

PREDIKSI JUMLAH PENUMPANG KERETA API MENGGUNAKAN MODEL VARIASI KALENDER DENGAN DETEKSI *OUTLIER* (Studi Kasus : PT. Kereta Api Indonesia DAOP IV Semarang)

Ani Funtika Saputri¹, Abdul Hoyyi², Sugito³

¹Mahasiswa Departemen Statistika FSM Universitas Diponegoro

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

ABSTRACT

Transportation is an inseparable and indispensable part of society in everyday life. Trains became one of the most popular public transportation, especially during the Eid. The shifting of the lunar month of Eid forms a pattern called calendar variation. The calendar variation model is a model that combines the dummy regression model with the ARIMA model. In time series models sometimes there are outliers that can affect the suitability of the model. So that modeling and forecasting method is done using model of calendar variation with outlier detection. Based on the analysis that has been done on the data of the number of passengers of Argo Bromo Anggrek railway, we get the ARIMA model $([11], 0, 1), D_t, D_{t-2,t}$ with the addition of 4 outliers as the best model and the resulted forecasting shows increase Railway passengers increase in the months leading up to Eid.

Keywords: Train, Calendar Variations, Outlier Detection

1. PENDAHULUAN

Transportasi^[7] merupakan suatu bagian yang tidak dapat dipisahkan dan sangat dibutuhkan masyarakat dalam kehidupan sehari-hari. Terdapat hubungan erat antara transportasi dengan jangkauan dan lokasi kegiatan manusia baik barang atau jasa. Dalam kaitannya dengan kehidupan manusia, transportasi memiliki peranan yang signifikan dalam berbagai aspek, baik dalam aspek sosial, ekonomi, lingkungan, politik, pertahanan dan keamanan. Betapa besar dan penting peranan transportasi dalam kehidupan manusia, tampak dari usaha-usaha manusia untuk senantiasa memperbaiki dan meningkatkan sistem serta kapasitas angkut sepanjang zaman dahulu kala hingga masa sekarang ini.

PT. Kereta Api Indonesia (PT. KAI) merupakan perusahaan transportasi tunggal kereta api yang senantiasa melakukan perbaikan dari segi pelayanan maupun kenyamanan konsumen. Berdasarkan data jumlah penumpang yang dihimpun oleh PT. KAI DAOP IV Semarang dari tahun ke tahun, terlihat bahwa terjadi kenaikan jumlah penumpang pada bulan-bulan menjelang maupun pasca perayaan Hari Raya Idul Fitri.

Variasi kalender merupakan pola periodik dan berulang-ulang dengan panjang periode yang bervariasi. Hal ini biasanya disebabkan oleh kebudayaan dan agama yang dianut masyarakat di wilayah tertentu^[9]. Agama Islam memiliki kalender yang berbeda dengan kalender Masehi, yaitu kalender Hijriyah. Jumlah bulan yang dimiliki Kalender Hijriyah sama dengan kalender Masehi, namun jumlah hari dalam tiap bulannya berbeda. Hal ini akan menimbulkan perbedaan waktu Hari Raya Idul Fitri pada setiap tahunnya jika dilihat dari kalender Masehi. Sedangkan pergeseran bulan terjadinya Hari Raya Idul Fitri terjadi secara periodik setiap tiga tahun sekali. Hal ini menimbulkan suatu variasi kalender. Tujuan dari penelitian ini adalah membuat model variasi kalender dengan deteksi *outlier* dan meramalkan data jumlah penumpang Kereta Api Argo Bromo Anggrek.

2. TINJAUAN PUSTAKA

2.1 Model Regresi *Dummy*

Dalam analisis regresi, seringkali terjadi bahwa variabel tak bebas dipengaruhi tidak hanya oleh variabel bebas yang bersifat kuantitatif, tetapi juga bersifat kualitatif. Akan tetapi, dalam variabel kualitatif ini perlu dikonversikan ke dalam bentuk kuantitatif sehingga dapat mengaplikasikan metode regresi dengan membentuk variabel yang sifatnya artifisial (*dummy*) ke dalam persamaan regresi. Variabel *dummy* bernilai 1 atau 0. Nilai 1 menunjukkan adanya atribut sedangkan nilai 0 menunjukkan tidak adanya atribut. Bentuk umum model regresi *dummy* adalah sebagai berikut:

$$y_t = \beta_0 + \beta_1 D_{1t} + \beta_2 D_{2t} + \dots + \beta_m D_{mt} + \varepsilon_t \quad (1)$$

dimana β_0 adalah intersep dan $\beta_1, \beta_2, \dots, \beta_m$ adalah koefisien parameter terkait dengan variabel *dummy* $D_{1t}, D_{2t}, \dots, D_{mt}$ dimana ε_t adalah residual model regresi *dummy*^[5].

2.2 Model ARIMA Non-Musiman

2.2.1 Proses *Autoregressive Integrated Moving Average* atau *ARIMA* (p,d,q)

Proses ARIMA (p,d,q) ini merupakan model *time series* yang non stasioner^[11]. Bentuk umum model ini adalah :

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)a_t \quad (2)$$

2.2.2 Model Subset ARIMA

Model subset ARIMA merupakan bagian dari model ARIMA tergeneralisasi, sehingga tidak dapat dinyatakan dalam bentuk umum^[10]. Contoh model subset ARIMA ([1,5],0,[1,12]) dapat ditulis sebagai :

$$(1 - \phi_1 B - \phi_5 B^5)Z_t = (1 - \theta_1 B - \theta_{12} B^{12})a_t$$

2.3 Model Variasi Kalender

Runtun waktu Y_t yang mengandung variasi kalender dapat dinyatakan sebagai berikut^[2]:

$$Y_t = f(X_t; \xi) + N_t \quad (3)$$

dengan $f(X_t; \xi)$ merupakan fungsi dari vektor parameter ξ dan vektor X_t yang terdiri atas variabel-variabel bebas yang diamati saat t , sedangkan N_t merupakan proses stokastik yang disebut gangguan atau *noise*.

Fungsi $f(X_t; \xi)$ dapat dianggap sebagai model regresi yang memuat efek variasi kalender. Jika efek yang berpengaruh terhadap variasi kalender hanya efek liburan, maka fungsi $f(X_t; \xi)$ disebut efek variasi liburan, dinotasikan dengan L_t , sehingga model variasi kalender juga dapat dinyatakan sebagai berikut:

$$Y_t = L_t + N_t \quad (4)$$

2.4 Pemeriksaan Diagnostik

Diagnosa/verifikasi dilakukan untuk memeriksa apakah model yang diestimasi sudah cocok dengan data yang ada. Jika ditemui penyimpangan, maka harus merumuskan model yang baru untuk diidentifikasi dan diestimasi lagi^[8].

2.4.1 Uji Signifikansi Parameter^[1]

Hipotesis:

$H_0 : \hat{\tau} = 0$ (tidak terdapat pengaruh variabel terhadap model)

$H_1 : \hat{\tau} \neq 0$ (terdapat pengaruh variabel terhadap model)

Statistik uji:

$$t = \frac{\hat{\tau}}{SE(\hat{\tau})} \quad (5)$$

dengan $\hat{\tau}$ = estimasi parameter model variasi kalender

Kriteria penolakan:

Menolak H_0 jika $|t| > t_{(\alpha/2, n_p)}$ dengan n_p adalah banyaknya parameter atau menolak H_0 jika $p_{value} < \alpha$.

2.4.2 Uji White Noise^[11]

Hipotesis:

$H_0 : \rho_1 = \rho_2 = \dots = \rho_m = 0$ (tidak ada korelasi residual antar lag)

H_1 : Paling sedikit ada satu $\rho_k \neq 0$ dengan $k = 1, 2, \dots, m$ (ada korelasi residual antar lag)

Satistik uji:

$$Q = n(n+2) \sum_{k=1}^j \frac{\hat{\rho}_k^2}{(n-k)} \quad (6)$$

dimana:

n : banyaknya data pengamatan

k : lag yang diuji dengan $k = 1, 2, \dots, j$

ρ_k : dugaan *Autocorrelation Function* residual pada periode lag ke- k

Kriteria penolakan: menolak H_0 jika $Q_{hitung} > \chi_{(\alpha, df)}^2$ tabel, dengan derajat bebas (df) adalah k atau $p_{value} < \alpha$.

2.4.3 Uji Asumsi Distribusi Normal

Cara menguji apakah residual data memenuhi asumsi normalitas yaitu menggunakan uji *Kolmogorov-Smirnov* dengan tahapan sebagai berikut^[3]:

Hipotesis :

H_0 : Residual data berdistribusi normal

H_1 : Residual data tidak berdistribusi normal

Statistik Uji :

$$D = \sup_x |S(x) - F_0(x)| \quad (7)$$

dimana:

D : nilai supremum, untuk semua x , dari nilai mutlak beda $S(x) - F_0(x)$.

$F_0(x)$: fungsi distribusi yang dihipotesiskan yaitu distribusi normal.

$S(x)$: fungsi distribusi sampel atau empirik.

Kriteria penolakan :

H_0 ditolak jika $D > D_{\alpha, n}$ atau $p_{value} < \alpha$.

2.5 Pemilihan Model Terbaik

Penentuan model terbaik dari beberapa model yang memenuhi syarat dapat dilakukan dengan melihat nilai AIC (*Akaike's Information Criterion*)^[11]. Model terbaik ialah model yang memiliki nilai AIC terkecil. AIC didefinisikan sebagai berikut:

$$AIC(M) = n \ln \hat{\sigma}_a^2 + 2M \quad (8)$$

dimana M adalah banyaknya parameter dalam model dan n adalah banyaknya pengamatan yang efektif yang sama dengan jumlah residual yang dihitung dari deret. Dengan $\hat{\sigma}_a^2$ adalah penduga maksimum likelihood dari σ_a^2 .

2.6 Heteroskedastisitas

Pengujian yang dapat dilakukan untuk mendeteksi keberadaan heteroskedastisitas adalah menggunakan Uji *ARCH-Lagrange Multiplier* (ARCH-LM) dengan tahapan pengujian^[4]:

Hipotesis:

$H_0 : \theta_1 = \theta_2 = \dots = \theta_s = 0$ (tidak ada efek ARCH)

H_1 : minimal ada satu nilai $\theta_j \neq 0$ untuk $j = 1, 2, 3, \dots, s$ (terdapat efek ARCH)

Statistik Uji :

$$LM = (n - s)R^2 \quad (9)$$

dimana n adalah banyak data dan R^2 adalah koefisien determinasi model regresi dari kuadrat residual.

Kriteria penolakan :

H_0 ditolak jika $LM > X^2_{(\alpha; s)}$ atau $p_{value} < \alpha$.

2.7 Deteksi Outlier

Outlier adalah pengamatan yang secara jelas berbeda dengan pengamatan lainnya^[10]. Outlier menyebabkan kesimpulan dari analisis data yang dihasilkan tidak valid, sehingga prosedur yang mendeteksi dan menghapus efek outlier sangat penting dalam analisis data. Dalam runtun waktu, outlier diklasifikasikan menjadi *Innovational Outlier* (IO), *Additive Outlier* (AO), *Temporary Change* (TC), dan *Level Shift* (LS)^[11]. *Additive Outlier* (AO) hanya berpengaruh pada pengamatan ke- T , sedangkan tiga jenis outlier lainnya yaitu *Innovational Outlier* (IO), *Level Shift* (LS) dan *Temporary Change* (TC) berpengaruh pada pengamatan ke- T , $T+1$, ..., dan seterusnya.

Bentuk umum sebuah *Additive Outlier* (AO) dalam proses ARMA diuraikan sebagai berikut :

$$Z_t = \frac{\theta(B)}{\phi(B)} a_t + \omega I_t^{(T)} \quad (10)$$

Bentuk umum sebuah *innovational outlier* didefinisikan sebagai berikut :

$$Z_t = X_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)} = \frac{\theta(B)}{\phi(B)} (a_t + \omega I_t^{(T)}) \quad (11)$$

Model outlier *Level Shift* dinyatakan sebagai :

$$Z_t = X_t + \frac{1}{(1-B)} \omega I_t^{(T)} \quad (12)$$

Model *Temporary Change* dapat dituliskan sebagai berikut :

$$Z_t = X_t + \frac{1}{(1-\delta B)} \omega I_t^{(T)} \quad (13)$$

2.8 Evaluasi Model Peramalan

Dalam peramalan, diperlukan ukuran-ukuran relatif yang menyangkut presentase kesalahan. Salah satu ukuran presentase kesalahan adalah MAPE (*Mean Absolut Percentage Error*).

$$MAPE = \sum_{i=1}^n |PE_i| / n \quad (14)$$

dimana $PE_i = \left(\frac{X_i - F_i}{X_i} \right) \times 100$

dengan n adalah banyaknya ramalan yang dilakukan, X_i adalah data sebenarnya dan F_i adalah data hasil ramalan

Nilai evaluasi yang dihasilkan mempunyai kriteria MAPE sebagai berikut^[6]:

1. $MAPE < 10\%$: kemampuan peramalan sangat baik
2. $10\% \leq MAPE < 20\%$: kemampuan peramalan baik
3. $20\% \leq MAPE < 50\%$: kemampuan peramalan cukup
4. $MAPE \geq 50\%$: kemampuan peramalan buruk

3. METODE PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder mengenai jumlah penumpang KA Argo Bromo Anggrek. Data jumlah penumpang yang digunakan merupakan data dalam kurun waktu Januari 2010 sampai dengan Desember 2016 dengan periode bulanan.

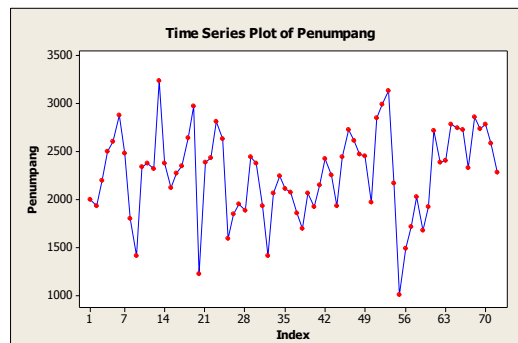
3.2 Langkah-langkah Analisis Data

Pengolahan data pada penelitian ini yaitu menggunakan *Software Microsoft Excel 2013, Minitab 14, E-Views 7 dan SAS 9.1.3 Portable*. Adapun Langkah-langkah yang dilakukan untuk menganalisis data adalah:

1. Membagi data menjadi dua bagian, yaitu data *in-sample* dan data *out-sample*.
2. Melakukan identifikasi model
3. Menghilangkan efek variasi kalender dari variabel respons dengan menggunakan model regresi *dummy*.
4. Melakukan uji *white noise* pada N_t dengan melihat plot ACF N_t . Jika memenuhi asumsi *white noise* maka dilanjutkan ke peramalan data. Jika tidak, maka dilakukan pemodelan N_t dengan metode ARIMA Box-Jenkins.
5. Melakukan uji stasioneritas dalam *mean* dan varian.
6. Melakukan pengujian model ARIMA yang diperoleh pada langkah ketiga.
7. Melakukan uji signifikansi parameter menggunakan uji t .
8. Melakukan uji asumsi residual yaitu memenuhi asumsi residual *white noise* menggunakan uji *Ljung-Box* dan asumsi residual berdistribusi normal menggunakan uji *Kolmogorov-Smirnov*.
9. Melakukan uji homoskedastisitas menggunakan uji ARCH-LM.
10. Pemilihan model terbaik berdasarkan nilai AIC terkecil.
11. Melakukan pendeteksian outlier pada model terbaik yang telah diperoleh.
12. Melakukan pemodelan dengan memasukkan outlier.

4. HASIL DAN PEMBAHASAN

Tahap awal identifikasi model adalah dengan melihat pola data jumlah penumpang KA Argo Bromo Angrek:



Gambar 1. *Time series plot* jumlah penumpang KA Argo Bromo Angrek

Diduga model regresi untuk data jumlah penumpang KA Argo Bromo Angrek sebagai berikut:

$$y_t = \beta_0 + \beta_1 t + \beta_2 D_t + \beta_3 D_{t-1} + \beta_4 D_{t-2} + \beta_5 D_{t+1} + \beta_6 D_{t,t} + \beta_7 D_{t-1,t} + \beta_8 D_{t-2,t} + \beta_9 D_{t+1,t} + \varepsilon_t$$

Langkah selanjutnya dilakukan pengujian signifikansi parameter.

Tabel 1. Nilai signifikansi parameter uji serentak dan parsial


i	Parameter (β_i)	Estimasi Parameter ($\hat{\beta}_i$)	p value (uji parsial)	Keputusan	p value (uji serentak)
0	β_0	2311,47	0,000	H_0 ditolak	0,000
1	β_2	-758,6	0,000	H_0 ditolak	
2	β_8	8,553	0,039	H_0 ditolak	

Diperoleh parameter β_0, β_2 , dan β_8 memiliki pengaruh signifikan terhadap variabel tak bebas y pada model regresi *dummy*.


Setelah melakukan pemodelan regresi dan menghasilkan model regresi dummy yang sesuai maka langkah selanjutnya adalah menguji asumsi *white noise* untuk residual (N_t) dari model tersebut. N_t harus memenuhi asumsi *white noise*, karena jika asumsi ini tidak terpenuhi maka dilakukan pemodelan N_t menggunakan model ARIMA.

Hasil uji *white noise* menunjukkan bahwa N_t belum *white noise* karena $p_{value} < \alpha$. Oleh karena itu perlu dilakukan pemodelan N_t dengan menggunakan ARIMA. Pemodelan ini disebut sebagai model variasi kalender.

Langkah pertama identifikasi model variasi kalender adalah mengidentifikasi apakah N_t stasioner dalam *mean* dan varian. Pengujian stasioneritas dalam *mean* menggunakan uji *Dickey Fuller* dan pengujian stasioneritas dalam varian menggunakan transformasi *Box-Cox*. Dari uji yang dilakukan, diperoleh bahwa N_t stasioner dalam *mean* dan varian. Selanjutnya melakukan identifikasi plot ACF dan plot PACF terhadap N_t untuk menduga model ARIMA.



Gambar 2. Plot PACF Residual N_t



Gambar 3. Plot ACF Residual N_t

Berdasarkan Gambar 2 dan 3, terdapat 13 kemungkinan model variasi kalender yang terbentuk dengan variabel *dummy* D_t dan $D_{t-2,t}$ yaitu ARIMA (1, 0, 0), ARIMA (0, 0, 1), ARIMA (1, 0, 1), ARIMA ([11], 0, 0), ARIMA ([11], 0, 1), ARIMA ([17], 0, 0), ARIMA ([17], 0, 1), ARIMA ([1,11], 0, 0), ARIMA ([1,11], 0, 1), ARIMA ([1,17], 0, 0), ARIMA ([1,17], 0, 1), ARIMA ([1,11, 17], 0, 0), dan ARIMA ([1,11, 17], 0, 1).

Setelah pendugaan model, dilakukan analisis dengan menguji parameter-parameter model variasi kalender dan terdapat 2 model yang seluruh parameternya signifikan, yaitu ARIMA ([11], 0, 0), $D_t, D_{t-2,t}$ dan ARIMA ([11], 0, 1), $D_t, D_{t-2,t}$.

Setelah semua variabel signifikan, maka perlu dilakukan pengujian asumsi *white noise* terhadap residual (a_t). Hasil uji *white noise* menunjukkan bahwa a_t pada model ARIMA ([11], 0, 1), $D_t, D_{t-2,t}$ telah memenuhi asumsi *white noise* sehingga model variasi kalender dapat digunakan. Selanjutnya dilakukan uji asumsi residual berdistribusi normal pada model ARIMA ([11], 0, 1), $D_t, D_{t-2,t}$ dan didapatkan hasil p_{value} bernilai $> 0,15$ sehingga residual data memiliki distribusi normal.

Setelah itu, dilakukan uji ARCH-LM untuk mengetahui apakah asumsi homoskedastisitas terpenuhi atau tidak.

Tabel 2. Nilai p_{value} untuk *Lagrange-Multiplier* Model Variasi Kalender

Order	Pr > LM	Order	Pr > LM
1	0.7043	7	0.6974
2	0.9211	8	0.7717
3	0.5709	9	0.7412
4	0.6316	10	0.8095
5	0.5148	11	0.8621
6	0.6089	12	0.6089

Nilai p_{value} untuk LM lebih dari nilai taraf signifikansi, yaitu 0,05. Hal ini menunjukkan bahwa asumsi homoskedastisitas terpenuhi, sehingga pemodelan ARIMA dapat digunakan.

Model ARIMA ([11], 0, 1), D_t , $D_{t-2,t}$ adalah model terbaik karena seluruh parameternya signifikan dan semua asumsinya terpenuhi, dengan nilai AIC = 1.047.

Kemudian dilakukan pendeteksian *outlier* dan didapatkan jumlah *outlier* seperti pada Tabel 3 berikut:

Tabel 3. Deteksi *Outlier* Model Variasi Kalender

Obs	Periode	Type	Estimasi	Chi-Square	p_{value}
13	Januari 2011	Additive	920.92553	8.55	0.0035
20	Agustus 2011	Additive	-665.7627	5.12	0.0237
61	Januari 2015	Shift	284.23598	5.7	0.017
25	Januari 2012	Additive	-544.3705	6.05	0.0139
50	Februari 2014	Additive	-458.6332	4.34	0.0371

Setelah seluruh *outlier* terdeteksi, dilakukan estimasi parameter untuk model ARIMA ([11], 0, 1), D_t , $D_{t-2,t}$ dengan menambahkan *outlier* tersebut satu persatu. Pada penambahan *outlier* pengamatan ke-50 menghasilkan keputusan tidak signifikan, maka selanjutnya hanya *outlier* pengamatan ke-13, 20, 61 dan 25 yang digunakan dalam model. Sehingga model akhir untuk model variasi kalender dengan deteksi *outlier* adalah sebagai berikut:

$$\hat{Z}_t = 2.258,2 - 612,411D_t + 6,248D_{t-2,t} + \frac{(1 + 0,697 B)a_t}{(1 + 0,381 B^{11})} + 851,808 I_t^{A(13)} - 910,035 I_t^{A(20)} + 282,089 I_t^{S(61)} - 402,492 I_t^{A(25)}$$

Untuk melakukan evaluasi peramalan, dapat dilihat melalui nilai $MAPE_{in}$ dan $MAPE_{out}$. Nilai $MAPE_{in}$ sebesar 0,089 atau 8,9 % dengan kriteria kemampuan peramalan sangat baik. Sedangkan nilai $MAPE_{out}$ sebesar 0,295 atau 29,5 % sehingga dapat disimpulkan bahwa kemampuan peramalan cukup.

Tabel 4. Penghitungan Nilai $MAPE_{out}$

Periode	Aktual (Z_t)	Forecast (\hat{Z}_t)	$(Z_t - \hat{Z}_t)$	$\left(\frac{Z_t - \hat{Z}_t}{Z_t}\right)$	$\left \frac{Z_t - \hat{Z}_t}{Z_t}\right $
73	2765	2517	247.951	0.09	0.090
74	3087	2592	494.914	0.16	0.160
75	3160	2446	713.635	0.226	0.226
76	3142	2616	526.274	0.167	0.167
77	4121	2949	1171.836	0.284	0.284
78	2791	2387	403.765	0.145	0.145
79	4353	1804	2549.104	0.586	0.586
80	3633	2465	1168.373	0.322	0.322
81	4385	2448	1937.113	0.442	0.442
82	3658	2521	1136.682	0.311	0.311
83	4072	2637	1435.399	0.353	0.353
84	4730	2549	2180.926	0.461	0.461
Total					3.546
Nilai $MAPE_{out}$					0.295

Adapun peramalan jumlah penumpang KA Argo Bromo Anggrek dilakukan untuk 12 (dua belas) periode ke depan yang hasilnya disajikan dalam Tabel 5 berikut:

Tabel 15. Hasil Peramalan untuk 12 Periode ke Depan

Periode	Waktu	Nilai Peramalan
85	Januari 2017	2.521
86	Februari 2017	2.576
87	Maret 2017	2.512
88	April 2017	3.118
89	Mei 2017	2.598
90	Juni 2017	1.975
91	Juli 2017	2.569
92	Agustus 2017	2.575
93	September 2017	2.547
94	Oktober 2017	2.504
95	November 2017	2.537
96	Desember 2017	2.548

Dari hasil peramalan diketahui bahwa jumlah penumpang yang terbanyak yaitu pada Bulan April 2017 dengan jumlah penumpang sebanyak 3.118 orang.

5. KESIMPULAN

1. Model terbaik adalah model ARIMA ([11], 0, 1), D_t , $D_{t-2,t}$ dengan penambahan 4 buah *outlier*. Model ini memiliki nilai AIC sebesar 1.014.
2. Model akhir yang diperoleh yaitu:

$$\hat{Z}_t = 2.258,2 - 612,411D_t + 6,248D_{t-2,t} + \frac{(1 + 0,697 B)a_t}{(1 + 0,381 B^{11})} + 851,808 I_t^{A(13)} - 910,035 I_t^{A(20)} + 282,089 I_t^{S(61)} - 402,492 I_t^{A(25)}$$

3. Peramalan jumlah penumpang KA Argo Bromo Anggrek untuk periode bulanan mulai dari Bulan Januari – Bulan Desember 2017 dilakukan menggunakan model variasi kalender dengan penambahan 4 buah *outlier*. Hasil peramalan menunjukkan jumlah penumpang KA Argo Bromo terbanyak terjadi pada Bulan April 2017 yaitu sebanyak 3.118 orang.

DAFTAR PUSTAKA

- [1] Aswi dan Sukarna. 2006. *Analisis Deret Waktu dan Aplikasi*. Makassar: Andira Publisher.
- [2] Bell, W.R. dan Hilmer, S. 1983. Modelling Time Series with Calendar Variation, *Journal of American Statistical Association*. 78, 526-534.
- [3] Daniel, W. W. 1989. *Statistika Nonparametrik Terapan*. Jakarta. PT. Gramedia.
- [4] Engle, R.F. 1982. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, Vol. 50, No. 4. (Jul., 1982), pp. 987-1007.
- [5] Gujarati, N.D. 1978. *Ekonometrika Dasar*. Jakarta: Erlangga.
- [6] Halimi, R, Anggraeni, W, Tyasnurita, R. 2013. *Pembuatan Aplikasi Peramalan Jumlah Permintaan Produk Dengan Metode Time Series Exponential Smoothing Holts Winter di PT. Telekomunikasi Indonesia Tbk*. Surabaya: ITS.
- [7] Siregar, M. S. 1968. *Managemen Pengangkutan*. Jakarta: Berdikasri Student.

- [8] Soejoeti, Z. 1987. *Analisis Runtun Waktu*, Materi Pokok UT. Jakarta. Karunika.
- [9] Suhartono. (2010). Calendar Variation Model Based on ARIMAX for Forecasting Sales Data with Ramadhan Effect. *Proceedings of the Regional Conference on Statistical Sciences*. 349-361. Malaysia Institute of Mathematical Sciences University of Malaya.
- [10] Tarno. 2013. *Kombinasi Prosedur Pemodelan Subset Arima dan Deteksi Outlier untuk Prediksi Data Runtun Waktu*. Prosiding Seminar Nasional Statistika UNDIP 2013. Semarang.
- [11] Wei, W.W.S. 2006. *Time Series Analysis, Univariate and Multivariate Methods*. Canada. Addison Wesley Publishing Company.