

BAB II

TINJAUAN PUSTAKA

Pada bab ini dijelaskan mengenai tinjauan pustaka, penelitian terdahulu yang digunakan sebagai acuan dasar teori dan penunjang dalam menyelesaikan permasalahan Tugas Akhir.

2.1 Energi Listrik

Energi listrik adalah salah satu kebutuhan yang sangat penting dalam kehidupan manusia modern. Serta sebagai sumber daya ekonomis yang paling utama dibutuhkan dalam berbagai bidang kegiatan. Adapun proses produksi listrik di Indonesia diantaranya pembangkitan, pengantaran dan pembagian. Penyediaan energi listrik di Indonesia dilakukan oleh Perusahaan Listrik Negara atau yang biasa disebut PLN (Gultom, 2017). Sesuai dengan UU No. 20 Tahun 2002, PLN merupakan BUMN yang ditunjuk sebagai Pemegang Kuasa Usaha Ketenaga Listrikan (PKUK). PLN bertugas sebagai penyedia listrik di Indonesia. Untuk dapat menyediakan listrik dengan baik, maka PLN wajib menyelenggarakan usahanya secara efisien serta dapat menyediakan listrik sesuai kemampuan rakyat (Nizam, 2008). Berdasarkan sumber daya pembangkit, produksi tenaga listrik PLN berasal dari air, panas bumi, minyak/diesel, gas alam, batubara, campuran, dan matahari. Penyediaan dan penjualan energi listrik oleh PLN terbagi menjadi empat sektor pelanggan, yaitu sebagai berikut (Gultom, 2017):

- a. Rumah Tangga, mencakup pelayanan bagi masyarakat umum yang unit pelanggannya merupakan rumah tangga.
- b. Industri, mencakup pelayanan bagi industri, seperti industri berat yang membutuhkan daya lebih besar dari rumah tangga.
- c. Usaha/ komersil, mencakup pelayanan bagi pelaku usaha.
- d. Urusan publik, mencakup pelayanan listrik untuk layanan publik yang disediakan oleh pemerintah.

2.2 Suhu Udara

Salah satu unsur cuaca yang sangat penting ialah suhu udara. Suhu udara dalam suatu wilayah biasanya diukur dalam dua kondisi atau keadaan, yaitu suhu udara minimum dan suhu udara maksimum. Suhu udara minimum adalah suatu keadaan suhu udara berada pada titik terendah dalam suatu wilayah. Sedangkan suhu udara maksimum adalah keadaan dimana suhu udara berada di titik tertinggi dalam suatu wilayah tertentu. Dari suhu tersebut didapatkan suhu rata-rata tiap harinya (Anwar, 2017). Pemanasan global mengakibatkan terjadinya kenaikan suhu udara. Dalam penelitian yang dilakukan oleh Ahmed dkk (2012) mengungkapkan bahwa kenaikan suhu global berdampak signifikan pada permintaan konsumsi listrik.

2.3 Peramalan

Peramalan ialah suatu proses memperkirakan suatu kejadian dimasa mendatang secara sistematis dengan menggunakan informasi dari masa lalu dan sekarang agar kesalahannya dapat diperkecil (Rohmawati dkk, 2017). Menurut jangka waktunya, peramalan dibagi menjadi 3 periode, yaitu sebagai berikut (Lutkepohl dan Kratzig, 2004):

- a. Peramalan jangka pendek (*Short - Term Forecasting*)
Peramalan jangka pendek merupakan peramalan dalam jangka waktu harian hingga setiap jam atau mingguan. Data yang digunakan lebih sedikit dibandingkan pada peramalan jangka panjang dan jangka menengah.
- b. Peramalan jangka menengah (*Mid – Term Forecasting*)
Merupakan peramalan yang dilakukan dalam waktu bulanan. Data yang digunakan tidak terlalu banyak seperti peramalan jangka panjang.
- c. Peramalan jangka panjang (*Long – Term Forecasting*)
Merupakan peramalan yang dilakukan pada jangka panjang, seperti dalam beberapa tahun kedepan. Data historis yang digunakan berjumlah banyak sesuai dengan sampel untuk data yang diramalkan.

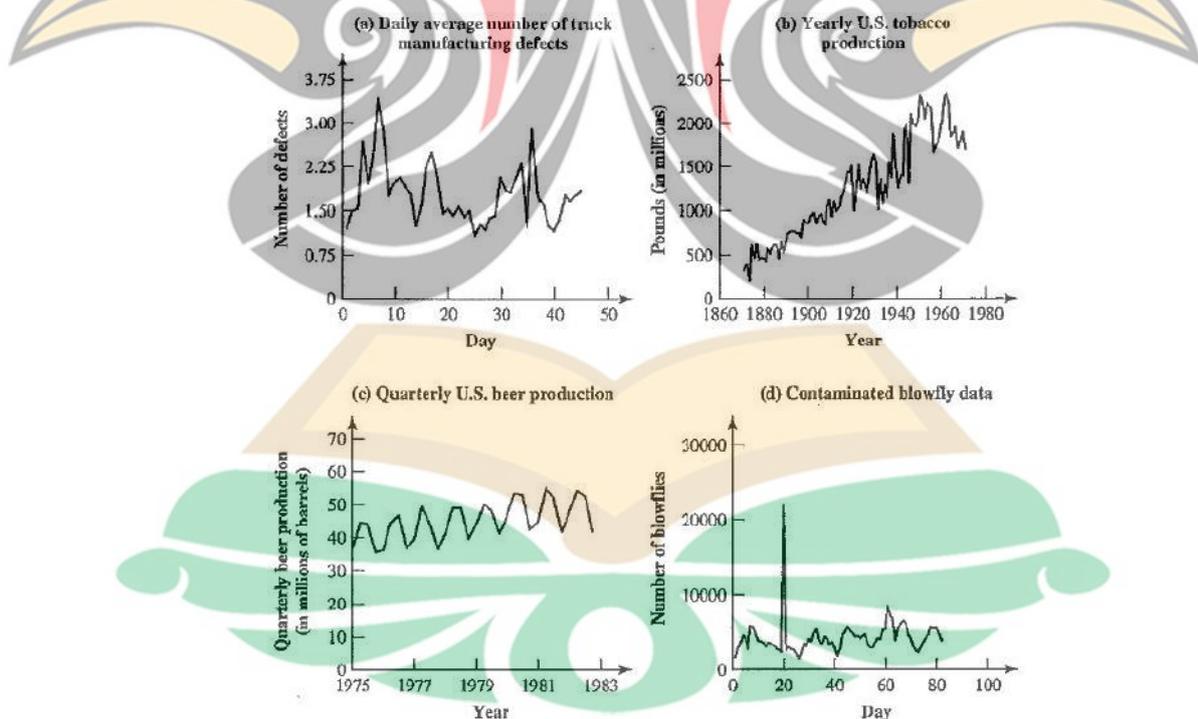
2.4 Time Series (Deret Waktu)

Analisis deret waktu pertama kali diperkenalkan oleh George E.P. Box dan Gwilym M. Jenkins (1970) melalui bukunya yang berjudul *Time Series Analysis: Forecasting and Control*. *Time series* merupakan serangkaian pengamatan yang dilakukan pada suatu variabel dalam waktu yang berurutan dan ditulis sesuai waktu kejadiannya dengan jarak waktu yang sama.

Secara matematis, *time series* didefinisikan oleh nilai-nilai dari Z_1, Z_2, \dots, Z_n dari suatu variabel Z untuk titik-titik waktu t_1, t_2, \dots, t_n . Dengan demikian, Z merupakan sebuah fungsi dari t dan disimbolkan dengan $Z = f(t)$ (Wei, 2006).

2.5 Stasioneritas

Ciri-ciri model *time series* adalah dengan mengasumsikan bahwa data dalam keadaan stasioner. Data dikatakan stasioner jika tidak terjadi kenaikan maupun penurunan nilai secara tajam pada data. Sehingga dengan kata lain, *time series* yang stasioner ialah tidak ada perubahan kecenderungan dalam rata-rata dan perubahan variansi. Berikut pola data *time series* disajikan dalam Gambar 2.1.



Gambar 2.1 Pola data *time series* (Wei, 2006)

1. Pola horizontal, terjadi jika nilai data berfluktuasi disekitar nilai *mean* yang konstan. Tipe pola ini pada *time series* disebut sebagai *stationary*.

2. Pola Tren, terjadi apabila adanya bentuk kenaikan atau penurunan data dalam perubahan waktu dan data bersifat tidak stasioner.
3. Pola Musiman (*Seasonal*), terjadi fluktuasi yang berulang pada data dalam suatu kurun waktu tertentu.
4. Pola Siklis (*Cyclical*), terjadi apabila data dipengaruhi oleh fluktuasi jangka panjang membentuk pola siklis/gelombang. Biasanya pola ini relatif lebih panjang dibandingkan musiman.

(Makridakis dkk, 1999)

Salah satu pengujian stasioneritas dapat dilakukan dengan uji *unit root*. Uji *unit root* yang biasa digunakan adalah Uji *Augmented Dickey-Fuller* (Aswi dan Sukarna, 2006).

2.5.1 Uji *Augmented Dickey-Fuller* (ADF) Tests

Uji *Augmented Dickey-Fuller test* merupakan versi pengujian Fuller (1976) dan Dickey & Fuller (1979). Persamaan uji stasioner dengan ADF tes adalah sebagai berikut (Lutkepohl dan Kratzig, 2004):

$$\Delta y_t = \phi y_{t-1} + \sum_{j=1}^{p-1} \alpha_j^* y_{t-j} + u_t, \quad (2.1)$$

dimana $\phi = \alpha$ dan $\alpha_j^* = (\alpha_{j+1} + \dots + \alpha_p)$. Dalam model ini diperlukan adanya hipotesis. Berikut hipotesis dari uji stasioner data adalah:

H_0 : Data tidak stasioner

H_1 : Data stasioner

Pada uji stasioneritas *Augmented Dickey-Fuller*, data dikatakan stasioner jika *p-value* < 0,05 maka hipotesis awal (H_0) ditolak.

Apabila data tidak stasioner, maka perlu dilakukan pembedaan (*differencing*). Metode ini dilakukan dengan cara mengurangi nilai data pada periode ke-*t* dengan nilai periode sebelumnya (Lutkepohl dan Kratzig, 2004).

Bentuk differensiasi pertama ($d=1$) adalah sebagai berikut:

$$\nabla y_t = y_t - y_{t-1} \quad (2.2)$$

2.6 *Autocorelation Function* (ACF)

Autocorelation Function (ACF) atau fungsi autokorelasi berguna untuk mengukur hubungan suatu nilai dengan nilai masa depan ($Z_{t+1}, Z_{t+2}, \dots, Z_{t+N}$) atau

nilai masa lalu ($Z_{t-1}, Z_{t-2}, \dots, Z_{t-N}$). Koefisien autokorelasi untuk lag- k dari data *time series* dinyatakan sebagai berikut (Wei, 2006) :

$$r_k = \rho_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, k = 1, 2, \dots \quad (2.3)$$

dimana $\bar{Z} = \sum_{t=1}^n Z_t / n$

dengan r_k = koefisien autokorelasi

Z_t = nilai variabel Z pada waktu t

Z_{t+k} = nilai variabel Z pada waktu $t + k$

\bar{Z} = nilai rata-rata variabel Z_t

ρ_k merupakan fungsi autokorelasi karena r_k adalah fungsi atas k , sehingga hubungan koefisien autokorelasi dengan lagnya disebut sebagai fungsi autokorelasi. Koefisien autokorelasi ρ_k diduga dengan autokorelasi sampel (Makridakis, 1999).

Adapun hipotesis untuk menguji koefisien autokorelasi signifikan adalah sebagai berikut:

$H_0 : \rho_k = 0$ (koefisien autokorelasi tidak signifikan)

$H_1 : \rho_k \neq 0$ (koefisien autokorelasi signifikan)

Statistik uji yang digunakan ialah $t = \frac{r_k}{SE r_k}$ dengan $SE = \frac{1}{\sqrt{n}}$. Keputusan Tolak H_0 jika $|t_{hitung}| > t_{\alpha/2, n-1}$, dengan n adalah banyaknya data (Wei, 2006).

2.7 Partial Autocorelation Function (PACF)

Partial Autocorelation Function (PACF) atau fungsi autokorelasi parsial merupakan korelasi antara Z_t dan Z_{t+k} dengan mengabaikan ketidakbebasan ($Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$). Autokorelasi parsial Z_t dan Z_{t+k} dapat diturunkan dari model regresi linear, Z_{t+k} sebagai variabel terikat dan variabel bebasnya adalah $Z_{t+k-1}, Z_{t+k-2}, \dots$, dan Z_t sehingga dapat dituliskan sebagai berikut (Wei, 2006):

$$Z_{t+k} = \phi_{k1} Z_{t+k-1} + \phi_{k2} Z_{t+k-2} + \dots + \phi_{kk} Z_t + a_{t+k} \quad (2.4)$$

dengan ϕ_{ki} = parameter regresi ke- i ; $i = 1, 2, \dots, k$

a_{t+k} = residu dengan rata-rata 0 dan tidak berkorelasi dengan Z_{t+k-j}

Untuk $j = 1, 2, \dots, k$. Dengan mengalikan Z_{t+k-j} pada kedua ruas persamaan (2.4), didapatkan

$$\gamma_j = \phi_{k1}\gamma_{j-1} + \phi_{k2}\gamma_{j-2} + \dots + \phi_{kk}\gamma_{j-k} \quad (2.5)$$

dan

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k} \quad (2.6)$$

Untuk $j = 1, 2, \dots, k$, diperoleh sistem persamaan berikut:

$$\begin{aligned} \rho_1 &= \phi_{k1}\rho_0 + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1} \\ \rho_2 &= \phi_{k1}\rho_1 + \phi_{k2}\rho_0 + \dots + \phi_{kk}\rho_{k-2} \\ &\vdots \\ \rho_k &= \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{kk}\rho_0 \end{aligned}$$

dengan menggunakan aturan Cramer, berturut-turut $k = 1, 2, \dots$, diperoleh

$$\phi_{11} = \rho_1$$

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}}$$

$$\phi_{33} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}}$$

\vdots

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & 1 \end{vmatrix}}$$

ϕ_{kk} disebut fungsi autokorelasi parsial karena ϕ_{kk} merupakan fungsi atas k . Adapun hipotesis untuk menguji koefisien autokorelasi parsial adalah sebagai berikut:

$$H_0 : \phi_{kk} = 0$$

$$H_1 : \phi_{kk} \neq 0$$

Statistik uji yang digunakan ialah $t = \frac{\phi_{kk}}{SE(\phi_{kk})}$ dengan $SE(\phi_{kk}) = \frac{1}{\sqrt{n}}$. Tolak H_0 jika

$|t_{hitung}| > t_{\alpha/2df}$, $df = n-1$, dengan n adalah banyaknya data (Wei, 2006).

2.8 Metode ARIMA (Box-Jenkins)

Metode ARIMA atau *Autoregressive Integrated Moving Average* adalah metode yang tepat digunakan untuk menyelesaikan peramalan *time series* yang mempunyai variasi pola data dan situasi peramalan yang sulit. Metode ARIMA (Box-Jenkins) ini sangat baik digunakan dalam peramalan jangka pendek dan menengah. Secara umum, model ARIMA dapat dituliskan dengan notasi ARIMA (p, d, q), notasi p menyatakan orde dari proses *autoregressive* (AR), d menyatakan pembedaan (*differencing*), dan q menyatakan orde dari proses *moving average* (MA) (Wei, 2006).

2.8.1 Autoregressive (AR)

Model *autoregressive* memiliki orde yang dinotasikan sebagai AR (p) atau model ARIMA ($p, 0, 0$) dinyatakan sebagai berikut

$$\hat{y}_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + e_t \quad (2.7)$$

dengan \hat{y}_t = variabel terikat

$\phi_1, \phi_2, \dots, \phi_p$ = parameter *autoregressive*

$y_{t-1}, y_{t-2}, \dots, y_{t-p}$ = variabel bebas

e_t = nilai error pada periode t

(Montgomery, 2008)

2.8.2 Moving Average (MA)

Model *Moving Average* dinotasikan dalam MA (q) atau model ARIMA ($0, 0, q$) dinyatakan sebagai berikut.

$$\hat{y}_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.8)$$

dengan \hat{y}_t = nilai variabel pada waktu ke- t

$e_t, e_{t-1}, \dots, e_{t-q}$ = selisih nilai aktual dengan nilai peramalan

$\theta_1, \theta_2, \dots, \theta_q$ = parameter *moving average* orde q

(Montgomery, 2008)

2.8.3 Autoregressive Moving Average (ARMA)

Model ARMA (p, q) adalah gabungan dari model *autoregressive* (AR) dan *moving average* (MA). Secara umum bentuk persamaanya adalah sebagai berikut

$$\hat{y}_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (2.9)$$

(Montgomery, 2008)

2.8.4 Autoregressive *Integrated Moving Average* (ARIMA)

Model ARIMA adalah model dari ARMA (*autoregressive moving average*) yang tidak stasioner. Pada model ARMA (p, q) nonstasioner, dilakukan proses *differencing* (pembedahan) agar menjadi stasioner. Model ARMA dilakukan *differencing* sebanyak d kali sampai stasioner, sehingga model ARMA (p, q) menjadi model ARIMA (p, d, q) .

Model ARIMA (p, d, q) dapat dituliskan secara matematis, yaitu sebagai Berikut (Hyndman dan Athanasopoulos, 2018) :

$$\phi_p(B)(1 - B)^d y_t = \theta_q(B)e_t \quad (2.10)$$

dimana :

- $\phi_p(B) = (1 - \phi_1(B) - \dots - \phi_p(B)^p)$: Operator proses AR
- $\theta_q(B) = (1 - \theta_1(B) - \dots - \theta_q(B)^q)$: Operator proses MA
- B : Operator *Backshift*
- y_t : nilai variabel pada waktu ke- t
- $(1 - B)^d$: Operator pembeda
- d : Ordo *Differencing*

Persamaan (2.10) dapat diuraikan dalam bentuk lain, yaitu

$$\begin{aligned} (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d y_t &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)e_t \\ (y_t - \phi_1 y_{t-1} - \phi_2 y_{t-2} - \dots - \phi_p y_{t-p})(1 - B)^d \hat{y}_t &= e_t - \theta_1 e_{t-1} - \\ \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \end{aligned} \quad (2.11)$$

Untuk nilai $d=1$ dapat menggunakan ARIMA $(p, 1, q)$, yaitu sebagai berikut.

$$\begin{aligned} y_t - y_{t-1} &= \phi_1(y_{t-1} - y_{t-2}) + \phi_2(y_{t-2} - y_{t-3}) + \dots + \phi_p(y_{t-p} - y_{t-p-1}) + \\ e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \\ y_t &= (1 + \phi_1)y_{t-1} + (\phi_2 - \phi_1)y_{t-2} + (\phi_3 - \phi_2)y_{t-3} + \dots + (\phi_p - \phi_{p-1})y_{t-p} - \\ \phi_p y_{t-p-1} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \end{aligned} \quad (2.12)$$

2.9 Plot ACF dan PACF

Penentuan model sementara ARIMA dilakukan dengan identifikasi ordo ARIMA berdasarkan plot ACF dan PACF dari data yang telah stasioner. Penentuan ordo ARIMA ditampilkan pada tabel berikut.

Tabel 2.1 Penentuan ordo ARIMA

Orde	ACF	PACF
<i>White Noise</i>	Tidak ada yang melewati batas interval pada lag > 0	Tidak ada yang melewati batas interval pada lag > 0
AR(<i>p</i>)	Lag dalam autokorelasi turun secara eksponensial (<i>dies-down</i>).	PACF signifikan pada lag 1, 2, ..., <i>p</i> dan <i>cuts-off</i> setelah lag <i>p</i> .
MA(<i>q</i>)	ACF signifikan pada lag 1, 2, ..., <i>q</i> dan <i>cuts-off</i> setelah lag <i>q</i> .	Lag dalam autokorelasi parsial turun secara eksponensial (<i>dies-down</i>).
AR(<i>p</i>) atau MA(<i>q</i>)	ACF signifikan pada lag 1, 2, ..., <i>q</i> dan <i>cuts-off</i> setelah lag <i>q</i> .	PACF signifikan pada lag 1, 2, ..., <i>p</i> dan <i>cuts-off</i> setelah lag <i>p</i> .
ARMA(<i>p, q</i>)	Lag dalam autokorelasi turun secara eksponensial (<i>dies-down</i>).	Lag dalam autokorelasi parsial turun secara eksponensial (<i>dies-down</i>).
Tidak terdapat AR (<i>p</i>) atau MA (<i>q</i>)	Tidak ada lag yang signifikan pada ACF.	Tidak ada lag yang signifikan pada PACF.

(Bowerman dan O'Connel, 1993)

2.10 Ketepatan Metode Peramalan

Tujuan dilakukannya peramalan ialah untuk menghasilkan ramalan optimum yang tidak memiliki kesalahan (*error*) atau *error* yang kecil. Jika tingkat kesalahan yang dihasilkan semakin kecil, maka hasil peramalan akan semakin mendekati nilai *actual*. Menurut Lutkepohl dan Kratzig (2004) untuk menghitung kesalahan prediksi, alat ukur yang digunakan antara lain:

1. *Mean Absolute Percentage Error* (MAPE)

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|}{n} \times 100 \quad (2.13)$$

2. *Mean Square Error* (MSE)

$$MSE = \frac{\sum_{t=1}^n (A_t - F_t)^2}{n} \quad (2.14)$$

3. *Root Mean Square Error* (RMSE)

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (A_t - F_t)^2}{n}} \quad (2.15)$$

dengan

n = banyaknya data

A_t = data observasi pada waktu t

F_t = data hasil peramalan pada waktu t

2.12 Analisis Regresi Linear

Analisis regresi merupakan metode statistika yang banyak digunakan dalam penelitian. Istilah regresi pertama kali diperkenalkan oleh Sir Francis Galton pada tahun 1986. Regresi linear digunakan untuk membentuk model atau hubungan antara satu atau lebih variabel bebas (X) dengan variabel terikat (Y). Analisis regresi dengan satu variabel bebas (X) disebut dengan regresi linear sederhana, sedangkan jika terdapat lebih dari satu variabel bebas (X) disebut sebagai regresi linear berganda. Model regresi linear berganda, yaitu :

$$Y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (2.16)$$

dengan

Y : Variabel terikat

α : Konstanta (nilai Y apabila $x_1, x_2, \dots, x_k = 0$)

$\beta_1, \beta_2, \dots, \beta_k$: Koefisien regresi

x_1, x_2, \dots, x_k : Variabel bebas

ε : Error

(Draper and Smith, 1992)

2.13 Uji Asumsi Klasik

Suatu model regresi dapat dikatakan sebagai model yang baik jika memenuhi kriteria BLUE (*Best Linear Unbias Estimator*). *Unbias* atau tidak bias artinya nilai yang diharapkan sama dengan nilai sebenarnya. BLUE dapat dicapai bila memenuhi Asumsi Klasik (Gujarati, 2004).

Menurut Ghozali (2011) tujuan pengujian asumsi klasik, yaitu untuk memberikan kepastian bahwa persamaan regresi yang diperoleh memiliki ketepatan

dalam estimasi, tidak bias dan konsisten. Adapun asumsi yang harus dipenuhi dalam model regresi antara lain:

a. Uji Multikolinieritas

Salah satu syarat model regresi yang baik adalah tidak terjadi korelasi yang tinggi diantara variabel bebas. *VIF* (*Variance Inflation Factor*) merupakan salah satu cara untuk mengukur besar kolinieritas dan dapat dituliskan sebagai berikut:

$$VIF = \frac{1}{1-R_j^2} \quad (2.17)$$

dimana R_j^2 adalah koefisien determinasi regresi. $j = 1, 2, \dots, k$ dan k adalah banyaknya variabel bebas. Jika nilai $VIF < 10$ maka pengujian tidak terdapat multikolinieritas (Gujarati, 2004).

b. Uji Normalitas

Uji normalitas residu berguna untuk mengetahui apakah dalam persamaan regresi tersebut residual berdistribusi normal. Pengujian residu dapat dilakukan dengan analisis grafik *normal probability plot*. Jika residu berdistribusi normal, maka residu akan berada disekitar garis diagonal. Sebaliknya jika residu tidak berdistribusi normal, maka residu akan menyebar. (Ghozali, 2011).

c. Uji Heteroskedastisitas

Uji heteroskedastisitas bertujuan untuk menguji ketidaksamaan varians setiap sisaan (e_i) dari residual antar pengamatan. Model regresi yang baik adalah model yang homoskedastisitas atau tidak terjadi heteroskedastisitas. Model regresi dikatakan tidak terjadi heteroskedastisitas jika nilai *p-value* hasil uji heteroskedastisitas lebih dari $\alpha = 0,05$ atau dalam matematis dapat dituliskan sebagai berikut (Gujarati, 2004) :

$$Var(e_i) = \sigma^2, i = 1, 2, \dots, n \quad (2.18)$$

d. Uji Autokorelasi

Asumsi lainnya dari regresi linear adalah tidak terdapat autokorelasi. Model regresi yang baik adalah model yang tidak terjadi autokorelasi. Adapun hipotesis yang digunakan dalam uji ini ialah:

H_0 : Tidak terdapat autokorelasi

H_1 : Terdapat autokorelasi

Autokorelasi dapat juga dilihat pada nilai *p value*. Jika nilai *p value* $> \alpha$ artinya tolak H_0 . Dengan $\alpha = 0,05$ (taraf signifikansi). Menurut Gujarati (2004)

Jika terdapat autokorelasi, nilai parameter estimator model persamaan regresi tetap linear dan tidak bias atau *Linear Unbias Estimator (LUE)* dalam memprediksi nilai parameter sebenarnya. Tetapi nilai varians tidak minimum dan akan bias.

2.14 Penelitian Terdahulu

Berikut adalah rangkuman hasil penelitian terdahulu yang memiliki keterkaitan dengan penelitian yang telah dilakukan.

Tabel 2.2 Penelitian terdahulu

No	Nama dan Tahun Publikasi	Hasil
1	Ahmed dkk, 2012	Metode : Analisis Regresi Berganda Hasil : Faktor suhu udara berpengaruh signifikan pada permintaan listrik terlebih pada saat musim panas dan dingin.
2	Anwar. S, 2017	Metode : <i>Autoregressive Integrated Moving Average (ARIMA)</i> Hasil : Model ARIMA terbaik untuk meramalkan suhu udara harian minimum dan maksimum di Kota Banda Aceh adalah model ARIMA (0,2,5) dan ARIMA (0,2,3).
3	Machmudin dan Ulama, 2012	Metode : ARIMA dan <i>Artificial Neural Network</i> Hasil : Model ARIMA untuk temperatur Kota Surabaya adalah ARIMA (0,1,2). Sedangkan model <i>Artifial Neural Network</i> menghasilkan model FFNN (5,10,1).