

PEMODELAN DERET WAKTU MUSIMAN DENGAN FAKTOR INTERVENSI PADA JUMLAH PENUMPANG PESAWAT DALAM PENERBANGAN DOMESTIK DI BANDARA SOEKARNO-HATTA

Muhammad Farhan Thomasi, Tiara Shofi Edriani*, Dear Michiko Mutiara Noor
Program Studi Matematika, Institut Teknologi Sumatera, Lampung

*Penulis korespondensi: tiara.edriani@ma.itera.ac.id

ABSTRAK

Moda pesawat udara menjadi pilihan utama masyarakat, khususnya bagi yang memiliki kegiatan dengan mobilitas tinggi dan jangkauan wilayah yang luas, dalam mengoptimalkan waktu. Hal ini menyebabkan permintaan masyarakat akan ketersediaan kursi penerbangan tidak pernah sepi. Dalam waktu-waktu tertentu setiap tahunnya terjadi perulangan kenaikan dan penurunan penumpang pesawat sehingga menimbulkan pola musiman pada grafik data jumlah penumpang. Studi ini membahas mengenai pembentukan model deret waktu musiman (SARIMA) serta model SARIMA dengan faktor intervensi pada data jumlah penumpang pesawat dalam penerbangan domestik di Bandara Soekarno-Hatta mulai Januari 2016 hingga Juni 2023. Adanya pandemi Covid-19 di rentang waktu tersebut dianggap sebagai suatu intervensi yang menyebabkan data mengalami penurunan dengan signifikan. Berdasarkan data yang digunakan, diperoleh model ARIMA $(0,1,1)(0,0,1)_{12}$ dengan MAPE sebesar 5,88% dan model ARIMA $(3,2,1)(0,0,1)_{12}$, faktor intervensi $b = 0, r = 0, s = 19$ dengan MAPE 7,05%. Nilai MAPE dari kedua model menunjukkan hasil yang kurang dari 10%, artinya kedua model sangat baik dalam mewakili gambaran pergerakan data historis serta dapat memberikan hasil prediksi data jumlah penumpang pesawat di masa yang akan datang dengan baik. Hasil prediksi dari model tersebut diharapkan dapat membantu pihak terkait dalam mempersiapkan kebijakan-kebijakan untuk mengelola aktivitas penerbangan Bandara Soekarno-Hatta di masa mendatang.

Kata kunci: Deret Waktu, Intervensi, Jumlah Penumpang Pesawat, SARIMA

1 PENDAHULUAN

Indonesia merupakan negara kepulauan yang terdiri atas ribuan pulau, terbentang dari Sabang sampai Merauke. Hal ini membuat transportasi menjadi elemen penting dalam kehidupan sehari-hari. Indonesia memiliki berbagai jenis moda transportasi, mulai dari transportasi darat, laut dan udara. Transportasi udara menjadi salah satu pilihan transportasi umum yang digunakan untuk mengangkut baik barang maupun orang ke tujuan tertentu. Saat ini, transportasi udara telah menjadi pilihan umum karena efisiensi dan kemampuannya untuk mempersingkat waktu perjalanan. Hal ini menyebabkan meningkatnya minat masyarakat dalam menggunakan transportasi udara, terlebih pada masa liburan sekolah maupun libur keagamaan. Namun sebaliknya, penggunaan transportasi udara juga dapat mengalami penurunan yang disebabkan beberapa faktor, yaitu keamanan, keselamatan, regulasi serta kebijakan yang diberikan oleh pemerintah.

Pandemi Covid-19 sejak awal Maret 2020 di Indonesia berdampak global pada seluruh bidang kehidupan. Kepadatan penduduk pada suatu wilayah sangat mempengaruhi pola penyebaran Covid-19 (Edriani, Rahmadani, & Noor, 2021). Demikian pula dengan pergerakan harga saham saat Covid-19 (Edriani, Pasaribu, Afrianti, & Astute, 2021) yang mengalami naik turun secara fluktuatif. Hal yang serupa terjadi pada jumlah penumpang pesawat dalam penerbangan

domestik di Indonesia yang mengalami penurunan saat Covid-19. Hal ini disebabkan adanya pembatasan bahkan penutupan jumlah operasional penerbangan. Selain itu, kebijakan Pemberlakuan Pembatasan Kegiatan Masyarakat (PPKM) oleh pemerintah mewajibkan masyarakat yang akan melakukan penerbangan untuk menyediakan beberapa persyaratan tambahan dalam memenuhi protokol kesehatan demi meminimalisir penyebaran Covid-19.

Fenomena ini terjadi di berbagai bandara di Indonesia, termasuk Bandara Internasional Soekarno-Hatta yang merupakan bandara terbesar di Indonesia. Badan Pusat Statistik mencatat bahwa jumlah penumpang pesawat pada keberangkatan domestik di Bandara Soekarno-Hatta menurun menjadi 8,6 juta orang sepanjang 2020. Jumlah ini turun 55% dibandingkan dengan 19,3 juta orang pada 2019 (Badan Pusat Statistik (BPS), 2024). Keadaan ini tentu saja mempengaruhi operasionalisasi bandara. Oleh sebab itu, diperlukan suatu model prediksi terhadap keadaan tersebut agar dapat memberikan informasi mengenai prediksi jumlah penumpang di masa yang akan datang, sehingga dapat dimanfaatkan bagi pihak terkait dalam pengambilan keputusan dan pengembangan kebijakan saat menghadapi lonjakan atau penurunan penumpang.

Tahapan memprediksi data di masa mendatang erat hubungannya dengan proses *forecasting*. Data yang digunakan biasanya berupa data deret waktu. Data deret waktu adalah data yang dikumpulkan dan kemudian diurutkan berdasarkan waktu tertentu. Terdapat berbagai metode untuk melakukan *forecasting*, seperti *Recurrent Neural Network* (Ghozi, Aprianti, Dimas, & Fauzi, 2022) yang pernah dilakukan dalam memprediksi data kasus Covid-19. Namun pada studi ini akan dibahas model deret waktu untuk menyelesaikan proses *forecasting*. Sebelumnya data awal diolah dan dianalisa sehingga membentuk suatu model deret waktu. Dari model tersebut, *forecasting* data dapat dilakukan sehingga dapat digunakan sebagai landasan dalam pengambilan keputusan. Model deret waktu yang digunakan untuk meramalkan data yang mengandung elemen musiman adalah model *Season Autoregressive Integrated Moving Average* (SARIMA).

Dalam proses pemodelan deret waktu, model SARIMA harus stasioner pada rata-rata dan variansi. Namun dalam analisis deret waktu, terkadang muncul situasi dimana data mengalami perubahan yang tidak terduga. Perubahan ini bisa disebabkan oleh suatu kejadian baik sengaja maupun tidak disengaja. Contoh perubahan yang disebabkan oleh suatu kejadian yang tidak sengaja adalah terjadinya bencana alam, sedangkan jika terjadi dengan sengaja seperti peristiwa yang dirancang oleh pihak tertentu. Perubahan semacam ini dianggap sebagai intervensi. Metode yang digunakan untuk mengolah data dan menjelaskan efek dari perubahan atau sesuatu yang terjadi karena pengaruh faktor yang berbeda disebut analisis intervensi. Beberapa penelitian terkait SARIMA dan intervensi adalah (Geovani, Hatidja, & Tumilaar, 2022) yang membahas mengenai penerapan model SARIMA dengan faktor intervensi Fungsi Step untuk memprediksi jumlah pengunjung objek wisata Londa. Kemudian dengan model yang sama (Widianingsih, Darmawan, & Sunengsih, 2022) membahas mengenai analisis intervensi dalam model SARIMA untuk memprediksi laju inflasi di Kota Tasikmalaya. Penelitian terkait model SARIMA juga dilakukan oleh (Assakhiy, Anwar, & AR, 2019) mengenai peramalan realisasi penerimaan zakat pada baitulmala Aceh dengan mempertimbangkan efek dari variansi kalender.

Studi ini membahas mengenai penerapan model SARIMA dengan faktor intervensi pada data jumlah penumpang pesawat penerbangan domestik di Bandara Soekarno-Hatta. Data tersebut cenderung bersifat musiman karena adanya kenaikan dan penurunan penumpang di waktu-

waktu tertentu yang berulang setiap tahunnya. Pemodelan deret waktu musiman dapat menangkap keadaan tersebut. Pengambilan data sebelum, saat, dan sesudah pandemi Covid-19 menimbulkan dugaan awal adanya intervensi pada data. Oleh sebab itu, dilakukan pula pemodelan deret waktu musiman dengan faktor intervensi. Efektivitas dari kedua model akan dibandingkan untuk mendapatkan hasil prediksi yang baik bagi data.

2 METODE

Pada studi ini data yang digunakan merupakan data sekunder, yakni data bulanan jumlah penumpang pesawat pada keberangkatan domestik di Bandara Soekarno-Hatta dari Januari 2016 hingga Juni 2023. Data ini diperoleh melalui situs Badan Pusat Statistik. Dari data tersebut akan dilakukan pembentukan model SARIMA dan model SARIMA dengan faktor intervensi. Selanjutnya, model akan digunakan untuk memprediksi jumlah penumpang selama 6 bulan ke depan yaitu dari Juli 2023 hingga Desember 2023.

2.1 Season Autoregressive Integrated Moving Average (SARIMA)

SARIMA adalah salah satu model deret waktu yang menjadi perluasan dari model *Autoregressive Integrated Moving Average* (ARIMA) (p, d, q) . Pada model SARIMA, data pengamatan z_t memiliki sifat musiman atau *seasonal* yang jelas. Secara umum model SARIMA $(p, d, q)(P, D, Q)^s$ dinyatakan pada Persamaan 1 (Wei, 2006).

$$\phi_p(B)\Phi_p(B^s)(1-B)^d(1-B^s)^D z_t = \theta_q(B)\Theta_Q(B^s)e_t \quad (1)$$

Keterangan:

- $\phi_p(B)$: Parameter model AR non
- $\Phi_p(B^s)$: Parameter model AR musiman
- $\theta_q(B)$: Parameter model MA non musiman
- $\Theta_Q(B^s)$: Parameter model MA musiman
- $(1-B)^d$: Proses *differencing* orde d
- $(1-B^s)^D$: Proses *differencing* orde D

2.2 Analisis Intervensi pada Model Deret Waktu

Intervensi merupakan suatu kejadian yang tak terduga dalam proses deret waktu yang biasanya menyebabkan perubahan terhadap rata-rata atau variansi dalam proses tersebut (Wei, 2006). Analisis intervensi dilakukan untuk mengolah data dan menjelaskan efek dari sesuatu yang terjadi karena pengaruh faktor yang berbeda. Intervensi memiliki 2 faktor yaitu, fungsi *step* dan fungsi *pulse*. Fungsi *step* adalah sebuah bentuk intervensi dimulai pada waktu T kemudian berlanjut untuk waktu yang lama, sedangkan fungsi *pulse* adalah intervensi yang dimulai ketika waktu T kemudian tidak berlanjut. Model deret waktu dengan faktor intervensi dapat dirumuskan pada Persamaan 2.

$$z_t = \frac{\omega_s(B)}{\delta_r(B)} B^b I_t + \frac{\theta_q(B)\Theta_Q(B^s)e_t}{\phi_p(B)\Phi_p(B^s)(1-B)^d(1-B^s)^D} \quad (2)$$

Keterangan :

- Z_t : Variabel respon pada saat t
- I_t : Variabel Intervensi
- ω : Besarnya efek intervensi
- ω_s : $\omega_0 - \omega_1 B - \omega_2 B^2 \dots - \omega_s B^s$
- δ : Penentu gerak efek intervensi
- δ_r : $1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_r B^r$
- s : Lamanya waktu intervensi yang dibutuhkan hingga mengalami

r : penurunan
 : Pola grafik respon intervensi
 $\frac{\theta_q(B)\theta_Q(B^s)e_t}{\phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D}$: Model deret waktu SARIMA data sebelum intervensi

2.3 Tahapan Pemodelan SARIMA

Tahapan pembentukan model SARIMA melibatkan beberapa langkah-langkah dalam memperoleh model yang terbaik agar nantinya dapat digunakan untuk memprediksi. Tahapan pemodelan SARIMA sebagai berikut (Putri & Sofro, 2022):

1. Identifikasi Model SARIMA.
2. Estimasi Parameter Model SARIMA.
3. Uji Diagnostik Model SARIMA.

2.4 Tahapan Pemodelan SARIMA dengan Faktor Intervensi

Langkah-langkah pemodelan SARIMA dengan faktor intervensi memiliki kesamaan dengan pemodelan SARIMA pada Sub Bab 2.3. Namun ada beberapa hal yang membedakannya, seperti adanya tahapan membagi data menjadi dua bagian dan penentuan orde b, s, r . Berikut ini tahapan pembentukan model SARIMA dengan faktor intervensi (Geovani, Hatidja, & Tumilaar, 2022):

1. Bentuk grafik dari data pengamatan, lalu tentukan intervensi pada data.
2. Bagilah data menjadi dua kelompok, yaitu data sebelum intervensi dan data ketika intervensi terjadi sampai data akhir.
3. Pada data sebelum intervensi, lakukan pemodelan SARIMA melalui langkah-langkah berikut:
 - a) Identifikasi model SARIMA sebelum intervensi.
 - b) Estimasi parameter model dan dilanjutkan dengan pengujian signifikansi parameter.
 - c) Uji diagnostik Model SARIMA sebelum intervensi.

Model SARIMA sebelum intervensi akan digunakan untuk membentuk plot respon intervensi. Plot tersebut digunakan untuk mengidentifikasi model intervensi. Plot respon intervensi diperoleh dengan menghitung selisih antara hasil prediksi menggunakan model SARIMA sebelum intervensi dengan data aktualnya.


4. Identifikasi model intervensi: menentukan orde b, s, r dari plot respon intervensi.
5. Estimasi parameter model SARIMA dengan faktor intervensi.
6. Uji Diagnostik model SARIMA dengan faktor intervensi.
7. Prediksi menggunakan model SARIMA dengan faktor intervensi

Pada saat proses pemodelan deret waktu, sangat mungkin terjadinya perolehan model lebih dari satu yang dapat menggambarkan data. Ada beberapa cara untuk melakukan pemilihan model, salah satunya adalah menggunakan nilai AIC (*Akaike Information Criterion*). Nilai AIC bertujuan untuk melihat ukuran informasi mengenai kelayakan suatu model. Apabila nilai AIC kecil, dapat dinyatakan bahwa model termasuk semakin baik begitu pun sebaliknya (Cryer, 2008).

3 HASIL DAN PEMBAHASAN

Grafik data bulanan jumlah penumpang pesawat pada keberangkatan domestik di Bandara Soekarno-Hatta dari Januari 2016 hingga Juni 2023 terdapat pada **Gambar 1**. Berdasarkan grafik tersebut diketahui bahwa data mengandung unsur musiman, yaitu pola data mengalami perulangan di rentang waktu yang sama. Pola mengalami kenaikan memasuki akhir tahun yaitu pada Desember serta mengalami penurunan ketika memasuki awal tahun yaitu bulan Januari.

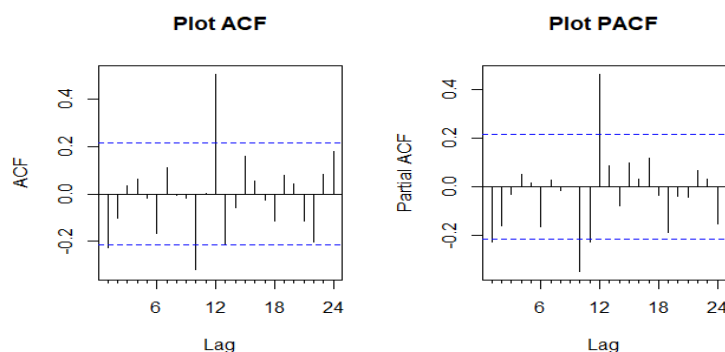
Kemudian pada Mei 2020, jumlah penumpang mengalami penurunan secara signifikan. Rata-rata jumlah penumpang semula berada di atas satu juta penumpang lalu turun menjadi 27.500 penumpang. Hal ini merupakan dampak dari beberapa kebijakan pemerintah akibat pandemi Covid-19. Oleh sebab itu, pada studi ini kejadian tersebut dianggap sebagai intervensi.



Gambar 1. Plot data penumpang pesawat pada keberangkatan domestik di Bandara Soekarno-Hatta periode Januari 2016 - Juni 2023

3.1 Model SARIMA pada Data Jumlah Penumpang Penerbangan Domestik di Bandara Soekarno-Hatta

Pembentukan model SARIMA diawali membagi data menjadi data *training* dan data *testing*. Data *training* meliputi data dari Januari 2016 hingga Januari 2023, sedangkan data *testing* dimulai pada Februari 2023 hingga Juni 2023. Selanjutnya tahapan pembentukan model SARIMA melibatkan data *training*, dimulai dengan identifikasi kestasioneran data baik secara variansi ataupun rata-ratanya. Selanjutnya apabila data telah stasioner, dilakukan pembentukan plot ACF dan PACF dari data agar diperoleh kandidat model. Lalu dilakukan estimasi pada semua parameter dari kandidat model yang sudah terbentuk. Dari model yang parameternya yang telah signifikan, kemudian dilakukan uji diagnostik model. Model yang sudah melewati tahapan ini dapat digunakan untuk melakukan prediksi. **Gambar 1** menunjukkan data *training* yang belum stasioner baik terhadap variansi maupun rata-ratanya. Oleh sebab itu, dilakukan proses transformasi dan *differencing* sehingga diperoleh plot ACF dan PACF data stasioner yang ditampilkan pada **Gambar 2**.



Gambar 2. Plot ACF (Kiri) dan PACF (Kanan) dari data penumpang pesawat pada keberangkatan domestik di Bandara Soekarno-Hatta periode Januari 2016 - Juni 2023 yang sudah stasioner

Berdasarkan **Gambar 2**, plot ACF dan PACF menunjukkan bahwa untuk non musiman signifikan pada lag-1 dan untuk musiman pada lag-12. Dengan demikian, identifikasi kandidat model ditampilkan pada **Tabel 1**.

Tabel 1. Kandidat Model SARIMA

SARIMA	
<i>ARIMA</i> (1, 1, 1)(1, 0, 1) ₁₂	<i>ARIMA</i> (1,1,0)(1,0,0) ₁₂
<i>ARIMA</i> (1, 1, 0)(1, 0, 1) ₁₂	<i>ARIMA</i> (1,1,0)(0,0,1) ₁₂
<i>ARIMA</i> (0, 1, 1)(1, 0, 1) ₁₂	<i>ARIMA</i> (0,1,1)(1,0,0) ₁₂
<i>ARIMA</i> (0, 1, 0)(1, 0, 1) ₁₂	<i>ARIMA</i> (0,1,1)(0,0,1) ₁₂
<i>ARIMA</i> (1, 1, 1)(1, 0, 0) ₁₂	<i>ARIMA</i> (0,1,0)(1,0,0) ₁₂
<i>ARIMA</i> (1, 1, 1)(0, 0, 1) ₁₂	<i>ARIMA</i> (0,1,0)(0,0,1) ₁₂

Selanjutnya dilakukan estimasi parameter model serta uji signifikansi parameter pada setiap kandidat model menggunakan *software* Rstudio. Parameter yang signifikan dari kandidat model diperoleh dengan ketentuan jika $p\text{-value} < \alpha$, dengan $\alpha = 5\%$. Dari tahap ini dipilih model *ARIMA* (0,1,1)(0,0,1)₁₂ dan *ARIMA* (0,1,1)(1,0,0)₁₂, karena memiliki parameter yang telah signifikan serta nilai AIC yang rendah diantara model lainnya yang juga memenuhi uji signifikansi parameter.

Model *ARIMA* (0,1,1)(0,0,1)₁₂ dan *ARIMA* (0,1,1)(1,0,0)₁₂ dapat lanjut ke tahap uji diagnostik model. Tahapan ini dilakukan untuk mengetahui apakah model yang diperoleh sudah dapat dikatakan baik untuk digunakan dalam pemodelan dan prediksi. Uji diagnostik model terdiri dari uji normalitas residual serta uji independensi residual. Pengujian independensi residual dapat dilakukan melalui perhitungan Ljung-Box dan analisis plot ACF Residual, sedangkan uji normalitas menggunakan uji Shapiro Test. Dengan ketentuan jika $p\text{-value} > \alpha$, dengan $\alpha = 5\%$, maka dikatakan residual telah memenuhi asumsi independensi dan berdistribusi secara normal.

Tabel 2. Uji Diagnostik Model SARIMA

Model	Normalitas	Ljung-Box Test
<i>ARIMA</i> (0, 1, 1)(1, 0, 0) ₁₂	$p\text{-value} = 0,6048$ (Normal)	$p\text{-value} = 0,1508$ (Memenuhi)
<i>ARIMA</i> (0, 1, 1)(0, 0, 1) ₁₂	$p\text{-value} = 0,9158$ (Normal)	$p\text{-value} = 0,07965$ (Memenuhi)

Berdasarkan hasil uji diagnostik model pada **Tabel 2**, kedua model sudah memenuhi kelayakan model dan dapat digunakan untuk melakukan prediksi. Namun demi memperjelas manakah model yang baik untuk digunakan maka dilakukan perbandingan nilai MAPE kedua model tersebut. Nilai MAPE dihitung menggunakan data aktual (data *testing*) dan hasil prediksi kedua model pada Februari 2023 sampai Juni 2023.

Tabel 3. Hasil Prediksi 5 Bulan ke depan dengan Model *ARIMA* (0,1,1)(1,0,0)₁₂

Bulan	Hasil Prediksi	Data Aktual
Februari 2023	1107597	1295183
Maret 2023	1315989	1452671
April 2023	1322555	1490933
Mei 2023	1546272	1645287
Juni 2023	1523819	1604017
MAPE		9,240737%

Tabel 4. Hasil Prediksi 5 Bulan ke depan dengan Model ARIMA (0,1,1)(0,0,1)₁₂

Bulan	Hasil Prediksi	Data Aktual
Februari 2023	1498259	1295183
Maret 2023	1544365	1452671
April 2023	1430400	1490933
Mei 2023	1658597	1645287
Juni 2023	1562913	1604017
MAPE		5,884603%

Berdasarkan **Tabel 3** dan **Tabel 4**, nilai MAPE yang didapatkan dari kedua model bernilai < 10%, artinya kedua model tersebut dikategorikan sangat baik untuk digunakan. Namun karena nilai MAPE model ARIMA (0,1,1)(0,0,1)₁₂ lebih kecil dibandingkan ARIMA (0,1,1)(1,0,0)₁₂, maka dipilih model ARIMA (0,1,1)(0,0,1)₁₂ dengan persamaan sebagai berikut.

$$(1 - B)^1 Z_t = \theta_1(B) \theta_1(B)^{12} e_t$$

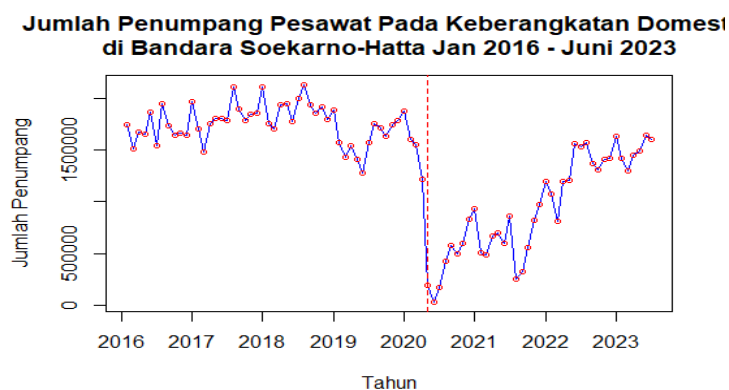
$$Z_t = Z_{t-1} + e_t - \theta_1 e_{t-12} - \theta_1 e_{t-1} + \theta_1 \theta_1 e_{t-13}$$

$$Z_t = Z_{t-1} + e_t - (-0,660543)e_{t-12} - (-0,999982)e_{t-1} + (-0,999982)(-0,660543)e_{t-13}$$

(3)

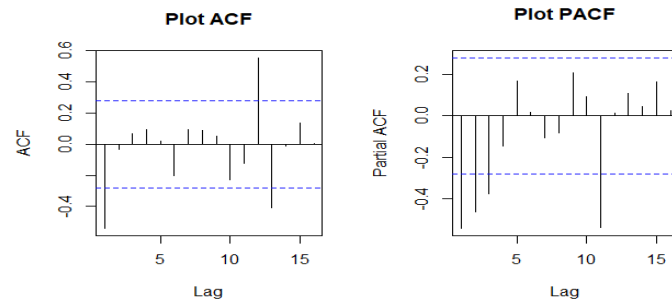
3.2 Model SARIMA dengan Faktor Intervensi pada Data Jumlah Penumpang Penerbangan Domestik di Bandara Soekarno-Hatta

Dalam membentuk model deret waktu dengan faktor intervensi, data akan dibagi menjadi dua, yaitu data sebelum intervensi yang dimulai dari bulan Januari 2016 hingga April 2020 serta sesudah intervensi dimulai dari Mei 2020 hingga Januari 2023. Data *testing* yang akan digunakan dimulai dari Februari 2023 hingga Juni 2023. Gambar 3 menunjukkan plot data sebelum intervensi dan sesudah intervensi sampai data akhir yang akan digunakan.



Gambar 3 Pembagian Data Sebelum dan Setelah Intervensi

Langkah awal adalah pembentukan model SARIMA sebelum intervensi. **Gambar 3** menunjukkan data sebelum intervensi yang sudah stasioner terhadap variansi namun belum terhadap rata-ratanya. Oleh sebab itu, dilakukan proses *differencing* sehingga diperoleh plot ACF dan PACF data stasioner yang ditampilkan pada **Gambar 4**.



Gambar 4 Plot ACF (Kiri) dan PACF (Kanan) dari data sebelum Intervensi yang Sudah Stasioner

Jika diamati dari **Gambar 4**, Plot ACF menunjukkan bahwa untuk non musiman signifikan pada lag-1 dan untuk musiman pada lag-12, sedangkan pada plot PACF menunjukkan bahwa untuk non musiman signifikan di lag-1, lag-2, dan lag-3 dan untuk musiman pada lag-12. Oleh sebab itu, kandidat model ditampilkan pada pada **Tabel 5**.

Tabel 5 Kandidat Model Deret Waktu SARIMA Sebelum Intervensi

Model SARIMA	
ARIMA (1, 2, 1)(0, 0, 1) ₁₂	ARIMA (1,1,1)(0,0,1) ₁₂
ARIMA (1, 2, 0)(0, 0, 1) ₁₂	ARIMA (1,1,0)(0,0,1) ₁₂
ARIMA (2, 2, 1)(0, 0, 1) ₁₂	ARIMA (2,1,1)(0,0,1) ₁₂
ARIMA (2, 2, 0)(0, 0, 1) ₁₂	ARIMA (2,1,0)(0,0,1) ₁₂
ARIMA (3, 2, 1)(0, 0, 1) ₁₂	ARIMA (3,1,1)(0,0,1) ₁₂
ARIMA (3, 2, 0)(0, 0, 1) ₁₂	ARIMA (3,1,0)(0,0,1) ₁₂
ARIMA (0, 2, 1)(0, 0, 1) ₁₂	ARIMA (0,1,1)(0,0,1) ₁₂
ARIMA (0, 2, 0)(0, 0, 1) ₁₂	ARIMA (0,1,0)(0,0,1) ₁₂

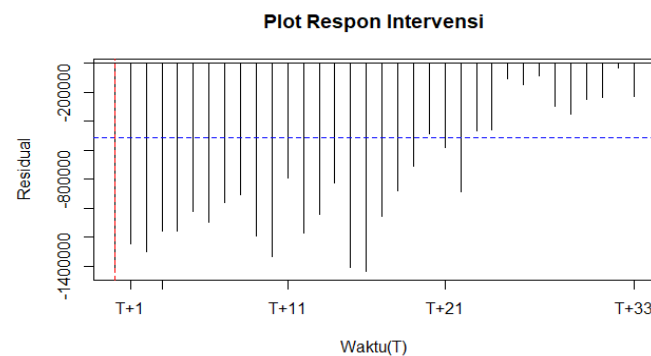
Selanjutnya dilakukan estimasi parameter model serta uji signifikansi parameter pada setiap kandidat model dengan menggunakan *software* Rstudio. Parameter yang signifikan dari kandidat model diperoleh dengan ketentuan jika $p\text{-value} < \alpha$, dengan $\alpha = 5\%$. Dari tahap ini diperoleh model ARIMA (2,2,1)(0,0,1)₁₂, ARIMA (3,2,1)(0,0,1)₁₂, ARIMA (1,1,1)(0,0,1)₁₂, ARIMA (2,1,1)(0,0,1)₁₂, dan ARIMA (3,1,1)(0,0,1)₁₂, karena memiliki nilai AIC yang lebih rendah dibandingkan model yang lain.

Model ARIMA ARIMA (2,2,1)(0,0,1)₁₂, ARIMA (3,2,1)(0,0,1)₁₂, ARIMA (1,1,1)(0,0,1)₁₂, ARIMA (2,1,1)(0,0,1)₁₂, dan ARIMA (3,1,1)(0,0,1)₁₂, dapat lanjut ke tahap uji diagnostik model. Hasil uji diagnostik model ditampilkan pada **Tabel 6**.

Setelah dilakukan uji independensi residual serta uji normalitas residual, diperoleh model ARIMA (3,2,1)(0,0,1)₁₂ dan ARIMA (3,1,1)(0,0,1)₁₂ yang sudah memenuhi kelayakan model untuk lanjut ke tahap selanjutnya. Tahapan selanjutnya adalah membentuk plot residual respon intervensi ketika intervensi terjadi dan setelah intervensi terjadi. Dari plot tersebut ditentukan pula orde dari intervensi yaitu b, s, r . Plot residual respon intervensi diperoleh dari hasil selisih antara data aktual (data saat dan setelah terjadinya intervensi sampai data akhir) dan hasil prediksi dari model SARIMA sebelum intervensi.


Tabel 6 Uji Diagnostik Model SARIMA Sebelum Intervensi

Model	Normalitas	Ljung-Box Test
ARIMA (2, 2, 1)(0, 0, 1) ₁₂	$p\text{-value} = 0,1416$ (Normal)	$p\text{-value} = 0,07129$ (Sudah Memenuhi)
ARIMA (3, 2, 1)(0, 0, 1) ₁₂	$p\text{-value} = 0,3534$ (Normal)	$p\text{-value} = 0,07161$ (Sudah Memenuhi)
ARIMA (1, 1, 1)(0, 0, 1) ₁₂	$p\text{-value} = 0,6952$ (Normal)	$p\text{-value} = 0,06966$ (Sudah Memenuhi)
ARIMA (2, 1, 1)(0, 0, 1) ₁₂	$p\text{-value} = 0,3846$ (Normal)	$p\text{-value} = 0,2602$ (Sudah Memenuhi)
ARIMA (3, 1, 1)(0, 0, 1) ₁₂	$p\text{-value} = 0,8813$ (Normal)	$p\text{-value} = 0,5791$ (Sudah Memenuhi)



Gambar 5 Plot Respon Residual Intervensi yang Diperoleh dari Selisih Antara Hasil Prediksi Model ARIMA (3,2,1)(0,0,1)₁₂ dengan Data Aktual

Berdasarkan **Gambar 5**, orde b, s, r yang didapatkan adalah orde $b = 0$ karena efek intervensi langsung terjadi pada saat terjadinya intervensi (T), orde $s = 19$ karena efek intervensi memerlukan waktu agar kembali stabil dari $T + 1$ hingga $T + 19$, serta orde $r = 0$ karena plot residual respon intervensi tidak membentuk pola. Dengan demikian, diperoleh model intervensi fungsi *step* dengan orde $b = 0, s = 19, r = 0$.



Gambar 6 Plot Respon Residual Intervensi yang Diperoleh dari Selisih Antara Hasil Prediksi Model ARIMA (3,1,1)(0,0,1)₁₂ dengan Data Aktual

Berdasarkan **Gambar 6**, diperoleh orde b, s, r yaitu orde $b = 0$ karena efek intervensi langsung terjadi pada saat terjadinya intervensi (T), orde $s = 24$ karena efek intervensi memerlukan waktu kembali stabil dari $T + 1$ hingga $T + 24$, serta orde $r = 0$ karena plot residual respon intervensi tidak membentuk pola. Dengan demikian, diperoleh model intervensi fungsi *step* dengan orde $b = 0, s = 24, r = 0$.

Selanjutnya dilakukan estimasi parameter dan uji signifikansi parameter untuk setiap kandidat model menggunakan *software* Rstudio dan dilanjutkan dengan uji diagnostik model. Hasil uji diagnostik model ditampilkan pada **Tabel 7**.

Tabel 7 Hasil Signifikansi Parameter dan Uji Diagnostik Model pada ARIMA (3,2,1)(0,0,1)₁₂ dengan Faktor Intervensi $b = 0, s = 19, r = 0$ dan ARIMA (3,1,1)(0,0,1)₁₂ dengan Faktor Intervensi $b = 0, s = 24, r = 0$

	ARIMA (3, 2, 1)(0, 0, 1) ₁₂ dengan faktor intervensi $b = 0, r = 0, s = 19$	ARIMA (3, 1, 1)(0, 0, 1) ₁₂ dengan faktor intervensi $b = 0, r = 0, s = 24$
Uji Signifikansi Parameter	Belum Memenuhi	Belum Memenuhi
Uji Independensi Residual	$p\text{-value} = 0,9095$ (Memenuhi)	$p\text{-value} = 0,9962$ (Memenuhi)
Uji Normalitas Residual	$p\text{-value} = 0,2819$ (Memenuhi)	$p\text{-value} = 0,0002483$ (Tidak Memenuhi)

Berdasarkan **Tabel 7**, kedua model memang belum memenuhi dalam kategori uji signifikansi parameter, dikarenakan ada beberapa parameter di dalam model yang belum signifikan. Namun dapat dilihat berdasarkan hasil uji diagnostik modelnya, model ARIMA (3,2,1)(0,0,1)₁₂ dengan faktor intervensi $b = 0, r = 0, s = 19$ dapat lanjut ke tahap prediksi. Hal ini disebabkan karena model tersebut telah memenuhi asumsi normalitas residual karena memiliki nilai $p\text{-value} < \alpha$, dengan $\alpha = 5\%$. Dengan demikian, model yang dapat dinyatakan dengan persamaan berikut.

$$Z_t = \frac{\omega_{19}(B)B^0}{\delta_0(B)} + \frac{\theta_1(B)\theta_1(B^{12})}{\phi_3(B)(1-B)^2}$$

$$Z_t = (\omega_0 - \omega_1B^1 - \omega_2B^2 - \omega_3B^3 - \omega_4B^4 - \omega_5B^5 - \omega_6B^6 - \omega_7B^7 - \omega_8B^8 - \omega_9B^9 - \omega_{10}B^{10} - \omega_{11}B^{11} - \omega_{12}B^{12} - \omega_{13}B^{13} - \omega_{14}B^{14} - \omega_{15}B^{15} - \omega_{16}B^{16} - \omega_{17}B^{17} - \omega_{18}B^{18} - \omega_{19}B^{19})S_t^{(52)} + \frac{(1-\theta_1B)(1-\theta_1B^{12})}{(1-\phi_1B-\phi_2B^2-\phi_3B^3)(1-B)^2} e_t \quad (4)$$

Setelah melalui berbagai tahapan, selanjutnya dilakukan perhitungan nilai MAPE terhadap model ARIMA (3,2,1)(0,0,1)₁₂ dengan faktor intervensi $b = 0, r = 0, s = 19$.

Tabel 8 Hasil Prediksi 5 Bulan ke depan dengan Model ARIMA (3,2,1)(0,0,1)₁₂ dengan Faktor Intervensi $b = 0, s = 19, r = 0$

Bulan	Hasil Prediksi	Data Aktual
Februari 2023	1503211	1295183
Maret 2023	1503211	1452671
April 2023	1503211	1490933
Mei 2023	1503211	1645287
Juni 2023	1503211	1604017
MAPE		7,056848%

Berdasarkan pembahasan dari Sub Bab 3.1 dan 3.2, maka model yang dapat mewakili data historis jumlah penumpang pesawat pada keberangkatan domestik di Bandara Soekarno-Hatta dari Januari 2016 hingga Juni 2023 adalah model ARIMA (0,1,1)(0,0,1)₁₂ dan ARIMA (3,2,1)(0,0,1)₁₂ dengan faktor intervensi $b = 0, r = 0, s = 19$. Efektivitas dari kedua model kemudian dibandingkan berdasarkan nilai MAPE.

Tabel 9 Perbandingan Nilai MAPE pada Model Deret Waktu SARIMA dan SARIMA dengan Faktor Intervensi

Model	MAPE
$ARIMA (0, 1, 1)(0, 0, 1)_{12}$	5,884603%
$ARIMA (3, 2, 1)(0, 0, 1)_{12}$ dengan faktor intervensi $b = 0, r = 0, s = 19$	7,056848%

Berdasarkan **Tabel 9**, kedua model memiliki nilai MAPE yang kurang dari 10%, artinya model sudah sangat baik untuk digunakan. Namun Model $ARIMA (0,1,1)(0,0,1)_{12}$ memiliki MAPE yang lebih rendah dibandingkan $ARIMA (3,2,1)(0,0,1)_{12}$ dengan faktor intervensi $b = 0, r = 0, s = 19$. Dengan demikian model $ARIMA (0,1,1)(0,0,1)_{12}$ akan digunakan untuk memprediksi data jumlah penumpang pesawat pada keberangkatan domestik di Bandara Soekarno-Hatta pada Juli 2023 hingga Desember 2023.

Tabel 10 Hasil Prediksi Data Jumlah Penumpang Pesawat dalam Keberangkatan Domestik di Bandara Soekarno-Hatta pada Juli hingga Desember 2023

Periode	Hasil Prediksi
Juli 2023	1664445
Agustus 2023	1540506
September 2023	1480142
Oktober 2023	1478118
November 2023	1449599
Desember 2023	1520411

4 KESIMPULAN

Dari studi ini, maka dapat disimpulkan bahwa Model SARIMA yang dibentuk dari data jumlah penumpang pesawat dalam penerbangan domestik di Bandara Soekarno-Hatta pada Januari 2016 hingga Januari 2023 adalah $ARIMA (0,1,1)(0,0,1)_{12}$. Dengan menggunakan data yang sama model SARIMA dengan faktor intervensi yang dibentuk adalah $ARIMA (3,2,1)(0,0,1)_{12}$ dengan faktor intervensi $b = 0, r = 0, s = 19$. Tingkat akurasi hasil prediksi model SARIMA dan SARIMA dengan faktor intervensi ditunjukkan dengan nilai MAPE yang kurang dari 10%. Hal ini berarti model sangat baik untuk digunakan. Hasil prediksi jumlah penumpang pesawat dalam keberangkatan domestik di Bandara Soekarno-Hatta pada Juli hingga Desember 2023 berturut-turut adalah 1664445, 1540506, 1480142, 1478118, 1449599, 1520411 penumpang.

UCAPAN TERIMA KASIH

Terima kasih kepada Badan Pusat Statistik atas akses data yang dapat digunakan dalam studi ini.

DAFTAR PUSTAKA

- Ardhia, W. (2015). Pelayanan Penumpang Angkutan Udara di Terminal 2 Domestik Bandar Udara Juanda Surabaya. *Jurnal Perhubungan Udara*, hal 219.
- Assakhiy, R., Anwar, S., & AR, F. (2019). Peramalan Realisasi Penerimaan Zakat Pada Baitulmala Aceh dengan Mempertimbangkan Efek dari Variasi Kalender. *Jurnal Ekonomi dan Pembangunan*, 27-45.

- Badan Pusat Statistik (BPS). (Juni de 2024). *Jumlah Penumpang Pesawat di Bandara Utama*.
Fonte: <https://www.bps.go.id/id:> <https://www.bps.go.id/id/statistics-table/2/NjYjMg==/jumlah-penumpang-pesawat-di-bandara-utama--orang-.html>
- Cryer, J. C. (2008). *Time Series Analysis : With Application in R Second Edition*. USA: Springer Science and Business Media, LLC.
- Edriani, T. S., Pasaribu, U. S., Afrianti, Y. S., & Astute, N. W. (2021). The Geometric Brownian Motion of Indosat Telecommunications Daily Stock Price During the Covid-19 Pandemic in Indonesia. *Journal of Physics*, 2084.
- Edriani, T. S., Rahmadani, A., & Noor, D. M. (2021). Analisis Hubungan Kepadatan Penduduk dengan Pola Penyebaran Covid-19 Provinsi DKI Jakarta Menggunakan Regresi Robust. *Indonesian Journal of Applied Mathematics*, 51-60.
- Geovani, C., Hatidja, D., & Tumilaar, R. (2022). Penerapan Metode SARIMA dalam Model Intervensi Fungsi Step untuk Memprediksi Jumlah Pengunjung Objek Wisata Londa. 96-103.
- Ghozi, A. A., Aprianti, A., Dimas, A. P., & Fauzi, R. (20022). Analisis Prediksi Data Kasus Covid-19 di Provinsi Lampung Menggunakan Recurrent Neural Network (RNN). *Indonesian Journal of Applied Mathematics*, 25-32.
- Putri, S., & Sofro, A. (2022). Peramalan Jumlah Keberangkatan Penumpang Pelayaran dalam Negeri di Pelabuhan Tanjung Perak Menggunakan Metode ARIMA dan SARIMA . *Jurnal Ilmiah Matematika*.
- Wei, W. W. (2006). *Time Series Analysis : Univariate and Multivariate Method*. USA: Pearson.
- Widianingsih, P., Darmawan, G., & Sunengsih, N. (2022). Analisis Intervensi dalam Model SARIMA untuk Memprediksi Laju Inflasi di Kota Tasikmalaya. *Formosa Journal of Science and Technology*, 293-304.