

BAB II

MATERI PENUNJANG

2.1 REGRESI LINIER BERGANDA

2.1.1 MODEL REGRESI LINIER BERGANDA

Suatu model regresi yang mencakup lebih dari satu variabel bebas disebut model regresi berganda.

Definisi 2.1.1 :

Secara umum model regresi linier berganda, dengan variabel tidak bebas Y dapat dihubungkan pada k variabel bebas ($x_1, x_2, x_3, \dots, x_k$), yakni :

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad \dots (2.1)$$

dimana $\varepsilon \sim \text{NID}(0, \sigma_\varepsilon^2)$, dengan β_i ($i=1,2,\dots,k$) disebut koefisien regresi.

2.1.2 PENYELESAIAN KOEFISIEN REGRESI LINIER BERGANDA

Model umum regresi linier berganda adalah :

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon$$

Model regresi untuk setiap vektor pengamatan (misal pengamatan ke- i) adalah :

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i$$

Harga taksiran untuk y_i adalah

$$\begin{aligned} E(y_i) &= E(\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i) \\ &= E(\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki}) + E(\varepsilon_i) \\ &= E(\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki}) + 0 \end{aligned}$$

karena $E(\varepsilon_i)$ adalah nol, sehingga :

$$\begin{aligned} E(y_i) &= E(\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki}) \\ &= \hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \hat{\beta}_2 x_{2i} + \dots + \hat{\beta}_k x_{ki} \end{aligned}$$

$$\text{jadi } E(y) = \hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \hat{\beta}_2 x_{2i} + \dots + \hat{\beta}_k x_{ki}$$

Untuk menyelesaikan koefisien pada regresi linier berganda digunakan metode kuadrat terkecil.

Fungsi kuadrat terkecil adalah :

$$\begin{aligned} L &= \sum_{i=1}^n \varepsilon_i^2 \\ &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 \\ &= \sum_{i=1}^n (y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \hat{\beta}_2 x_{2i} + \dots + \hat{\beta}_k x_{ki}))^2 \\ &= \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{1i} - \hat{\beta}_2 x_{2i} - \dots + \hat{\beta}_k x_{ki})^2 \\ &= \sum_{i=1}^n (y_i - \hat{\beta}_0 - \sum_{j=1}^k \hat{\beta}_j x_{ji})^2 \quad \dots (2.2) \end{aligned}$$

Fungsi L tersebut diminimumkan terhadap $\hat{\beta}_0$ dan $\hat{\beta}_j$.

penaksir kuadrat terkecil $\beta_0, \beta_1, \beta_2, \dots, \beta_k$ harus memenuhi :

$$\begin{aligned} \frac{\partial L}{\partial \beta_0} \Big|_{\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k} &= -2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \sum_{j=1}^k \hat{\beta}_j x_{ji}) = 0 \\ \frac{\partial L}{\partial \beta_j} \Big|_{\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k} &= -2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \sum_{j=1}^k \hat{\beta}_j x_{ji}) x_{ji} = 0 \end{aligned} \quad \dots (2.3)$$

dari persamaan (2.3) diperoleh persamaan-persamaan normal kuadrat terkecil :

$$\begin{aligned} n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n x_{1i} + \hat{\beta}_2 \sum_{i=1}^n x_{2i} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{ki} &= \sum_{i=1}^n y_i \\ \hat{\beta}_0 \sum_{i=1}^n x_{1i} + \hat{\beta}_1 \sum_{i=1}^n x_{1i}^2 + \hat{\beta}_2 \sum_{i=1}^n x_{1i} x_{2i} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{1i} x_{ki} &= \sum_{i=1}^n x_{1i} y_i \\ \vdots & \vdots \\ \hat{\beta}_0 \sum_{i=1}^n x_{ki} + \hat{\beta}_1 \sum_{i=1}^n x_{ki} x_{1i} + \hat{\beta}_2 \sum_{i=1}^n x_{ki} x_{2i} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{ki}^2 &= \sum_{i=1}^n x_{ki} y_i \end{aligned} \quad \dots (2.4)$$

Dengan menyelesaikan persamaan (2.4), yang terdiri dari $p=k+1$ persamaan normal maka diperoleh nilai taksiran untuk $\beta_0, \beta_1, \beta_2, \dots, \beta_k$.

2.13 KOEFISIEN KORELASI PADA REGRESI BERGANDA

Dalam regresi berganda, kaitan antara dua variabel dapat dinyatakan dengan perhitungan korelasi antara dua variabel.

Definisi 2.1.2 : Kovarian antara dua variabel X dan Y untuk n pasangan observasi (X_i, Y_i) , $i=1,2,3,\dots,n$ adalah :

$$\text{Cov } XY = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \quad \dots (2.5)$$

Koefisien korelasi dapat dengan mudah dinyatakan dari definisi kovarian yang dibagi dengan standar deviasi dari masing-masing variabelnya.

Definisi 2.1.3 : Korelasi antara dua variabel X dan Y untuk n pasangan observasi (X_i, Y_i) , $i=1,2,3,\dots,n$ adalah :

$$r_{xy} = \frac{\text{Cov XY}}{\sqrt{\text{Cov XX} \text{ Cov YY}}} \quad \dots (2.6)$$

dimana :

$$\text{Cov XX} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

$$\text{Cov YY} = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})^2$$

Dalam suatu regresi linier berganda , manfaat atau kegunaan dalam menghitung koefisien korelasi antara variabel tidak bebas Y dengan variabel bebas X adalah untuk menunjukkan tingkat keterkaitan antara variabel tidak bebas Y dengan variabel bebas X.

2.2 DERET BERKALA (TIME SERIES) UNIVARIATE

Dalam pembahasan deret berkala univariate ini akan dikhususkan pada deret berkala yang stasioner.

Definisi 2.2.1 : Bila T himpunan waktu yang diamati, t didalam T dan Y_t adalah hasil pengamatan pada saat t, maka $\{Y_t, t \in T\}$ disebut proses stokastik.

Untuk proses stokastik yang stasioner akan diberikan pada definisi 2.2.2, yakni :

Definisi 2.2.2 : Misal $Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}$ adalah pengamatan pada saat t_1, t_2, \dots, t_n dari proses stokastik $\{Y_t, t \in T\}$ dan distribusi peluang gabungan yang berkaitan adalah :

$$f(Y_{t_1}, Y_{t_2}, \dots, Y_{t_n})$$

jika dipenuhi :

$$f(Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}) = f(Y_{t_1+k}, Y_{t_2+k}, \dots, Y_{t_n+k})$$

untuk setiap pergeseran waktu sebesar k , maka proses stokastik $\{Y_t, t \in T\}$ disebut proses stokastik stasioner..

Akibat : $f(Y_1, Y_2, \dots, Y_n)$ bebas dari waktu sehingga proses stokastik stasioner mempunyai mean dan varian yang konstan, yaitu :

$$\text{Mean} = \mu = E[Y_t] = E[Y_{t+k}]$$

$$\text{Varian} = \tau_Y^2 = E[Y_t - \mu]^2 = E[Y_{t+k} - \mu]^2$$

Untuk sampel data Y_1, Y_2, \dots, Y_n maka taksiran mean dan varian adalah :

$$\hat{\mu} = \frac{1}{n} \sum_{t=1}^n Y_t \quad \text{dan} \quad \hat{\tau}^2 = \frac{1}{n} \sum_{t=1}^n (Y_t - \bar{Y})^2$$

Sementara itu fungsi autokovarians dan autokorelasi pada proses stokastik akan disajikan pada definisi berikut :

Definisi 2.2.3 : Fungsi autokovarian proses stokastik $\{Y_t, t \in T\}$ adalah :

$$\begin{aligned}\gamma_{YY}(t_1, t_2) &= \text{Cov}(Y_{t_1}, Y_{t_2}) \\ &= E(Y_{t_1} Y_{t_2})\end{aligned}$$

Untuk proses stokastik stasioner, fungsi auto kovariansi hanya bergantung pada selang waktu (lag) antara t_1 dan t_2 .

Misal untuk proses stasioner, selang waktu dinyatakan dalam k , maka fungsi autokovariansi menjadi :

$$\begin{aligned}\gamma_{YY}(k) &= \text{Cov}(Y_t, Y_{t+k}) \\ &= E(Y_t Y_{t+k})\end{aligned}$$

$\gamma_{YY}(k)$ ditulis γ_k .

Definisi 2.2.4 : Fungsi autokorelasi proses stokastik $\{Y_t, t \in T\}$ untuk selang waktu k (lag k) adalah :

$$\rho_{YY} = \frac{\gamma_k}{\tau_Y^2}$$

dimana τ_Y^2 adalah autokovarian dari Y dengan selang waktu, $k = 0$.

mengingat :

$$\begin{aligned}\gamma_0 &= \text{Cov}(Y_t, Y_{t+k}) \\ &= E(Y_t - \mu)(Y_{t+0} - \mu) \\ &= E(Y_t - \mu)^2 \\ &= \tau_Y^2\end{aligned}$$

maka:

$$\rho_{YY}(k) = \frac{\gamma_k}{\gamma_0}$$

adapun taksiran autokorelasi lag k adalah :

$$\hat{\rho}_k = r_k = \frac{\sum_{t=1}^n (Y_t - \bar{Y})(X_t - \bar{X})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}$$

Definisi 2.2.5 : White noise adalah barisan variabel acak a_t, a_{t-1}, \dots yang masing-masing tidak berkorelasi, dimana $a_t \sim (0, \sigma_a^2)$.

Autokovarians lag k white noise adalah :

$$\text{Cov}(a_t, a_{t+k}) = E[(a_t - E(a_t))(a_{t+k} - E(a_{t+k}))]$$

$$\text{Cov}(a_t, a_{t+k}) = E[(a_t a_{t+k} - a_t E(a_{t+k}) - E(a_t) a_{t+k} + E(a_t) E(a_{t+k}))]$$

karena $E(a_t) = 0$, sehingga:

$$\begin{aligned} \text{Cov}(a_t, a_{t+k}) &= E[a_t a_{t+k} - a_t E(a_{t+k})] \\ &= E(a_t a_{t+k}) - E(a_t E(a_{t+k})) \\ &= E(a_t a_{t+k}) \end{aligned}$$

$$\begin{aligned} \text{Untuk } k = 0 &\longrightarrow \text{Cov}(a_t, a_{t+k}) = E(a_t a_{t+k}) \\ &= E(a_t^2) \\ &= \sigma_a^2 \end{aligned}$$

$$\begin{aligned} \text{Untuk } k \neq 0 &\longrightarrow \text{Cov}(a_t, a_{t+k}) = E(a_t a_{t+k}) \\ &= 0 \end{aligned}$$

karena nilai-nilai white bersifat acak / random dan suatu nilai white noise tidak berkorelasi dengan nilai white noise sesudah atau sebelumnya.

Beberapa proses dari deret berkala univariate yang stasioner diantaranya adalah proses Autoregressive dengan orde p atau $AR(p)$.

Definisi 2.2.6 Bila Y dinyatakan dalam bentuk :

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \mu' + a_t$$

dengan $\phi_p \neq 0$, maka Y_t disebut proses Autoregressive dengan orde p atau $AR(p)$.

μ' pada persamaan diatas adalah tidak sama dengan "nilai tengah" dari deret Y .

Pengembangannya adalah sebagai berikut :

$$(Y_t - \mu) = \phi_1 (Y_{t-1} - \mu) + \phi_2 (Y_{t-2} - \mu) + \dots + \phi_p (Y_{t-p} - \mu) + a_t$$

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + (\mu - \phi_1 \mu - \phi_2 \mu - \dots - \phi_p \mu) + a_t$$

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \mu' + a_t$$

Contoh 2.2.1 :

Untuk $p=1$ dan $p = 2$, maka model $AR(p)$ adalah:

* untuk $AR(1)$: $Y_t = \mu' + \phi_1 Y_{t-1} + a_t$

* untuk $AR(2)$: $Y_t = \mu' + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + a_t$.

Proses lain dari deret berkala univariate adalah Proses Moving Averages Orde q atau $MA(q)$.

Definisi 2.2.7 :Bila Y_t dinyatakan dalam bentuk:

$$Y_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

dengan $\theta_q \neq 0$ disebut proses averages

dengan orde q atau $MA(q)$.

Contoh 2.2.2 :

Untuk $q = 1$ dan $q = 2$, yaitu:

* untuk MA(1): $Y_t = \mu + a_t - \theta_1 a_{t-1}$

* untuk MA(2): $Y_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$.

Sedangkan proses campuran dari AR(p) dan MA(q) biasa disebut Proses Autoregressive-Moving Averages atau ARMA(p,q).

Definisi 2.2.8 Bila Y_t dinyatakan dalam bentuk :

$$Y_t = \mu' + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t + \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

dinamakan Proses Autoregressive/Moving Averages Orde (p,q) atau ARMA (p,q)..

Contoh 2.2.3 :

Model ARMA untuk $p = 1$ dan $q = 1$ adalah :

* $Y_t = \mu' + \phi_1 Y_{t-1} + a_t + \theta_1 a_{t-1}$

2.3 PENAKSIRAN PARAMETER MODEL BERKALA UNIVARIATE.**2.3.1 PENAKSIRAN PARAMETER AR (P)**

Dari model Umum proses AR(p) :

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t$$

Kedua sisi dikalikan dengan Y_{t-k} , dimana $k = 1, 2, \dots, p$

$$Y_t Y_{t-k} = \phi_1 Y_{t-k} Y_{t-1} + \phi_2 Y_{t-k} Y_{t-2} + \dots + Y_{t-k} a_t$$

nilai harapan dari persamaan diatas adalah :

$$E(Y_t Y_{t-k}) = \phi_1 E(Y_{t-k} Y_{t-1}) + \phi_2 E(Y_{t-k} Y_{t-2}) + \dots + E(Y_{t-k} a_t)$$

dari definisi 2.2.3 dan karena $E(Y_{t-k}^a) = 0$, maka persamaan menjadi :

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

Kedua sisi dibagi dengan Varian dari Y_t , yaitu γ_0 , hasilnya adalah :

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p}, \quad k=1,2,\dots,p \quad \dots (2.7)$$

Karena nilai teoritis untuk $\rho_1, \rho_2, \rho_3, \dots, \rho_p$ tidak diketahui, maka diganti dengan nilai taksirannya yaitu $r_1, r_2, r_3, \dots, r_p$.

Kemudian persamaan diatas dapat dipecahkan untuk mengetahui nilai $\phi_1, \phi_2, \dots, \phi_p$.

Contoh 2.2.4

Misal $P = 2$, maka persamaan (2.7) diperoleh :

$$\rho_1 = \phi_1 + \phi_2 \rho_1$$

$$\rho_2 = \phi_1 \rho_1 + \phi_2$$

maka pemecahan persamaan diatas menjadi :

$$\hat{\phi}_1 = \frac{r_1 (1-r_2)}{1-r_1^2}$$

$$\hat{\phi}_2 = \frac{r_2 - r_1^2}{1-r_1^2}$$

2.3.2 PENAKSIRAN PARAMETER MODEL MA (q)

Model MA(q) ditulis:

$$Y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

kedua sisi dikalikan Y_{t-k} kemudian di cari nilai harapannya adalah :

$$\begin{aligned} E(Y_{t-k} Y_t) &= E[(a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}) \times \\ &\quad (a_{t-k} - \theta_1 a_{t-k-1} - \theta_2 a_{t-k-2} - \dots - \theta_q a_{t-k-q})] \\ \gamma_k &= E(a_t a_{t-k} - \theta_1 a_t a_{t-k-1} - \theta_2 a_t a_{t-k-2} - \dots - \theta_q a_t a_{t-k-q} \\ &\quad - \theta_1 a_{t-1} a_{t-k} + \theta_1^2 a_{t-1} a_{t-k-1} + \dots + \theta_1 \theta_q a_{t-1} a_{t-k-q} \\ &\quad - \theta_2 a_{t-2} a_{t-k} + \theta_1 \theta_2 a_{t-2} a_{t-k-1} + \dots + \theta_2 \theta_q a_{t-2} a_{t-k-q} \\ &\quad \vdots \\ &\quad - \theta_q a_{t-q} a_{t-k} + \theta_q \theta_1 a_{t-q} a_{t-k-1} + \dots + \theta_q^2 a_{t-q} a_{t-k-q}) \\ &\quad \dots (2.8) \end{aligned}$$

bila k sama dengan nol, maka :

$$\gamma_0 = E(a_t a_{t-0}) + \theta_1^2 E(a_{t-1} a_{t-0-1}) + \dots + \theta_q^2 a_{t-q} a_{t-0-q}$$

Karena $E(a_t a_{t+i}) = 0$, untuk $i \neq 0$

$$E(a_t a_{t+i}) = \sigma_a^2, \text{ untuk } i = 0$$

Jadi persamaannya menjadi :

$$\begin{aligned} \gamma_0 &= \sigma_a^2 + \theta_1^2 \sigma_a^2 + \dots + \theta_q^2 \sigma_a^2 \\ \gamma_0 &= \sigma_a^2 (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2) \quad \dots (2.9) \end{aligned}$$

Persamaan (2.9) adalah varians dari proses MA(q).

Bila k=1, persamaan (2.8) menjadi :

$$\gamma_1 = -\theta_1 E(a_{t-1} a_{t-1}) + \theta_1 \theta_2 E(a_{t-2} a_{t-2}) + \dots + \theta_{q-1} \theta_q E(a_{t-q-1} a_{t-q-1})$$

$$\gamma_1 = -\theta_1 \sigma_a^2 + \theta_1 \theta_2 \sigma_a^2 + \dots + \theta_{q-1} \theta_q \sigma_a^2$$

nilai semua suku lainnya adalah nol karena $E(a_t a_{t+1}) = 0$ untuk $i \neq 0$,

Secara umum untuk $k=k$, persamaannya menjadi:

$$\begin{aligned}\gamma_k &= -\theta_k \sigma_a^2 + \theta_1 \theta_{k+1} \sigma_a^2 + \dots + \theta_{q-k} \theta_q \sigma_a^2 \\ \gamma_k &= \sigma_a^2 (-\theta_k + \theta_1 \theta_{k+1} + \theta_2 \theta_{k+2} + \dots + \theta_{q-k} \theta_q) \\ &\dots (2.10)\end{aligned}$$

Bila persamaan (2.10) dibagi persamaan (2.9), maka :

$$\begin{aligned}\rho_{yy}(k) &= \frac{\gamma_k}{\gamma_0} = \frac{\sigma_a^2 (-\theta_k + \theta_1 \theta_{k+1} + \theta_2 \theta_{k+2} + \dots + \theta_{q-k} \theta_q)}{\sigma_a^2 (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2)} \\ &\dots (2.11)\end{aligned}$$

Contoh 2.2.5:

misal $q = 1$, maka persamaan (2.11) menjadi :

$$\begin{aligned}\rho_k &= \frac{-\theta_k}{1 + \theta_1^2} \Leftrightarrow \rho_k (1 + \theta_1^2) = -\theta_k \\ &\Leftrightarrow \rho_k + \rho_k \theta_1^2 + \theta_k = 0 \\ &\Leftrightarrow \rho_k \theta_1^2 + \theta_k + \rho_k = 0\end{aligned}$$

Karena seluruh suku termasuk indeks lebih besar dari satu, yang tidak terdapat pada model MA(1), jadi :

$$\rho_1 \theta_1^2 + \theta_1 + \rho_1 = 0$$

ρ_1 diganti oleh penaksirnya, r_1 , sehingga akan diperoleh:

$$r_1 \hat{\theta}_1^2 + \hat{\theta}_1 + r_1 = 0$$

Dengan mencari akar-akar kuadrat dari persamaan diatas akan diperoleh harga taksiran untuk θ_1 .

2.3.3 PENAKSIRAN PARAMETER MODEL CAMPURAN

Untuk memperoleh taksiran model-model ARMA, yaitu dengan mengkobinasikan persamaan fungsi kovarians model AR dan MA dan diambil nilai harapannya :

$$\gamma_k = \phi_1 E(Y_t Y_{t-k}) + \dots + \phi_p E(Y_{t-p} Y_{t-k}) + E(a_t Y_{t-k}) - \theta_1 E(a_{t-1} Y_{t-k}) - \dots + \theta_q E(a_{t-q} Y_{t-k}) \quad \dots (2.12)$$

apabila $k > q$, maka $E(a_t Y_{t-k}) = 0$, dan $E(a_{t-q} Y_{t-k})$ sehingga :

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

apabila $k < q$, kesalahan sebelumnya dan Y_{t+k} akan berkorelasi dan autokovarians akan dipengaruhi oleh bagian dari proses moving-averages, yang perlu diikutsertakan.

Varians dan autokovarians dari proses ARMA (1,1)

diperoleh sebagai berikut :

$$Y_t = \phi_1 Y_{t-1} + a_t - \theta_1 a_{t-1} + \mu' \quad \dots (2.13)$$

dengan mengalikan kedua sisi dengan Y_{t-k} dan memasukan nilai harapannya diperoleh :

$$E(Y_{t-k} Y_t) = \phi_1 E(Y_{t-k} Y_{t-1}) + E(Y_{t-k} a_t) - \theta_1 E(Y_{t-k} a_{t-1}) + E(\mu' Y_{t-k})$$

karena $E(\mu' Y_{t-k}) = 0$, maka untuk $k = 0$ adalah:

$$\gamma_0 = \phi_1 \gamma_1 + E[(\phi_1 Y_{t-1} + a_t - \theta_1 a_{t-1} + \mu') a_t] - \theta_1 E[(\phi_1 Y_{t-1} + a_t - \theta_1 a_{t-1} + \mu') a_{t-1}]$$

sehingga :

$$\gamma_0 = \phi_1 \gamma_1 + \sigma_a^2 - \theta_1 (\phi_1 - \theta_1) \sigma_a^2$$

sama halnya, apabila $k=1$

$$\gamma_1 = \phi_1 \gamma_0 - \theta_1 \sigma_a^2$$

pemecahan persamaan diatas untuk γ_0 dan γ_1 menghasilkan :

$$\gamma_0 = \frac{1 + \theta_1^2 - 2\phi_1 \theta_1}{1 - \phi_1^2} \sigma_a^2$$

$$\gamma_1 = \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 - \phi_1^2} \sigma_a^2$$

hasil bagi dari γ_1 dan γ_0 adalah :

$$\rho_1 = \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 - 2\phi_1 \theta_1} \quad \dots (2.14)$$

Akhirnya, apabila $k=2$, fungsi autokorelasi pada model AR adalah :

$$\rho_2 = \phi_1 \rho_1 \quad \text{atau} \quad \phi_1 = \frac{\rho_2}{\rho_1} \quad \dots (2.15)$$

dengan persamaan (2.14) dan (2.15) nilai-nilai penaksiran untuk parameter pada model ARMA dapat diperoleh.

