

BAB II

MATERI PENUNJANG

2.1. MODEL REGRESI GANDA

Secara umum model regresi ganda dirumuskan dengan

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_i \quad (2.1.1)$$

$$= \beta_0 + \sum_{j=1}^k \beta_j X_{ij} + \varepsilon_i, \quad i = 1, 2, \dots, n$$
$$\varepsilon_i \sim \text{NID.}(0, \sigma_\varepsilon^2)$$

Untuk mengestimasi harga-harga β_j digunakan estimasi kuadrat terkecil, yaitu dengan cara meminimalkan jumlah kuadrat sesatan ε_i yaitu

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Y_i - \beta_0 - \sum_{j=1}^k \beta_j X_{ij})^2 \quad (2.1.2)$$

Jika persamaan (2.1.2) ini diturunkan terhadap β_0 , β_1 , β_2 , ..., β_k dan menyamakannya dengan nol, maka akan diperoleh estimasi dari parameter regresi yaitu $\hat{\beta}_j$, $j = 1, 2, 3, \dots$

Model dalam persamaan (2.1.1) dapat pula dinyatakan dalam bentuk matriks, yaitu

$$\begin{pmatrix} n & \sum X_{i1} & \sum X_{i2} & \dots & \sum X_{ik} \\ \sum X_{i1} & \sum X_{i1}^2 & \sum X_{i1} X_{i2} & \dots & \sum X_{i1} X_{ik} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \sum X_{ik} & \sum X_{ik} X_{i1} & \sum X_{ik} X_{i2} & \dots & \sum X_{ik}^2 \end{pmatrix} \begin{pmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \vdots \\ \hat{\beta}_k \end{pmatrix} = \begin{pmatrix} \sum Y_i \\ \sum X_{i1} Y_i \\ \vdots \\ \sum X_{ik} Y_i \end{pmatrix}$$

$$\begin{aligned} E(\hat{\beta}) &= E[(X'X)^{-1}(X'Y)] \\ &= E[(X'X)^{-1}X'(X\beta + \varepsilon)] \\ &= E[(X'X)^{-1}X'X\beta + (X'X)^{-1}X'\varepsilon] \\ &= \beta \end{aligned}$$

karena $E(\varepsilon) = 0$ dan $(X'X)^{-1}X'X = I$. Jadi $\hat{\beta}$ adalah estimator tak bias dari β .

Estimasi dari σ_ε^2 diperoleh dari jumlah kuadrat sesatan

$$JKS = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n e_i^2 = e'e, \quad \text{dimana } e = \hat{\varepsilon}$$

Dengan mensubstitusikan $e = Y - X\hat{\beta}$, maka

$$\begin{aligned} JKS &= (Y - X\hat{\beta})'(Y - X\hat{\beta}) \\ &= Y'Y - \hat{\beta}'X'Y - Y'X\hat{\beta} + \hat{\beta}'X'X\hat{\beta} \\ &= Y'Y - 2\hat{\beta}'X'Y + \hat{\beta}'X'X\hat{\beta} \end{aligned}$$

Karena $X'X\hat{\beta} = X'Y$, maka persamaan terakhir menjadi

$$JKS = Y'Y - \hat{\beta}'X'Y \quad (2.1.3)$$

Jumlah kuadrat sesatan mempunyai derajat bebas $n-p$, karena p parameter di estimasi dalam regresi itu.

Rata-rata kuadrat sesatan dirumuskan dengan

$$RKS = \frac{JKS}{n-p}$$

Test untuk signifikansi dari model regresi adalah test untuk menentukan jika ada hubungan linear antara respon Y dan variabel regresor X_1, X_2, \dots, X_k . Test hipotesisnya adalah

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0$$

$$H_1 : \text{paling sedikit ada satu } \beta_j \neq 0$$

Penolakan dari $H_0 : \beta_j = 0$ berarti ~~paling sedikit satu~~ dari regresor X_1, X_2, \dots, X_k signifikan untuk model itu. Jumlah kuadrat total (JKT) dipartisi menjadi jumlah kuadrat regresi (JKR) dan jumlah kuadrat sesatan (JKS) yaitu

$$JKT = JKR + JKS$$

Statistik penguji untuk hipotesis diatas adalah

$$F_0 = \frac{JKR/k}{JKS/n-k-1} = \frac{RKR}{RKS}$$

Jika $F_0 > F_{(\alpha, k, n-k-1)}$ maka H_0 ditolak.

Perhitungan RKR diperoleh dari

$$JKS = Y'Y - \hat{\beta}' X' Y$$

dan jumlah kuadrat total

$$JKT = \sum_{i=1}^n Y_i^2 - \frac{(\sum_{i=1}^n Y_i)^2}{n} = Y'Y - \frac{(\sum_{i=1}^n Y_i)^2}{n} \quad (2.1.4)$$

$$JKS = Y'Y - \frac{(\sum_{i=1}^n Y_i)^2}{n} - \left[\hat{\beta}' X' Y - \frac{(\sum_{i=1}^n Y_i)^2}{n} \right]$$

$$JKS = JKT - JKR$$

Karena itu JKR-nya adalah

$$JKR = \hat{\beta}' X' Y - \frac{(\sum_{i=1}^n Y_i)^2}{n} \quad (2.1.5)$$

Tabel 1. Analisa Variansi

Sumber variasi	JK	DK	RK	F _o
Regresi	JKR	k	RKR	$\frac{RKR}{RKS}$
Sesatan	JKS	n-k-1	RKS	
Total	JKT	n-1		

2.2. MODEL RUNTUN WAKTU STASIONER UNIVARIAT

2.1.1. STASIONERITAS DAN WHITE NOISE

Definisi 2.2.1. (Fungsi Autokovariansi)

Jika $\{X_t, t = 0, \pm 1, \pm 2, \dots\}$ adalah proses sedemikian hingga $\text{var}(X_t) < \infty$ untuk setiap $t = 0, \pm 1, \pm 2, \dots$, maka fungsi autokovariansi $\gamma_x(\dots)$ dari $\{X_t\}$ dirumuskan dengan

$$\gamma_x(r, s) = \text{Cov}(X_r, X_s) = E[(X_r - E(X_r))(X_s - E(X_s))]$$

$$r, s = 0, \pm 1, \pm 2, \dots \quad (2.2.1)$$

Definisi 2.2.2.

Proses $\{X_t, t \in Z\}$ dengan $Z = \{0, \pm 1, \pm 2, \dots\}$ disebut stasioner jika

- (a) $E |X_t|^2 < \infty$ untuk semua $t \in Z$
- (b) $E (X_t) = m$ untuk semua $t \in Z$
- (c) $\gamma_x(r, s) = \gamma_x(r+t, s+t)$ untuk semua $r, s, t \in Z$

Jika $\{X_t, t \in Z\}$ adalah stasioner, maka $\gamma_x(r, s) = \gamma_x(r-s, 0)$ untuk semua $r, s \in Z$. Karena itu fungsi autokovariansi dari proses stasioner dapat didefinisikan sebagai fungsi dari satu variabel, yaitu $\gamma_x(h) = \gamma_x(h, 0) = \text{Cov} (X_{t+h}, X_t)$ untuk semua $t, h \in Z$. Fungsi $\gamma_x(\cdot)$ sebagai fungsi autokovariansi dari $\{X_t\}$ dan $\gamma_x(h)$ sebagai nilai autokovariansi pada "lag" h . Fungsi autokorelasi dari X_t pada lag h adalah $\rho_x(h) = \gamma_x(h)/\gamma_x(0) = \text{Corr} (X_{t+h}, X_t)$ untuk semua $t, h \in Z$.

Definisi 2.2.3.

Proses $\{a_t\}$ disebut white noise dengan mean 0 dan variansi σ_a^2 , atau ditulis

$$\{a_t\} \sim \text{WN}(0, \sigma_a^2)$$

jika dan hanya jika $\{a_t\}$ mempunyai mean nol dan fungsi kovariansi

$$r(h) = \begin{cases} \sigma_a^2 & \text{jika } h = 0 \\ 0 & \text{jika } h \neq 0 \end{cases} \quad (2.2.2)$$

Jadi proses $\{a_t\}$ disebut white noise jika $\{a_t\}$ adalah barisan variabel random yang tidak berkorelasi dari distribusi tetap dengan mean diasumsikan nol dan variansi konstan, $\text{Var}(a_t) = \sigma_a^2$ dan $r(h) = \text{Cov}(a_t, a_{t+h}) = 0$ untuk $h \neq 0$. Jadi proses white noise $\{a_t\}$ adalah stasioner dengan fungsi autokovariansi persamaan (2.2.2) dan fungsi autokorelasi

$$\rho(h) = \begin{cases} 1, & h = 0 \\ 0, & h \neq 0 \end{cases} \quad (2.2.3)$$

2.2.2. MODEL MOVING AVERAGE (MA) UNIVARIAT

Model umum MA (q) univariat dirumuskan dengan

$$X_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.2.4)$$

Model MA(q) X_t diperoleh dengan menerapkan bobot $1, -\theta_1, -\theta_2, \dots, -\theta_q$ pada variabel-variabel $a_t, a_{t-1}, a_{t-2}, \dots, a_{t-q}$.

Untuk model MA(1), $X_t = a_t - \theta a_{t-1}$, maka

$$E(X_t) = E(a_t - \theta a_{t-1}) = 0$$

$$\text{Var}(X_t) = E[(a_t - \theta a_{t-1})(a_t - \theta a_{t-1})] = (1 + \theta^2)\sigma_a^2$$

$$\text{Cov}(X_t, X_{t-1}) = \text{Cov}(a_t - \theta a_{t-1}, a_{t-1} - \theta a_{t-2})$$

$$= \text{Cov}(-\theta a_{t-1}, a_{t-1}) = -\theta \sigma_a^2$$

$$\text{Cov}(X_t, X_{t-2}) = \text{Cov}(a_t - \theta a_{t-1}, a_{t-2} - \theta a_{t-3}) = 0$$

karena tidak ada a dengan lag yang sama antara X_t dan X_{t-k} . Jadi $\text{Cov}(X_t, X_{t-k}) = 0$ untuk $k \geq 2$, yaitu proses tidak punya korelasi untuk lag melebihi satu. Sedangkan ρ_1 nya adalah

$$\rho_1 = \frac{\gamma_1}{\gamma_0} = \frac{-\theta \sigma_a^2}{(1 + \theta^2)\sigma_a^2} = \frac{-\theta}{1 + \theta^2}$$

2.2.3. MODEL AUTOREGRESSIVE (AR) UNIVARIAT

Secara umum, model AR(p) univariat dirumuskan dengan

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t \quad (2.2.5)$$

Nilai yang sekarang dari X_t adalah kombinasi linear dari p nilainya yang lalu, ditambahkan white noise a_t . Jadi diasumsikan a_t independen dengan X_{t-1}, X_{t-2}, \dots .

$$\text{Untuk model AR(1) } X_t = \phi X_{t-1} + a_t \quad (2.2.6)$$

$$\text{Var}(X_t) = \text{Var}(\phi X_{t-1} + a_t)$$

$$\text{Var}(X_t) = \phi^2 \text{Var}(X_{t-1}) + \text{Var}(a_t)$$

$$\gamma_0 = \phi^2 \gamma_0 + \sigma_a^2$$

$$\gamma_0 = \frac{\sigma_a^2}{1 - \phi^2}$$

Jika persamaan (2.2.6) dikalikan dengan X_{t-k} dan kemudian diambil ekspektasinya, maka akan diperoleh

$$E(X_t X_{t-k}) = \phi E(X_{t-1} X_{t-k}) + E(a_t X_{t-k})$$

Karena deret diasumsikan stasioner dan karena a_t dan X_{t-k} independen, diperoleh

$$\gamma_k = \phi \gamma_{k-1}, \text{ untuk } k = 1, 2, \dots \quad (2.2.7)$$

$$\text{Jika } k = 1, \gamma_1 = \phi \gamma_0 = \frac{\phi \sigma_a^2}{(1 - \phi^2)}$$

$$k = 2, \gamma_2 = \phi \gamma_1 = \frac{\phi^2 \sigma_a^2}{(1 - \phi^2)}$$

$$\vdots$$

$$\gamma_k = \frac{\phi^k \sigma_a^2}{(1 - \phi^2)}$$

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \phi^k, \quad k = 0, 1, 2, \dots$$

Untuk model AR(p) secara umum, yaitu

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t \text{ akan diperoleh}$$

$$E(X_t X_{t-k}) = E[(\phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p}) X_{t-k}]$$

$$\gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \dots + \phi_p \gamma_{k-p}$$

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p}, \quad k \geq 1 \quad (2.2.8)$$

Dengan mengambil $k = 1, 2, \dots, p$ dalam persamaan (2.2.7) dan mengambil $\rho_0 = 1$ dan $\rho_{-k} = \rho_k$, diperoleh persamaan Yule-Walker

$$\rho_1 = \phi_1 + \phi_2 \rho_1 + \dots + \phi_p \rho_{p-1}$$

$$\rho_2 = \phi_1 \rho_1 + \phi_2 + \dots + \phi_p \rho_{p-1}$$

$$\vdots \quad (2.2.9)$$

$$\rho_p = \phi_1 \rho_{p-1} + \phi_2 \rho_{p-2} + \dots + \phi_p$$

Jika diberikan nilai $\phi_1, \phi_2, \dots, \phi_p$, persamaan linear dapat diselesaikan untuk $\rho_1, \rho_2, \dots, \rho_p$. Kemudian persamaan (2.2.8) dapat digunakan untuk memperoleh ρ_k pada lag-lag yang lebih tinggi.

$$\begin{aligned}
 E(a_t X_t) &= E[a_t (\phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t)] \\
 &= E(a_t^2) \\
 &= \sigma_a^2
 \end{aligned}$$

Jika persamaan (2.2.5) dikalikan X_t dan diambil ekspektasinya, diperoleh

$$E(X_t X_t) = E[X_t (\phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t)]$$

$$\gamma_0 = \phi_1 \gamma_1 + \phi_2 \gamma_2 + \dots + \phi_p \gamma_p + \sigma_a^2$$

Dengan menggunakan $\rho_k = \gamma_k / \gamma_0$ maka

$$\rho_0 = \phi_1 \rho_1 + \phi_2 \rho_2 + \dots + \phi_p \rho_p + \frac{\sigma_a^2}{\gamma_0}$$

$$\rho_0 = \frac{\sigma_a^2}{1 - \phi_1 \rho_1 - \dots - \phi_p \rho_p} \quad (2.2.10)$$

2.2.4. MODEL AUTOREGRESSIVE MOVING AVERAGE (ARMA)

UNIVARIAT

Definisi 2.2.1

Proses $\{X_t, t = 0, \pm 1, \pm 2, \dots\}$ disebut proses ARMA(p,q)

jika $\{X_t\}$ stasioner dan jika untuk setiap t,

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

(2.2.11)

dengan $a_t \sim WN(0, \sigma_a^2)$. Dikatakan bahwa proses ARMA(p,q) dengan mean μ jika $\{X_t - \mu\}$ adalah proses ARMA(p,q).

Untuk model ARMA(1,1) modelnya adalah

$$X_t = \phi X_{t-1} + a_t - \theta a_{t-1} \quad (2.2.12)$$

Untuk memperoleh persamaan Yule-Walker, pertama-tama dihitung dulu

$$E(a_t X_t) = E[a_t (\phi X_{t-1} + a_t - \theta a_{t-1})] = \sigma_a^2$$

$$\begin{aligned} E(a_{t-1} X_t) &= E[a_{t-1} (\phi X_{t-1} + a_t - \theta a_{t-1})] = \phi \sigma_a^2 - \theta \sigma_a^2 \\ &= (\phi - \theta) \sigma_a^2 \end{aligned}$$

Jika persamaan (2.2.12) dikalikan dengan X_{t-k} dan diambil ekspektasinya, maka diperoleh

$$E(X_{t-k} X_t) = E[X_{t-k} (\phi X_{t-1} + a_t - \theta a_{t-1})] \quad (2.2.13a)$$

$$\gamma_0 = \phi \gamma_1 + (1 - \theta(\phi - \theta)) \sigma_a^2 \quad k = 0 \quad (2.2.13b)$$

$$\gamma_1 = \phi \gamma_0 - \theta \sigma_a^2 \quad k = 1 \quad (2.2.13c)$$

dan

$$\gamma_k = \phi \gamma_{k-1} \quad k \geq 2 \quad (2.2.13d)$$

Dari persamaan (2.2.13b) dan (2.2.13c) diperoleh

$$\begin{aligned}\gamma_o &= \phi\gamma_1 + (1 - \epsilon(\phi - \epsilon))\sigma_a^2 \\ &= \phi(\phi\gamma_o - \epsilon\sigma_a^2) + (1 - \epsilon(\phi - \epsilon))\sigma_a^2\end{aligned}$$

$$\gamma_o - \phi^2\gamma_o = -\phi\epsilon\sigma_a^2 + (1 - \epsilon\phi + \epsilon^2)\sigma_a^2$$

$$\gamma_o = \frac{(1 - 2\epsilon\phi + \epsilon^2)\sigma_a^2}{1 - \phi^2}$$

