



## Prediksi Jumlah Penumpang Pesawat Pada PT. Angkasa Pura II Bandar Udara Sultan Thaha Jambi dengan Pemodelan ARIMA

Nayla Desviona

Institut Teknologi dan Bisnis Muhammadiyah Purbalingga, Indonesia

E-mail: [nayladesviona02@gmail.com](mailto:nayladesviona02@gmail.com)

Article Info	Abstract
<b>Article History</b> Received: 2023-03-12 Revised: 2023-04-10 Published: 2023-05-03  <b>Keywords:</b> <i>Passenger;</i> <i>predictions;</i> <i>ARIMA;</i> <i>Outliers.</i>	<p>The growth in the number of air transport passengers every year that occurs at Sultan Thaha Jambi Airport shows increasing public interest in the use of these transportation services. This growth must be followed by the development of infrastructure at the airport to maintain the quality of service to passengers so it is necessary to predict the number of airplane passengers. ARIMA model time series analysis can be used to make estimates or predictions in the future. Observation data on the number of airplane passengers can be viewed as time series data. The purpose of this research is to determine the ARIMA model of the number of airplane passengers at Sultan Thaha Jambi Airport and then predict it for one year. However, at the identification stage, it is known that there are data that are significantly different from other data, so it can be indicated that there are outlier data. From this study the best ARIMA model for prediction is the ARIMA subset (0,1,[2,12]). With outlier detection where the addition of outliers to the model can improve outliers in the data. The conclusion of this study is that the ARIMA model with the addition of outliers is better than the ARIMA model without outliers. From the prediction results, the highest fluctuation in the increase in the number of arriving passengers occurred in December 2018 of 91,599 and the number of departing passengers was 89,912.</p>
Artikel Info	Abstrak
<b>Sejarah Artikel</b> Diterima: 2023-03-12 Direvisi: 2023-04-10 Dipublikasi: 2023-05-03  <b>Kata kunci:</b> <i>Penumpang;</i> <i>Prediksi;</i> <i>ARIMA;</i> <i>Outlier.</i>	<p>Pertumbuhan jumlah penumpang angkutan udara setiap tahun yang terjadi di Bandar Udara Sultan Thaha Jambi menunjukkan meningkatnya minat masyarakat terhadap penggunaan jasa transportasi tersebut. Pertumbuhan ini harus diikuti dengan pengembangan infrastruktur di bandara untuk menjaga kualitas pelayanan terhadap penumpang sehingga diperlukan prediksi jumlah penumpang pesawat. Analisis <i>time series</i> model ARIMA dapat digunakan untuk melakukan perkiraan atau prediksi pada masa yang akan datang. Data pengamatan banyaknya penumpang pesawat dapat dipandang sebagai data <i>time series</i>. Tujuan penelitian ini ialah untuk menentukan model ARIMA dari banyaknya penumpang pesawat di Bandara Sultan Thaha Jambi kemudian memprediksi untuk satu tahun. Namun pada tahap identifikasi diketahui terdapat data yang secara mencolok berbeda dengan data lainnya, maka dapat diindikasikan terdapat data pencilon atau <i>outlier</i>. Dari penelitian ini model ARIMA yang terbaik untuk prediksi adalah subset ARIMA (0,1,[2,12]). Dengan deteksi <i>outlier</i> dimana penambahan <i>outlier</i> ke dalam model dapat memperbaiki pencilon pada data. Kesimpulan dari penelitian ini adalah model ARIMA dengan penambahan <i>outlier</i> lebih baik daripada model ARIMA tanpa <i>outlier</i>. Dari hasil prediksi didapatkan fluktuasi kenaikan tertinggi jumlah penumpang datang terjadi pada bulan Desember 2018 sebesar 91.599 dan jumlah penumpang berangkat sebesar 89.912.</p>

### I. PENDAHULUAN

Saat ini pertumbuhan jumlah penumpang terus terjadi setiap tahunnya di Bandar Udara Sultan Thaha Jambi. Pertumbuhan jumlah penumpang sebesar 10% pada dua tahun terakhir yaitu tahun 2016 dan 2017. Jumlah penumpang yang ada tidak selalu sama, dimana saat terjadi kenaikan dapat menyebabkan penumpukan penumpang atau kerugian saat terjadi penurunan. Hal ini tentu menjadikan peranan prediksi dalam jumlah penumpang perlu dilakukan agar pihak Angkasa Pura II dapat

memberikan pelayanan dan kebijakan yang tepat. Tujuan penelitian ini yaitu untuk dapat menentukan model prediksi jumlah penumpang pesawat yang datang dan berangkat di Bandara Sultan Thaha Jambi. Salah satu metode yang dapat digunakan adalah analisis *time series* model ARIMA.

Model ARIMA terdiri dari dua aspek, yaitu aspek autoregressive dan moving average. Secara umum, model ARIMA ini dituliskan dengan notasi ARIMA ( $p, d, q$ ), dimana  $p$  menyatakan orde dari proses *autoregressive* (AR),  $d$  menyatakan pem-

bedaan (*differencing*), dan  $q$  menyatakan orde dari proses *moving average*. Model ARIMA telah digunakan untuk prediksi dalam berbagai bidang terapan. Lusi (2012) menggunakan metode ARIMA untuk peramalan trafik sms area Jabodetabek dan Yamin (2016) menggunakan ARIMA dan Winter dalam meramalkan data saham bank. Pada penelitian sebelumnya terfokus untuk model ARIMA, namun yang membahas subset ARIMA masih sangat terbatas selain itu penulis menemukan pencilaan dalam data runtun waktu yang digunakan sehingga penggunaan deteksi *outlier* dilakukan untuk memperbaiki model.

Pemodelan ARIMA terdiri dari beberapa tahapan yaitu identifikasi model, estimasi parameter, verifikasi model, dan *forecasting*. Salah satu tahapan penting dalam pemodelan ARIMA adalah identifikasi berdasarkan karakteristik data. Tahapan identifikasi digunakan untuk menentukan order ARIMA atau subset ARIMA yang tepat. Order tersebut ditentukan dari pola ACF dan PACF. Selanjutnya tahap estimasi hingga verifikasi model. Apabila telah diperoleh estimasi modelnya, maka salah satu cara untuk menentukan kesesuaian model adalah dengan melakukan deteksi *outlier*. Jika terdapat *outlier* dalam data harus diatasi dengan cara memasukkan *outlier* ke dalam model (Suparti, 2015). Dalam penelitian ini, akan digunakan model ARIMA dengan penambahan *outlier* yang diterapkan untuk prediksi jumlah penumpang pesawat.

Secara umum, model ARIMA ( $p, d, q$ ) dapat ditulis sebagai (Wei, 2006)

$$\phi(B)(1-B)^d Z_t = \theta_q(B)\alpha_t$$

## II. METODE PENELITIAN

### 1. Sumber Data dan Variabel Penelitian

Dalam penelitian ini, digunakan data sekunder yang diperoleh dari PT. Angkasa Pura II yaitu data jumlah penumpang pesawat yang datang dan berangkat di Bandar Udara Sultan Thaha Jambi selama enam tahun mulai bulan Januari 2012 sampai bulan Desember 2017. Data tersebut digunakan sebagai variabel dalam penelitian.

### 2. Analisis Data

Data yang telah dikumpulkan akan dianalisis dengan analisis *time series* ARIMA. Adapun langkah-langkah yang dilakukan dalam penelitian ini adalah sebagai berikut:

#### a) Identifikasi Model

Hal pertama yang dilakukan dalam melakukan peramalan dengan menggunakan metode Box-Jenkins adalah melihat data stasioner atau tidak. Uji stasioneritas data dalam *mean* juga dapat dilakukan dengan cara uji *Augmented-Dickey Fuller*. Apabila data tidak stasioner, maka perlu dimodifikasi untuk menghasilkan data yang stasioner dengan cara *differencing*. Identifikasi model berasal dari deret waktu yang stasioner. Berdasarkan data tersebut dapat diperoleh model sementara dengan cara mengamati plot ACF dan PACF (Montgomery, 2008).

#### b) Estimasi Parameter

Setelah diperoleh dugaan model awal ARIMA ( $p, d, q$ ) selanjutnya yaitu parameter ditaksir, sehingga didapatkan besaran koefisien model. Dengan diperoleh nilai estimasi parameter maka didapat model yang akan diuji signifikansi parameter.

#### c) Pemeriksaan Diagnostik

Pemeriksaan diagnostik dilakukan untuk menguji kelayakan model peramalan, jika model yang diperoleh belum layak maka dicari model lain. Ada dua uji yang dilakukan dalam tahap diagnostik yaitu uji kesignifikanan parameter dan juga uji kesesuaian model yang meliputi uji independensi dan kenormalan residual (Aswi dan Sukarna, 2006).

##### 1. Uji independensi residual

Uji ini dilakukan dengan melihat pasangan ACF dan PACF residual yang dihasilkan model. Selain menggunakan ACF dan PACF residual, independensi juga dapat dilakukan dengan melihat kerandoman residual yaitu dengan cara membandingkan nilai *P-value* pada output proses *Ljung Box Pierce* dengan selang kepercayaan yang digunakan dalam uji hipotesis. Rumus uji statistik *Ljung Box-Pierce* (Aswi dan Sukarna, 2006).

##### 2. Uji kenormalan residual

Uji ini dilakukan dengan melihat hasil uji statistik *Kolmogorov-Smirnov*. Jika model yang didapatkan dua atau lebih dari satu, untuk memilih model yang paling sesuai dilakukan dengan melihat nilai AIC dan SBC.

Setelah pemeriksaan diagnostik, selanjutnya dilakukan deteksi *outlier* untuk


dapat mengoptimalkan model yang ada. Proses mengatasi *outlier* dengan memasukkan *outlier* kedalam model hingga didapat uji kesesuaian residual signifikan terhadap *White-Noise* dan distribusi normal (Wei, 2006). Menurut Gaspersz (1998) suatu model dikatakan mempunyai kemampuan prediksi yang sangat baik jika nilai MAPE kurang dari 10%, mempunyai kemampuan yang baik jika nilai MAPE berada diantara 10% sampai 20%, mempunyai kemampuan yang cukup baik jika nilai MAPE antara 20% dan 50%, dan kemampuan prediksi yang rendah jika nilai MAPE lebih dari 50% dengan:

$$MAPE = \frac{1}{m} \sum_{i=1}^m \frac{|Z_i - \hat{Z}_i|}{Z_i} \times 100\%$$


d) Penerapan Model untuk prediksi

### III. HASIL DAN PEMBAHASAN

#### A. Identifikasi Model




Gambar 1. Plot Time Series Datang




Gambar 2. Plot Time Series Berangkat

Berdasarkan Gambar 1 dan 2 dapat dilihat secara visual bahwa data jumlah penumpang pesawat yang datang dan berangkat tidak stasioner karena adanya pola *trend* atau pola data yang cenderung naik atau turun. Pada gambar di atas menunjukkan pola data yang cenderung naik, kecenderungan data yang terus berfluktuasi naik memberi indikasi bahwa data tidak stasioner dalam *mean*. Kemudian dilakukan uji *Augmented Dickey-*

*Fuller* dan hasilnya data belum menunjukkan stasioner dalam *mean*.



Gambar 3. Transformasi Box-Cox Datang




Gambar 4. Transformasi Box-Cox Berangkat

Pada Gambar 3 dan 4 menunjukkan bahwa data telah stasioner dalam variansi dengan nilai *Rounded Value* yang diperoleh sebesar satu. Selain stasioner dalam variansi, data juga harus stasioner dalam *mean* sehingga dapat dilakukan pemodelan ARIMA dengan asumsi data stasioner terpenuhi.



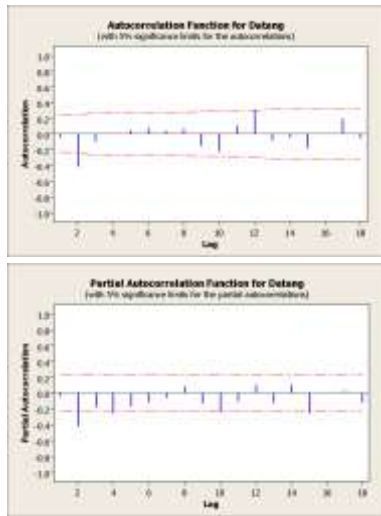
Gambar 5. Plot Differencing Datang



Gambar 6. Plot Differencing Berangkat



Selanjutnya dilakukan *differencing* satu kali untuk memperoleh data yang stasioner dalam

mean. Gambar 5 dan 6 menunjukkan data telah stasioner karena data sudah horizontal sepanjang sumbu waktu meskipun dari plot runtun waktu terlihat ada pengamatan yang berbeda dari pengamatan lain dan diduga sebagai *outlier*.



**Gambar 7.** Plot ACF dan PACF Penumpang Datang

Untuk mengidentifikasi model dugaan awal dapat dilakukan dengan melihat plot grafik ACF dan PACF seperti Gambar 7. Plot grafik ACF menunjukkan pada *lag* 2 signifikan berbeda dari nol dan terpotong pada *lag* tersebut, pada *lag* 12 juga signifikan artinya pada grafik plot ACF terpotong (*cuts-off*) pada *lag* 2 dan 12. Dari plot grafik PACF dimana *lag* 2 dan *lag* 4 signifikan berbeda dari nol dengan turun secara eksponensial (*dies-down*). Dari kedua grafik di atas dapat menguatkan uji pasangan ACF dan PACF bahwa proses tersebut adalah proses MA( $q$ ) dengan satu kali *differencing*. Dalam memutuskan model mana yang terbaik atau yang paling tepat untuk suatu deret waktu tertentu dapat dilakukan dengan mencoba berbagai kemungkinan nilai  $p, d, q$ . Dengan demikian dapat diidentifikasi beberapa model dugaan awal yaitu model ARIMA dengan satu *differencing* yaitu ARIMA  $([2,12],1,[2,4])$ , ARIMA  $([2,12],1,2)$ , ARIMA  $([2,12],1,0)$ , ARIMA  $(0,1,2)$ , dan ARIMA  $(0,1,[2,12])$ .



**Gambar 8.** Plot ACF dan PACF Penumpang Berangkat

Seperti identifikasi model awal pada data jumlah penumpang datang, plot grafik ACF dan PACF juga digunakan untuk menentukan model tentatif awal pada data jumlah penumpang berangkat. Plot grafik ACF menunjukkan signifikan pada *lag* 2 dan *lag* 12 dengan pola *cuts-off*. Dari plot grafik PACF dimana *lag* 2, 3, dan 10 signifikan berbeda dari nol dengan turun secara eksponensial (*dies-down*). Dari kedua grafik di atas dapat menguatkan uji pasangan ACF dan PACF bahwa proses tersebut adalah proses MA( $q$ ) dengan satu kali *differencing*. Dengan demikian dapat diidentifikasi beberapa model dugaan awal yaitu model ARIMA dengan satu *differencing* yaitu ARIMA  $([2,3,10],1,[2,12])$ , ARIMA  $([2,3],1,[2,12])$ , ARIMA  $(2,1,[2,12])$ , ARIMA  $(0,1,2)$ , dan ARIMA  $(0,1,[2,12])$ .

## B. Estimasi dan Uji Signifikansi Parameter

Hasil untuk uji signifikansi parameter beberapa model dugaan yang sesuai untuk model pada jumlah penumpang datang disajikan pada Tabel 2, sedangkan uji signifikansi parameter beberapa model dugaan yang sesuai untuk model pada jumlah penumpang berangkat disajikan pada Tabel 3.

**Tabel 1.** Uji Signifikansi Parameter Pada Model Jumlah Penumpang Datang

Model	Parameter	Estimate	P-Value	Lag	Ket
ARIMA $([2,12],1,[2,4])$ (no constant)	$\phi_2$	0.43001	0.0305	2	Parameter Signifikan
	$\phi_{12}$	0.44376	0.0015	12	
	$\theta_2$	1.08152	<.0001	2	
	$\theta_4$	-0.41969	0.0070	4	
ARIMA $([2,12],1,2)$	$\phi_0$	312.25094	0.2187	0	Parameter tidak signifikan
	$\phi_2$	0.42166	0.0617	2	
	$\phi_{12}$	0.28902	0.0002	12	
	$\theta_1$	0.22635	0.0460	2	
	$\theta_2$	0.77365	0.0467	12	
ARIMA $([2,12],1,0)$ (no constant)	$\phi_2$	-0.36462	0.0013	2	Parameter Signifikan
	$\phi_{12}$	0.28605	0.0186	12	



ARIMA (0,1,2)	$\theta_0$	280.52356	0.0023	0	Parameter Signifikan
	$\theta_1$	0.37519	0.0005	1	
	$\theta_2$	0.62481	<.0001	2	
ARIMA (0,1,[2,12]) (no constant)	$\theta_2$	0.56452	<.0001	2	Parameter Signifikan
	$\theta_{12}$	-0.46178	<.0001	12	

**Tabel 2.** Uji Signifikansi Parameter Pada Model Jumlah Penumpang Berangkat

Model	Parameter	Estimate	P-Value	Lag	Ket
ARIMA ([2,3,10],1,[2,12])	$\mu$	-136.49510	0.8870	0	Parameter Tidak Signifikan
	$\theta_2$	0.40578	0.0087	2	
	$\theta_{12}$	-0.52937	0.0001	12	
	$\phi_2$	-0.14416	0.4256	2	
ARIMA ([2,12],1,2)	$\phi_3$	-0.21726	0.0820	3	Parameter tidak signifikan
	$\phi_{10}$	0.02230	0.8595	10	
	$\mu$	-115.02831	0.9027	0	
	$\theta_2$	0.40694	0.0081	2	
ARIMA ([2,3],1,[2,12])	$\theta_{12}$	-0.52614	<.0001	12	Parameter tidak signifikan
	$\phi_2$	-0.14018	0.4322	2	
	$\phi_3$	-0.21741	0.0796	3	
	$\mu$	-82.84059	0.9366	0	
ARIMA ([2,12],1,0) (no constant)	$\theta_2$	0.39923	0.0142	2	Parameter tidak signifikan
	$\theta_{12}$	-0.51602	0.0001	12	
	$\phi_1$	-0.10733	0.3917	1	
	$\theta_{12}$	-0.52658	<.0001	12	

Berdasarkan pada kedua tabel di atas dapat diketahui bahwa model yang layak merupakan model yang memiliki semua parameter yang signifikan. Dengan memperhatikan lag-lag signifikan yang telah diidentifikasi pada tahapan sebelumnya diperoleh beberapa estimasi model subset ARIMA yang telah signifikan lalu dilakukan pemeriksaan diagnostik yang disajikan pada tabel berikut:

**Tabel 3.** Hasil Uji Verifikasi Model

Passengers	Model	Verifikasi Model	
		White-Noise	Normalitas
Datang	[(2,12),1,[2,4]]	Terpenuhi	Terpenuhi
	[(2,12),1,0]	Terpenuhi	Tidak Terpenuhi
	(0,1,2)	Terpenuhi	Tidak Terpenuhi
	(0,1,[2,12])	Terpenuhi	Terpenuhi
Berangkat	(0,1,2)	Tidak Terpenuhi	Tidak Terpenuhi
	(0,1,[2,12])	Terpenuhi	Terpenuhi

Pada model untuk jumlah penumpang datang terdapat dua model yang memenuhi sehingga dilakukan pemilihan model terbaik yaitu subset ARIMA (0,1,[2,12]) dengan nilai AIC dan SBC terkecil (Aswi dan Sukarna, 2006). Model terbaik untuk jumlah penumpang yang berangkat yaitu subset ARIMA (0,1,[2,12]). Berdasarkan persamaan (1) maka model yang terbentuk untuk subset ARIMA (0,1,[2,12]) yaitu:

$$(1-B)Z_t = (1-\theta_2 B^2 - \theta_{12} B^{12})\alpha_t$$

$$Z_t = \frac{(1-\theta_2 B^2 - \theta_{12} B^{12})\alpha_t}{(1-B)}$$

$$Z_t = Z_{t-1} - \theta_2 \alpha_{t-2} - \theta_{12} \alpha_{t-12} + \alpha_t$$

Untuk meyakinkan ada atau tidaknya *outlier* dalam data, maka dilakukan deteksi *outlier*. Hasilnya terdapat tiga buah *outlier* pada data jumlah penumpang datang yaitu pada data ke-45 dan 47 yang bertipe *Level Shift* (LS) dan data ke-62 bertipe *Additive Outlier* (AO). Sedangkan pada data jumlah penumpang yang berangkat memiliki 12 *outlier* dalam data yaitu data ke-47, 45, 48 dengan tipe *Level Shift* (LS) dan 19, 22, 31, 36, 43, 54, 67, 52, 62 bertipe *Additive Outlier* (AO). Setelah diperoleh *outlier* pada data, selanjutnya dilakukan penambahan *outlier* ke dalam model. Perbandingan model subset ARIMA (0,1,[2,12]) dengan penambahan *outlier* disajikan dalam tabel berikut:


**Tabel 4.** Perbandingan Model ARIMA Jumlah Penumpang Datang dengan dan Tanpa *Outlier*

Model	ARIMA (0,1,[2,12])	ARIMA (0,1,[2,12]) + 3 <i>outlier</i>
AIC	1519.064	1457.83
SBC	1523.59	1469.144
MAPE	73,4436%	14,6959%
Kinerja Model	Kurang Bagus	Bagus


**Tabel 5.** Perbandingan Model ARIMA Jumlah Penumpang Berangkat dengan dan Tanpa *Outlier*

Model	ARIMA (0,1,[2,12])	ARIMA (0,1,[2,12]) + 3 <i>outlier</i>
AIC	1524.962	1428.666
SBC	1529.488	1460.344
MAPE	84,6453%	5,0938%
Kinerja Model	Kurang bagus	Sangat bagus

Dari Tabel 4 dan 5 terlihat bahwa model dengan cara penambahan *outlier* mengalami penurunan nilai AIC dan SBC yang berarti model tersebut lebih baik. Untuk melihat perbandingan data aktual, prediksi model ARIMA (0,1,[2,12]) dan model ARIMA (0,1,[2,12]) dengan penambahan *outlier* disajikan dalam Gambar 9 dan 10.



**Gambar 9.** Perbandingan Data Datang



**Gambar 10.** Perbandingan Data Berangkat

Dari Gambar 9 dan 10 terlihat garis nilai prediksi model dengan penambahan *outlier* lebih mendekati garis data aktual. Sehingga model yang digunakan untuk prediksi jumlah penumpang pada periode ke depan yaitu model ARIMA dengan penambahan beberapa *outlier* yang telah terdeteksi dan bentuk matematis dari model yang diperoleh yaitu:

1. Model Untuk Prediksi Jumlah Penumpang Datang

$$Z_t = \frac{(1-0,31687B^2+0,65874B^{12})\alpha_t}{(1-B)} - \frac{1}{(1-B)} 43561,7I_t^{(45)} + \frac{1}{(1-B)} 48345,7I_t^{(47)} - 23226,3I_t^{(62)}$$

2. Model Untuk Prediksi Jumlah Penumpang Berangkat


$$Z_t = \frac{(1-0,33023B^2+0,72499B^{12})\alpha_t}{(1-B)} - \frac{1}{(1-B)} 46280,1I_t^{(45)} + \frac{1}{(1-B)} 47049,8I_t^{(47)} - 16372,9I_t^{(31)} + \frac{1}{(1-B)} 18973,9I_t^{(48)} - 17217,3I_t^{(54)} + 10746,0I_t^{(67)} + 7397,2I_t^{(22)} + 7714,3I_t^{(52)} + 11300,1I_t^{(62)} + 10741,2I_t^{(36)} + 9707,5I_t^{(43)} - 10041,9I_t^{(10)}$$

Setelah diperoleh model terbaik, dapat diprediksi jumlah penumpang pesawat yang datang dan berangkat pada tahun 2018 disajikan pada Tabel 6.


**Tabel 6.** Hasil prediksi jumlah penumpang tahun 2018

Bulan	Hasil Prediksi	
	Penumpang Datang	Penumpang Berangkat
Januari	84236	83897
Februari	81030	81267
Maret	76447	80700
April	76831	80937
Mei	74705	79387
Juni	80848	76265
Juli	86723	79230
Agustus	81367	81105
September	84480	83101
Oktober	85650	86051
November	86009	85471
Desember	91599	89912

Berikut akan ditampilkan grafik prediksi jumlah penumpang datang dan berangkat pada tahun 2018 yaitu:



**Gambar 11.** Prediksi Penumpang Datang



**Gambar 13.** Prediksi Penumpang Berangkat

Berdasarkan pada Gambar 11 dan 12 dapat diprediksikan nilai prediksi yang dihasilkan masih belum mengikuti pola data aktual namun model masih dapat digunakan karena nilai MAPE yang diperoleh sebesar 4,086% untuk prediksi jumlah penumpang datang dan 7,178% untuk prediksi jumlah penumpang berangkat yang menunjukkan kemampuan model prediksi sangat baik dan kenaikan tertinggi jumlah penumpang pesawat akan terjadi pada bulan Desember hal ini biasa terjadi mengingat bahwa banyak masyarakat memanfaatkan libur akhir tahun untuk bepergian menggunakan transportasi udara.

#### IV. SIMPULAN DAN SARAN

##### A. Simpulan

Berdasarkan pembahasan pada penelitian ini, dapat diambil kesimpulan sebagai berikut:

1. Model ARIMA yang sesuai untuk jumlah penumpang yang datang pada PT. Angkasa Pura II Bandar Udara Sultan Thaha adalah model ARIMA (0,1,[2,12]) dengan penambahan tiga *outlier* sehingga persamaannya sebagai berikut:

$$Z_t = Z_{t-1} - 0,31687\alpha_{t-2} + 0,65874\alpha_{t-12} - 43561,7I_t^{(45)} + 48345,7I_t^{(47)} - 23226,3I_t^{(62)} + 23226,3I_{t-1}^{(62)} + \alpha_t$$

2. Model ARIMA yang sesuai untuk jumlah penumpang yang berangkat pada PT. Angkasa Pura II Bandar Udara Sultan Thaha yaitu model ARIMA (0,1,[2,12]) dengan penambahan 12 *outlier* sehingga persamaannya sebagai berikut:

$$\begin{aligned} Z_t = & Z_{t-1} - 0,33023\alpha_{t-2} + 0,72499\alpha_{t-12} - \\ & 46280,1I_t^{(45)} + 47049,8I_t^{(47)} + 18973,9I_t^{(48)} - \\ & 16372,9I_t^{(31)} + 16372,9I_{t-1}^{(31)} - 17217,3I_t^{(54)} + \\ & 17217,3I_{t-1}^{(54)} + 10746,0I_t^{(67)} - \\ & 10746,0I_{t-1}^{(67)} + 7397,2I_t^{(22)} - 7397,2I_{t-1}^{(22)} - \\ & 7714,3I_t^{(52)} + 7714,3I_{t-1}^{(52)} - \\ & 11300,1I_t^{(62)} + 11300,1I_{t-1}^{(62)} + 10741,2I_t^{(36)} - \\ & 10741,2I_{t-1}^{(36)} + 9707,5I_t^{(43)} - \\ & 9707,5I_{t-1}^{(43)} - 10041,9I_t^{(10)} + 10041,9I_{t-1}^{(10)} + \\ & \alpha_t \end{aligned}$$

##### B. Saran

Saran yang dapat diberikan berkaitan dengan penelitian ini adalah disarankan untuk peneliti lain yang ingin melakukan prediksi yang sama dapat menggunakan metode analisis multivariat *time series* atau metode lainnya untuk perbandingan.

#### DAFTAR RUJUKAN

- Aswi dan Sukarna. 2006. *Analisis Deret Waktu Teori dan Aplikasi*. Adira Publisher, Makassar.
- Darsyah, M. Yamin dan Nur, M. S. 2016. Model Terbaik ARIMA dan Winter Pada Peramalan Data Saham Bank. *Jurnal Statistika*. 4(1):30-38.
- Gaspersz, V. 1998. *Time Production Planning and Inventory Control*. Gramedia Pustaka Utama, Jakarta.
- Montgomery, D.C., Jennings, C.L., and Kulahci, M. 2008. *Introduction Time Series Analysis and Forecasting*. John Wiley & Sons Inc, Hoboken, New Jersey.
- Suparti, Alfi, dan Sa'adah. 2015. *Analisis Data Inflasi Indonesia Menggunakan Model Autoregressive Integrated Moving Average (ARIMA) dengan Penambahan Outlier*. 8 (1): 1-11.
- Tofani, L dan A. Mauludiyanto. 2012. Peramalan Trafik Sms Area Jabodetabek dengan Metode ARIMA. *Jurnal Teknik*. 1: 139-144.
- Wei, W.W.S. 2006. *Time Series Analysis Univariate and Multivariate Methods Second Edition*. Pearson Education Inc, Canada.