rangle \langle X_{k-1}, e_r \rangle}$$

$$\Lambda_k = \prod_{l=1}^k \prod_{r,s=1}^N \left[\frac{\hat{a}_{sr}(k)}{a_{sr}} \right]^{\langle X_l, e_s \rangle \langle X_{l-1}, e_r \rangle}$$

dan definisikan peluang $P_{\hat{\theta}}$ sehingga

$$\left. \frac{dP_{\hat{\theta}}}{dP_{\theta}} \right|_{F_k} = \Lambda_k .$$

Lemma 3.3.2

Di bawah $P_{\hat{\theta}}$, jika $X_k = e_r$, maka $E_{\hat{\theta}}[\langle X_{k+1}, e_s \rangle | F_k] = \hat{a}_{sr}(k+1)$.

Teorema 3.3.3 (Elliott et. al. 1995)

$$\hat{a}_{sr}(k) = \frac{\hat{J}_k^{rs}}{\hat{O}_k^r} = \frac{\gamma_k \left(J_k^{rs} \right)}{\gamma_k \left(O_k^r \right)} . \quad (3.5)$$

Bukti: Berdasarkan definisi

$$\begin{aligned} \log \Lambda_k &= \log \left(\prod_{l=1}^k \prod_{r,s=1}^N \left[\frac{\hat{a}_{sr}(k)}{a_{sr}} \right]^{\langle X_l, e_s \rangle \langle X_{l-1}, e_r \rangle} \right) \\ &= \sum_{l=1}^k \sum_{r,s=1}^N \langle X_l, e_s \rangle \langle X_{l-1}, e_r \rangle (\log \hat{a}_{sr}(k) - \log a_{sr}) \\ &= \sum_{r,s=1}^N J_k^{rs} \log \hat{a}_{sr}(k) + R(a) \end{aligned}$$

di mana $R(a)$ tidak bergantung pada \hat{a} . Sehingga *pseudo-loglikelihood* bersyaratnya menjadi

$$E[\log \Lambda_k | Y_k] = \sum_{r,s=1}^N \hat{J}_k^{rs} \log \hat{a}_{sr}(k) + \hat{R}(a). \quad (3.6)$$

Parameter $\hat{a}_{sr}(k)$ harus memenuhi

$$\sum_{s=1}^N \hat{a}_{sr}(k) = 1$$

atau dalam bentuk dinamik

$$\sum_{l=1}^k \sum_{s=1}^N \langle X_{l-1}, e_r \rangle \hat{a}_{sr}(k) = k .$$

Bentuk dinamik di atas dapat dituliskan dalam bentuk bersyarat

$$\sum_{r,s=1}^N \hat{O}_k^r \hat{a}_{sr}(k) = k . \quad (3.7)$$

Masalah optimasinya sekarang menjadi memilih $\hat{a}_{sr}(k)$ yang memaksimumkan (3.7) dengan kendala (3.8). Definisikan fungsi Lagrange

$$L(\hat{a}, \lambda) = \sum_{r,s=1}^N \hat{J}_k^{rs} \log \hat{a}_{sr}(k) + \lambda \left(\sum_{r,s=1}^N \hat{O}_k^r \hat{a}_{sr}(k) - k \right)$$

Dari $\frac{\partial L}{\partial \lambda} = 0$ dan $\frac{\partial L}{\partial \hat{a}_{sr}(k)} = 0$ diperoleh

$$\sum_{r,s=1}^N \hat{O}_k^r \hat{a}_{sr}(k) = k \quad (3.8)$$

$$\frac{\hat{J}_k^{rs}}{\hat{a}_{sr}(k)} + \lambda \hat{O}_k^r = 0. \quad (3.9)$$

Dari persamaan (3.8) dan (3.9) diperoleh $\lambda = -1$. Dari persamaan (3.9) diperoleh

$$\hat{a}_{sr}(k) = \frac{\hat{J}_k^{rs}}{\hat{O}_k^r} = \frac{\gamma_k(\hat{J}_k^{rs})}{\gamma_k(1)} / \frac{\gamma_k(O_k^r)}{\gamma_k(1)} = \frac{\gamma_k(\hat{J}_k^{rs})}{\gamma_k(O_k^r)}.$$

Untuk mengubah parameter c_i menjadi $\hat{c}_i(k)$, misalkan

$$\lambda_{k+1}^*(X_k, y_{k+1}) = \exp \left(\frac{1}{2 \langle \sigma, X_k \rangle} \left\{ \langle c, X_k \rangle^2 - \langle \hat{c}, X_k \rangle^2 - 2y_{k+1} \langle c, X_k \rangle + 2y_{k+1} \langle \hat{c}, X_k \rangle \right\} \right)$$

$$\Lambda_k^* = \prod_{l=1}^k \lambda_l^*(X_{l-1}, y_l)$$

dan definisikan peluang P^* sehingga $\left. \frac{dP^*}{dP} \right|_{G_k} = \Lambda_k^*$.

Lemma 3.3.4

Di bawah P^* , $\{y_k - \langle \hat{c}, X_{k-1} \rangle\}$ $k \in \mathbb{N}$ adalah barisan peubah acak yang bebas stokastik identik menyebar $N(0, \sigma)$.

Bukti: Menurut Teorema Bayes bersyarat

$$\begin{aligned} P^*(y_{k+1} - \langle \hat{c}, X_k \rangle \leq t | G_k) &= E^*\left[I_{\{y_{k+1} - \langle \hat{c}, X_k \rangle \leq t\}} \middle| G_k \right] = \frac{E\left[\Lambda_{k+1}^* I_{\{y_{k+1} - \langle \hat{c}, X_k \rangle \leq t\}} \middle| G_k \right]}{E\left[\Lambda_{k+1}^* \middle| G_k \right]} \\ &= \frac{E\left[\Lambda_k^* \lambda_{k+1}^* I_{\{y_{k+1} - \langle \hat{c}, X_k \rangle \leq t\}} \middle| G_k \right]}{E\left[\Lambda_k^* \lambda_{k+1}^* \middle| G_k \right]} = \frac{\Lambda_k^* E\left[\lambda_{k+1}^* I_{\{y_{k+1} - \langle \hat{c}, X_k \rangle \leq t\}} \middle| G_k \right]}{\Lambda_k^* E\left[\lambda_{k+1}^* \middle| G_k \right]} = \frac{E\left[\lambda_{k+1}^* I_{\{y_{k+1} - \langle \hat{c}, X_k \rangle \leq t\}} \middle| G_k \right]}{E\left[\lambda_{k+1}^* \middle| G_k \right]}. \end{aligned}$$

Di bawah P , $y_{k+1} - \langle c, X_k \rangle = \langle c, X_k \rangle \omega_{k+1}$ dengan ω_{k+1} menyebar $N(0,1)$, sehingga $y_{k+1} - \langle c, X_k \rangle$ menyebar $N(\langle c, X_k \rangle, \langle \sigma, X_k \rangle)$. Jadi

$$\begin{aligned} E\left[\lambda_{k+1}^* \middle| G_k \right] &= \int_{-\infty}^{\infty} \exp\left(\frac{1}{2\langle \sigma, X_k \rangle} \left\{ \langle c, X_k \rangle^2 - \langle \hat{c}, X_k \rangle^2 - 2y_{k+1} \langle c, X_k \rangle + 2y_{k+1} \langle \hat{c}, X_k \rangle \right\} \right) \\ &\quad \times \frac{1}{\sqrt{2\pi\langle \sigma, X_k \rangle}} \exp\left(-\frac{1}{2\langle \sigma, X_k \rangle} \{y_{k+1} - \langle c, X_k \rangle\}^2 \right) dy_{k+1} \\ &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\langle \sigma, X_k \rangle}} \exp\left(-\frac{1}{2\langle \sigma, X_k \rangle} \{y_{k+1} - \langle \hat{c}, X_k \rangle\}^2 \right) dy_{k+1} = 1. \end{aligned}$$

Sehingga

$$\begin{aligned} P^*(y_{k+1} - \langle \hat{c}, X_k \rangle \leq t | G_k) &= E\left[\lambda_{k+1}^* I_{\{y_{k+1} - \langle \hat{c}, X_k \rangle \leq t\}} \middle| G_k \right] \\ &= \int_{-\infty}^{\infty} \exp\left(\frac{1}{2\langle \sigma, X_k \rangle} \left\{ \langle c, X_k \rangle^2 - \langle \hat{c}, X_k \rangle^2 - 2y_{k+1} \langle c, X_k \rangle + 2y_{k+1} \langle \hat{c}, X_k \rangle \right\} \right) \\ &\quad \times \frac{1}{\sqrt{2\pi\langle \sigma, X_k \rangle}} \exp\left(-\frac{1}{2\langle \sigma, X_k \rangle} \{y_{k+1} - \langle c, X_k \rangle\}^2 \right) I_{\{y_{k+1} \leq t + \langle \hat{c}, X_k \rangle\}} dy_{k+1} \\ &= \int_{-\infty}^{t - \langle \hat{c}, X_k \rangle} \frac{1}{\sqrt{2\pi\langle \sigma, X_k \rangle}} \exp\left(-\frac{1}{2\langle \sigma, X_k \rangle} \{y_{k+1} - \langle \hat{c}, X_k \rangle\}^2 \right) dy_{k+1} \\ &= \int_{-\infty}^t \frac{1}{\sqrt{2\pi\langle \sigma, X_k \rangle}} \exp\left(-\frac{1}{2\langle \sigma, X_k \rangle} u^2 \right) du \\ &= P^*(U \leq t) \\ &= P^*(y_{k+1} - \langle \hat{c}, X_k \rangle \leq t). \end{aligned}$$

Teorema 3.3.5 (Elliott et. al. 1995)

$$\hat{c}_r(k) = \frac{\hat{\tau}_k^r(y)}{\hat{O}_k^r} = \frac{\gamma_k(\tau_k^r(y))}{\gamma_k(O_k^r)}. \quad (3.10)$$

Bukti: Dari definisi

$$\begin{aligned}
\log \Lambda_k^* &= \sum_{l=1}^k \frac{\langle c, X_{l-1} \rangle^2 - \langle \hat{c}, X_{l-1} \rangle^2 - 2y_l \langle c, X_{l-1} \rangle + 2y_l \langle \hat{c}, X_{l-1} \rangle}{2 \langle \sigma, X_{l-1} \rangle} \\
&= \sum_{l=1}^k \sum_{r=1}^N \frac{\langle X_{l-1}, e_r \rangle (c_r^2 - \hat{c}_r^2(k) - 2y_l c_r + 2y_l \hat{c}_r(k))}{2\sigma_r} \\
&= \sum_{r=1}^N \frac{2\hat{\tau}_k^r(y) \hat{c}_r(k) - O_k^r \hat{c}_r^2(k)}{2\sigma_r} + R(c)
\end{aligned}$$

di mana $R(c)$ tidak bergantung pada \hat{c} .

Jadi

$$E[\log \Lambda_k^* | Y_k] = \sum_{r=1}^N \frac{2\hat{\tau}_k^r(y) \hat{c}_r(k) - \hat{O}_k^r \hat{c}_r^2(k)}{2\sigma_r} + \hat{R}(c)$$

sehingga

$$\frac{d}{d\hat{c}_r(k)} E[\log \Lambda_k^* | Y_k] = \frac{2\hat{\tau}_k^r(y) - 2\hat{O}_k^r \hat{c}_r(k)}{2\sigma_r} = 0$$

memberikan

$$\begin{aligned}
2\hat{\tau}_k^r(y) - 2\hat{O}_k^r \hat{c}_r(k) &= 0 \\
\hat{c}_r(k) &= \frac{\hat{\tau}_k^r(y)}{\hat{O}_k^r} = \frac{\gamma_k(\tau_k^r(y))}{\gamma_k(1)} / \frac{\gamma_k(O_k^r)}{\gamma_k(1)} = \frac{\gamma_k(\tau_k^r(y))}{\gamma_k(O_k^r)}.
\end{aligned}$$

Untuk mengubah parameter σ_i menjadi $\hat{\sigma}_i(k)$ (ambil c_i tetap), definisikan

$$\tilde{\lambda}_{k+1}(X_k, y_{k+1}) = \sqrt{\frac{\langle \sigma, X_k \rangle}{\langle \hat{\sigma}, X_k \rangle}} \frac{\exp\left(\frac{1}{2\langle \hat{\sigma}, X_k \rangle} \{y_{k+1} - \langle c, X_k \rangle\}^2\right)}{\exp\left(\frac{1}{2\langle \sigma, X_k \rangle} \{y_{k+1} - \langle c, X_k \rangle\}^2\right)}$$

$$\tilde{\Lambda}_k = \prod_{l=1}^k \tilde{\lambda}_l(X_{l-1}, y_l)$$

dan definisikan peluang \tilde{P} sehingga $\frac{d\tilde{P}}{dP}\Big|_{G_k} = \tilde{\Lambda}_k$.

Teorema 3.3.6 (Elliott et. al. 1995)

$$\hat{\sigma}_i(k) = \frac{\hat{\tau}_k^i(y^2) - 2c_i \hat{\tau}_k^i(y) + c_i^2 \hat{O}_k^i}{\hat{O}_k^i} = \frac{\gamma_k(\tau_k^i(y^2)) - 2c_i \gamma_k(\tau_k^i(y)) + c_i^2 \gamma_k(O_k^i)}{\gamma_k(O_k^i)} . \quad (3.11)$$

Bukti: Dari definisi

$$\log \tilde{\Lambda}_k = \sum_{l=1}^k -\frac{1}{2} \log \langle \hat{\sigma}, X_{l-1} \rangle - \frac{(y_l - \langle c, X_{l-1} \rangle)^2}{2 \langle \hat{\sigma}, X_{l-1} \rangle} + R(c, \sigma)$$

di mana $R(c, \sigma)$ tidak bergantung pada $\hat{\sigma}$. Karena

$$\begin{aligned} E[\log \tilde{\Lambda}_k | Y_k] &= E\left[\sum_{l=1}^k \sum_{i=1}^N -\frac{1}{2} \langle X_{l-1}, e_i \rangle \log \hat{\sigma}_i(k) - \frac{\langle X_{l-1}, e_i \rangle}{2\hat{\sigma}_i(k)} + (y_l^2 - 2y_l c_i + c_i^2) \middle| Y_k\right] + \hat{R}(c, \sigma) \\ &= -\frac{1}{2} \sum_{i=1}^N \left\{ \hat{O}_k^i \log \hat{\sigma}_i(k) + \frac{1}{\hat{\sigma}_i(k)} (\hat{\tau}_k^i(y^2) - 2c_i \hat{\tau}_k^i(y) + c_i^2 \hat{O}_k^i) \right\} + \hat{R}(c, \sigma), \end{aligned}$$

maka

$$\frac{d}{d\hat{\sigma}_i(k)} E[\log \tilde{\Lambda}_k | Y_k] = \frac{1}{2} \left\{ -\frac{\hat{O}_k^i}{\hat{\sigma}_i(k)} + \frac{1}{\hat{\sigma}_i(k)} (\hat{\tau}_k^i(y^2) - 2c_i \hat{\tau}_k^i(y) + c_i^2 \hat{O}_k^i) \right\} = 0$$

memberikan

$$\frac{\hat{O}_k^i}{\hat{\sigma}_i(k)} = \frac{1}{\hat{\sigma}_i^2(k)} (\hat{\tau}_k^i(y^2) - 2c_i \hat{\tau}_k^i(y) - c_i^2 \hat{O}_k^i)$$

atau

$$\begin{aligned} \hat{\sigma}_i(k) &= \frac{\hat{\tau}_k^i(y^2) - 2c_i \hat{\tau}_k^i(y) - c_i^2 \hat{O}_k^i}{\hat{O}_k^i} = \frac{\frac{\gamma_k(\tau_k^i(y^2))}{\gamma_k(1)} - 2c_i \frac{\gamma_k(\tau_k^i(y))}{\gamma_k(1)} - c_i^2 \frac{\gamma_k(O_k^i)}{\gamma_k(1)}}{\frac{\gamma_k(O_k^i)}{\gamma_k(1)}} \\ &= \frac{\gamma_k(\tau_k^i(y^2)) - 2c_i \gamma_k(\tau_k^i(y)) - c_i^2 \gamma_k(O_k^i)}{\gamma_k(O_k^i)}. \end{aligned}$$

Catatan 3.3.7 Berdasarkan observasi sampai waktu ke- k , parameter model yang baru yaitu $(\hat{a}_{ji}(k)), 1 \leq i, j \leq N; \hat{c}_i(k), 1 \leq i \leq N; \hat{\sigma}_i(k), 1 \leq i \leq N$ diberikan oleh persamaan (3.5), (3.10) dan (3.11). Nilai $\gamma_k(J_k^{rs}), \gamma_k(O_k^{rs}), \gamma_k(\tau_k^r(y)), \gamma_k(\tau_k^r(y^2))$ dan $\gamma_k(X_k)$ kemudian dapat dihitung kembali menggunakan parameter yang baru dan data pengamatan yang baru.

4. ALGORITMA MENDUGA PARAMETER MODEL

Diketahui parameter berbentuk

$$\theta = \{(a_{ji}), 1 \leq i, j \leq N; c_i, 1 \leq i \leq N; \sigma_i, 1 \leq i \leq N\}.$$

Akan ditentukan parameter

$$\hat{\theta}(k) = \{(\hat{a}_{ji}(k)), 1 \leq i, j \leq N; \hat{c}_i(k), 1 \leq i \leq N; \hat{\sigma}_i(k), 1 \leq i \leq N\}$$

yang memaksimumkan *pseudo-loglikelihood* bersyarat seperti pada bagian 3. Algoritma untuk memperoleh parameter tersebut adalah sebagai berikut.

Algoritma untuk menentukan parameter $\hat{\theta}(k)$

Langkah 1: Tetapkan N (banyaknya state)

M (banyak data)

Input data $\{y_k\}$.

Langkah 2: Tetapkan Nilai awal

$$\pi = (\pi_i)_{N \times 1}$$

$$A = (a_{ji})_{N \times N}$$

$$c = (c_i)_{N \times 1}$$

$$\sigma = (\sigma_i)_{N \times 1}.$$

Catatan: $\pi = E[X_0]$ dan memenuhi $A\pi = \pi$

Langkah 3: Lakukan untuk $l = 0$ sampai dengan M

1. Tetapkan

$$a_i = Ae_i$$

$$\gamma_0(X_0) = \pi$$

$$\gamma_0(J_{0 \ r}^{rs}) = 0$$

$$\gamma_0(O_0^r) = 0$$

$$\gamma_0(\tau_0(y)) = 0$$

$$\gamma_0(\tau_0(y^2)) = 0.$$

2. Lakukan untuk $k = 0$ sampai dengan $l - 1$

- a. Hitung penduga rekursif

$$\gamma_{k+1}(X_{k+1}) = \sum_{i=1}^N \langle \gamma_k(X_k), \Gamma^i(y_{k+1}) \rangle a_i$$

$$\gamma_{k+1,k+1}(J_{k+1}^{rs}) = \sum_{i=1}^N \langle \gamma_{k,k}(J_k^{rs}), \Gamma^i(y_{k+1}) \rangle a_i + \langle \gamma_k(X_k), \Gamma^r(y_{k+1}) \rangle a_s e_s$$

$$\gamma_{k+1}(J_{k+1}^{rs}) = \langle \gamma_{k+1,k+1}(J_{k+1}^{rs}), \bar{1} \rangle$$

$$\gamma_{k+1,k+1}(O_{k+1}^r) = \sum_{i=1}^N \langle \gamma_{k,k}(O_k^r), \Gamma^i(y_{k+1}) \rangle a_i + \langle \gamma_k(X_k), \Gamma^r(y_{k+1}) \rangle a_r$$

$$\gamma_{k+1}(O_{k+1}^r) = \langle \gamma_{k+1,k+1}(O_{k+1}^r), \bar{1} \rangle$$

$$\gamma_{k+1,k+1}(\tau_{k+1}^r(y)) = \sum_{i=1}^N \langle \gamma_{k,k}(\tau_k^r(y)), \Gamma^i(y_{k+1}) \rangle a_i + \langle \gamma_k(X_k), \Gamma^r(y_{k+1}) \rangle y_{k+1} a_r$$

$$\gamma_{k+1}(\tau_{k+1}^r(y)) = \langle \gamma_{k+1,k+1}(\tau_{k+1}^r(y)), \bar{1} \rangle$$

$$\gamma_{k+1,k+1}(\tau_{k+1}^r(y^2)) = \sum_{i=1}^N \langle \gamma_{k,k}(\tau_{k+1}^r(y^2)), \Gamma^i(y_{k+1}) \rangle a_i + \langle \gamma_k(X_k), \Gamma^r(y_{k+1}) \rangle y_{k+1}^2 a_r$$

$$\gamma_{k+1}(\tau_{k+1}^r(y^2)) = \langle \gamma_{k+1,k+1}(\tau_{k+1}^r(y^2)), \bar{1} \rangle.$$

- b. Hitung penduga parameter

$$\hat{a}_{sr}(k+1) = \frac{\gamma_{k+1}(J_{k+1}^{rs})}{\gamma_{k+1}(O_{k+1}^r)}$$

$$\hat{c}_r(k+1) = \frac{\gamma_{k+1}(\tau_{k+1}^r(y))}{\gamma_{k+1}(O_{k+1}^r)}$$

$$\hat{\sigma}_i(k+1) = \frac{\gamma_{k+1}(\tau_{k+1}^i(y^2)) - 2c_i \gamma_{k+1}(\tau_{k+1}^i(y)) + c_i^2 \gamma_{k+1}(O_{k+1}^i)}{\gamma_{k+1}(O_{k+1}^i)}.$$

- c. Tuliskan

$$\begin{aligned}\hat{A}(k+1) &= (\hat{a}_{sr}(k+1)) \\ \hat{c}(k+1) &= (\hat{c}_r(k+1)) \\ \hat{\sigma}(k+1) &= (\hat{\sigma}_i(k+1)).\end{aligned}$$

d. Tentukan

$$\hat{\pi}(k+1) \text{ dari persamaan } \hat{A}(k+1)\hat{\pi}(k+1) = \hat{\pi}(k+1).$$

e. Ulangi langkah a sampai dengan d untuk k berikutnya.

3. Beri nilai

$$\begin{aligned}A &\leftarrow \hat{A}(k) \\ c &\leftarrow \hat{c}(k) \\ \sigma &\leftarrow \hat{\sigma}(k).\end{aligned}$$

3. Ulangi langkah 1 s/d 3 untuk l berikutnya.

Langkah 4: Untuk $k = 1$ sampai dengan M , cetak

$$\hat{A}(k), \hat{\pi}(k), \hat{c}(k), \hat{\sigma}(k), \gamma_k(X_k)$$

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]. Elliot, R. J., Aggoun, L. dan Moore, J. B. 1995. *Hidden Markov models*, Springer Verlag, New York.
- [3]. Wong, E and Hajek, B. 1985. *Stochastic Process in Engineering System*. Springer Verlag, Berlin.