



JURNAL SUTET

Volume 7 - Nomor 2

Juni - Desember 2017

ISSN : 2356-1505

PENGARUH RUGI-RUGI SALURAN PADA JARINGAN TRANSMISI TEGANGAN MENENGAH
PENYULANG E2 GARDU INDUK EMBALUT TENGGARONG

Juara Mangapul Tambunan; DjokoSusanto; Rima Isyana Restuwangi

FIRE SENSING SYSTEM

Aas Wasri Hasanah; Rinna Hariyati; Oktaria Handayani

PERANCANGAN RANGKAIAN PENGUAT DAYA DENGAN TRANSISTOR

Tasdik Darmana; Tony Koerniawan

STUDI PERAMALAN BEBAN RATA-RATA JANGKA PENDEK MENGGUNAKAN METODA
AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA)

Adri Senen; Titi Ratnasari

PERANCANGAN SISTEM KONTROL GLYCOL REGENERATION UNIT DENGAN DCS DeltaV
DI ONSHORE GAS PLANT

Muhamad Syahrudin; Rummi Santi Rama Sirait

RANCANG BANGUN RUANG PINTAR MINIMALIS TENAGA SURYA DENGAN SISTEM KONTROL
BERBASIS ARDUINO

Dwi Anggraini; Miftahul Fikri; Hendrianto Husada

PERANCANGAN KENDALI GARASI RUMAH BERBASIS WEB VIA WIRELESS LAN

Akhmad Syahrani; Eka Purwa Laksona; Nifty Fath

ANALISA PROTEKSI HILANG EKSITASI PADA GENERATOR SINKRON DI PLTGU MUARA TAWAR
GT UNIT 1.3

Ibnu Hajar; Usman Fadillah



9 772356 150005

SEKOLAH TINGGI TEKNIK - PLN (STT-PLN)

JURNAL SUTET

VOL. 7

NO. 2

HAL.69-132

JUNI - DESEMBER 2017

ISSN : 2356-1505

STUDI PERAMALAN BEBAN RATA – RATA JANGKA PENDEK MENGUNAKAN METODA AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA)

Adri Senen¹; Titi Ratnasari²

Program Studi Teknik Elektro STT - PLN

ad_senen@yahoo.com; titi.ratnasari@sttpln.ac.id

Abstract : *Forecasting. Plans, power plants ,. Electricity needs are increasingly changing daily, so the State Electricity Company (PLN) as a provider of energy must be able to predict daily electricity needs. Short-term forecasting is the prediction of electricity demand for a certain period of time ranging from a few minutes to a week ahead. in short-term electrical forecasting much of the literature describes the techniques and methods applied in forecasting, Autoregressive Integrated Moving Average (ARIMA), linear regression, and artificial intelligence such as Artificial Neural Networks and fuzzy logic. Short-term forecasting will be done by the authors using time series data that is the data of the use of electric power daily (electrical load) and ARIMA as a method of forecasting. ARIMA method or often called Box-Jenkins technique to find this method is suitable to predict variable costs quickly, simply, and cheaply because it only requires data variables to be predicted. ARIMA can only be used for short-term forecasting. ARIMA is a special linear test, in the form of forecasting this model is completely independent variable variables because this model uses the current model and past values of the dependent variable to produce an accurate short-term forecast.*

Keywords: Load forecasting, ARIMA, Model Forecasting, time series, dependent variable, MAPE.

Abstrak : *Peramalan beban listrik berdampak besar dalam operasi sistem tenaga listrik mulai dari perencanaan pembangkitan, analisis aliran daya, unit comitment, hydro thermis dan operasi ekonomis sistem tenaga. Kebutuhan energi listrik semakin hari cenderung berubah-ubah, sehingga Perusahaan Listrik Negara (PLN) sebagai penyedia energi listrik harus bisa memprediksi kebutuhan beban listrik setiap harinya. Peramalan beban jangka pendek merupakan prediksi permintaan beban listrik untuk suatu jangka waktu tertentu mulai dari beberapa menit hingga satu minggu kedepan. dalam peramalan beban listrik jangka pendek banyak literatur memaparkan teknik dan metoda yang diaplikasikan dalam peramalan, diantaranya Autoregresif Integrated Moving Average (ARIMA), regresi linear, dan intelejensi buatan seperti Artificial Neural Network dan Fuzzy logic. Peramalan jangka pendek yang akan dilakukan oleh penulis menggunakan data time series berupa data penggunaan daya listrik harian (electrical load) dan ARIMA sebagai metoda peramalan,. Metoda ARIMA atau sering disebut teknik Box-Jenkins menunjukkan metode ini cocok untuk meramal sejumlah variabel dengan cepat, sederhana, dan murah karena hanya membutuhkan data variabel yang akan diramal. ARIMA hanya dapat digunakan untuk peramalan jangka pendek. ARIMA merupakan uji linear yang istimewa, dalam membuat peramalan model ini sama sekali mengabaikan variabel independen karena model ini menggunakan model sekarang dan nilai-nilai lampau dari variabel dependen untuk menghasilkan ramalan jangka pendek yang akurat.*

Kata kunci : Peramalan beban, ARIMA, Peramalan Model, time series, variabel dependen, MAPE.

1. PENDAHULUAN

Peramalan beban listrik berdampak besar dalam operasi sistem tenaga listrik mulai dari perencanaan pembangkitan, analisis aliran daya, *unit comitment*, *hydro thermis* dan operasi ekonomis sistem tenaga. Kebutuhan energi listrik semakin hari cenderung berubah-ubah, sehingga Perusahaan Listrik Negara (PLN) sebagai penyedia energi listrik harus bisa memprediksi kebutuhan beban listrik setiap harinya, ada banyak cara dalam dalam memprediksi atau meramalkan beban listrik sehingga sangat diperlukan pemilihan metode dalam meramalkan beban listrik karena dibutuhkan keakuratan yang tepat, sehingga dapat menekan biaya dalam memproduksi energi listrik.

Peramalan beban jangka pendek merupakan prediksi permintaan beban listrik untuk suatu jangka waktu tertentu mulai dari beberapa menit hingga satu minggu kedepan. Dalam proses peramalan dapat disadari bahwa ketidakakuratan dalam memprediksi sering terjadi, tetapi peramalan masih perlu dilakukan bahwa setiap perencanaan dan keputusan tetap harus diambil yang nantinya akan mempengaruhi langkah-langkah kebijakan pada masa akan datang. Suatu secara ilmiah lebih dapat diterima dan berarti jika dibandingkan memprediksi yang hanya mengandalkan intuisi saja.

Dalam peramalan beban listrik jangka pendek banyak literatur memaparkan teknik dan metoda yang diaplikasikan dalam peramalan, diantaranya *Autoregresif Integrated Moving Average* (ARIMA), regresi linear, dan intelegensi buatan seperti *Artificial Neural Network* dan *Fuzzy logic*. Peramalan jangka pendek yang akan dilakukan oleh penulis menggunakan data *time series* berupa data penggunaan daya listrik harian (*electrical load*) dan ARIMA sebagai metoda peramalan,. Metoda ARIMA atau sering disebut teknik *Box-Jenkins* menunjukkan metode ini cocok untuk meramal sejumlah variabel dengan cepat, sederhana, dan murah karena hanya membutuhkan data variabel yang akan

diramal. ARIMA hanya dapat digunakan untuk peramalan jangka pendek. ARIMA merupakan uji linear yang istimewa, dalam membuat peramalan model ini sama sekali mengabaikan variabel independen karena model ini menggunakan model sekarang dan nilai-nilai lampau dari variabel dependen untuk menghasilkan ramalan jangka pendek yang akurat.

Penelitian ini nantinya diharapkan dapat menjadi referensi bagi penelitian selanjutnya dalam mengenai teknik peramalan untuk penelitian yang lebih lanjut dan Bagi PLN penelitian ini dapat menjadi kontribusi positif dalam memprediksi atau meramalkan beban listrik yang akurat sehingga dapat mengurangi kerugian finansial dalam penyediaan daya listrik, khususnya pada unit-unit pembangkit yang akan menyuplai beban.

2. LANDASAN TEORI

2.1. Peramalan Beban Listrik Jangka Pendek

Peramalan (*forecasting*) merupakan prediksi nilai-nilai sebuah peubah kepada nilai yang diketahui dari peubah tersebut atau peubah yang berhubungan. Meramalkan juga dapat didasarkan kepada keahlian penilaian, yang pada gilirannya didasarkan pada data historis dan pengalaman.

Peramalan beban jangka pendek adalah peramalan beban untuk jangka waktu beberapa jam sampai dengan satu minggu, dengan memperhatikan berbagai informasi yang mempengaruhi besarnya beban pada sistem seperti acara televisi, cuaca dan suhu udara.

Beban sistem tenaga listrik merupakan pemakaian tenaga listrik dari para pelanggan listrik. Oleh karenanya besar kecil beban serta perubahannya tergantung kepada kebutuhan para pelanggan akan tenaga listrik. Tidak ada perhitungan eksak mengenai berapa besarnya beban sistem pada suatu saat, yang biasa dilakukan hanyalah membuat perkiraan beban.

Dalam pengoperasian sistem tenaga listrik diusahakan agar daya yang dibangkitkan tidak ada yang terbuang. Maka masalah perkiraan beban merupakan masalah yang sangat menentukan bagi perusahaan listrik, baik dari segi manajerial maupun bagi segi operasional, oleh karenanya perlu mendapat perhatian khusus. Untuk dapat membuat perkiraan beban yang baik, diperlukan data beban harian tenaga listrik yang sudah terjadi dimasa lalu untuk dianalisa

2.2. Pemodelan Deret Berkala

Baxter (2001) mendefinisikan deret berkala (deret waktu) adalah sekumpulan observasi atau pengamatan yang dibangkitkan secara sekuensial dalam waktu. Deret waktu yang dilambangkan dengan Z_t secara konseptual dipandang sebagai peubah acak. Sekuen $\{Z_1, Z_2, \dots\}$ atau $\{\dots, Z_0, Z_1, \dots\}$ dibangkitkan oleh suatu proses stokastik atau proses yang dikendalikan oleh mekanisme peluang. Hal tersebut dapat dirumuskan seperti berikut :

$$Z_t = F_t + e_t$$

dimana Z_t adalah pengamatan deret waktu, F_t sebagai komponen yang terdiri dari *trend*, *cyclic*, musiman dan statistik, sedangkan e_t adalah komponen acak (galat).

Untuk membentuk kelas model yang sangat umum dan berguna dalam model deret berkala yang biasa dinamakan pola atau proses autoregresif/moving average (ARMA)

Pemodelan mencakup identifikasi model, penyesuaian terhadap data dan menggunakan model yang tepat untuk peramalan. Salah satu pendekatan Box-Jenkins yang menarik adalah menemukan proses yang menyediakan deskripsi yang cukup dari data.

Prosedur pemodelan terdiri dari tiga tahap proses iteratif yaitu penyeleksian model, pendugaan parameter, dan pemeriksaan model. Penjelasan terbaru dari ketiga proses tersebut sering menambahkan tahap awal sebagai persiapan data dan tahap akhir sebagai aplikasi model

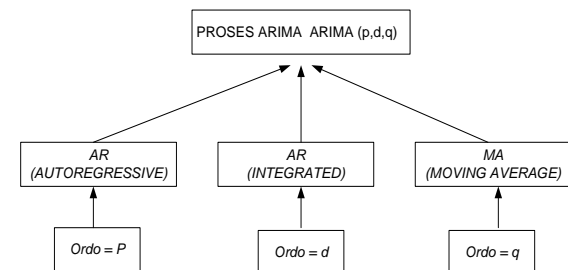
2.3 Proses ARIMA

Proses ARIMA adalah model matematika yang digunakan untuk peramalan. ARIMA atau *Autoregressive Integrated Moving Average* dikembangkan oleh George Box dan Gwilym Jenkins pada awal tahun 1970-an, sehingga proses ARIMA lebih dikenal sebagai model Box-Jenkins.

Pendekatan ARIMA untuk peramalan berdasarkan ide-ide berikut :

1. Peramalan berdasarkan pada fungsi linear pengamatan contoh.
2. Tujuannya adalah untuk memperoleh model sederhana yang menyediakan deskripsi yang cukup mengenai data pengamatan.

Setiap proses ARIMA(p,d,q) terdiri dari tiga bagian : proses *Autoregressive* (AR), *Integrated* (I), dan *Moving Average* (MA). Proses AR adalah bagian dari model yang menerangkan setiap pengamatan adalah sebuah fungsi dari p pengamatan sebelumnya.



Gambar.1 Diagram proses ARIMA

Secara umum proses AR dengan ordo p dinotasikan sebagai berikut :

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + e_t$$

dimana :

μ = Konstanta

ϕ_j = Parameter Autoregressive ke-j

e_t = Sisaan pada waktu ke-t

Atau model di atas dapat dituliskan :

$$\phi(B)Z_t = \mu + e_t$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

Integrated menunjukkan apakah nilai pengamatan perlu dimodelkan secara langsung atau perlu dilakukan pembedaan sebanyak d kali untuk mencapai kestasioneran.

Proses MA adalah bagian dari model yang menerangkan setiap pengamatan adalah sebuah fungsi dari q sisaan sebelumnya. Secara umum proses MA dengan ordo q dinotasikan sebagai berikut:

$$Z_t = \mu + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}$$

dimana :

μ = Konstanta

θ_j = Parameter Autoregressive ke-j

e_t = Sisaan pada waktu ke-t

atau dapat dituliskan sebagai berikut :

$$Z_t = \mu + \theta(B)a_t$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

Secara umum proses atau model ARIMA(p,d,q) adalah :

$$\phi_p(B)(1-B)^d Z_t = \mu + \theta_q(B)e_t$$

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} + e_t$$

Proses ARIMA yang tidak mengalami perbedaan ($d = 0$) maka nilai pengamatan dimodelkan secara langsung atau ARIMA(p,d,q) sama dengan ARMA(p,q)

2.4 Fungsi Autokorelasi dan Autokorelasi Parsial

Penyeleksian model awal yang potensial dapat dilakukan dengan melihat distribusi koefisien autokorelasi (ACF) dan koefisien autokorelasi parsial (PACF). Koefisien autokorelasi menunjukkan keeratan hubungan nilai peubah yang sama tetapi untuk periode waktu yang berbeda.

Fungsi autokorelasi teoritik untuk beda waktu k adalah :

$$\rho_k = \frac{E[(z_t - \mu)(z_{t+k} - \mu)]}{\sigma_z^2}$$

Karena fungsi ini tidak diketahui, maka harus diestimasi dengan fungsi autokorelasi contoh:

$$s_{r_k} = \frac{\left(1 + 2 \sum_{j=1}^{k-1} r_j^2\right)^{1/2}}{N}$$

$$t_{r_k} = \frac{r_k}{s_{r_k}}$$

Dimana N adalah panjang deret waktu. Secara umum, untuk memperoleh pendugaan fungsi autokorelasi yang baik

dibutuhkan paling sedikitnya 50 observasi dan autokorelasi contoh dihitung sampai lag $k \leq N/4$ yang pertama.

Koefisien autokorelasi parsial mengukur keeratan hubungan antara Z_t dan Z_{t-k} dengan menghilangkan pengaruh dari peubah $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$. Fungsi autokorelasi parsial pada lag ke-k dinotasikan oleh :

$$\phi_{kk} = \text{Corr}(Z_t, Z_{t-k} | Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1})$$

Notasi ganda kk menegaskan bahwa ϕ_{kk} adalah parameter autoregressive ϕ_k dari model autoregressive dengan ordo k.

Sedangkan fungsi autokorelasi parsial contoh :

$$r_{kk} = \begin{cases} r_1 & \text{Jika } k=1 \\ \frac{r_k - \sum_{j=1}^{k-1} r_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} r_{k-1,j} r_j} & \text{Jika } k=2, 3, \dots \end{cases}$$

$$s_{r_k} = 1/(N)^{1/2}$$

$$t_{r_k} = \frac{r_k}{s_{r_k}}$$

2.5 Uji Diagnostik Model

Salah satu cara memeriksa model adalah menggunakan uji Pormanteau. Model dikatakan memadai jika galat yang dihasilkan sudah bersifat saling bebas atau tidak berkorelasi. Statistik Ljung-Box-Pierce (Q^*) dipakai untuk menguji perilaku autokorelasi sisaan secara serempak yaitu:

$$Q^* = n(n+2) \sum_{i=1}^k \frac{r_i^2(\hat{e}_i)}{n-k}$$

dimana $r_i(\hat{e}_i)$ adalah autokorelasi contoh pada lag I dan k adalah maksimum lag yang diinginkan. Jika nilai Q^* lebih besar dari nilai $\chi_{(\alpha)}^2$ dengan derajat bebas k-p-q atau nilai peluang statistik Q^* lebih kecil dari taraf nyata 0.05, maka model tidak memadai.

$$r_k = \frac{\sum_{t=1}^{N-k} (z_t - \bar{z})(z_{t+k} - \bar{z})}{\sum_{t=1}^N (z_t - \bar{z})^2} \quad k = 0,1,2,\dots,k$$

Tingkat Keakuratan Peramalan

Untuk mengetahui tingkat keakuratan hasil peramalan (*forecasting performance*) digunakan perhitungan *Mean Absolute*

Percentage Error (MAPE) yang mengukur mengukur rata-rata persentase simpangan nilai hasil peramalan dari nilai aktual yang ada dengan notasi :

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{Z_t - F_t}{Z_t} \right|$$

dimana Z_t adalah data aktual dan F_t adalah data hasil peramalan. Semakin kecil nilai MAPE menunjukkan data hasil peramalan mendekati nilai aktual.

3. METODOLOGI PENELITIAN

3.1 Persiapan Data

Penentuan periode pengelompokan data dilakukan pada tahap awal ini, untuk *Fitting* model digunakan. Selanjutnya memeriksa kestasioneran data deret waktu agar bisa dimodelkan dengan pendekatan Model Box-Jenkins. Pemodelan data deret waktu umumnya diterapkan pada proses-proses yang stasioner. Kestasioneran tercapai bila (misalnya) pada deret waktu y_t , untuk semua t dan $t-s$, tiga hal berikut ini terpenuhi :

$$E(y_t) = \mu$$

$$E[(y_t - \mu)^2] = E[(y_{t-s} - \mu)^2] = \sigma_y^2$$

$$E[(y_t - \mu)(y_{t-s} - \mu)] = \gamma_s$$

μ , σ_y^2 , dan γ_s adalah konstanta

Bila proses yang diamati menunjukkan gejala non-stasioner maka proses tersebut harus distasionerkan melalui metode pemodelan data deret waktu non-stasioner.

Grafik fungsi autokorelasi (ACF) dapat digunakan untuk memeriksa kestasioneran tersebut. Persiapan mencakup transformasi dan pembedaan (diferensiasi). Transformasi data dapat membantu menstabilkan ragam dari deret waktu. Salah satu cara untuk mengatasi ketidakhomogenan ragam adalah dengan menggunakan transformasi logaritma.

Proses pembedaan akan menghasilkan nilai tengah yang konstan sepanjang waktu. Untuk memperoleh deret yang stasioner, deret baru dihitung dengan melakukan pembedaan periode waktu secara berturut-turut. Pembedaan pertama dapat didefinisikan dengan sebagai berikut :

$$\nabla Z_t = (1-B) Z_t = Z_t - Z_{t-1}$$

Dimana ∇ merupakan operator pembedaan dan B adalah *Backward shift operator*.

3.2 Identifikasi Model

Selanjutnya dilakukan seleksi model yang dilakukan secara tentatif berdasarkan transformasi dan pembedaan untuk mengidentifikasi model yang sesuai dengan data. Alat yang digunakan dalam proses ini adalah ACF dan PACF. Penentuan model didasarkan pada kriteria pada Tabel 1.

Tabel 1. Pedoman dalam Identifikasi Model Box-Jenkins

Model	Correlogram	Partial Correlogram
AR(p)	Menurun secara eksponensial	Terpotong setelah lag ke-p
MA(q)	Terpotong setelah lag ke-q	Menurun secara eksponensial
ARMA(p,q)	Menurun secara eksponensial	Menurun secara eksponensial

Jumlah parameter yang kecil akan menghasilkan penduga parameter yang lebih stabil dan peramalan terbaik..

3.3. Pendugaan Parameter

Pendugaan parameter dimaksudkan untuk mencari koefisien model yang paling sesuai dengan data. Salah satu cara yang digunakan yaitu dengan cara mencoba-coba (*trial and error*), memeriksa beberapa nilai yang berbeda dan memilih nilai parameter yang meminimumkan jumlah kuadrat galat.

Pendugaan Model ARIMA diproses dengan metode nonlinear. Program yang digunakan akan selalu memilih model yang stasioner dan *invertible*.

Kemudian dilakukan proses *overfitting* dengan memperkecil p atau q yang memiliki t-hitung kecil atau menambah ordo p atau q yang memiliki t-hitung besar.

3.4. Pemeriksaan Model

Pemeriksaan kecukupan model dilakukan untuk menguji asumsi, sehingga model yang diperoleh cukup memadai.

Jika tidak memadai maka kembali ke tahap identifikasi guna memperoleh model yang lebih baik.

Langkah awal yang dilakukan adalah memeriksa koefisien parameter model sementara. Misal dinotasikan θ sebagai parameter model Box-Jenkins, $\hat{\theta}$ adalah penduga dari θ , dan $S_{\hat{\theta}}$ adalah galat baku pendugaan. Hipotesis yang diuji adalah $H_0 : \theta = 0$ dan hipotesis alternatifnya adalah $H_1 : \theta \neq 0$. Tolak H_0 jika nilai $t = \hat{\theta}/S_{\hat{\theta}}$ terletak di daerah kritik atau nilai peluang lebih kecil dari taraf nyata α .

Kemudian dilakukan analisis sisaan menggunakan ACF, PACF dan statistik uji Q^* Ljung-Box-Pierce. Jika model memadai maka sisaan yang diperoleh adalah acak (*white noise*) dan menyebar menurut sebaran normal.

Pemilihan model terbaik juga ditentukan dari nilai MSE (*Mean Squared Error*) dan MAPE yang terkecil yang diperoleh dari data perbandingan antara data ramalan dengan data aktual.

3.5. Peramalan

Langkah terakhir adalah melakukan peramalan setelah diperoleh model yang memadai. Model tersebut digunakan untuk memperkirakan nilai pengamatan masa datang. Misalkan dinotasikan T sebagai periode terakhir, sehingga peramalan nilai pada periode waktu $T+\tau$ adalah

4. HASIL DAN PEMBAHASAN

4.1. Persiapan dan Pemeriksaan Kestasioner Data

Jika diketahui data-data dari suatu daerah mempunyai beban rata-rata listriknya adalah sebagai berikut :


Tahun	Beban Rata-rata (MW)
1986	12.46
1987	12.66
1988	12.86
1989	13.06
1990	13.26
1991	13.46
1992	13.66
1993	13.87
1994	14.07
1995	14.27
1996	14.47
1997	14.67
1998	14.87
1999	15.07
2000	15.28
2001	15.48
2002	15.68
2003	15.43
2004	16.17
2005	16.25
2006	16.57
2007	17.33
2008	17.57
2009	18.05
2010	18.56
2011	17.98
2012	18.75
2013	19.50
2014	19.98
2015	20.06

Pemodelan deret waktu ARIMA dapat dilakukan jika data telah stasioner dengan ragam homogen. Alat yang digunakan untuk identifikasi model ARIMA secara tentatif adalah ACF dan PACF, dimana *correlogram* dari MA(q) terpotong pada lag q dan *partial correlogram* dari AR(p) terpotong pada lag p

4.2 Kestasioneran Data


Untuk memeriksa kestasioneran data dapat dilihat dari plot data aktual. Seperti yang terlihat pada gambar. Disini memperlihatkan adanya trend naik . Plot ini juga memperlihatkan struktur data yang *random walk* dan adanya perubahan pada *mean level*. Hal ini mengindikasikan bahwa nilai tengah data tidak konstan. Dengan kata lain data belum stasioner

Tabel 2. Data beban rata-rata




Gambar.2 Grafik beban rata-rata

Data yang tidak stasioner juga tergambar dari plot autokorelasi (ACF) yang menurun secara eksponensial dimana nilai autokorelasinya cukup signifikan sampai lag ke-5



Gambar 3. Autokorelasi Data sebelum didiferensiasi.

Agar diperoleh data yang stasioner maka perlu dilakukan Pembedaan sekali (diferensiasi ordo pertama). Pembedaan ini menghasilkan nilai tengah yang relatif konstan sepanjang waktu. Plot data yang telah stasioner terlihat pada Gambar 4.




Gambar .4 Grafik data setelah diferensiasi Ordo 1.

4.3. Identifikasi Model


Setelah diperoleh data yang stasioner maka untuk mengidentifikasi model perlu di Plot autokorelasi data hasil pembedaan. pada Gambar 2 terlihat bahwa nilai

autokorelasi tidak signifikan (tidak ada yang memotong batas lag nya). Hal ini tidak mengindikasikan adanya faktor musiman pada data (telah stasioner).



Gambar 5. Autokorelasi Data Diferensiasi Ordo 1.

Sedangkan plot autokorelasi parsial memperlihatkan bahwa nilai autokorelasi parsial yang berbeda nyata pada nilai 0 hanya untuk lag ke-1 namun tidak signifikan untuk lag lainnya seperti terlihat pada Gambar 6. dan tidak ada terpotongnya *partial correlogram*, mengindikasikan bahwa proses yang terjadi adalah *Autoregressive*.



Gambar .6 Autokorelasi Parsial Data Diferensiasi Ordo 1.

4.4. Pendugaan Model

Proses *overfitting* yang dilakukan dengan memperkecil atau menambah ordo p dan q menghasilkan beberapa model sementara. Keseluruhan model tersebut akan di uji dan dari uji t parameter untuk koefisien maka model ARIMA yang memiliki parameter yang signifikan atau berpengaruh terhadap model. Selanjutnya dilakukan diagnostik model untuk memilih model terbaik. Untuk pendugaan model dilakukan dengan bantuan *software minita* ver. 13.02, sehingga diperoleh hasil sebagai berikut:

Constant 0.7865 0.1380 5.70
 0.000
 Differencing: 1 regular difference
 Number of observations: Original series
 30, after differencing 29
 Residuals: SS = 1.87648
 (backforecasts
 excluded)
 MS = 0.07819 DF = 24

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	6.4	9.1	*	*
DF	7	19	*	*
P-Value	0.499	0.971	*	*

Setelah dilakukan uji statistik, seperti nilai di atas terlihat nilai P lebih kecil dari taraf α (nilai acuan untuk menolak hipotesis awal), biasanya digunakan **alpha = 0.05**. jika :

- p-value $\leq \alpha$, Tolak H_0
- p-value $> \alpha$, Terima H_0

Berdasarkan hasil pengolahan data, model ARIMA yang digunakan adalah **(2,1,2)** karena memiliki parameter yang signifikan.

4.5. Pemeriksaan Model

Selanjutnya Model dugaan sementara yang diperoleh akan dilakukan pemeriksaan guna mengetahui kecukupan model. Pemeriksaan dilakukan dengan penghitungan nilai MAPE, yang didasarkan pada perbandingan antara data ramalan yang dihasilkan masing-masing model dengan data aktual. Dari hasil perhitungan diperoleh :

Tabel 3. Nilai MAPE BEBAN RATA-RATA

Data Aktual	Ramalan	Simp. Peramln	Abs SP
15.43	15.9883	-0.036182761	0.036183
16.17	16.3456	-0.010859617	0.01086
16.25	16.7028	-0.027864615	0.027865
16.57	17.0601	-0.02957755	0.029578
17.33	17.4173	-0.005037507	0.005038
17.57	17.7746	-0.011644849	0.011645
18.05	18.1318	-0.004531856	0.004532
18.56	18.4891	0.003820043	0.00382
17.98	18.8464	-0.048186874	0.048187
18.75	19.2036	-0.024192	0.024192
Jumlah Total			0.201898
MAPE			2%

Dari hasil uji statistik dan pemeriksaan model ternyata model ARIMA(2,1,2) tersebut cukup baik digunakan untuk meramalkan. Model atau ARIMA(2,1,2) dapat diturunkan sebagai berikut :

$$\begin{aligned} \phi_p(B)(1-B)^d Z_t &= \mu + \theta_q(B)e_t \\ (1 - \phi_1 B - \phi_2 B^2)(1-B)Z_t &= \mu + (1 - \Phi_1 B - \Phi_1 B^2)e_t \\ [1 - B - \phi_1 B^2 - \phi_2 B^2 + \phi_2 B^3]Z_t &= \mu + e_t - \Phi_1 B e_t - \Phi_1 B^2 e_t \end{aligned}$$

$$Z_t = Z_{t-1} - \phi_1 Z_{t-1} - \phi_2 Z_{t-2} + \phi_2 Z_{t-3} + \mu + e_t - \Phi_1 e_{t-1} - \Phi_2 e_{t-2}$$

Dengan mensubstitusikan nilai-nilai yang diperoleh dari perhitungan sebelumnya maka diperoleh model peramalan, yaitu :

$$\begin{aligned} Z_t &= Z_{t-1} - \phi_1 Z_{t-1} - \phi_2 Z_{t-2} + \phi_2 Z_{t-3} + \mu + e_t - \Phi_1 e_{t-1} - \Phi_2 e_{t-2} \\ &= Z_{t-1} - 0.9882Z_{t-1} - 0.9833Z_{t-2} - 0.9833Z_{t-3} + \mu + e_t + 0.7673e_{t-1} + 0.8813e_{t-2} \end{aligned}$$

4.6. Peramalan

Setelah diperoleh model peramalan tersebut, selanjutnya dilakukan perhitungan peramalan untuk 10 (sepuluh) tahun kedepan berdasarkan model yang telah diperoleh, sehingga didapat hasilnya sebagai berikut :

Tabel 4. Hasil

Tahun	Ramalan Beban Rata-rata
2017	20.5118
2018	20.4929
2019	20.8539
2020	21.3022
2021	21.2908
2022	21.6478
2023	22.0928
2024	22.0885
2025	22.4417
2026	22.8834

5. Kesimpulan

1. Data beban puncak yang diperoleh tidak stasioner dalam varians maupun means, maka dilakukan transformasi data yaitu dengan dua kali transformasi hingga mencapai stasioner dalam varians ($\lambda = 1$) dan melakukan *differencing* sebanyak satu kali ($d = 1$) untuk mencapai stasioner dalam *means*.

2. Model terbaik yang dipilih menurut MAPE adalah model ARIMA (2,1,2), dengan nilai MAPE sebesar 2 % yang menandakan model ARIMA ini bagus untuk peramalan jangka pendek.
3. Persamaan matematis yang digunakan untuk peramalan dengan model ARIMA (2,1,2) adalah :

$$\begin{aligned}
 Z_t &= Z_{t-1} - \phi_1 Z_{t-1} - \phi_2 Z_{t-2} + \phi_2 Z_{t-3} \\
 &\quad + \mu + e_t - \Phi_1 e_{t-1} - \Phi_2 e_{t-2} \\
 &= Z_{t-1} - 0,9882 Z_{t-1} - 0,9833 Z_{t-2} - \\
 &\quad 0,9833 Z_{t-3} + \mu + e_t + 0,7673 e_{t-1} \\
 &\quad + 0,8813 e_{t-2}
 \end{aligned}$$

4. Semakin banyak data time series yang digunakan maka peramalan akan semakin baik, untuk semua model yang signifikan.

- [4] Gonen, Turan. 1987. *Electric Power Distribution System Engineering*. Mc.Graw-Hill Int. Ed.
- [5] Makridakis, Spyros., Syeven C Wheelwright., dan Victor E. McGEE. 1999. *Metode dan Aplikasi Peramalan*. Terjemahan Hari Suminto. Jakarta: Binarupa Aksara.
- [6] Windayati. 2010. *Analisis Autokorelasi Pada Model Arima (Autoregressive Integrated Moving Average)*. Jurusan Matematika Fakultas Sains Dan Teknologi. Universitas Islam Negeri (UIN) Maulana Malik Ibrahim. Malang.
- [7] Suhartono. 2008. *Analisis Data Statistik Dengan R*. Jurusan Statistika Institut Teknologi Sepuluh Nopember. Surabaya

REFERENSI

- [1] Putra, Frans Rahmadhan. 2010. *Aplikasi Jaringan Saraf Tiruan Dalam Perkiraan Beban Listrik Jangka Pendek*. Jurusan Teknik Elektro Fakultas Teknik. Universitas Andalas. Padang.
- [2] Sadeq, Ahmad. 2008. *Tesis: Analisis Prediksi Indeks Harga Saham Gabungan Dengan Metode Arima*. Universitas Diponegoro. Semarang.
- [3] Zuhail. 1992. *Dasar Teknik Tenaga Listrik dan Elektronika Daya*. Gramedia : Jakarta.