

BAB III
PENDEKATAN BAYESIAN PADA REGRESI LINEAR

3.1 Pendekatan Bayesian Pada Regresi Linear

Pada model linear harus memenuhi asumsi normalitas yakni variabel acak y dan X berdistribusi normal sehingga parameter θ juga berdistribusi normal. Model linear berbentuk $y = X\theta + \varepsilon$. Diberikan parameter $\theta' = (\theta_1, \dots, \theta_n)$ vektor acak berukuran $p \times 1$, matriks X berukuran $n \times p$ diambil dari observasi x_1, \dots, x_n , vektor acak y berukuran $n \times 1$ dan variabel acak bebas $\varepsilon' = (\varepsilon_1, \dots, \varepsilon_n)$ yang berdistribusi normal, $N(0, \sigma^2)$.

Dalam mencari distribusi prior diperlukan fungsi *likelihood* dari parameter θ . Diketahui vektor $X\theta = E(y|\theta)$ sebagai nilai rata-rata dan matriks kovarians $D(y|\sigma^2) = \sigma^2 P^{-1}$ di mana P merupakan matriks definit positif.

Misalkan $(y|\theta, \sigma^2) \sim N(X\theta, \sigma^2 P^{-1})$ dan σ^2 merupakan parameter yang tidak diketahui. Didefinisikan $\tau = \sigma^{-2}$. Karena $(y|\theta, \sigma^2) \sim N(X\theta, \sigma^2 P^{-1})$ diperoleh $(\det \tau^{-1} P^{-1})^{-\frac{1}{2}} = (\det P)^{\frac{1}{2}} \tau^{\frac{n}{2}}$

Fungsi *likelihood*

$$p(y|\theta, \tau, C) = (2\pi)^{-\frac{n}{2}} (\det P)^{\frac{1}{2}} \tau^{\frac{n}{2}} \exp\left(-\frac{\tau}{2} (y - X\theta)' P (y - X\theta)\right) \\ \propto \tau^{\frac{n}{2}} \exp\left(-\frac{\tau}{2} (y - X\theta)' P (y - X\theta)\right) \quad (3.1)$$

Distribusi prior untuk θ dan τ adalah distribusi normal-gamma

$$\theta, \tau \sim \text{NG}(\mu, V, \alpha, b)$$

dimana $\theta|\tau \sim N(\mu, V)$ dan $\tau \sim G(\alpha, b)$

Fungsi kepadatan peluang dari distribusi prior adalah :

$$p(\theta, \tau|C) = \frac{1}{(2\pi)^{\frac{n}{2}} (\det V)^{\frac{1}{2}} \Gamma(b)} \alpha^b \tau^{\frac{n}{2} + b - 1} \exp\left(-\frac{\tau}{2} (2\alpha + (\theta - \mu)' V^{-1} (\theta - \mu))\right) \\ \propto \tau^{\frac{n}{2} + b - 1} \exp\left(-\frac{\tau}{2} (2\alpha + (\theta - \mu)' V^{-1} (\theta - \mu))\right) \quad (3.2)$$

Selanjutnya akan dicari distribusi posterior dari θ dan τ dengan mengoperasikan distribusi prior (3.2) dengan fungsi *likelihood* (3.1),

$$p(\theta, \tau|y, C) \propto p(\theta, \tau|C) \times p(y|\theta, \tau, C)$$

$$\begin{aligned}
&\propto \tau^{\frac{u}{2}+b-1} \exp\left(-\frac{\tau}{2}(2\alpha + (\theta - \mu)'V^{-1}(\theta - \mu))\right) \\
&\quad \tau^{\frac{n}{2}} \exp\left(-\frac{\tau}{2}(y - X\theta)'P(y - X\theta)\right) \\
&\propto \tau^{\frac{n}{2}+\frac{u}{2}+b-1} \exp\left(-\frac{\tau}{2}\left(2\alpha + (\theta - \mu)'V^{-1}(\theta - \mu) + \right.\right. \\
&\quad \left.\left.(y - X\theta)'P(y - X\theta)\right)\right) \quad (3.3)
\end{aligned}$$

Akan diuraikan $(2\alpha + (\theta - \mu)'V^{-1}(\theta - \mu) + (y - X\theta)'P(y - X\theta))$

$$\begin{aligned}
&(2\alpha + (\theta - \mu)'V^{-1}(\theta - \mu) + (y - X\theta)'P(y - X\theta)) \\
&\Leftrightarrow 2\alpha + \theta'V^{-1}\theta - \theta'V^{-1}\mu - \mu'V^{-1}\theta + \mu'V^{-1}\mu + y'Py - y'PX\theta \\
&\quad - \theta'X'Py + \theta'X'PX\theta \\
&\Leftrightarrow 2\alpha + y'Py + \mu'V^{-1}\mu - 2\theta'(X'Py + V^{-1}\mu) + \theta'(X'PX + V^{-1})\theta \\
&\Leftrightarrow 2\alpha + y'Py + \mu'V^{-1}\mu - \mu'_0(X'PX + V^{-1})\mu_0 \\
&\quad + (\theta - \mu_0)'(X'PX + V^{-1})(\theta - \mu_0) \\
&\Leftrightarrow 2\alpha + y'Py + \mu'V^{-1}\mu - 2\mu'_0(X'Py + V^{-1}\mu) + \mu'_0(X'PX + V^{-1})\mu_0 \\
&\quad + (\theta - \mu_0)'(X'PX + V^{-1})(\theta - \mu_0) \\
&\Leftrightarrow 2\alpha + y'Py + \mu'V^{-1}\mu - 2\mu'_0X'Py - 2\mu'_0V^{-1}\mu + \mu'_0X'PX\mu_0 + \mu'_0V^{-1}\mu_0 \\
&\quad + (\theta - \mu_0)'(X'PX + V^{-1})(\theta - \mu_0) \\
&\Leftrightarrow 2\alpha + (\mu - \mu_0)'V^{-1}(\mu - \mu_0) + (y - X\mu_0)'P(y - X\mu_0) \\
&\quad + (\theta - \mu_0)'(X'PX + V^{-1})(\theta - \mu_0) \quad (3.4)
\end{aligned}$$

Substitusikan Persamaan (3.4) kedalam Persamaan (3.3) sehingga diperoleh

$$\begin{aligned}
&\propto \tau^{\frac{n}{2}+\frac{u}{2}+b-1} \exp\left(-\frac{\tau}{2}\left[2\alpha + (\mu - \mu_0)'V^{-1}(\mu - \mu_0) + (y - X\mu_0)'P(y - X\mu_0)\right.\right. \\
&\quad \left.\left.+ (\theta - \mu_0)'(X'PX + V^{-1})(\theta - \mu_0)\right]\right) \\
&\propto \tau^{\frac{n}{2}} \exp\left\{-\frac{\tau}{2}\left[(\theta - \mu_0)'(X'PX + V^{-1})(\theta - \mu_0)\right]\right\} \\
&\quad \tau^{\frac{u}{2}+b-1} \exp\left\{-\frac{\tau}{2}\left[2\alpha + (\mu - \mu_0)'V^{-1}(\mu - \mu_0)\right.\right. \\
&\quad \left.\left.+ (y - X\mu_0)'P(y - X\mu_0)\right]\right\} \quad (3.5)
\end{aligned}$$

Distribusi posterior untuk θ dan τ pada (3.5) merupakan distribusi normal-gamma.

$$\theta, \tau \sim \text{NG}(\mu_0, V_0, \alpha_0, b_0)$$

dimana $\theta|\tau \sim \text{N}(\mu_0, V_0)$ dan $\tau \sim \text{G}(\alpha_0, b_0)$

dengan

$$\mu_0 = (X'PX + V^{-1})^{-1}(X'Py + V^{-1}\mu)$$

$$V_0 = (X'PX + V^{-1})^{-1}$$

$$a_0 = a + \frac{1}{2} [(\mu - \mu_0)'V^{-1}(\mu - \mu_0) + (y - X\mu_0)'P(y - X\mu_0)]$$

$$b_0 = \frac{1}{2}n + b$$

Selanjutnya distribusi posterior dari ε dapat diturunkan dengan bentuk $\varepsilon = y - X\theta$ dan diketahui bahwa ε merupakan fungsi linear dari parameter θ . De Groot (2004) menjelaskan bahwa distribusi ε akan singular hanya pada ruang p-dimensi.

Misalkan $H = X(R + X'X)^{-1}X$, maka distribusi posterior dari ε yang bersyarat τ akan menghasilkan distribusi normal multivariat singular dengan rata-rata $\hat{\varepsilon} = y - X\hat{\theta}$ dan matrik kovarians $\tau^{-1}H$.

Dengan memisalkan h_{ij} merupakan elemen-elemen dari H, maka setiap ε_i (untuk $i = 1, 2, \dots, n$) memiliki distribusi t dengan lokasi $\hat{\varepsilon}_i$, ketelitian $\frac{a_1}{b_1 h_{ii}}$ dan $2a_1$ sebagai derajat kebebasan. (DeGroot, 2004, hlm. 42). Matrik kovarians dari ε merupakan proporsi dari H.

Distribusi prior improper dari Zellner (1996) $p(\theta, \tau|C) = \tau^{-1}$, misalkan $R \rightarrow 0$, $a \rightarrow -\frac{1}{2}p$ dan $b \rightarrow 0$. Misalkan

$$\hat{\theta} = (X'X)^{-1}X'y, s^2 = \frac{(y - X\hat{\theta})'(y - X\hat{\theta})}{(n - p)}$$

Selanjutnya DeGroot (2004, hlm. 252) menunjukkan bahwa distribusi posterior dari ε merupakan distribusi t multivariate pada ruang p-dimensi dengan

$$\hat{\varepsilon} = y - X\hat{\theta}, H = X(X'X)^{-1}X, \quad a_1 = \frac{1}{2}(n - p), \quad b_1 = \frac{1}{2}(n - p)s^2$$

Untuk mendeteksi observasi yang merupakan pencilan, didefinisikan peluang p_i menjadi $pr(|\varepsilon_i| > k\sigma|y)$, peluang posterior pada observasi ke-i yang didefinisikan sebagai sebuah pencilan.

Misalkan $\Phi(z)$ merupakan fungsi distribusi normal standar dengan

$$z_1 = \frac{(k - \hat{\varepsilon}_i\sqrt{\tau})}{\sqrt{h_{ii}}}, \quad z_2 = \frac{(-k - \hat{\varepsilon}_i\sqrt{\tau})}{\sqrt{h_{ii}}} \quad (3.6)$$

Selanjutnya diperoleh

$$p_i = \text{pr}(|\varepsilon_i| > k\sigma|y) = \int \{1 - \Phi(z_1) + \Phi(z_2)\} p(\tau|y) d\tau \quad (3.7)$$

Hasil dari p_i dapat dibandingkan dengan peluang prior $2\Phi(-k)$. Nilai dengan peluang posterior p_i yang tinggi yang menjadi pencilan akan memiliki $|\hat{\varepsilon}_i|$ yang besar atau h_{ii} yang besar ataupun keduanya. Ketika $|\hat{\varepsilon}_i|$ membesar akibatnya $|\varepsilon_i|$ juga ikut membesar, namun ketika h_{ii} membesar ada ketidakpastian untuk ε_i . Banyaknya h_{ii} sering menunjukkan sebagai *leverage*.

3.2 Penentuan Nilai k

Nilai k dapat dipilih sehingga peluang prior yang tidak memiliki pencilan besar, misalkan 0,95. Ini memberikan $k = \Phi^{-1}\{0,5 + \frac{1}{2} (0,95^{1/n})\}$, dengan mensubstitusikan nilai n dan melihat Daftar Distribusi Normal Baku (lampiran 1).

Cara lain yang dapat digunakan apabila dalam pertimbangannya model diperlukan untuk menggambarkan data bukan terhadap model yang stokastik, maka nilai $k = 2$ dapat digunakan untuk menemukan observasi yang tidak baik dijelaskan oleh data maupun ukuran sampel.

Dalam Chaloner (1988), observasi dinamakan sebagai pencilan ketika peluang posterior (3.7) lebih besar dari peluang prior $2\Phi(-k)$.