

BAB 2

TINJAUAN PUSTAKA

Pada bab ini akan dijelaskan mengenai tinjauan pustaka dan teori yang terkait dengan penelitian Tugas Akhir ini.

21 Energi Listrik

Energi yang sangat bermanfaat dalam kebutuhan hidup masyarakat masa kini adalah energi listrik. Pengertian energi listrik adalah energi akhir yang dibutuhkan bagi peralatan listrik untuk menggerakkan motor, lampu penerangan, memanaskan, mendinginkan ataupun untuk menggerakkan motor, lampu penerangan, memanaskan, mendinginkan ataupun untuk menggerakkan kembali suatu peralatan mekanik untuk menghasilkan bentuk energi yang lain. Energi yang dihasilkan dapat berasal dari berbagai sumber, seperti air, minyak, batu bara, angin, panas bumi, nuklir, matahari, dan lainnya. Energi ini besarnya dari beberapa volt sampai ribuan hingga jutaan volt (Gardina, 2012).

Permasalahan dalam sistem tenaga listrik membentuk pola beban listrik yang fluktuatif di berbagai sektor, maka perlu adanya karakteristik beban tenaga listrik untuk mengetahui secara detail permasalahan yang ada di industri tenaga listrik. Karakteristik beban biasa disebut dengan pola pembebanan. Pada sektor rumah tangga terdapat adanya fluktuasi konsumsi energi listrik yang cukup besar. Hal ini disebabkan konsumsi energi listrik tersebut dominan pada malam hari. Sedangkan pada sektor industri fluktuasi konsumsi energi sepanjang hari akan hampir sama, sehingga perbandingan beban puncak terhadap beban rata-rata hampir mendekati satu. Beban pada sektor komersial dan usaha memiliki karakteristik yang hampir sama, tetapi pada sektor komersial mempunyai beban puncak yang tinggi pada malam hari (Adijwi, 2016).

Menurut Adijwi dkk (2016), karakteristik beban berdasarkan jenis konsumen di bagi menjadi empat: beban komersial, beban industri beban fasilitas umum dan beban rumah tangga. Perbedaan dari empat jenis beban diatas adalah dari daya yang digunakan dan juga waktu pembebanannya. Pemakaian daya pada beban rumah

www.itk.ac.id

tangga akan lebih banyak pada pagi dan malam hari, sedangkan pada beban komersil lebih banyak pada siang dan sore hari. Pemakaian daya pada industri akan lebih merata, karena banyak industri yang bekerja siang-malam. Sehingga jelas diketahui bahwa pemakaian daya pada industri akan lebih menguntungkan karena kurva bebannya akan lebih merata. Sedangkan pada beban fasilitas umum lebih banyak pada siang dan malam hari, contohnya seperti tempat wisata. Pelanggan bisnis sangat mempengaruhi penjualan kWh walaupun jumlah pelanggan bisnis jauh lebih kecil dibanding dengan pelanggan rumah tangga tetapi tetap lebih banyak penggunaan beban listrik di sektor rumah tangga.

2.2 Peramalan (*Forecasting*)

Peramalan (*Forecasting*) adalah objektif ilmiah (*scientific*), yang bisa dilakukan berulang-ulang (*reproducible*), bebas dari praduga individu, dan ada kemungkinan *error* di dalamnya yang mengacu pada tingkat besaran (*measurement*). Peramalan ada dua jenis yaitu, peramalan secara kualitatif dan peramalan secara kuantitatif. Peramalan kualitatif adalah peramalan dengan analisis data dinyatakan tidak berbentuk angka yaitu berupa data nominal. Sedangkan, peramalan kuantitatif adalah peramalan dengan analisis data menggunakan data-data berupa angka diperoleh melalui pengukuran yaitu data interval dan rasio (Hidayatul, 2015).

2.3 Analisis *Time Series* (Deret Waktu) Stasioner dan Tak Stasioner

Time series merupakan suatu himpunan pengamatan yang dibangun secara berurutan dalam waktu. Waktu atau periode yang dibutuhkan dalam melakukan peramalan biasanya disebut dengan *lead time* yang bervariasi untuk setiap persoalan. Berdasarkan himpunan pengamatan yang tersedia maka *time series* terbagi menjadi dua pengamatan yaitu pengamatan kontinu dan diskrit (Jenkins et. al, 1976). Jenkins (1976), menotasikan $\hat{Z}_t(l)$ sebagai peramalan terhadap awal pengamatan waktu (t) yang dimisalkan terhadap data penjualan, Z_{t+1} yang terjadi saat *lead time* (l). Fungsi $\hat{Z}_t(l)$, $l = 1, 2, 3, \dots$ disebut sebagai fungsi peramalan pada awal pengamatan. Pembangunan data untuk *time series* diskrit memiliki 2 langkah, yaitu:

www.itk.ac.id

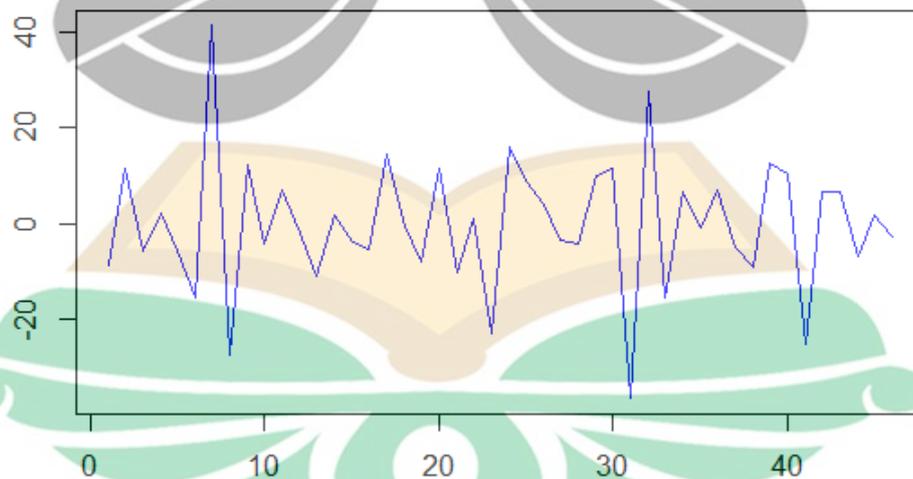
1. Melalui *sampling* dari deret waktu kontinu, yang memiliki arti sebuah data

yang kontinu diambil sampelnya dalam interval waktu yang sama.

2. Melalui akumulasi peubah dalam suatu waktu tertentu. Contohnya, curah hujan yang biasanya diakumulasikan melalui suatu periode waktu tertentu (hari, bulan, dan seterusnya).

Stasioneritas data merupakan kriteria yang sangat penting. Data *time series* dikatakan sangat stasioner jika sifatnya tidak dipengaruhi oleh perubahan asal waktu. Dengan kata lain, jika distribusi probabilitas gabungan dari pengamatan $Z_t, Z_{t+1}, \dots, Z_{t+n}$ persis sama dengan distribusi probabilitas gabungan dari pengamatan $Z_{t+k}, Z_{t+k+1}, \dots, Z_{t+k+n}$ maka data *time series* terbukti stasioner. Ketika $n = 0$, asumsi stasioneritas memiliki arti bahwa distribusi probabilitas Z_t sama untuk semua periode waktu dan dapat juga dituliskan sebagai $f(Z)$. *Time series* juga dikatakan stasioner apabila tidak ada unsur *trend* di dalam data, tidak terdapat unsur musiman atau rata-rata dan variannya tetap. Selain plot *time series*, stasioneritas data juga dapat dilihat dari tiga hal berikut:

1. Nilai ekspektasi dari *time series* yang tidak bergantung pada waktu.
2. Fungsi autokovarians yang didefinisikan sebagai $\text{Cov}(Z_t, Z_{t+k})$, untuk setiap *lag-k* hanya dari k , yaitu $Z_y(k) = \text{Cov}(Z_t, Z_{t+k})$.
3. Fungsi autokorelasi yang turun secara lambat.



Gambar 2.1 Stasioner *time series*

Dari Gambar 2.1 dapat disimpulkan bahwa data stasioner merupakan data yang relatif konstan, dapat dilihat dari plot data yang menyebar disekitaran rata-rata serta ragamnya konstan. Menurut Montgomery et.all (2008), deret waktu yang

menunjukkan *trend* merupakan salah satu deret waktu yang tidak stasioner. *Trend* artinya plot data menyebar membentuk suatu kecenderungan menaik ataupun menurun secara konstan. Pemodelan dan peramalan dari deret waktu tersebut dapat disederhanakan jika dihilangkan trendnya. Salah satu cara untuk melakukannya adalah dengan menyesuaikan model regresi yang menggambarkan *trend* ke data lalu menguranginya dari pengamatan asli, kemudian tersisa satu kumpulan data yang bebas dari *trend*. Model *trend* yang biasanya digunakan adalah *linear trend*, dimana rata-rata Z_t diharapkan berubah secara linier seiring waktu seperti persamaan berikut ini.

$$E(Z_t) = \beta_0 + \beta_1 t . \quad (2.1)$$

2.4 ACF dan PACF

Analisis *time series* (deret waktu) memiliki tahapan analisis dengan syarat salah satu asumsi harus dipenuhi dan layak dari sebuah deret data dilakukan analisis regresi deret waktu adalah adanya autokorelasi antar pengamatan. Analisis deret waktu terdapat dua jenis korelasi yaitu autokorelasi (ACF) dan parsial autokorelasi (PACF).

2.4.1 Autocorrelation Function (ACF)

Menurut Wei (2006), untuk deret waktu yang diamati Z_1, Z_2, \dots, Z_n , ACF didefinisikan sebagai berikut.

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} , \quad k = 0, 1, 2, \dots \quad (2.2)$$

$\bar{Z} = \sum_{t=1}^n \frac{Z_t}{n}$, adalah sampel rata-rata. Plot dari $\hat{\rho}_k$ biasanya disebut dengan sampel korelasi. Untuk proses stasioner Gaussian dapat ditunjukkan bahwa untuk $k > 0$ dan $k + j > 0$,

$$\begin{aligned} Cov(\hat{\rho}_k, \hat{\rho}_{k+j}) \approx & \frac{1}{n} \sum_{i=-\infty}^{\infty} \rho_i \rho_{i+j} + \rho_{i+k+j} \rho_{i-k} - 2\rho_k \rho_i \rho_{i-k-j} \\ & - 2\rho_{k+j} \rho_i \rho_{i-k} + 2\rho_k \rho_{k+j} \rho_i^2 . \end{aligned} \quad (2.3)$$

$\hat{\rho}_k$ diaproksimasikan terdistribusi normal dengan rata-rata $\hat{\rho}_k$ dan variansi.

$$Var(\hat{\rho}_k) \approx \frac{1}{n} \sum_{i=-\infty}^{\infty} \rho_i^2 + \rho_{i+k}\rho_{i-k} - 4\rho_k\rho_i\rho_{i-k} + 2\rho_k^2\rho_i^2. \quad (2.4)$$

Saat $\rho_k = 0$ untuk $k > m$, perkiraan Bartlett's pada persamaan(2.4) menjadi

$$Var(\hat{\rho}_k) \approx \frac{1}{n} (1 + 2\rho_1^2 + 2\rho_2^2 + \dots + 2\rho_m^2). \quad (2.5)$$

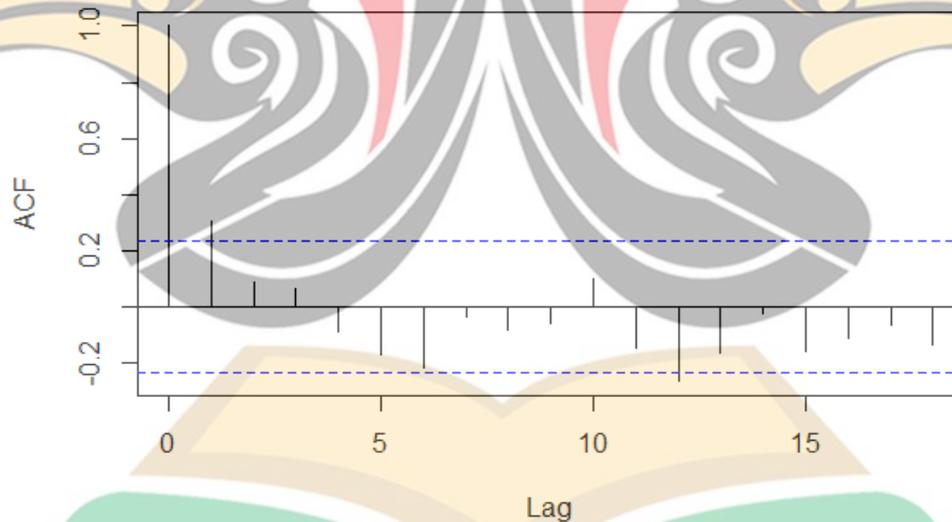
Kemudian diterapkan, ρ_i ($i = 1,2,3,\dots,m$) tidak diketahui dan digantikan oleh perkiraan sampel $\hat{\rho}_i$, dan terdapat lag besar standar eror dari $\hat{\rho}_k$,

$$S_{\hat{\rho}_k} = \sqrt{\frac{1}{n} (1 + 2\hat{\rho}_1^2 + 2\hat{\rho}_2^2 + \dots + 2\hat{\rho}_m^2)}. \quad (2.6)$$

Jika menguji proses *white noise*, maka kita gunakan

$$S_{\hat{\rho}_k} = \sqrt{\frac{1}{n}}. \quad (2.7)$$

Berikut merupakan gambar Fungsi ACF.



Gambar 2.2 Autocorrelation function

Pada Gambar 2.2 dapat disimpulkan bahwa ACF memotong pada lag 1 kemudian ACF turun secara eksponensial melewati batas garis UCL (*Upper Confidence Limit*) dan LCL (*Lower Confidence Limit*).

2.4.2 Partial Autocorrelation Function (PACF)

Autokorelasi parsial (PACF) adalah korelasi antara Z_t dan Z_{t+k} dengan mengabaikan ketidakbebasan $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$. Fungsi autokorelasi parsial Z_t

dan dapat diturunkan dari model regresi linier, dengan variabel *dependent* dan *independent* $Z_{t+k-1}, Z_{t+k-2}, \dots, Z_t$ seperti berikut.

$$(2.8)$$

dimana adalah parameter regresi ke- i untuk $i = 1, 2, \dots, k$ dan . merupakan residu dengan rata-rata nol dan tidak berkorelasi dengan untuk $j = 1, 2, \dots, k$. dengan mengalikan pada kedua ruas persamaan (2.8) dan menghitung nilai nol harapannya (*expected value*), diperoleh seperti berikut

$$(2.9)$$

dan

$$(2.10)$$

Saat $j = 1, 2, \dots, k$, diperoleh sistem persamaan berikut.

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

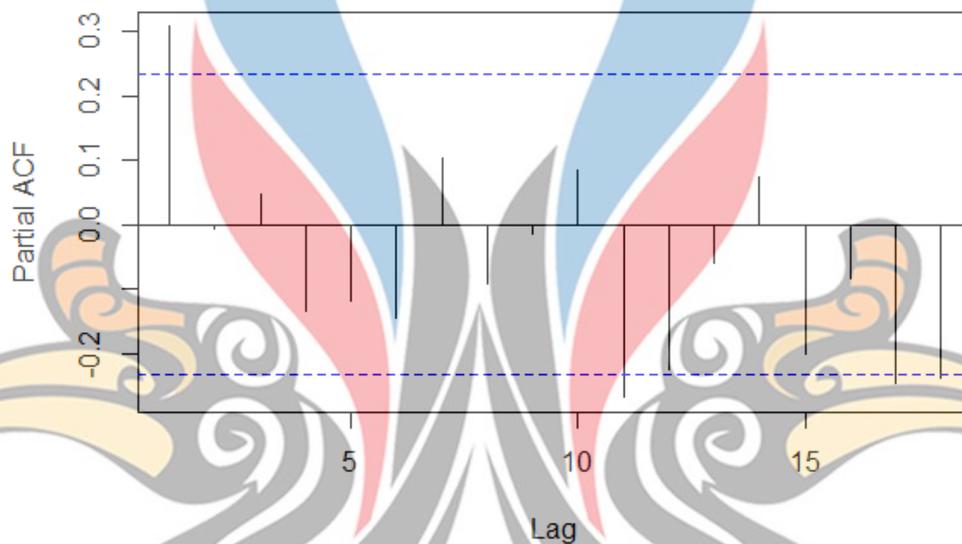
$$\begin{array}{|c|c|} \hline & \\ \hline & \\ \hline \rho & \\ \hline \rho & \\ \hline \end{array}$$

www.itk.ac.id

www.itk.ac.id

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & 1 \end{vmatrix}} \quad (2.11)$$

ϕ_{kk} merupakan fungsi atas k , maka ϕ_{kk} disebut fungsi autokorelasi parsial (*PACF*) (Wei, 2006). Berikut merupakan gambar Fungsi *PACF*.



Gambar 2.3 *Partial Autocorrelation*

Gambar 2.3 dapat disimpulkan bahwa *PACF* memotong saat lag 1, *PACF* turun secara eksponensial melewati batas garis *UCL* (*Upper Confidence Limit*) dan *LCL* (*Lower Confidence Limit*).

2.5 Model-model Deret Waktu (*Time Series*)

Model-model deret waktu terbagi menjadi dua jenis, yaitu stasioner dan tak stasioner. Pengertian dari kedua jenis tersebut telah di jelaskan pada subbab sebelumnya. Model yang termasuk ke dalam kategori stasioner ini adalah *AR* (*Autoregressive*), *MA* (*Moving Average*) dan *ARMA* (*Autoregressive Moving Average*). Sedangkan, model yang termasuk dalam kategori ketakstasioner adalah *ARIMA* (*Autoregressive Integreted Moving Average*).

2.5.1 AR (Autoregressive)

Model stokastik yang sangat berguna dalam representasi deret secara praktis adalah model autoregresi (AR). Model AR didefinisikan sebagai berikut

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + a_t. \quad (2.12)$$

Model tersebut menyatakan hubungan antara peubah tak bebas Z terhadap himpunan peubah bebas $\tilde{Z}_{t-1}, \tilde{Z}_{t-2}, \dots, \tilde{Z}_{t-p}$ ditambah sebuah suku yang menyatakan eror a_t , model AR sering dinyatakan sebagai model regresi dan dikatakan Z diregresikan terhadap $\tilde{Z}_{t-1}, \tilde{Z}_{t-2}, \dots, \tilde{Z}_{t-p}$. Pada persamaan (2.12) Z diregresikan terhadap nilai-nilai sebelumnya dari peubah Z itu sendiri, karena itulah model ini dikatakan sebagai model autoregresif (Jenkins et. all, 1976).

2.5.2 MA (Moving Average)

Model autoregresif pada persamaan (2.12) menyatakan deviasi \tilde{Z}_t dari proses sebagai jumlah bobot yang terbatas dari deviasi p sebelumnya yaitu $\tilde{Z}_{t-1}, \tilde{Z}_{t-2}, \dots, \tilde{Z}_{t-p}$ dengan standar eror a_t . Secara ekuivalen, \tilde{Z}_t dinyatakan sebagai jumlah berbobot yang tak terbatas dari a . Model MA didefinisikan sebagai berikut.

$$\tilde{Z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}. \quad (2.13)$$

\tilde{Z}_t tak bebas linier pada jumlahan berhingga q dari nilai-nilai a sebelumnya (Jenkins et. all, 1976).

2.5.3 ARMA (Autoregressive Moving Average)

Model ini merupakan gabungan antara AR(p) dengan MA(q), sehingga dinyatakan sebagai ARMA(p, q), dengan bentuk umumnya:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + a_t + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q}. \quad (2.14)$$

Kemudian persamaan (2.14) menjadi:

$$\tilde{Z}_t - \phi_1 \tilde{Z}_{t-1} - \dots - \phi_p \tilde{Z}_{t-p} = a_t + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q}. \quad (2.15)$$

Persamaan (2.15) dapat ditulis dengan menggunakan operator B (*backshift*), menjadi:

$$(1 - \phi_1 B - \dots - \phi_p B^p) \tilde{Z}_t = (1 + \theta_1 B + \dots + \theta_q B^q) a_t .$$

Sehingga diperoleh

$$\Phi(B) \tilde{Z}_t = \theta(B) a_t . \tag{2.16}$$

Model ini terdiri dari $p + q + 2$ parameter yang tak diketahui perlu diestimasi dari data. Pada kenyataannya, seringkali suatu *time series* stasioner dapat direpresentasikan dengan AR, MA, atau ARMA dengan p, q yang tidak lebih dari 2 (Jenkins et. all, 1976).

2.5.4 ARIMA (*Autoregressive Integrated Moving Average*)

Model ARIMA adalah model yang telah melalui proses *differencing*. Bentuk umum persamaan dari model ARIMA pada orde ke- p, q dengan proses *differencing* sebanyak d adalah sebagai berikut.

$$\phi_p(B)(1 - B)^d \tilde{Z}_t = \theta_q(B) a_t , \tag{2.17}$$

dengan

$$\phi_p(B) = (1 - \phi_1 B^1 - \dots - \phi_p B^p) , \tag{2.18}$$

dan

$$\theta_p(B) = (1 - \theta_1 B^1 - \dots - \theta_q B^q) , \tag{2.19}$$

Identifikasi model ARIMA dapat dilakukan dengan melihat plot *time series*, plot ACF dan PACF yang digunakan untuk menentukan orde p dan q dari model ARIMA (Montgomery et. All, 2008). Diambil sebuah contoh, model ARIMA (1,1,1) dapat di modelkan sebagai berikut:

$$(1 - B)(1 - \phi_1 B) \tilde{Z}_t = (1 + \theta_1 B) a_t . \tag{2.20}$$

Tabel 2.1 Perilaku teoritis ACF dan PACF untuk proses stasioner

Model	ACF	PACF
AR (p)	Menurun secara eksponensial/sinusoidal	Terputus setelah lag p
MA (q)	Terputus setelah lag q	Menurun secara eksponensial/sinusoidal
ARMA (p, q)	Menurun setelah lag p atau q	Menurun setelah lag p atau q

2.6 Seasonal ARIMA (Autoregressive Integrated Moving Average)

Menurut Montgomery et. all (2008), beberapa variabel *time series* menunjukkan adanya pola periodik yang kuat. Hal ini biasanya disebut sebagai *seasonal time series* atau deret waktu yang memiliki sifat musiman. *Time series* dengan sifat musiman terutama terjadi saat variabel yang diambil lebih spesifik dalam interval bulanan, mingguan dan sebagainya. *Time series* yang memiliki perilaku musiman sering disebut sebagai *Seasonal ARIMA* atau *SARIMA*. Oleh karena itu, model *SARIMA* tersebut merupakan perluasan dari model dasar *ARIMA*. Berikut adalah persamaan *Seasonal ARIMA* dengan notasi menggunakan periode sebagai berikut.

$$\phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D Z_t = \delta + \Theta_Q(B^s)\theta_q(B)a_t. \quad (2.21)$$

Keterangan:

- δ = *intercept*,
- Z_t = nilai variabel respon pada waktu ke- t ,
- $(1-B)^d$ = *integrated*,
- $\phi_p(B)$ = parameter *Autoregressive* orde ke- p ,
- $\theta_q(B)$ = parameter *Moving Average* orde ke- q ,
- $(1-B^s)^D$ = *seasonal integrated*,
- $\Phi_P(B^s)$ = $1 - \Phi_1 B - \dots - \Phi_P B^{Ps}$,
- $\Theta_Q(B^s)$ = $1 - \Theta_1 B - \dots - \Theta_Q B^{Qs}$,
- a_t = nilai kesalahan pada waktu ke- t ,
- s = *seasonal*,
- d = *regular differencing*,
- D = *seasonal differencing*.

Berikut adalah contoh dari persamaan (2.21) dengan menggunakan model *SARIMA* (1,1,1)(1,1,0)¹².

$$\begin{aligned} \phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D Z_t &= \delta + \Theta_Q(B^s)\theta_q(B)a_t \\ (1-\phi B)(1-\Phi B^{12})(1-B)^1(1-B^{12})^1 Z_t &= (1-\theta B)a_t \\ (1-\Phi B^{12}-\phi B+\phi \cdot \Phi B^{13})(1-B)(1-B^{12}) Z_t &= (1-\theta B)a_t \\ (1-\Phi B^{12}-\phi B+\phi \cdot \Phi B^{13})(1-B) Z_t &= (1-\theta B)a_t \\ (1-\Phi B^{12}-\phi B+\phi \cdot \Phi B^{13})(1-B^{12}-B+B^{13}) Z_t &= (1-\theta B)a_t \end{aligned}$$

$$(1 - \Phi B^{12} - \phi B + \phi \cdot \Phi B^{13}) - B + \Phi B^{13} + \phi B^2 - \phi \cdot \Phi B^{14} - B^{12} + \Phi B^{24} Z_t + \phi B^{13} - \phi \cdot \Phi B^{26} + B^{13} - \Phi B^{26} - \phi B^{15} + \phi \cdot \Phi B^{26}) Z_t = (1 - \theta B) a_t$$

$$Z_t = \phi Z_{t-1} + Z_{t-1} - \phi Z_{t-2} + \Phi Z_{t-12} - \phi \cdot \Phi Z_{t-13} - \Phi Z_{t-13} - \phi Z_{t-13} - Z_{t-13} + \phi \cdot \Phi Z_{t-14} + \phi Z_{t-15} - \Phi Z_{t-24} + \Phi Z_{t-26} + \phi \cdot \Phi Z_{t-26} - \phi \cdot \Phi Z_{t-26} + \theta a_{t-1} + a_t$$

Adapun langkah-langkah dalam peramalan dengan metode *Seasonal ARIMA*, yaitu:

a. Identifikasi Data dan Model

Pada langkah ini dilakukan plot *time series*, *ACF* dan *PACF*. Jika data *time series* tidak stasioner maka perlu dilakukan *differencing* atau pembedaan.

1. Proses *Differencing*

Differencing (pembedaan) dilakukan untuk membuat data non stasioner menjadi data yang stasioner. Operator *shift* mundur (*backward shift*) sangat tepat untuk menggambarkan proses *differencing*. Penggunaan *backward shift* adalah sebagai berikut:

$$BY_t = Y_{t-1}. \quad (2.22)$$

Keterangan:

Y_t : Nilai variabel Y pada waktu t ,

Y_{t-1} : Nilai variabel Y pada waktu $t-1$,

B : *Backward shift*.

Notasi B yang dipasang pada Y memiliki pengaruh untuk menggeser data satu waktu ke belakang. Sebagai contoh, jika suatu data deret waktu non stasioner maka data tersebut dapat dibuat mendekati stasioner dengan melakukan *differencing* orde pertama, yaitu:

$$Y'_t = Y_t - Y_{t-1}, \quad (2.23)$$

Y'_t adalah nilai variabel Y pada waktu t setelah *differencing* dengan menggunakan *backward shift*, persamaan (2.23) dapat ditulis sebagai berikut:

$$Y'_t = (1 - B)Y_t. \quad (2.24)$$

Differencing pertama pada persamaan (2.24) dinyatakan sebagai $(1 - B)$ (Makridakis, 1999).

2. Uji ADF (*Augmented Dickey-Fuller*)

Uji stasioner yang digunakan pada penelitian ini adalah uji ADF (*Augmented Dickey-Fuller*) dengan hipotesis sebagai berikut:

H_0 : data *time series* tidak stasioner,

H_1 : data *time series* stasioner.

Kriteria Pengujian:

P -value < α atau taraf signifikan, pada penelitian ini menggunakan taraf signifikan atau α sebesar 0,05 atau 5%. Jika P -value < α maka tolak H_0 dengan kata lain data *time series* stasioner (Anis, 2020). Jika data telah stasioner maka dapat ditetapkan sebuah model yang telah diketahui orde AR, orde I, orde MA Nonseasonal dan orde AR, orde I, orde MA Seasonal. Ada dua jenis pola pada ACF dan PACF yaitu, pola *cut off* adalah pola yang membentuk *lag* menurun drastis dan pola *dying down* adalah pola yang perlahan *lag*-nya menuju nol atau membentuk sinusoidal.

Menurut Hynmand (2018) menentukan orde musiman AR atau MA akan terlihat pada *lag* musiman PACF dan ACF. Misalnya, ARIMA (0,0,0)(0,0,1)¹², model tersebut akan menunjukkan lonjakan *lag* 12 di ACF tetapi tidak ada lonjakan yang signifikan di *lag* lainnya. Terjadinya peluruhan eksponensial pada *lag* musiman PACF (mengidentifikasi pada *lag* 12,24,36,...). Penentuan orde *seasonal* yang sesuai untuk model Seasonal ARIMA, perlu membatasi perhatian pada *lag* musiman.

b. Uji Signifikansi Parameter

Uji ini dilakukan untuk mengetahui apakah nilai estimator signifikan atau tidak. Estimator yang tidak signifikan maka akan dikeluarkan dari model lalu dilakukan estimasi parameter selanjutnya untuk model dengan estimator yang sudah signifikan. Secara umum, dimisalkan θ adalah salah satu parameter SARIMA dan $\hat{\theta}$ adalah nilai taksiran dari parameter tersebut, maka uji signifikansi dapat dilakukan dengan hipotesis sebagai berikut:

Hipotesis:

H_0 : $\theta = 0$

H_1 : $\theta \neq 0$

Uji signifikansi dapat menggunakan uji t atau dengan $p\text{-value} < \alpha$, jika H_0 ditolak maka parameter signifikan begitu pun sebaliknya (Zahroh, 2010). Tahapan *overfitting* adalah tahapan yang dilakukan apabila diperlukan model yang lebih luas dengan membandingkan beberapa model yang telah diduga dengan model *overfitting* untuk melihat model mana yang terbaik untuk peramalan (Gatri dkk, 2017).

c. Pengujian Diagnostik

Pengujian diagnostik dilakukan untuk membuktikan kecukupan model. Terdapat dua asumsi yang harus dipenuhi yaitu, residual harus *white noise* dan berdistribusi normal. Berikut penjelasannya:

1. Uji Residual *White Noise*

White Noise adalah tidak adanya korelasi pada deret residual. Uji *white noise* suatu model dikatakan baik jika nilai *error* yang bersifat acak menunjukkan tidak terdapatnya autokorelasi yang memiliki arti bahwa residual tidak berpola tertentu. Cara melihat proses *white noise* pada model yaitu dengan menggunakan uji *Ljung-Box*.

Hipotesis :

H_0 : data tidak memenuhi asumsi *white noise*,

H_1 : data memenuhi asumsi *white noise*.

Kriteria Pengujian :

Nilai signifikansi ($p\text{-value}$) pada *Ljung-Box* $> \alpha = 0,05$ maka tolak H_0 (Bintang, 2018).

2. Uji Normalitas *Kolmogorov-Smirnov*

Uji *Kolmogorov-Smirnov* merupakan salah satu uji normalitas yang akan digunakan pada penelitian ini dengan hipotesis sebagai berikut:

H_0 : data tidak mengikuti persebaran garis normal,

H_1 : data mengikuti persebaran garis normal.

Statistik Uji:

$$D = \sup x |S(x) - F_0(x)| . \quad (2.25)$$

dimana:

$F_0(x)$ = Fungsi yang diduga berdistribusi normal,

$S(x)$ = Fungsi distribusi kumulatif dari data asal,

www.itk.ac.id

Kriteria Pengujian:

Jika $D_{hitung} > D_{tabel}$ atau jika $p\text{-value} > \alpha = 0,05$ maka keputusan tolak H_0 (Mutmainnah, 2019).

2.7 Penentuan Model Terbaik

Penentuan model terbaik dapat dilakukan berdasarkan nilai AIC (*Akaike's Information Criterion*). AIC merupakan kriteria yang menyediakan ukuran informasi yang dapat menyeimbangkan ukuran kebaikan dan efisiensi suatu model. Model yang dipilih berdasarkan nilai AIC yang terkecil.

$$AIC = n \ln \hat{\sigma}_\varepsilon^2 + 2(p + q + 1). \quad (2.26)$$

Keterangan:

$$\hat{\sigma}_\varepsilon^2 = \frac{SSE}{n},$$

n = banyaknya pengamatan,

p = orde AR ,

q = orde MA .

(Rosadi, 2010)

2.8 Ketepatan Model Peramalan

Pada proses peramalan tidak menutup kemungkinan akan terjadinya suatu kesalahan, seperti yang diketahui bahwa tidak ada metode peramalan yang dapat memprediksi suatu kejadian secara akurat di masa yang akan datang atau pada periode berikutnya. Adapun beberapa faktor yang mempengaruhi terjadinya penyimpangan pada peramalan tersebut, seperti terdapat adanya *outlier*, komponen *trend*, komponen musiman, ataupun komponen siklus yang terdapat pada data yang memungkinkan bahwa metode yang digunakan tidak tepat. Pada penelitian ini dalam mengukur ketepatan suatu model menggunakan metode $MAPE$ (*Mean Absolute Percentage Error*).

$MAPE$ atau biasa disebut rata-rata penyimpangan persentase *absolute* merupakan perhitungan antara data *actual* dengan data *predict* yang kemudian

dimutlakkan dan dihitung dalam bentuk persentase. Hasil persentase tersebut kemudian didapat *mean*-nya. Suatu model dikatakan memiliki tingkat keakuratan yang tinggi jika persentasenya dibawah 10% atau diantara 10%-20% (Mutmainnah, 2019). Berikut adalah persamaannya:

$$MAPE = \frac{\sum_{t=1}^n |PE_t|}{n}, \quad (2.27)$$

dimana,

$$PE_t = \frac{actual_t - predict_t}{actual_t} \times 100\%. \quad (2.28)$$

Keterangan:

PE_t = Percentage Error,

n = Jumlah data.

2.9 Penelitian Terdahulu

Berikut adalah ringkasan hasil dari penelitian terdahulu yang memiliki keterkaitan dengan penelitian yang akan dilakukan.

Tabel 2.2 Penelitian terdahulu

No	Nama dan Tahun Publikasi	Hasil
1	James et. all, 2013	Metode : <i>Short-term Forecasting of Anomalous Load Using Rule-based Triple Saesonal Method</i> Hasil : Evaluasi empat kelas yang berbeda dari pemodelan univariat pendekatan, ketika digunakan bersama dengan empat berbeda aturan Metode HWT berbasis aturan baru memiliki daya tarik kesederhanaan bila dibandingkan dengan versi berbasis aturan Metode SARMA, ANN dan SVD, keduanya dalam hal model struktur dan jumlah parameter. Secara keseluruhan, kombinasi dari metode HWT dan SARMA berbasis aturan paling akurat.
2	Kim et. all 2000	Metode : <i>Short-Term Load Forecasting for Special Days in Anomalous Load Conditions Using Neural Networks and Fuzzy Inference Method.</i> Hasil : Metode peramalan <i>Fuzzy Inference Method</i> dapat memberikan peningkatan yang cukup dari akurasi peramalan untuk hari-hari khusus. Oleh karena itu, jika metode ini diterapkan pada sistem peramalan untuk hari-hari khusus dalam kondisi beban anomali, ia dapat secara efektif mendukung sistem peramalan beban

jangka pendek konvensional dan peramal manusia.

3 Kim et. all
2013

Metode : *Modelling special-day effects for forecasting intraday electricity demand*

Hasil : Model yang didapat terbukti dalam analisis empiris dan diverifikasi lebih lanjut melalui distribusi dua variabel yang menentukan efek hari-khusus berbasis per jam melalui perbandingan grafis sederhana. Dengan demikian, studi empiris menunjukkan bahwa pendekatan pemodelan hari khusus berbasis jam memberikan hasil perkiraan yang lebih baik daripada banyak model benchmark, termasuk pendekatan pemodelan hari spesial berbasis harian.

4 Hidayatul dkk.
2015

Metode : Peramalan Beban Jangka Pendek Hari Libur Nasional dengan *Interval Type-2 Fuzzy Inference System* pada Sistem Jawa-Bali

Hasil : Penggunaan *Interval Type-2 Fuzzy inference System (IT2FIS)* untuk peramalan beban jangka pendek pada hari libur nasional studi kasus Sistem kelistrikan Jawa Bali , menunjukkan nilai *mean absolute perstage error (MAPE)* lebih kecil dibandingkan menggunakan *Interval Type-1 Fuzzy Inference System*. Nilai MAPE lebih kecil pada T2FIS dibandingkan T1FIS, menunjukkan metode T2FIS lebih baik untuk menyelesaikan kasus ini.

