

**PERAMALAN DAYA LISTRIK BERDASARKAN JUMLAH PELANGGAN PLN
MENGUNAKAN MODEL FUNGSI TRANSFER DENGAN OUTLIER
(Studi Kasus di PT PLN (Persero) Rayon Semarang Selatan)**

Retza Bahtiar Anugrah¹, Sudarno², Budi Warsito³

¹Mahasiswa Departemen Statistika FSM Universitas Diponegoro

^{2,3}Staff Pengajar Departemen Statistika FSM Universitas Diponegoro

ABSTRACT

Electrical energy is one of the components of Gross Domestic Product which able to stimulate the economic matter because it has been becoming a primary needs in the society. In order to meet the growing electrical energy, State-Owned Enterprises (SOEs) need to develop systems and proper planning. It needs a forecasting of electric power based on customer to meet a sufficient electricity supply. This study aims to predict the electrical power by electric customers using transfer function model with outliers. The use of transfer function model is intended to determine the role of power users that have an impact on the electric power. One of the stages of modeling the transfer function is to set the order of the transfer function parameters, they are b, r, and s. And by modeling the outlier is useful to eliminate the effect of outliers itself. The analysis and discussion show that based on the AIC value, the best model is the transfer function model by weighting the impulse response of the parameter that is $\omega_0 = 55,55652$ and the noise series model of the transfer function is ARIMA (1,0,1) with 8 outliers. The details of the outliers consist of one Additive Outliers type in the 33rd and seven Level Shift Outliers in the 14th, 31st, 9th, 10th, 21st, 22nd and 58th. Size forecasting accuracy using MAPE value 19.77%.

Keywords: Transfer function, outliers, ARIMA, electrical power, AIC, MAPE

1. PENDAHULUAN

Pertumbuhan pemakaian energi listrik akan terus meningkat seiring dengan kemajuan ekonomi di Indonesia, karena energi listrik sudah menjadi kebutuhan pokok dalam masyarakat (Kadir, 1982). Sehingga perlu adanya rencana pengembangan sistem maupun operasi dalam rangka memenuhi kebutuhan konsumsi energi listrik yang semakin tinggi. Hal ini terjadi karena jumlah pelanggan PLN terus bertambah setiap bulannya, sehingga daya listrik yang diperlukan juga akan meningkat. Oleh karena itu, perlu dilakukan prediksi daya listrik untuk merencanakan pembangunan dalam bidang kelistrikan agar dapat memenuhi kebutuhan pelanggan akan energi listrik.

Untuk mendapat nilai ramalan dari daya listrik, diperlukan model untuk mengestimasi daya listrik berdasarkan jumlah pelanggan PLN dengan menggunakan model fungsi transfer. Dalam analisis runtun waktu kadang terjadi ketidaknormalan residual, hal ini diduga terdapat outlier, sehingga perlu prosedur pendeteksian outlier. Penelitian ini bertujuan untuk meramalkan daya listrik menggunakan model fungsi transfer dengan outlier yang terbaik di Semarang Selatan.

2. TINJAUAN PUSTAKA

Data runtun waktu merupakan suatu deretan observasi yang diambil secara berurutan berdasarkan waktu dengan interval yang sama, bisa harian, mingguan, bulanan, tahunan atau yang lainnya (Wei, 2006). Dalam pembentukan model runtun waktu diasumsikan data telah stasioner dalam *mean* maupun stasioner dalam varian. Pengujian stasioneritas dalam *mean* dapat menggunakan uji *Dickey Fuller*. Bila data tidak stasioner dalam *mean* perlu dilakukan pembedaan. Data runtun waktu akan stasioner dalam varian apabila plot runtun waktu tidak memperlihatkan adanya perubahan varian yang jelas dari waktu ke waktu (Makridakis, 1999). Jika data tidak stasioner dalam varian maka data perlu ditransformasi dengan transformasi *Box-Cox* yang dirumuskan sebagai berikut (Wei, 2006):

$$T(X_t) = \frac{X_t^\lambda - 1}{\lambda}$$

Setelah data stasioner, selanjutnya perlu mengetahui dari fungsi autokorelasi dan fungsi autokorelasi parsial. Fungsi autokorelasi pada *lag k* merupakan kovarian dan korelasi antar deret pengamatan pada X_t sampai X_{t+k} yang didefinisikan sebagai berikut:

$$\rho_k = \frac{Cov(X_t, X_{t+k})}{\sqrt{var(X_t)}\sqrt{var(X_{t+k})}} = \frac{\gamma_k}{\gamma_0}$$

Fungsi autokorelasi parsial adalah suatu fungsi yang menunjukkan besarnya korelasi parsial antara X_t dan X_{t+k} . Autokorelasi parsial dari X_t pada *lag k* didefinisikan sebagai:

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

Fungsi autokorelasi dan autokorelasi parsial kemudian dibuat plot yang berguna untuk memodelkan ARIMA. Secara umum model ARIMA(p, d, q) dapat ditulis dalam bentuk sebagai berikut:

$$\phi_{p_x}(B)(1-B)^d X_t = \theta_{q_x}(B)\alpha_t$$

Penentuan orde p_x dan q_x dari model ARIMA pada suatu data runtun waktu dilakukan dengan mengidentifikasi plot Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF) dari data yang sudah stasioner (Wei, 2006). Terdapat empat tahap dalam pembentukan model ARIMA, yaitu identifikasi model, estimasi parameter dan uji signifikansi parameter, diagnosis model yang terdiri dari uji *white noise* residual dan uji normalitas residual, dan yang terakhir evaluasi model terbaik berdasarkan nilai AIC yang terkecil.

Dalam menetapkan model yang sederhana yang menghubungkan Y_t dengan X_t dimana model ARIMA X_t telah diketahui maka diperlukan model fungsi transfer. Menurut Makridakis, et al. (1999), model fungsi transfer adalah suatu model dimana terdapat runtun waktu deret *output*, disebut Y_t , yang diperkirakan akan dipengaruhi oleh runtun waktu deret *input*, disebut X_t , dan *input-input* lain yang digabungkan dalam suatu kelompok yang disebut residual (*noise*), N_t . Model umum dari fungsi transfer adalah:

$$Y_t = \frac{\omega_s(B)}{\delta_r(B)} X_{t-b} + \frac{\theta_{q_N}(B)}{\phi_{p_N}(B)} a_t$$

Tahapan dalam pembentukan model fungsi transfer sebagai berikut:

1. Persiapan deret *input* dan deret *output*.
2. *Prewhitening* deret *input* dan *prewhitening* deret *output*.
3. Perhitungan fungsi korelasi silang.

4. Penaksiran langsung bobot respon impuls.
5. Penetapan b, r, s untuk model fungsi transfer.
6. Penentuan model deret *noise*.
7. Estimasi parameter model fungsi transfer.
8. Uji diagnosis model fungsi transfer seperti pemeriksaan korelasi silang antara deret *input prewhitening* dan residual model deret *noise* dan pemeriksaan korelasi antar residual dari model deret *noise*. Kedua pemeriksaan ini untuk mengetahui apakah residual model fungsi transfer telah *white noise* atau tidak. Selain itu juga dilakukan uji normalitas residual
9. Pemilihan model terbaik dengan menggunakan AIC terkecil. Nilai AIC model fungsi transfer dirumuskan sebagai berikut:

$$AIC = n \ln(\hat{\sigma}^2) + 2(r + s + p_N + q_N)$$

Setelah terpilih model terbaik, maka akan diidentifikasi dengan model terbaik apakah terdapat outlier atau tidak. Outlier adalah peristiwa yang menimbulkan pengamatan menjadi tidak konsisten dalam data runtun waktu atau nilainya jauh berbeda dari data lainnya. Hal ini dapat menyebabkan kesimpulan dari analisis data yang dihasilkan tidak valid, sehingga prosedur mendeteksi dan menghapus efek *outlier* sangat penting dalam analisis data. Model *outlier* secara umum dapat ditulis:

$$Y_t = \sum_{j=1}^k w_j v_j(B) I_t^{(T)} + O_t$$

dimana $O_t = \frac{\theta(B)}{\phi(B)} \beta_t$ yang mengikuti model ARIMA, $v_j(B) = 1$ untuk AO dan $v_j(B) = \frac{1}{(1-B)}$ untuk LS pada waktu $t = T$.

Ada empat macam jenis *outlier* yaitu *Innovational Outlier (IO)*, *Additive Outlier (AO)*, *Temporary Change (TC)*, dan *Level Shift (LS)*. AO hanya memberikan pengaruhnya pada waktu ke- T , sedangkan untuk IO, LS, dan TC memberikan pengaruh yang bersifat tetap (mempengaruhi pada pengamatan ke- T , $T+1$, ..., n). Model untuk *outlier* dapat dituliskan sebagai berikut:

$$Y_t = \frac{\theta(B)}{\phi(B)} \beta_t + w I_{A,t}^{(T)}, \quad \text{untuk AO}$$

$$Y_t = \frac{\theta(B)}{\phi(B)} (\beta_t + w I_{I,t}^{(T)}), \quad \text{untuk IO}$$

$$Y_t = O_t + \frac{1}{(1-B)} w I_{L,t}^{(T)}, \quad \text{untuk LS}$$

$$Y_t = O_t + \frac{1}{(1-\delta B)} w I_{T,t}^{(T)}, \quad \text{untuk TC}$$

dengan

$$I_{A,t}^{(T)} = \begin{cases} 1 & t = T \\ 0 & t \neq T \end{cases} \quad I_{(I,L,T);t}^{(T)} = \begin{cases} 1 & t \geq T \\ 0 & t < T \end{cases}$$

3. METODE PENELITIAN

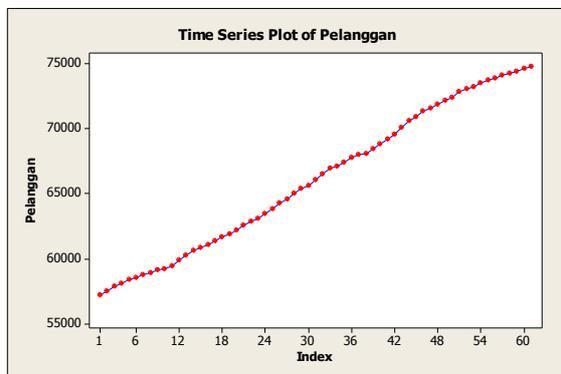
Data yang digunakan merupakan data sekunder yang diambil dari PT PLN (Persero) Rayon Semarang Selatan. Variabel penelitian yang digunakan yaitu daya listrik sebagai variabel Y dan pelanggan PLN sebagai variabel X. Data yang digunakan berjumlah 61 observasi dari bulan Mei 2011 sampai dengan bulan Mei 2016. Langkah-langkah yang dilakukan untuk menganalisis data penelitian adalah:

1. Menentukan model ARIMA yang sesuai dengan deret *input (X)*.

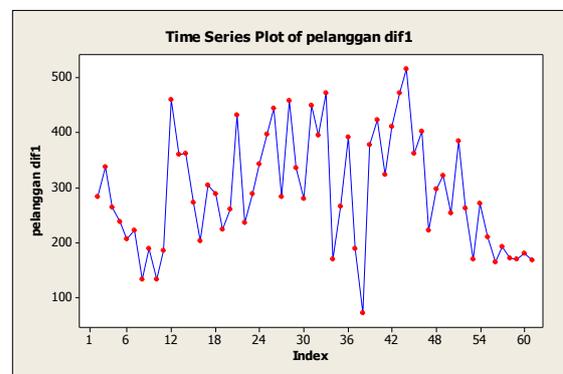
2. Menentukan model fungsi transfer yang terbaik untuk deret *output* (Y) berdasarkan deret *input* (X).
3. Melakukan deteksi *outlier* kemudian melakukan pemodelan dan mengestimasi ulang fungsi transfer dengan penambahan parameter outlier sesuai dengan jenis outlier kemudian dicari model terbaiknya.
4. Peramalan dengan model terbaik dari model fungsi transfer dengan *outlier*.

4. HASIL DAN PEMBAHASAN

Langkah awal dalam pemodelan fungsi transfer yaitu mencari model ARIMA dari deret input. Dalam mencari model ARIMA deret input, pertama-tama perlu mengidentifikasi model deret input. Dalam mengidentifikasi model deret input, perlu melihat plot runtun waktu terlebih dahulu. Pada Gambar 1 menunjukkan data mengandung tren naik sehingga perlu dilakukan pembedaan sekali. Setelah dilakukan *differencing* pada Gambar 2, selanjutnya diuji stasioneritasnya dalam *mean* dengan uji *Dickey Fuller* (Tabel 1) dan stasioneritas dalam varian dengan transformasi Box-Cox (Gambar 3).



Gambar 1. Plot *Time Series*

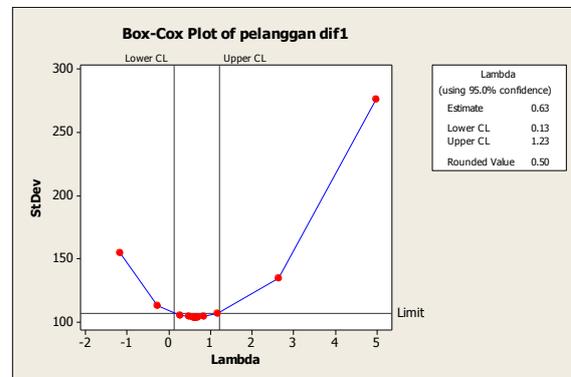


Gambar 2. Plot *Time Series* (d=1)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.764403	0.0002
Test critical values:		
1% level	-3.546099	
5% level	-2.911730	
10% level	-2.593551	

*MacKinnon (1996) one-sided p-values.

Tabel 1. Uji *Dickey Fulller*

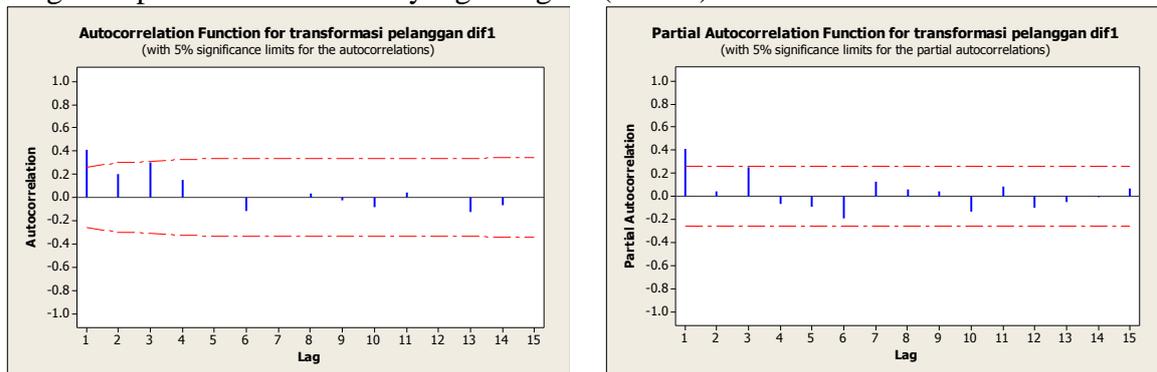


Gambar 3. Plot *Box-Cox*

Dengan menguji *Dickey Fuller* dari Gambar 3, terlihat nilai p-value = 0,0002 yang berarti lebih kecil dari nilai $\alpha = 0,05$. Sehingga stasioneritas dalam mean telah terpenuhi. Pada plot Box-Cox, terlihat nilai lambda (*rounded value*) sama dengan 0,5. Sehingga perlu dilakukan transformasi pada data deret input. Transformasi yang tepat bila nilai lambda 0,50 yaitu $\sqrt{X_t}$. Setelah data ditransformasi, maka stasioneritas dalam varian telah terpenuhi.

Selanjutnya dilakukan pemodelan ARIMA dengan melihat plot ACF dan PACF. Berdasarkan Gambar 4, pada plot ACF dan PACF menunjukkan pola yang memotong garis batas signifikan pada lag 1. Sehingga dapat disimpulkan bahwa orde untuk AR yaitu $p_x = 1$ dan orde untuk MA yaitu $q_x = 1$. Dan model yang mungkin terbentuk yaitu ARIMA

(1,1,0), ARIMA (0,1,1) dan ARIMA (1,1,1). Kemudian diuji signifikansi parameter dan uji diagnosis pada model ARIMA yang mungkin (tabel 1).



Gambar 4. Plot ACF dan PACF untuk Deret Input

Tabel 2. Uji Signifikansi Parameter dan Diagnosis Model

No.	Model ARIMA	Signifikansi Parameter	Normalitas Residual	Independensi Residual	Kesimpulan
1	(1,1,0)	✓	✓	✗	Model tidak layak
2	(0,1,1)	✓	✓	✗	Model tidak layak
3	(1,1,1)	✓	✓	✓	Model layak

✓ = memenuhi asumsi

✗ = tidak memenuhi asumsi

$\alpha = 5\%$

Berdasarkan Tabel 2, dapat disimpulkan bahwa hanya model ARIMA (1,1,1) yang layak untuk digunakan sehingga model ARIMA (1,1,1) menjadi model terbaik untuk deret *input*.

Setelah model ARIMA deret input diketahui, langkah selanjutnya adalah proses *prewhitening* deret input maupun deret output. *Prewhitening* deret *input* jumlah pelanggan dengan model ARIMA (1,1,1) dengan nilai $\theta_1 = 0,51922$, $\phi_1 = 0,98738$ dan didefinisikan bahwa $x_t = \sqrt{X_t}$ maka *prewhitening* deret *input*:

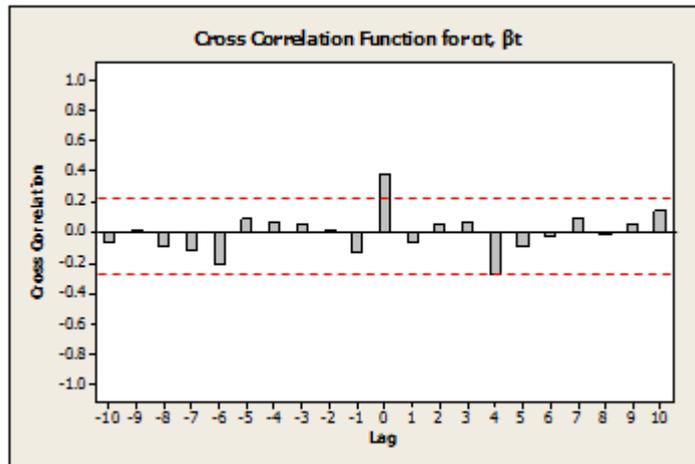
$$x_t = \frac{(1 - 0,51922B)\alpha_t}{(1 - 0,98738B)(1 - B)}$$

$$\alpha_t = x_t - 1,98738x_{t-1} + 0,98738x_{t-2} + 0,51922\alpha_{t-1}$$

Untuk *prewhitening* deret *output*, yaitu dengan mengubah α_t menjadi β_t dan x_t menjadi y_t pada persamaan model terbaik deret *input*. Berikut pemutihan deret *output*:

$$\beta_t = y_t - 1,98738y_{t-1} + 0,98738y_{t-2} + 0,51922\beta_{t-1}$$

Dengan nilai α_t dan β_t yang diperoleh dari proses *prewhitening*, akan dilakukan perhitungan korelasi silang antara deret *input* yang telah diputihkan (*prewhitening*) dengan deret *output* yang telah diputihkan. Hasil perhitungan korelasi silang dapat dilihat pada Gambar 5.



Gambar 5. Plot CCF antara α_t dan β_t

Dari perhitungan korelasi silang, nilai korelasi silang berguna untuk menentukan bobot respon impuls. Sebelum menentukan bobot respon impuls, perlu diketahui nilai rata-rata dan standar deviasi dari deret *input* dan deret *output* yang ditampilkan pada Tabel 3:

Tabel 3. Nilai Rata-rata Deret Input dan Deret Output yang telah Diputihkan

Pelanggan (α_t)		Pelanggan (β_t)	
Rata-rata	0,00516	Rata-rata	0,392
Standar Deviasi	0,1893	Standar Deviasi	20,75

Mencari bobot respon impuls dengan menggunakan hasil dari korelasi silang dengan mengabaikan nilai k yang bertanda negative. Berikut hasil perhitungan bobot respon impuls:

Tabel 4. Bobot Respon Impuls

k	v_k	k	v_k	k	v_k	k	v_k
0	42,640	3	7,783	6	-3,179	9	5,590
1	-8,112	4	-30,363	7	10,633	10	15,456
2	5,042	5	-10,304	8	-1,425		

Berdasarkan plot korelasi silang pada Gambar 5, *lag* yang pertama kali signifikan yaitu pada *lag* ke-0, sehingga nilai b adalah 0. Untuk s bernilai 0, karena setelah ada lag yang signifikan langsung terjadi penurunan lag yang tajam. Sedangkan nilai dari r juga sama dengan 0, karena tidak terjadi pola yang jelas pada Gambar 5. Sehingga dapat disimpulkan nilai b, r, s yaitu (0,0,0).

Bobot respon impuls yang telah diperoleh, berguna untuk menghitung taksiran awal deret *noise* dalam mengidentifikasi deret *noise*. Kemudian dilakukan pemodelan dengan tahapan yang sama dengan ARIMA biasa. Model yang terbentuk yaitu ARIMA (1,0,0), ARIMA (0,0,1) dan ARIMA (1,0,1). Kemudian dilakukan uji signifikansi parameter dan uji diagnosis. Dan model terbaik dari deret noise yaitu model ARIMA (1,0,1) karena memiliki nilai AIC terkecil.

Setelah semua proses identifikasi model fungsi transfer selesai, selanjutnya perlu mengestimasi parameter, pengujian signifikansi parameter dan uji diagnosis model. Persamaan model fungsi transfer yang terbentuk dengan nilai orde b, r, s dan model deret *noise* ARIMA (1,0,1) yaitu :

$$y_t = \omega_0 x_t + \frac{(1 - \theta_1 B)}{(1 - \phi_1 B)} a_t$$

Setelah model terbentuk, maka langkah selanjutnya adalah melakukan uji signifikansi parameter dan uji diagnosis model.

Tabel 5. Uji Signifikansi Parameter dan Diagnosis Model

Model Fungsi Transfer	Signifikansi Parameter	Normalitas	Korelasi Silang	Autokorelasi
(0,0,0)(1,0,1)	✓	✗	✓	✓

✓ = memenuhi asumsi

✗ = tidak memenuhi asumsi

$\alpha = 5\%$

Berdasarkan Tabel 5, hanya asumsi normalitas residual saja yang tidak terpenuhi. Ketidaknormalan ini dapat diduga adanya *outlier* dalam data yang menjadikan residual tidak berdistribusi normal.

Sehingga perlu deteksi outlier yang berguna untuk meyakinkan apakah terdapat outlier dalam data atau tidak. Hasilnya terdeteksi terdapat outlier dalam data dengan rincian rincian yaitu pada data ke-33 yang merupakan outlier bertipe *Additive Outlier (AO)* dan pada data ke-14, 31, 9, 10, 21, 22, dan 58 yang merupakan outlier bertipe *Level Shift (LS)*.

Selanjutnya dilakukan uji signifikansi parameter dan pemeriksaan diagnosis pada model fungsi transfer terbaik dengan menambahkan parameter outlier satu per satu yang telah diestimasi ulang. Hasil dari pengujian signifikansi dan pemeriksaan diagnosis model dapat dilihat pada Tabel 6.

Tabel 6. Uji Signifikansi Parameter dan Diagnosis Model

No.	Model Fungsi Transfer + Outlier Data ke -	Signifikansi Parameter	Normalitas	Korelasi Silang	Autokorelasi
1	14	✗	✓	✓	✓
2	14,31	✗	✓	✓	✓
3	14,31,9	✗	✓	✓	✓
4	14,31,9,33	✗	✓	✓	✓
5	14,31,9,33,10	✗	✓	✓	✓
6	14,31,9,33,10,21	✗	✓	✓	✓
7	14,31,9,33,10,21,22	✗	✓	✓	✓
8	14,31,9,33,10,21,22,58	✓	✓	✓	✓

✓ = memenuhi asumsi

✗ = tidak memenuhi asumsi

$\alpha = 5\%$

Berdasarkan Tabel 6, dapat disimpulkan bahwa model terbaik fungsi transfer dengan outlier yaitu model fungsi transfer dengan 8 outlier karena semua asumsi terpenuhi.

Tabel 7. Nilai AIC

Model Fungsi Transfer tanpa Outlier	AIC = 518,2511
Model Fungsi Transfer dengan 8 Outlier	AIC = 447,5201

Dalam menentukan model terbaik perlu melihat nilai AIC dari masing-masing model. Diketahui dengan nilai AIC lebih kecil yaitu 447,5201 yang merupakan nilai AIC dari model fungsi transfer dengan penambahan outlier data ke 14, 31, 9, 33, 10, 21, 22 dan 58, dibandingkan dengan model fungsi transfer tanpa penambahan outlier yang mempunyai nilai AIC = 518,2511 Penulisan model fungsi transfer dengan penambahan 8 outlier sebagai berikut:

$$y_t = 55,55652x_t + \frac{(2B)a_t}{(1 + 0,77635B)(1 - B)} + \frac{70,23269}{(1 - B)} I_{L,t}^{(14)} + \frac{62,12757}{(1 - B)} I_{L,t}^{(31)} + \frac{53,21085}{(1 - B)} I_{L,t}^{(9)} - 17,91813 I_{A,t}^{(33)} + \frac{31,41145}{(1 - B)} I_{L,t}^{(10)} + \frac{37,90434}{(1 - B)} I_{L,t}^{(21)} + \frac{32,18296}{(1 - B)} I_{L,t}^{(22)} + \frac{27,22939}{(1 - B)} I_{L,t}^{(58)}$$

dengan

$$I_{A,t}^{(T)} = \begin{cases} 1 & t = T \\ 0 & t \neq T \end{cases} \quad I_{L,t}^{(T)} = \begin{cases} 1 & t \geq T \\ 0 & t < T \end{cases}$$

Dengan model yang terbentuk yaitu model fungsi transfer dengan 8 outlier akan dilakukan peramalan. Hasil peramalan untuk daya listrik dengan menggunakan model terbaik yaitu fungsi transfer dengan 8 outlier dengan mengkuadratkan nilai peramalan dari model terbaik karena deret *input* dan deret *output* telah ditransformasi dengan akar kuadrat.

Tabel 8. Hasil Peramalan 12 Periode Ke Depan

Periode	Peramalan Daya
Juni 2016	185.313.769,00
Juli 2017	185.794.346,81
Agustus 2016	186.237.879,61
September 2016	186.701.070,10
Oktober 2016	187.139.937,61
Novembar 2016	187.588.359,76
Desember 2016	188.020.315,20
Januari 2017	188.456.062,08
Februari 2017	188.879.944,09
Maret 2017	189.304.577,44
April 2017	189.719.770,25
Mei 2017	190.133.763,21

5. KESIMPULAN

Model fungsi transfer dengan 8 outlier yang terbentuk pada pemodelan deret *input* jumlah pelanggan mempengaruhi deret *output* daya listrik sebagai berikut:

$$\begin{aligned}
 y_t = & 55,55652 x_t + \frac{(2B)a_t}{(1 + 0,77635B)(1 - B)} + \frac{70,23269}{(1 - B)} I_{L,t}^{(14)} \\
 & + \frac{62,12757}{(1 - B)} I_{L,t}^{(31)} + \frac{53,21085}{(1 - B)} I_{L,t}^{(9)} - 17,91813 I_{A,t}^{(33)} \\
 & + \frac{31,41145}{(1 - B)} I_{L,t}^{(10)} + \frac{37,90434}{(1 - B)} I_{L,t}^{(21)} + \frac{32,18296}{(1 - B)} I_{L,t}^{(22)} \\
 & + \frac{27,22939}{(1 - B)} I_{L,t}^{(58)}
 \end{aligned}$$

dengan

$$I_{A,t}^{(T)} = \begin{cases} 1 & t = T \\ 0 & t \neq T \end{cases} \quad I_{L,t}^{(T)} = \begin{cases} 1 & t \geq T \\ 0 & t < T \end{cases}$$

DAFTAR PUSTAKA

- [1] Ariefianto, M.D. 2012. *Ekonometrika Esensi dan Aplikasi dengan Menggunakan Eviews*. Edisi 4. Yogyakarta : UPP.STIM YKPN.
- [2] Daniel, W. W. 1989. *Statistika Nonparametrik Terapan*. Jakarta: Gramedia.
- [3] Kadir, A. 1982. *Energi: Sumberdaya, Inovasi, Tenaga Listrik dan Potensi Ekonomi*. Edisi Ketiga. Jakarta: Penerbit Universitas Indonesia.
- [4] Makridakis, S, Wheelwright, S.C, & McGee, V.E. Alih bahasa oleh Andriyanto, U.S., Basith, A. 1999. *Metode dan Aplikasi Peramalan*. Jilid I. Edisi 2. Jakarta: Erlangga.
- [5] Rosadi, D. 2012. *Ekonometrika & Analisis Runtun Waktu Terapan*. Yogyakarta: Andi.
- [6] Tsay, RS. 1988. *Outlier, Level Shift, and Variance Changes in Time Series*. Journal of Forecasting Vol. 7, Hal. 1-20
- [7] Wei, W.W.S. 2006. *Time Series Analysis, Univariate and Multivariate Methods*. Canada: Addison Wesley Publising Company.