

BAB II

LANDASAN TEORI

Bab ini membahas beberapa pengertian dasar yang diperlukan pada pembahasan bab-bab berikutnya, yaitu mengenai teorema Bayes, metode maksimum likelihood, algoritma EM (*Expectation-Maximization*), dan uji rasio likelihood.

2.1 Teorema Bayes

Misalkan B_1, B_2, \dots, B_T merupakan partisi dari ruang sampel S , $B_i \neq \emptyset, i = 1, 2, \dots, T$, yang bersifat:

- $B_1 \cup B_2 \cup \dots \cup B_T = S$
- $B_i \cap B_j = \emptyset$, untuk $i \neq j$.

Misalkan A adalah sembarang kejadian yang merupakan himpunan bagian S , yang bersifat $P(A) \neq 0$. Kejadian A dapat dipandang sebagai gabungan kejadian-kejadian $B_1 \cap A, B_2 \cap A, \dots, B_T \cap A$ yang saling terpisah satu sama lain.

$$A = (B_1 \cap A) \cup (B_2 \cap A) \cup \dots \cup (B_T \cap A) \quad (2.1.1)$$

Karena $B_1 \cap A, B_2 \cap A, \dots, B_T \cap A$ merupakan himpunan-himpunan yang saling lepas, maka probabilitas kejadian A dapat dituliskan sebagai berikut:

$$\begin{aligned} P(A) &= P[(B_1 \cap A) \cup (B_2 \cap A) \cup \dots \cup (B_T \cap A)] \\ &= P(B_1 \cap A) + P(B_2 \cap A) + \dots + P(B_T \cap A) \\ &= P(B_1)P(A|B_1) + P(B_2)P(A|B_2) + \dots + P(B_T)P(A|B_T) \quad (2.1.2) \\ &= \sum_{i=1}^T P(B_i)P(A|B_i) \end{aligned}$$

Kemudian, menurut definisi peluang bersyarat diketahui bahwa:

$$\begin{aligned} P(B_r | A) &= \frac{P(B_r \cap A)}{P(A)} \\ &= \frac{P(B_r)P(A|B_r)}{P(A)} \end{aligned} \quad (2.1.3)$$

Dengan mensubstitusikan persamaan (2.1.2) ke persamaan (2.1.3), didapatkan:

$$P(B_r | A) = \frac{P(B_r)P(A|B_r)}{\sum_{i=1}^T P(B_i)P(A|B_i)} \quad (2.1.4)$$

Jadi, dapat dinyatakan jika terdapat kejadian-kejadian B_1, B_2, \dots, B_T merupakan partisi dari ruang sample S dengan $B_i \neq \emptyset, i = 1, 2, \dots, T$, maka untuk sembarang kejadian A, dengan $P(A) \neq 0$, berlaku:

$$P(B_r | A) = \frac{P(B_r)P(A|B_r)}{\sum_{i=1}^T P(B_i)P(A|B_i)}$$

untuk $r = 1, 2, \dots, T$

2.2 Taksiran Maksimum Likelihood

Misalkan X_1, X_2, \dots, X_n adalah suatu sampel random berukuran n dari suatu distribusi dengan pdf $f(X; \theta)$, yang bergantung pada $\theta \in \Omega$, Ω disebut ruang parameter. Karena X_1, X_2, \dots, X_n merupakan sample random, pdf bersama dari X_1, X_2, \dots, X_n dapat dinyatakan sebagai:

$$f(X_1, X_2, \dots, X_n; \theta) = f(X_1; \theta) \cdot f(X_2; \theta) \cdots f(X_n; \theta) \quad (2.2.1)$$

Pdf bersama dari X_1, X_2, \dots, X_n mengandung parameter θ , sehingga persamaan (2.2.1) dapat dituliskan sebagai suatu fungsi dari θ , sebut $L(\theta)$.

$$\begin{aligned} L(\theta) &= f(X_1, X_2, \dots, X_n; \theta) \\ &= f(X_1; \theta) \cdot f(X_2; \theta) \cdots f(X_n; \theta) \\ &= \prod_{i=1}^n f(X_i; \theta) \end{aligned} \quad (2.2.2)$$

$L(\theta)$ disebut fungsi *likelihood*.

Akan dicari θ yang memaksimumkan $L(\theta)$. Untuk mempermudah perhitungan dalam mencari nilai θ , $L(\theta)$ dapat dimodifikasi ke dalam bentuk \ln , karena nilai θ yang memaksimumkan $\ln L(\theta)$ sama dengan nilai θ yang memaksimumkan $L(\theta)$.

Sehingga persamaan (2.2.2) dapat dimodifikasi menjadi:

$$\begin{aligned}\ln L(\theta) &= \ln \left(\prod_{i=1}^n f(X_i; \theta) \right) \\ &= \sum_{i=1}^n \ln f(X_i; \theta)\end{aligned}\tag{2.2.3}$$

Nilai θ yang memaksimumkan $\ln L(\theta)$, diperoleh dengan mendiferensialkan $\ln L(\theta)$ terhadap θ dan menyamakannya dengan 0.

Nilai $\theta = u(X_1, X_2, \dots, X_n)$ yang memaksimumkan $\ln L(\theta)$ disebut sebagai taksiran *maximum likelihood* dari θ dan dinotasikan dengan $\hat{\theta}$.

2.3 Algoritma EM (*Expectation-Maximization*)

Algoritma EM merupakan suatu algoritma yang bersifat iteratif yang dapat digunakan untuk mencari MLE dimana salah satu variabel dalam model merupakan variabel laten. Misalkan X adalah suatu variabel laten dan Y_1, Y_2, \dots, Y_n adalah *observed variable*, yang mempunyai joint pdf $p(\mathbf{y}, \theta)$.

Misalkan $L(\mathbf{y}, \theta)$ adalah fungsi log likelihood dari \mathbf{Y} .

$$L(\mathbf{y}, \theta) = \log [p(\mathbf{y}, \theta)]\tag{2.3.1}$$

Misalkan $p(\mathbf{y}, x, \theta)$ adalah pdf bersama dari \mathbf{Y} dan X , dengan θ adalah parameter dalam model. Karena, seperti yang telah dinyatakan pada pemisalan awal, X adalah variabel laten, maka salah satu cara untuk mencari

taksiran θ yang memaksimalkan fungsi likelihood dari \mathbf{Y} adalah dengan menggunakan algoritma EM.

Prinsip dari algoritma EM dapat dijelaskan menjadi 2 bagian sebagai berikut:

1) *E-Step*

E-step dilakukan untuk mencari $E[\log[p(x, y, \theta_t)] | y, \hat{\theta}_{t-1}]$, dimana:

$\hat{\theta}_{t-1}$ adalah taksiran θ pada iterasi ke-($t-1$).

θ_t adalah nilai θ pada iterasi ke-(t).

θ_0 adalah suatu nilai taksiran awal yang diberikan.

2) *M-Step*

Pada *M-step*, maksimumkan $E[\log[p(x, y, \theta_t)] | y, \hat{\theta}_{t-1}]$ terhadap θ_t

untuk mendapatkan taksiran θ_t pada iterasi ke-(t), sebut $\hat{\theta}_t$.

Proses *E-step* dan *M-step* ini akan dilakukan terus secara iteratif sampai didapatkan suatu estimasi untuk θ yang konvergen atau $|\hat{\theta}_t - \hat{\theta}_{t-1}|$ cukup kecil.

Dapat ditunjukkan bahwa iterasi algoritma EM seperti yang dijelaskan melalui *E-step* dan *M-step* diatas akan meningkatkan nilai $L(y, \theta)$ pada setiap iterasinya.

Bukti:

Misalkan $q(x)$ adalah suatu pdf sebarang dari X , dimana $\sum_x q(x) = 1$. Maka

persamaan (2.3.1) dapat dituliskan sebagai:

$$\begin{aligned}
 L(\mathbf{y}, \theta) &= \log[p(\mathbf{y}, \theta)] \\
 &= \sum_x q(x) \log[p(\mathbf{y}, \theta)] \\
 &= \sum_x q(x) \log\left[\frac{p(\mathbf{y}, x, \theta)}{p(x|\mathbf{y}, \theta)} \times \frac{q(x)}{q(x)}\right] \\
 &= \sum_x q(x) \left\{ \log[p(\mathbf{y}, x, \theta)] - \log[q(x)] + \log\left[\frac{q(x)}{p(x|\mathbf{y}, \theta)}\right] \right\} \\
 &= \sum_x q(x) \log[p(x, \mathbf{y}, \theta)] - \sum_x q(x) \log[q(x)] + \sum_x q(x) \log\left[\frac{q(x)}{p(x|\mathbf{y}, \theta)}\right]
 \end{aligned} \tag{2.3.2}$$

Definisikan:

$$Q(q \| p_{\text{joint}}) = \sum_x q(x) \log[p(x, \mathbf{y}, \theta)] \tag{2.3.3}$$

$$H(q \| q) = -\sum_x q(x) \log[q(x)] \tag{2.3.4}$$

$$KL(q \| p_{\text{post}}) = \sum_x q(x) \log\left[\frac{q(x)}{p(x|\mathbf{y}, \theta)}\right] \tag{2.3.5}$$

Jadi, persamaan (2.3.1) dapat dituliskan kembali menjadi:

$$L(\mathbf{y}, \theta) = Q(q \| p_{\text{joint}}) + H(q \| q) + KL(q \| p_{\text{post}}) \tag{2.3.6}$$

Pandang persamaan (2.3.6), dapat dibuktikan bahwa bagian terakhir, KL, bersifat:

- a) $KL(q \parallel p_{\text{post}}) \geq 0 \quad \forall q$
- b) $\exists p$ sedemikian sehingga $KL(p \parallel p_{\text{post}}) = 0$ (2.3.7)

Bukti:

- a) Akan dibuktikan $KL(q \parallel p_{\text{post}}) \geq 0$

$$\begin{aligned} KL(q \parallel p_{\text{post}}) &= \sum_x q(x) \log \left[\frac{q(x)}{p(x | \mathbf{y}, \theta)} \right] \\ &= \sum_x q(x) \left(-\log \left[\frac{p(x | \mathbf{y}, \theta)}{q(x)} \right] \right) \end{aligned} \quad (2.3.8)$$

Berdasarkan pertidaksamaan Jensen, untuk f suatu fungsi konveks

$E[f(x)] \geq f(E[x])$, dan karena $-\log \left[\frac{p(x | \mathbf{y}, \theta)}{q(x)} \right]$ adalah suatu fungsi

konveks, maka berlaku:

$$\begin{aligned} E \left[-\log \left[\frac{p(x | \mathbf{y}, \theta)}{q(x)} \right] \right] &\geq -\log \left(E \left[\frac{p(x | \mathbf{y}, \theta)}{q(x)} \right] \right) \\ \sum_x q(x) \left(-\log \left[\frac{p(x | \mathbf{y}, \theta)}{q(x)} \right] \right) &\geq -\log \left(\sum_x q(x) \left[\frac{p(x | \mathbf{y}, \theta)}{q(x)} \right] \right) \end{aligned} \quad (2.3.9)$$

Berdasarkan (2.3.10) dan (2.3.8), maka $KL(q \parallel p)$ dapat dituliskan sebagai berikut:

$$\begin{aligned}
 KL(q \parallel p) &= \sum_x q(x) \log \left[\frac{q(x)}{p(x | \mathbf{y}, \theta)} \right] = \sum_x q(x) \left(-\log \left[\frac{p(x | \mathbf{y}, \theta)}{q(x)} \right] \right) \\
 &\geq -\log \left[\sum_x q(x) \left(\frac{p(x | \mathbf{y}, \theta)}{q(x)} \right) \right] \\
 &= -\log \left[\sum_x p(x | \mathbf{y}, \theta) \right] = -\log[1] \\
 &= 0
 \end{aligned} \tag{2.3.10}$$

Jadi, $KL(q \parallel p) \geq 0, \forall q$.

b) Akan dibuktikan $\exists p$ sedemikian sehingga $KL(p \parallel p_{\text{post}}) = 0$

Misal pilih $q(x) = p(x | \mathbf{y}, \theta)$, maka $\sum_x p(x | \mathbf{y}, \theta) = 1$, dan:

$$\begin{aligned}
 \log \left[\frac{q(x)}{p(x | \mathbf{y}, \theta)} \right] &= \log \left[\frac{p(x | \mathbf{y}, \theta)}{p(x | \mathbf{y}, \theta)} \right] \\
 &= \log[1] \\
 &= 0
 \end{aligned} \tag{2.3.11}$$

Maka $KL(q \parallel p_{\text{post}})$ sesuai dengan persamaan (2.3.5), dapat dituliskan

sebagai berikut:

$$\begin{aligned}
 KL(q \parallel p_{\text{post}}) &= \sum_x q(x) \log \left[\frac{q(x)}{p(x | \mathbf{y}, \theta)} \right] \\
 &= \sum_x p(x | \mathbf{y}, \theta) \times 0 \\
 &= 0
 \end{aligned}$$

Jadi, untuk $q(x) = p(x | \mathbf{y}, \theta)$, nilai $KL(q \parallel p_{\text{post}}) = 0$

Misal $q(x) = p(x | \mathbf{y}, \hat{\theta}_{t-1})$, maka $KL = 0$. Kemudian, sebut:

$$Q_{\hat{\theta}_{t-1}} = \sum_x p(x | \mathbf{y}, \hat{\theta}_{t-1}) \log [p(x, \mathbf{y}, \theta_t)] \quad (2.3.12)$$

$$H_{\hat{\theta}_{t-1}} = -\sum_x p(x | \mathbf{y}, \hat{\theta}_{t-1}) \log [p(x | \mathbf{y}, \hat{\theta}_{t-1})] \quad (2.3.13)$$

Dengan mensubstitusikan (2.3.13), dan (2.3.14) ke (2.3.6), maka berlaku:

$$\begin{aligned} L(\mathbf{y}, \theta_t) &= Q_{\hat{\theta}_{t-1}} + H_{\hat{\theta}_{t-1}} + 0 \\ &= Q_{\hat{\theta}_{t-1}} + H_{\hat{\theta}_{t-1}} \end{aligned} \quad (2.3.14)$$

dimana $H_{\hat{\theta}_{t-1}}$ tidak bergantung pada θ_t (seperti terlihat pada (2.3.13)).

Misalkan $\hat{\theta}_t$ adalah taksiran θ yang memaksimumkan $Q_{\theta_{t-1}}$, maka:

$$\begin{aligned} L(\mathbf{y}, \theta_t) &= Q_{\hat{\theta}_{t-1}} + H_{\hat{\theta}_{t-1}} \\ &\leq Q_{\hat{\theta}_t} + H_{\hat{\theta}_t} \\ &= L(\mathbf{y}, \theta_{t+1}) - KL_{\theta_t} \\ &= L(\mathbf{y}, \theta_{t+1}) - 0 \\ &= L(\mathbf{y}, \theta_{t+1}) \end{aligned} \quad (2.3.16)$$

Jadi, $L(\mathbf{y}, \theta_t) \leq L(\mathbf{y}, \theta_{t+1})$.

Jadi, terbukti bahwa dengan menggunakan algoritma EM akan didapatkan taksiran θ yang memaksimumkan fungsi likelihood dari \mathbf{Y} .

2.4 Uji Rasio Likelihood

Terdapat variabel random X_1, X_2, \dots, X_n yang memiliki pdf

$f_i(X_i; \theta_1, \theta_2, \dots, \theta_m)$ untuk $i = 1, 2, \dots, n$. Parameter-parameter dari populasi

$\theta_1, \theta_2, \dots, \theta_m$ dimisalkan berada pada ruang parameter Ω . Misalkan ω

merupakan subset dari Ω dan akan diuji hipotesis sebagai berikut:

$$H_0 : (\theta_1, \theta_2, \dots, \theta_m) \in \omega$$

H_1 : tidak demikian

Definisikan fungsi likelihood sebagai berikut:

- Sebut joint pdf dari X_1, X_2, \dots, X_n pada saat $(\theta_1, \theta_2, \dots, \theta_m) \in \omega$:

$$L(\omega)$$

- Sebut joint pdf dari X_1, X_2, \dots, X_n pada saat $(\theta_1, \theta_2, \dots, \theta_m) \in \Omega$:

$$L(\Omega)$$

Pandang rasio likelihood dari kedua fungsi likelihood sebagai berikut:

$$\lambda^* = \frac{L(\omega)}{L(\Omega)}$$

Nilai λ^* tidak dapat digunakan sebagai statistik uji untuk menguji H_0 dan H_1

karena nilai $L(\omega)$ dan $L(\Omega)$ biasanya tidak dapat ditetapkan dengan

lengkap, Misalkan $\hat{\omega}$ merupakan taksiran maksimum likelihood untuk ω dan

$\hat{\Omega}$ merupakan taksiran maksimum likelihood untuk Ω .

Pandang:

$$\lambda(x_1, x_2, \dots, x_n) = \lambda = \frac{L(\hat{\omega})}{L(\hat{\Omega})}$$

Nilai λ dapat dicari. λ dapat digunakan sebagai statistik uji untuk menguji H_0 dan H_1 .

Perhatikan $\lambda = \frac{L(\hat{\omega})}{L(\hat{\Omega})}$.

$L(\hat{\omega})$ dan $L(\hat{\Omega})$ bernilai positif sehingga λ juga akan bernilai positif, atau $\lambda \geq 0$. Kemudian karena $\hat{\omega}$ adalah subset dari $\hat{\Omega}$, maka $L(\hat{\omega}) \leq L(\hat{\Omega})$.

Karena $L(\hat{\omega}) \leq L(\hat{\Omega})$, maka nilai $\lambda \leq 1$. Jadi, diperoleh $0 \leq \lambda = \frac{L(\hat{\omega})}{L(\hat{\Omega})} \leq 1$.

Apabila $\lambda = 0$ maka $L(\hat{\omega}) = 0$, H_0 ditolak.

Jadi, H_0 akan ditolak apabila λ bernilai kecil (mendekati 0).

Misalkan λ_0 adalah suatu bilangan positif sedemikian sehingga

$H_0 : (\theta_1, \theta_2, \dots, \theta_m) \in \omega$ akan ditolak apabila $\lambda(x_1, x_2, \dots, x_n) = \lambda \leq \lambda_0$.

Misalkan α adalah tingkat signifikansi yang dipakai dalam pengujian.

$$\alpha = \Pr[\lambda(x_1, x_2, \dots, x_n) \leq \lambda_0; H_0].$$

Jika pdf dari statistik $\lambda = \lambda(X_1, X_2, \dots, X_n)$ dapat diketahui untuk H_0 benar, λ_0

dapat ditentukan, sedemikian sehingga $\alpha = \Pr[\lambda(x_1, x_2, \dots, x_n) \leq \lambda_0; H_0]$.

Namun, seringkali, di bawah H_0 benar, sulit untuk menentukan distribusi dari

$\lambda = \lambda(X_1, X_2, \dots, X_n)$. Oleh karena itu tidak mungkin untuk menemukan λ_0 sedemikian sehingga $\alpha = \Pr[\lambda(x_1, x_2, \dots, x_n) \leq \lambda_0; H_0]$.

Karena distribusi dari statistik $\lambda = \lambda(X_1, X_2, \dots, X_n)$ sulit ditentukan, maka dicari statistik uji lain yaitu $L^2 = -2 \ln \lambda$ (log rasio likelihood). Dapat dibuktikan bahwa $-2 \ln \lambda$ akan berdistribusi χ^2_r , dimana $r = \text{dimensi } \Omega - \text{dimensi } \omega$.

