

Model ARIMA Musiman dengan *Outlier* untuk Peramalan Penumpang Pesawat Tujuan Domestik dari Bandara Soekarno Hatta di Masa Pandemi Covid-19

Seasonal ARIMA Model with Outlier for Forecasting Domestic Airplane Passengers from Soekarno Hatta Airport during the Covid-19

Siti Puji Utami¹⁾, Gama Putra Danu Sohibien²⁾

¹BPOM, Jl. Percetakan Negara No. 23, Jakarta

sitipujiutami2801@gmail.com

²Politeknik Statistika STIS, Jl. Otto Iskandardinata 64 C Jakarta Timur

maputra@stis.ac.id

INFO ARTIKEL

Histori Artikel:

Diterima: 07 Februari 2021

Direvisi: 22 Juni 2021

Disetujui: 28 Juni 2021

Dipublikasi online: Juni 2021

Keywords:

Airplane, ARIMA, Forecasting, Outlier, Passengers

Kata kunci:

ARIMA, Pencilan, Penumpang, Peramalan Pesawat Terbang

Permalink/DOI:

<https://dx.doi.org/10.25104/wa.v47i1.409.17-26>

©2021 Puslitbang Transportasi Udara, Badan litbang Perhubungan -Kementerian Perhubungan RI. This is an open access article under the CC BY-NC-SA license

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

ABSTRACT/ ABSTRAK

Time series modeling is particularly vulnerable due to data outliers. The presence of outlier data may lead to unfulfilled assumptions of normal distributed errors. This study aims to apply seasonal ARIMA with outlier for forecasting domestic aircraft passengers from Soekarno-Hatta Airport during the Covid-19 pandemic. A model formed is useful for forecasting the number of aircraft passengers in the future. The results of the study find that the ARIMA model $(0,1,1)(0,1,0)^{12}$ with outlier variables was selected because it meets white noise assumptions and can overcome the problem of violation of normal assumptions that occur in ordinary ARIMA. Domestic flight passenger forecast from Soekarno Hatta Airport in June 2021 was 858,112 and December 2021 was 792,124

Pemodelan deret waktu sangat rentan akibat adanya data outlier. Kehadiran data outlier bisa menyebabkan tidak terpenuhinya asumsi error berdistribusi normal. Penelitian ini bertujuan untuk mengaplikasikan ARIMA musiman dengan outlier untuk peramalan penumpang pesawat terbang domestik dari Bandara Soekarno-Hatta di masa pandemi Covid-19. Model yang terbentuk bermanfaat untuk meramal jumlah penumpang pesawat terbang ke depannya. Hasil penelitian didapatkan bahwa model ARIMA $(0,1,1)(0,1,0)^{12}$ dengan variabel outlier terpilih karena sudah memenuhi asumsi *white noise* dan dapat mengatasi masalah pelanggaran asumsi *error* berdistribusi normal yang terjadi pada ARIMA biasa. Peramalan penumpang pesawat terbang domestik dari Bandara Soekarno Hatta pada bulan Juni 2021 adalah 858.112 dan Desember 2021 adalah 792.124

PENDAHULUAN

Bandara Soekarno-Hatta merupakan salah satu bandar udara yang melayani penerbangan untuk Jakarta, Indonesia. Dalam rangka percepatan penanganan COVID-19, gugus tugas percepatan penanganan COVID-19 menetapkan beberapa ketentuan penyelenggaraan bandar udara. Guna mengimplementasikan ketentuan penyelenggaraan penerbangan di masa pandemi, pihak bandara perlu memiliki informasi mengenai berapa banyak penumpang pada beberapa periode waktu ke depan. Oleh karena itu perlu suatu model yang dapat meramalkan banyaknya penumpang pada beberapa hari ke depan.

Pemodelan data deret waktu sangat rentan tidak memenuhi asumsi *error* berdistribusi normal jika terdapat data *outlier* (pencilan). Data *outlier* merupakan data yang nilainya ekstrim bisa sangat kecil atau sangat besar dibandingkan dengan data yang lain. Nilai data yang sangat besar atau kecil tersebut bisa disebabkan oleh beberapa faktor, seperti bencana alam, peraturan pemerintah, kestabilan ekonomi, kerusakan, dan terorisme (Budiarti, Tarno, dan Warsito, 2013). Ada nya kebijakan pembatasan penerbangan pada awal diumumkannya kasus Covid-19 menyebabkan ada nya penurunan drastis jumlah penerbangan dibandingkan periode sebelumnya. Hal ini dapat mengakibatkan data pada periode tersebut menjadi salah satu data outlier yang cukup besar.

Dari penelitian yang sudah dilakukan belum ada penelitian yang membuat model ramalan jumlah penumpang pesawat terbang yang dilakukan di masa pandemi COVID-19 dan mempertimbangkan adanya pengaruh dari data *outlier*. Oleh karena itu penelitian ini bertujuan untuk membuat model penumpang pesawat terbang domestik dari bandara Soekarno-Hatta di masa pandemi Covid-19 dengan mengaplikasikan *Autoregressive Integrated Moving Average* (ARIMA) musiman dengan *outlier*. Model ARIMA musiman dengan *outlier* digunakan karena model ini mampu mengakomodasi adanya pengaruh

musiman dan adanya *outlier* yang sering kali terdapat pada data penumpang pesawat terbang.

TINJAUAN PUSTAKA

Beberapa penelitian sudah dilakukan terkait peramalan penumpang pesawat terbang, diantaranya Durrah (2018), Hayoto (2019), dan Rumiana, dkk (2018). Durrah (2018) membuat model peramalan jumlah penumpang pesawat di Bandara Sultan Iskandar Muda dengan metode ARIMA Musiman. Hayoto (2019) membuat model peramalan jumlah penumpang pesawat terbang di pintu kedatangan Bandara Pattimura dengan ARIMA Box-Jenkins, dan Rumiana, dkk (2018) membuat model peramalan jumlah frekuensi penumpang pesawat terbang lion air pada bandar udara Halu Oleo dengan metode least square.

Pemodelan deret waktu menggunakan ARIMA dengan *outlier* sudah pernah dilakukan pada beberapa penelitian, diantaranya Ahmar, dkk (2018) memodelkan data yang mengandung *outlier* dengan menggunakan ARIMA *Additive Outlier* dan Saki, dkk (2018) menggunakan ARIMA *outlier* untuk meramal produksi tekstil di US.

Dengan demikian, berdasarkan penelitian terdahulu yang sudah dijelaskan sebelumnya, peramalan data deret waktu dapat dilakukan secara univariate.

METODOLOGI

Metode Pengumpulan Data

Data yang digunakan pada penelitian ini, adalah data sekunder yang bersumber dari website Badan Pusat Statistik (2020). Data yang digunakan adalah data jumlah penumpang dengan tujuan domestik yang berangkat dari bandara Soekarno-Hatta. Data yang digunakan merupakan data bulanan dari Januari 2006 sampai dengan Maret 2021. Data akan dibagi menjadi dua, yaitu data pada Januari 2006- Agustus 2016 sebagai data training dan data pada September 2016- Maret 2021 sebagai data *testing*.

Pengolahan Data

Pengolahan data dilakukan dengan pendekatan kuantitatif menggunakan *software* Minitab 19 dan SAS university edition.

Analisis Data

Analisis data dilakukan secara inferensia dengan membentuk model ARIMA dengan *outlier*. Model ARIMA seringkali digunakan pada peramalan data time series (Budiarti, Tarno, dan Warsito, 2013). Namun model ARIMA memiliki kelemahan ketika terdapat pengamatan yang mengalami fluktuasi cukup tinggi (pengamatan *outlier*). Oleh karena itu dibutuhkan model ARIMA yang dapat mengakomodasi pengamatan outlier tersebut yang disebut sebagai model ARIMA dengan *outlier*.

Berikut adalah tahapan pembentukan model:

1. Tahap Identifikasi Model

Tahap ini terdiri dari identifikasi kestasioneran data dan identifikasi order ARIMA.

• Identifikasi Kestasioneran Data

Identifikasi kestasioneran data dilakukan dalam rata-rata dan dalam varians. Identifikasi stasioneritas data dalam varians dilakukan dengan melihat nilai *rounded value* dari *plot Box-Cox*. Jika nilai *rounded value* belum bernilai satu maka data perlu dilakukan transformasi agar stasioneritas data dalam *variens* terpenuhi. Sedangkan identifikasi stasioneritas data dalam rata-rata dilakukan dengan melihat *plot autocorrelation function* (ACF). Jika plot ACF menunjukkan penurunan secara perlahan maka data diindikasikan belum stasioner pada rata-rata. Identifikasi data dalam rata-rata dilakukan untuk musiman maupun non musiman. Data yang tidak stasioner dalam rata-rata kemudian dilakukan differencing agar menjadi stasioner dalam rata-rata.

• Identifikasi Order Model

Langkah berikut nya adalah melakukan identifikasi order ARIMA. Identifikasi order ARIMA dilakukan dengan melihat *plot autocorrelation function* (ACF) dan *partial*

autocorrelation function (PACF). Penentuan order ARIMA ditunjukkan pada Tabel 1.

Tabel 1. Ketentuan Penentuan Order ARIMA

Proses	ACF	PACF
AR(p)	Menurun secara eksponensial	Terpotong setelah lag p (<i>cut off</i>)
MA(q)	Terpotong setelah lag q (<i>cut off</i>)	Menurun secara eksponensial (<i>dies down</i>)
ARMA (p, q)	Menurun secara eksponensial (<i>dies down</i>) atau <i>cut off</i>	Menurun secara eksponensial (<i>dies down</i>) atau <i>cut off</i>

2. Estimasi Parameter Model

Langkah berikut nya adalah melakukan estimasi koefisien parameter model ARIMA. Estimasi koefisien parameter model dapat dilakukan dengan menggunakan metode least square. Sohibien, G.P.D (2018) menuliskan bentuk umum dari model ARIMA, adalah sebagai berikut:

$$Y_t = \frac{\theta_q(B)\Theta(B^s)}{\phi_p(B)\Phi(B^s)(1-B)^d(1-B^s)^D} a_t \quad (1)$$

dimana

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

$$\Phi_p(B^s) = (1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{ps})$$

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

$$\Theta_Q(B^s) = (1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs})$$

ϕ_p adalah koefisien parameter AR pada lag ke-p

Φ_p adalah koefisien parameter AR musiman pada lag ke-P

θ_q adalah koefisien parameter MA pada lag ke-q

Θ_Q adalah koefisien parameter MA musiman pada lag ke-Q

d adalah order differencing

D adalah order differencing musiman

B adalah operator back shift, misal:

$$B^2 z_t = z_{t-2}$$

s adalah order musiman

3. Diagnostic Check

Langkah berikutnya adalah melakukan diagnostic check model yang terbentuk. Diagnostic check dilakukan untuk mengecek apakah residual model yang terbentuk sudah white noise dan berdistribusi normal. Uji white noise perlu dilakukan karena pelanggaran asumsi ini dapat menyebabkan penduga parameter model menjadi tidak efisien yang menyebabkan statistik uji parameter tidak dapat digunakan. Pengecekan kondisi *white noise residual* dilakukan dengan menggunakan Uji *Ljung-Box*. Hipotesis yang digunakan, yaitu:

$$H_0: \rho_1 = \rho_2 = \dots = \rho_k$$

$$H_1: \text{minimal ada 1 } \rho_j \neq 0, j=1, 2, \dots, k$$

Statistik uji yang digunakan, yaitu:

$$Q = T(T+2) \sum_{j=1}^K \frac{\hat{\rho}_j^2}{T-j} \quad (2)$$

Dimana,

T adalah banyaknya sampel yang digunakan

$\hat{\rho}_j$ adalah estimasi ACF dari residual pada lag-k

Tolak H_0 jika nilai $Q > \chi^2_{\alpha; k-p-q}$

Pengecekan bahwa residual sudah berdistribusi normal pada penelitian ini dilakukan dengan menggunakan metode Anderson Darling dan Kolmogorov-Smirnov. Jika residual belum berdistribusi normal, kemungkinan diakibatkan karena adanya pengamatan outlier sehingga perlu dilakukan pendeteksian *outlier*.

4. Pendeteksian outlier

Pendeteksian *outlier* dilakukan dengan mengecek residual ARIMA dari tiap pengamatan yang dihasilkan model pada langkah nomor 2. Pada penelitian ini deteksi outlier dilakukan dengan menggunakan metode tukey (Kurniawan dkk, 2019). Berdasarkan metode tukey data dikatakan *outlier* jika nilai residual $< Q1-1,5 \text{ IQR}$ atau $>$

$Q3+1,5 \text{ IQR}$. Hal ini artinya observasi yang residualnya berada di kedua rentang tersebut memiliki nilai yang jauh berbeda dibandingkan dengan data yang lainnya.

5. Pemodelan ARIMA dengan Outlier

Langkah berikutnya adalah membentuk model ARIMA dengan *outlier*. Pada penelitian ini outlier yang didapatkan dari langkah 4 dibagi ke dalam dua variabel *outlier*, yaitu outlier saat residual $< Q1-1,5 \text{ IQR}$ (p_{1t}) dan outlier saat residual $> Q3+1,5 \text{ IQR}$ (p_{2t}). Berikut adalah bentuk umum model ARIMA dengan Outlier pada penelitian ini

$$Y_t = \alpha_1 p_{1t} + \alpha_2 p_{2t} + \frac{\theta(\beta)}{\phi(\beta)} a_t \quad (3)$$

dimana:

α_1 adalah koefisien variabel outlier p_{1t}

α_2 adalah koefisien variabel outlier p_{2t}

6. Lakukan *diagnostic check* dari model yang dihasilkan di nomor 5.


7. Jika asumsi *error white noise* dan normal sudah terpenuhi maka model sudah dapat digunakan.

8. Lakukan validasi model dengan menggunakan data validasi (*data testing*).


HASIL DAN PEMBAHASAN

Dari gambar 1 dapat dilihat bahwa secara umum jumlah penumpang pesawat terbang dari bandara Soekarno-Hatta untuk penerbangan domestik memiliki trend yang meningkat namun pada April 2020 terjadi penurunan yang amat tajam. Penurunan jumlah penumpang pesawat terbang terjadi akibat adanya dampak dari pembatalan penerbangan akibat adanya pandemi Covid-19.


Identifikasi stasioneritas data dalam varians dilakukan dengan menggunakan *Box-Cox*. Hasil *plot Box-Cox* dapat dilihat di Gambar 2. Data sudah tidak perlu ditransformasi karena *rounded value* dari *Box Cox* sudah bernilai 1 yang artinya data sudah stasioner dalam varians.



Gambar 1. *Time Series Plot* Penumpang Pesawat Terbang dari Bandara Soekarno-Hatta untuk Penerbangan Domestik



Gambar 2. Plot Box Cox




Gambar 3. Plot ACF


Langkah berikutnya adalah melakukan identifikasi stasioneritas data dalam rata-rata. Identifikasi ini dilakukan dengan membuat *plot Autocorrelation Function (ACF)* dari data yang sudah stasioner dalam varians. Hasil plot ACF dapat dilihat di Gambar 3. Plot ACF menunjukkan bahwa pola tidak hanya turun secara perlahan namun juga meningkat setiap selang 12 periode. Hal ini mengindikasikan bahwa data jumlah penumpang pesawat

domestik belum stasioner dalam musiman dan non musiman rata-rata.

Karena data belum stasioner dalam musiman dan non musiman rata-rata maka data harus dilakukan differencing musiman ($D=1, s=12$) dan non musiman ($d=1$). Plot ACF setelah dilakukan *differencing* musiman dan non musiman dapat dilihat di Gambar 4.



Gambar 4. Plot ACF setelah Dilakukan Differencing Musiman dan Non Musiman



Gambar 5. Plot PACF setelah Dilakukan Differencing Musiman dan Non Musiman

Dari Gambar 4 dapat dilihat bahwa plot ACF tidak lagi turun secara perlahan. Hal ini berarti data sudah stasioner. *Plot Partial Autocorrelation Function (PACF)* dari data yang sudah dilakukan *differencing* dapat dilihat pada Gambar 5.

Dari Gambar 4 dan Gambar 5, identifikasi order ARIMA dapat dilakukan. Karena ACF *cut off* pada lag 1 maka model terpilih berdasarkan Identifikasi order ARIMA adalah ARIMA (0,1,1) (0,1,0)12.

Hasil estimasi parameter model ARIMA (0,1,1) (0,1,0)12 untuk banyak penumpang

penerbangan domestik, adalah sebagai berikut

Tabel 2. Estimasi Parameter Model ARIMA (0,1,1)(0,1,0)12

Type	Coef	SE Coef	T-Value	P-Value
MA 1	0,5702	0,0919	-6,20	0,000

Model yang terbentuk dapat dituliskan sebagai berikut

$$(1-B)(1-B^{12})Y_t = (1-\theta B)a_t$$

$$\Delta Y_t - \Delta Y_{t-12} = -0,5702a_{t-1} + a_t \quad (4)$$

Hasil uji *diagnostic white noise* dan normalitas *error* dapat dilihat di Tabel 3. Karena nilai p-value sudah lebih besar dari 5 persen maka dapat dikatakan bahwa model yang terbentuk sudah memenuhi asumsi *error white noise*

Tabel 3. Hasil Uji Diagnostik White Noise

Lag	12	24	36	48
Chi-Square	12,62	25,44	45,97	59,21
DF	11	23	35	47
P-Value	0,319	0,328	0,102	0,109

Uji asumsi *error* berdistribusi normal dapat dilihat di Tabel 4. Karena nilai p-value kurang dari 5 persen maka model yang terbentuk belum memenuhi asumsi *error* berdistribusi normal.

Tabel 4. Hasil Uji Error Berdistribusi Normal

Test	p-Value
Kolmogorov-Smirnov	<0.0100
Anderson-Darling	<0.0050

Karena asumsi *error* berdistribusi normal belum terpenuhi maka perlu dilakukan pengecekan pengamatan *outlier*. Dengan menggunakan penghitungan dengan metode tukey, pengamatan pada penelitian ini dikatakan outlier jika nilai residualnya kurang dari -25670,328 atau lebih dari 324810,9. Hasil pendeteksian outlier dengan menggunakan metode tukey observasi-observasi yang termasuk outlier, yaitu observasi ke-28, 98, 115, 121, 171, 172, dan 183

Setelah didapatkan pengamatan-pengamatan outlier, langkah berikutnya adalah membuat model ARIMA (1,1,0) (0,1,0)12 dengan memasukkan variabel outlier yang terbagi dua, yaitu p1t (jika residualnya kurang dari -25670,328) dan p2t (jika nilai residual lebih dari 324810,9). Hasil estimasi parameter model ARIMA (0,1,1) (0,1,0)12 dengan 2 variabel outlier dapat dilihat di Tabel 5.

Tabel 5. Output Estimasi Parameter Model ARIMA (0,1,1) (0,1,0)12 dengan Outlier

Term	Coef	SE Coef	T-Value	P-Value
MA (1)	-0,2284	0,0569	-4,01	0,000
p1t	-532044	54907	-9,69	0,000
p2t	344574	38869	8,86	0,000

Berdasarkan Tabel 5, model ARIMA (0,1,1)(0,1,0)12 dengan outlier yang terbentuk, adalah sebagai berikut.

$$\Delta Y_t - \Delta Y_{t-12} = -0,2284a_{t-1} - 532044p_{1t} + 344574p_{2t} + a_t \quad (5)$$

dimana:


$$\Delta Y_t = Y_t - Y_{t-1}$$

$$\Delta Y_{t-12} = Y_{t-12} - Y_{t-13}$$


Model pada persamaan (5) memiliki makna bahwa pergerakan data bulanan jumlah penumpang pesawat terbang domestik dari Bandara Soekarno Hatta dipengaruhi oleh residual model bulan sebelumnya dan variabel *outlier*.

Hasil uji *diagnostik white noise* pada model ini dapat dilakukan dengan melihat plot ACF dari residual model di Gambar 6. Tidak ada garis dari ACF yang *cut off* (melewati batas garis merah). Hal ini memiliki makna bahwa model sudah memenuhi asumsi *white noise*.

Hasil uji asumsi normalitas dari model 5 dapat dilihat di Tabel 6. Karena p-value sudah lebih dari 5 persen, artinya model sudah memenuhi asumsi *error* berdistribusi normal.



Gambar 6. Plot ACF Residual Model ARIMA (0,1,1) (0,1,0)¹² dengan Outlier



Gambar 7. Time Series Plot antara Data Aktual, Data Fit, dan Hasil peramalan ARIMA (0,1,1)(0,1,0)¹² dengan Outlier

Tabel 6. Hasil Uji Error Berdistribusi Normal

Test	p Value
Kolmogorov-Smirnov	>0.1500
Anderson-Darling	>0.09

Karena asumsi dari *error white noise* dan *error* berdistribusi normal sudah terpenuhi, maka model sudah dapat diaplikasikan untuk peramalan penumpang pesawat terbang domestik.

Perbandingan kinerja peramalan dari model ARIMA dengan *outlier* terhadap model lain dilakukan dengan melihat nilai *Root Mean Square Error* (RMSE) yang diperoleh dari data testing. Tabel 7 menunjukkan bahwa nilai RMSE terkecil adalah pada model ARIMA (0,1,1) (0,1,0)¹² dengan *outlier*. Hal ini memiliki makna bahwa model ARIMA (0,1,1)

(0,1,0)¹² dengan *outlier* memiliki kinerja peramalan yang lebih baik dibandingkan *regresi time series* dan ARIMA (0,1,1) (0,1,0)¹².

Tabel 7. Perbandingan kinerja peramalan

Model	RMSE
Regresi Time Series	887150
ARIMA (0,1,1) (0,1,0) ¹²	43342,17
ARIMA(0,1,1)(0,1,0) ¹² dengan outlier	42895,54

Hasil time series plot antara data aktual, data fit, dan hasil peramalan dapat dilihat pada Gambar 7.

Dari gambar 7 dapat dilihat bahwa pola time series plot nilai fit dari model ARIMA (0,1,1) (0,1,0)¹² dengan *outlier* sudah

mendekati pola data aktual. Hal ini salah satunya disebabkan oleh sudah terakomodasinya data-data yang outlier. Salah satu *outlier* adalah data pada 24 Mei 2020. Saat itu pemerintah menghentikan sementara seluruh penerbangan yang mengakibatkan jumlah penumpang pesawat domestik menjadi merosot. Model ARIMA (0,1,1) (0,1,0)₁₂ dengan *outlier* sudah dapat mengakomodasi hal ini sehingga nilai fit dan peramalan periode selanjutnya masih dapat mengikuti pola dari data aktual.

Hasil ramalan penumpang pesawat domestik dari Bandara Soekarno-Hatta untuk bulan April sampai dengan Desember 2021, yaitu.

Tabel 8. Ramalan Penumpang Pesawat Terbang Domestik dari Bandara Soekarno Hatta April-Desember 2021

Bulan	Ramalan
April 2021	757.437
Mei 2021	621.158
Juni 2021	858.112
Juli 2021	947.874
Agustus 2021	837.533
September 2021	615.786
Oktober 2021	790.392
Nopember 2021	917.049
Desember 2021	792.124

KESIMPULAN

ARIMA dengan *outlier* bisa mengatasi masalah pelanggaran asumsi residual normal untuk model peramalan penumpang pesawat terbang domestik dari bandara Soekarno Hatta di masa pandemi covid-19.

Penelitian ini bermanfaat memberikan alternatif pemodelan untuk peramalan jumlah penumpang pesawat terbang ketika terdapat kondisi yang dapat menyebabkan terjadinya *outlier*.

SARAN

Pengaplikasian ARIMA *subset* musiman outlier perlu dilakukan dan dibandingkan dengan ARIMA musiman *outlier* untuk mendapatkan model yang lebih baik.

DAFTAR PUSTAKA

- Ahmar, dkk. (2018). Modeling Data Containing Outlier using ARIMA Additive Outlier (ARIMA-AO). IOP Conf. Series: Journal of Physics: Conf. Series 954 (2018) 012010
- Budiarti, L., Tarno, T., & Warsito, B. (2013). Analisis Intervensi Dan Deteksi Outlier Pada Data Wisatawan Domestik (Studi Kasus Di Daerah Istimewa YOGYAKARTA). Jurnal Gaussian, 2(1), 39-48.
- Badan Pusat Statistik. Data Penumpang Pesawat Terbang Domestik dari Bandara Soekarno Hatta. (<https://www.bps.go.id/indicator/17/66/1/jumlah-penumpang-pesawat-di-bandara-utama.html>, diakses tanggal 5 November 2020)
- Durrah, dkk. (2018). Peramalan Jumlah Penumpang Pesawat Di Bandara Sultan Iskandar Muda Dengan Metode SARIMA (Seasonal Autoregressive Integrated Moving Average). Journal of Data Analysis, Vol.1, No.1, Juni 2018, p.01-11
- Hayoto, dkk. (2019). Peramalan Jumlah Penumpang Pesawat Terbang di Pintu Kedatangan Bandar Udara Internasional Pattimura Ambon dengan menggunakan Metode ARIMA Box-Jenkins. Barekeng, Vol 13. No.3, P135-144.
- Kurniawan, Robert & Sohibien, Gama & Rahani, Rini. (2019). Cara Mudah Belajar Statistik: Analisis Data dan Eksplorasi, Prenada Media Group
- Ruamianan, dkk. (2018). Aplikasi Forecasting Jumlah Frekuensi Penumpang Pesawat Terbang Lion Air pada Bandar Udara Halu Oleo dengan Menggunakan Metode Least Square. Semantik, Vol.4, No.1, pp 151-160.
- Saki, dkk (2018). Forecasting U.S. Textile Comparative Advantage Using Autoregressive Integrated Moving Average Models and Time Series Outlier Analysis. JSM 2018-Business and Economic Statistics Section, p 1996-2006.

Sohibien, G. P. D. (2018, September). Analysis of the effect of fuel price policy on Jakarta inflation by using multi-input intervention model. In AIP Conference Proceedings (Vol. 2014, No. 1, p. 020125). AIP Publishing LLC.

Wati, D. F. K. (2020). Peramalan jumlah penumpang keberangkatan bus di Terminal Purabaya menggunakan Metode SARIMA (Seasonal Autoregressive Integrated Moving Average) (Doctoral dissertation, UIN Sunan Ampel Surabaya).

Wei, W. W. S. (2006), Time Series Analysis, Addison-Wesley Publishing Company, Inc, United States