

---

## Peramalan Jumlah Penumpang Kereta Api di Indonesia Menggunakan Metode *Seasonal Autoregressive Integrated Moving Average (SARIMA)*

Pramesthi Utomo<sup>1</sup>, Aris Fanani<sup>2</sup>

<sup>1</sup>UIN Sunan Ampel Surabaya, [h72216040@uinsby.ac.id](mailto:h72216040@uinsby.ac.id)

<sup>2</sup>UIN Sunan Ampel Surabaya, [arisfa@uinsby.ac.id](mailto:arisfa@uinsby.ac.id)

**Abstrak:** Transportasi merupakan penunjang kehidupan ekonomi, sosial budaya, pertahanan keamanan hingga politik di suatu negara. Kereta api adalah efisien serta anti macet, dimana problema sampai pada hari ini adalah kemacetan terutama di kota-kota besar. Jumlah penumpang kereta api terus bertambah tiap tahunnya dan lonjakan jumlah penumpang kereta api terjadi pada libur hari natal dan tahun baru sehingga data berpola musiman. Untuk mengantisipasi lonjakan penumpang kereta api, diperlukan adanya peramalan untuk memprediksi periode kedepan. *Seasonal Autoregressive Integrated Moving Average* secara umum merupakan pengembangan dari metode ARIMA yaitu penggabungan antara *autoregressive* serta *moving average*, sebagai tambahannya metode ini di khususkan untuk data yang berpola *seasonal*, dengan demikian SARIMA adalah metode yang tepat untuk data jumlah penumpang kereta api. Tujuan dari penelitian ini adalah meramalkan jumlah penumpang kereta api di Indonesia menggunakan Metode SARIMA dan menghasilkan model terbaik yaitu  $(1,1,2)(0,1,1)^{12}$ , dari model tersebut diperoleh prediksi jumlah keseluruhan penumpang kereta api di Indonesia pada tahun 2020 adalah 492.230.700 orang penumpang dengan nilai MSE sebesar 0,046875 dan nilai MAPE sebesar 6,26%.

**Kata kunci:** *Transportasi, Penumpang Kereta Api, SARIMA*

**Abstract:** *Transportation is a supporter of economic life, social culture, defense and security to politics in a country. The train is efficient and anti-traffic, where the problem to this day is congestion, especially in big cities. The number of train passengers continues to increase each year and the surge in the number of train passengers occurs on Christmas and New Year holidays so that the data is seasonal. To anticipate the surge in train passengers, forecasting is needed to predict future periods. Seasonal Autoregressive Integrated Moving Average is generally a development of the ARIMA method, which is a combination of autoregressive and moving average, in addition this method is specifically for data patterned seasonal, thus SARIMA is the right method for data on train passenger numbers. The purpose of this study is to predict the number of train passengers in Indonesia using the SARIMA Method and produce the best model of  $(1,1,2)(0,1,1)^{12}$ , from this model a prediction of the total number of train passengers is obtained fire in Indonesia in 2020 was 492,230,700 passengers with MSE value is 0.046875 and MAPE value is 6.26 %.*

**Keywords:** *Transpotation, Train Passengers, SARIMA*

## **1. Pendahuluan**

Salah satu elemen yang sangat penting dalam suatu negara adalah transportasi, bahkan transportasi merupakan penunjang kehidupan ekonomi, pertahanan keamanan, politik hingga sosial budaya. Selain sebagai fasilitas umum, transportasi juga berguna untuk memperkuat hubungan antar bangsa untuk tujuan bersama dan termuat dalam UU No.22 Tahun 2009 yang didalamnya menjelaskan tentang transportasi atau angkutan jalan yang memiliki peran penting di dalam integrasi nasional dan pembangunan sebagai upaya untuk memajukan kesejahteraan masyarakat.

Semakin hari semakin banyak orang yang melakukan perjalanan, baik perjalanan untuk kepentingan pribadi, bisnis maupun wisata. Problema berupa waktu dan juga biaya sering menjadi hambatan bagi sebagian orang untuk bepergian [1]. Kereta api merupakan transportasi darat yang digunakan untuk perjalanan jauh, selain cepat kereta api juga merupakan transportasi anti macet dimana problema sampai pada hari ini adalah kemacetan di jalan, terutama di kota-kota besar. Selain ramah lingkungan dan murah, kereta api juga dilengkapi dengan berbagai fasilitas [2].

Berdasarkan catatan dari PT. KAI, jumlah penumpang pada hari libur Natal dan tahun baru tahun 2018-2019 meningkat sebanyak 5% dari tahun sebelumnya yaitu tahun 2017-2018. Dilansir dari berita DetikNews, menurut Supriyanto, Manager Humas PT KAI Daop 5 Purwokerto, penumpang pada hari libur Natal dan tahun baru yang berakhir pada tanggal 6 Januari 2019 mencapai 274.739 orang, jika dibandingkan dengan libur Natal dan tahun baru 2018 yang jumlah penumpangnya mencapai 252.716 orang. Selisihnya mencapai 22.023 orang dari tahun lalu. PT. KAI Daop 5 juga mempersiapkan 26 kereta api tambahan [3].

Untuk mengatasi jumlah penumpang yang terus bertambah, perlu adanya peramalan sehingga dapat dipersiapkan fasilitas yang diperlukan untuk kelancaran transportasi kereta api tersebut. Kegiatan yang berulang-ulang dilakukan sehingga membentuk data time series atau yang berpola trend maupun musiman dapat menjadi pedoman dalam menghitung peramalan untuk periode mendatang.

Penelitian ini mengambil tema peramalan jumlah penumpang kereta api di Indonesia, studi kasus yang diambil adalah untuk wilayah Jabodetabek, Jawa non-Jabodetabek dan Sumatera karena di wilayah ini merupakan persebaran kereta api di wilayah NKRI, ditinjau dari data jumlah penumpang kereta api, dalam kurun waktu lebih dari 10 tahun kenaikan paling besar didominasi pada bulan Desember dikarenakan mendekati hari libur natal dan tahun baru dan bulan Januari tahun selanjutnya akan mengalami penurunan, sebagai contoh jumlah penumpang kereta api bulan Desember 2017 yang mencapai 36.807.000 orang penumpang yang kemudian mengalami penurunan pada bulan Januari 2018 yaitu 34.717.000 orang penumpang. Pada bulan Desember tahun 2018 pun juga mengalami kenaikan yaitu 37.956.000 orang penumpang, sedangkan pada bulan Januari tahun 2019 mengalami penurunan yaitu 35.122.000 orang penumpang, data tersebut berpola musiman sehingga digunakan metode SARIMA.

SARIMA adalah adopsi dari metode ARIMA yang sempat diperkenalkan ke publik oleh George Box dan Gwilyn Jenkins, bedanya pada SARIMA dikhususkan untuk data yang berpola musiman [4]. Penelitian terdahulu dengan topik yang serupa telah dilakukan oleh Wahida Yanti (2015), metode yang digunakan yaitu SARIMA dan menggunakan data penumpang pelayaran dalam negeri di pelabuhan Kota

Makassar, didapatkan peramalan dengan model  $(0,1,1)(1,1,0)^{12}$  dan menghasilkan lonjakan untuk penumpang naik di tahun 2015 bulan Juli sebesar 75.371 orang dan untuk penumpang turun adalah 53.196 orang. Sedangkan di tahun 2016 pada bulan Juli juga terjadi lonjakan penumpang naik yaitu sebesar 78.310 orang dan untuk penumpang turun adalah 56.911 orang. Dari penelitian Wahida juga didapatkan lonjakan jumlah penumpang terjadi setiap musim libur dan juga arus mudik lebaran [5].

Langkah-langkah pemodelan dari SARIMA adalah yang pertama menstasionerkan data yang belum stasioner, kemudian mengidentifikasi data secara umum, selanjutnya melakukan identifikasi model sementara, lalu mengestimasi parameter yang ada, memeriksa diasnotik serta memilih model terbaik, kemudian selanjutnya dapat dilakukan peramalan [6].

## 2. Kajian Teori

### 2.1 Peramalan

Peramalan adalah suatu perkiraan tentang keadaan di masa yang akan datang, peramalan dapat dilakukan dengan berbagai metode yang disesuaikan dengan pola data yang ada. Kegiatan yang berulang-ulang dilakukan sehingga membentuk deret waktu atau yang berpola naik turun maupun musiman dapat dijadikan acuan dalam menghitung peramalan dimasa yang akan datang. Peramalan dapat digunakan untuk berbagai bidang, seperti pada bidang perindustrian, perdagangan, transportasi hingga sosial [7]. Menurut jangka waktunya, peramalan dibagi menjadi peramalan jangka pendek, menengah dan jangka panjang. Peramalan jangka pendek hanya memprediksi satu periode yang kurang dari 1 tahun, sedangkan peramalan jangka menengah dilakukan untuk meramalkan 1-5 tahun dan peramalan jangka panjang dilakukan untuk lebih dari 5 tahun [8].

### 2.2 Stasioner

#### 1. Stasioner dalam rata-rata

Merupakan kondisi ketidaktetapan data berada pada nilai rata-rata yang konstan. Hal ini menunjukkan ketidakbergantungan pada waktu maupun variansi yang berubah-ubah. Kestasioneran dalam rata-rata ini dapat dikenali dengan melihat plot data dan dapat ditinjau dari plot ACF yang akan menurun hingga nol pada lag kelima atau enam tergantung pada data yang digunakan. Dalam analisi regresi variabel  $x$  pada waktu  $t$ , juga variabel bebas  $x$  waktu  $(t, i)$  yang merupakan variabel selisih waktu atau biasa dikenal dengan sebutan lag. Solusi untuk data yang belum stasioner dalam rata-rata adalah differensiasi.

$$Z'_t = Z_t - Z_{t-1} \quad (1)$$

Sedangkan untuk data musiman menggunakan persamaan berikut

$$Z'_t = Z_t - Z_{t-s} \quad (2)$$

Keterangan :

$Z'_t$  = nilai dari variabel  $Z$  pada waktu  $t$  setelah differensiasi

$s$  = periode musiman

[9]

#### 2. Stasioner dalam variansi

Dikatakan stasioner dalam variansi adalah apabila fluktuasi data tetap dari waktu ke waktu. Fluktuasi data ini tetap dan tidak berubah-ubah. Suatu data dapat dilihat stasioner dalam variansi juga dapat dilihat pada plot data deret berkala

tersebut. Ciri-ciri data yang belum stasioner dalam variansi adalah jika nilai Rounded Value belum bernilai 1, cara yang perlu dilakukan adalah mentransformasikan data sampai Rounded Value bernilai 1 [8].

$$y = Z_t^\lambda \quad (3)$$

Keterangan :

$Z$  = data aktual

$\lambda$  = parameter transformasi

### 2.3 Autocorrelative Function (ACF)

ACF adalah perhitungan autokorelasi berdasarkan varians dan kovariansnya. Autokorelasi merupakan cara untuk melihat adanya hubungan atau korelasi pada data yang sama antar waktu. Varians didefinisikan sebagai hubungan data pada waktu yang sama. Sedangkan kovarians didefinisikan sebagai hubungan data antar waktu. Kunci dari time series sendiri adalah terdapat pada koefisien korelasi. Ukuran korelasi pada time series dengan dirinya ada pada lag atau biasa dikenal dengan selisih waktu 0, 1, 2, sampai dengan lag pada data. Sedangkan plot ACF berfungsi untuk mengenali kestasioneran data. Berikut persamaannya [5].

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (4)$$

Keterangan :

$\hat{\rho}_k$  = nilai estimasi fungsi autokorelasi la ke-k

$\bar{Y}$  = nilai rata-rata

### 2.4 Partial Autocorrelative Function (PACF)

Partial Autocorrelative Function adalah suatu persamaan yang berfungsi sebagai penghitung ukuran kekuatan dari variabel  $Y_t$  dan  $Y_{t+k}$ . Perbedaan PACF dan ACF adalah terletak pada model partialnya. Pada PACF, pengawalan perhitungan nilai dimulai dengan  $\hat{\Phi}_{kk} = \hat{\rho}_1$ , dimana  $\hat{\rho}_1$  adalah nilai dari autocorrelative lag pertama. Berikut ini adalah persamaan untuk menghitung nilai *partial autocorrelative function* lag ke-k dengan menentukan hasil  $\hat{\Phi}_{kk}$  [8].

$$\hat{\Phi}_{kk} = \frac{\hat{\rho}_1 \sum_{j=1}^{k-1} \phi_{k-1j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1j} \rho_{k-j}} \quad (5)$$

Keterangan :

$\hat{\Phi}_{kk}$  = nilai *partial autocorrelative function* pada lag ke-k

$\rho_k$  = nilai *autocorrelative function* lag ke-k

### 2.5 Seasonal Autoregressive Integrated Moving Average (SARIMA)

Seasonal Autoregressive Integrated Moving Average secara umum mengandung model yang cocok pada situasi musiman, model ini juga merupakan pengembangan dari model sebelumnya yaitu ARIMA. Model Seasonal ARIMA ini dinotasikan dengan (p,d,q)(P,D,Q)<sup>s</sup> [10]. Pada model ini, terdapat 2 bagian yang dinotasikan dengan huruf kecil dan huruf kapital, pada (p,d,q) adalah notasi dari bagian dari model pada bagian yang tidak musiman. Sedangkan (P,D,Q) adalah notasi dari bagian model yang musiman. Untuk pangkat “s” adalah notasi untuk jumlah periode permusim. Berikut persamaannya.

$$\phi_p(B^s)\phi_p(B)(1-B)^d(1-B^s)^D Z_t = \theta_q(B)\theta_Q(B^s)\varepsilon_t \quad (6)$$

Keterangan :

$B$  = operator *backshift* berfungsi menggeser data ke periode sebelumnya  
 $\varepsilon_t$  = *error* periode  $t$

## 2.6 White Noise

*White noise* merupakan suatu proses stasioneritas dengan menggunakan fungsi autokovariansi. Proses  $\{\alpha\}$  dikatakan sebagai proses *white noise* apabila terindikasi adanya suatu ketidak korelasian variabel random dengan rata-rata konstan, yang secara persamaan dapat dituliskan  $E\alpha_t = \mu_0 = 0$  dan variansi yang konstan dapat dituliskan  $Var(\alpha_t) = \sigma_\alpha^2$  serta  $Cov(\alpha_t, \alpha_{t+k}) = 0$ , untuk persamaan tersebut harus memenuhi syarat  $k \neq 0$  [11].

Proses *white noise* dapat dideteksi dengan uji autokorelasi residual pada saat menganalisis besarnya *error*. Untuk melihat apakah residu dalam proses *white noise* memenuhi atau belum, digunakan pengujian *Ljung-Box*.

$$Q = n(n + 2) \sum_{k=1}^k \frac{\rho_k^2}{n-k} \quad (7)$$

Apabila taraf signifikansi yang ditetapkan  $\alpha = 5\%$  dan apabila *p-value* lebih besar dari  $\alpha$  maka  $H_0$  ditolak dan berarti tidak memenuhi *white noise*. Sebaliknya apabila *p-value* kurang dari  $\alpha$  maka secara otomatis  $H_1$  memenuhi *white noise*. Secara sederhana,  $H_0$  tidak diterima apabila  $Q < X_{\alpha, df=k-p-d}^2$ . *P-value* atau nilai probabilitas merupakan nilai besarnya probabilitas pada uji statistik, sedangkan  $\alpha$  adalah batas maksimal yang sudah ditentukan. Secara sederhana nilai probabilitas adalah hasil yang didapatkan pada perhitungan statistik dan  $\alpha$  sebagai pembatasnya [8].

## 3. Metode Penelitian

### 3.1 Sumber Data

Data yang digunakan dalam penelitian ini bersumber dari publikasi BPS dimana terdapat data jumlah penumpang pada Januari 2006 sampai Desember 2019

### 3.2 Tahapan Penelitian

Tahapan-tahapan dalam penelitian ini adalah sebagai berikut :

1. Membuat plot *time series* kemudian membuat plot ACF dan plot PACF.
2. Mengidentifikasi kestasioneran data. Jika data belum stasioner dalam variansi maka harus ditransformasi dan apabila data belum stasioner dalam rata-rata maka harus dilakukan differensiasi.
3. Menentukan model dengan melakukan estimasi parameter.
4. Melakukan uji *white noise*
5. Memilih model terbaik dengan melihat *error* terkecil pada model terpilih
6. Melakukan peramalan

## 4. Hasil dan Pembahasan

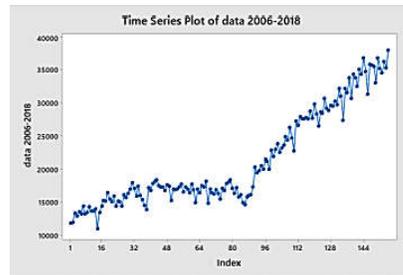
Data yang digunakan adalah data penumpang kereta api di Indonesia meliputi wilayah Jabodetabek, Jawa non-Jabodetabek dan Sumatera dari bulan Januari tahun 2006 sampai bulan Desember tahun 2019. Satuan angka dalam data adalah ribu orang, data dibagi menjadi data *training* dari bulan Januari 2006 sampai Desember 2018 dan

data *testing* mulai dari bulan Januari sampai Desember tahun 2019. Data dapat dilihat pada tabel berikut.

Tabel 1. Data Jumlah Penumpang Kereta Api di Indonesia

Tahun	Januari	Februari	Maret	April	Mei	Juni	Juli	Agustus	September	Oktober	November	Desember
2006	11.828	11.931	13.314	12.909	13.575	13.203	14.433	13.255	13.436	14.290	13.631	13.614
2007	13.960	10.969	13.409	14.415	15.232	15.104	16.454	15.419	15.033	15.866	14.391	15.084
2008	15.027	14.378	16.071	15.711	16.363	17.010	17.887	17.108	15.879	17.337	15.973	15.332
2009	14.494	13.869	17.132	16.775	17.824	18.143	18.385	17.527	17.281	17.281	16.778	17.581
2010	17.424	15.207	16.992	16.832	16.988	17.259	17.680	16.477	17.301	16.908	16.469	17.733
2011	16.891	14.890	16.978	16.441	17.522	17.265	18.132	14.846	16.921	16.461	16.179	16.811
2012	16.283	15.490	17.090	16.746	17.771	18.062	18.309	17.056	16.368	17.127	15.773	16.104
2013	14.900	14.594	15.826	16.000	16.113	17.301	20.245	19.423	19.738	20.534	19.919	21.417
2014	21.092	19.998	22.836	21.908	22.988	23.840	22.500	23.199	23.593	24.923	24.356	26.275
2015	24.676	22.790	27.267	26.565	27.910	27.562	27.612	27.796	27.549	28.718	27.669	29.831
2016	28.358	26.510	28.617	28.435	30.703	29.159	28.851	29.588	29.516	30.263	29.690	32.150
2017	30.949	27.342	32.170	31.502	33.745	30.723	34.310	33.791	32.498	35.070	34.361	36.807
2018	34.717	31.278	35.875	35.754	35.482	33.030	36.800	35.190	34.504	36.236	35.298	37.965
2019	35.122	31.899	35.751	35.809	35.102	35.090	37.906	35.189	35.221	36.448	35.877	37.463

#### 4.1 Identifikasi Plot *Time Series*

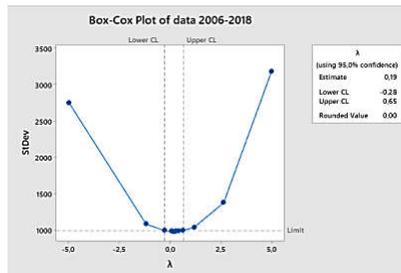


Gambar 1. Plot Data Penumpang Kereta Api

Pada Gambar 4.1 dapat dilihat apabila data mempunyai pola musiman dilihat dari plot data yang naik turun, dan juga terdapat pola trend dimana data terus mengalami kenaikan. Pola musiman dapat dideteksi dari pola yang diulang dimana data akan menunjukkan naik dan turun dalam jangka waktu yang tetap.

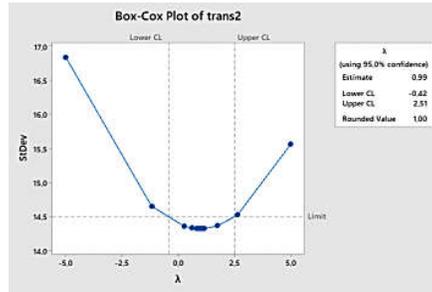
#### 4.2 Identifikasi Stasioneritas Data

##### 4.2.1 Terhadap variansi



Gambar 2. Box-Cox Data Penumpang Kereta Api

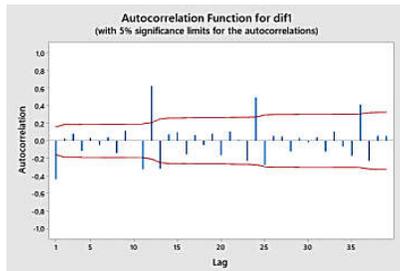
Pada Gambar 2 dapat dilihat nilai *Rounded Value* atau  $\lambda$  bernilai 0, yang artinya data belum stasioner dalam variansi, jadi langkah yang harus dilakukan adalah mentransformasikan data tersebut, berikut adalah plot Box-Cox pada data jumlah penumpang kereta api yang telah ditransformasi sebanyak 2 kali untuk memperoleh nilai 0 pada  $\lambda$ .



Gambar 3. Plot *Box-Cox* Setelah Transformasi 2 kali

#### 4.2.2 Terhadap rata-rata

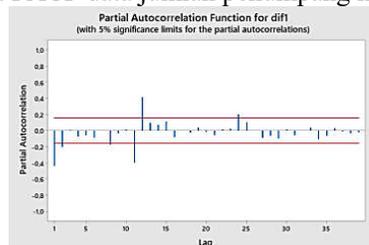
Untuk menstasionerkan data terhadap rata-rata, hasil dari transformasi akan didifferensiasi. Berikut hasil differensiasi dan diperoleh hasil yang stasioner karena pada lag 2 langsung *cut off* atau menuju nol.



Gambar 4. Plot ACF Setelah *Differencing* lag-1

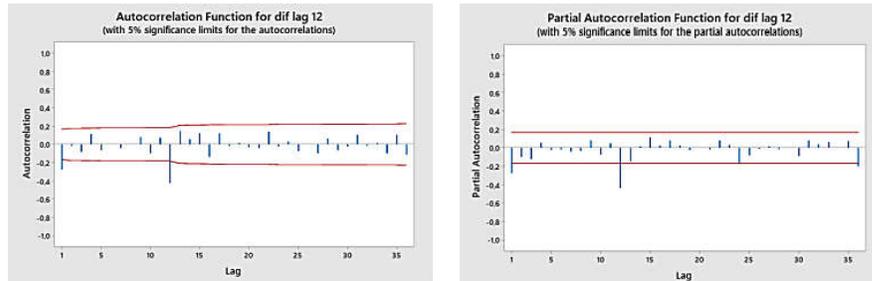
#### 4.3 Identifikasi Model

Setelah data telah stasioner terhadap rata-rata dan variansi, maka didapatkan model sementara dari hasil uji data. Model yang digunakan adalah  $(p,d,q)(P,D,Q)^s$ , p adalah asumsi untuk nilai AR non-musiman, sedangkan P adalah asumsi nilai AR musiman, d dan D adalah differencing non-musiman dan musiman, sedangkan q adalah ordo dari MA non-musiman dan Q adalah ordo dari MA musiman. Berikut ini adalah plot ACF dan plot PACF data jumlah penumpang kereta api.



Gambar 5. Plot PACF Setelah *Differencing* lag-1

Dikarenakan data jumlah penumpang kereta api di Indonesia bersifat seasonal atau musiman, maka perlu dilakukan *differencing* pada lag 12. Digunakan lag 12 dipilih karena periode yang diambil adalah tahunan, sementara data bersifat bulanan maka pada lag 12 berarti pada bulan ke-12. Berikut ini adalah plot ACF dan plot PACF setelah dilakukan *differencing* pada lag 12.



**Gambar 6 & 7.** Plot ACF dan PACF Setelah *Differencing* Musiman

Dari beberapa praduga model sementara yang diperoleh dari pengamatan plot ACF dan PACF. Selanjutnya akan dilakukan uji signifikan terhadap pendugaan parameter, pengujian signifikan ini ukur dari *p-value* yang didapat, apabila *p-value* < 0,5 maka dinyatakan signifikan dan apabila *p-value* > 0,5 maka dinyatakan tidak signifikan. Hasil dari uji signifikan didapat 2 model yang memenuhi syarat.

**Tabel 2.** Hasil Uji Signifikan

Model	Parameter	<i>p-value</i>	Keterangan
$(0,1,1)(0,1,1)^{12}$	MA 1	0,000	Signifikan
	SMA 12	0,000	Signifikan
$(1,1,2)(0,1,1)^{12}$	AR 1	0,000	Signifikan
	MA 1	0,000	Signifikan
	MA 2	0,000	Signifikan
	SMA 12	0,000	Signifikan

#### 4.4 Uji Asumsi Residual

Pada uji asumsi residual, model dinyatakan signifikan apabila *p-value* pada setiap parameter bernilai lebih dari 0,05.

**Tabel 3.** Hasil Uji Asums Residual

Model	Lag	<i>p-value</i>	Keterangan
$(0,1,1)(0,1,1)^{12}$	12	0,114	Signifikan
	24	0,417	Signifikan
	36	0,383	Signifikan
	48	0,741	Signifikan
$(1,1,2)(0,1,1)^{12}$	12	0,072	Signifikan
	24	0,374	Signifikan
	36	0,300	Signifikan
	48	0,653	Signifikan

**Tabel 4.** *White Noise*

Model	Residu		
	<i>p-value</i>	Keputusan	Kesimpulan
$(0,1,1)(0,1,1)^{12}$	0,150	$H_0$ diterima	<i>white noise</i>
$(1,1,2)(0,1,1)^{12}$	0,150	$H_0$ diterima	<i>white noise</i>

Dari hasil uji diatas dapat dilihat kedua model telah memenuhi semua uji yang dilakukan.

#### 4.5 Pemilihan Model Terbaik

Karena terdapat 2 model yang terpilih, maka akan diambil salah satu model terbaik yaitu yang memiliki nilai *error* paling kecil. Berikut adalah hasil dari perhitungan MAPE dan MSE.

**Tabel 5.** *Nilai Error*

Model	MAPE	MSE
$(0,1,1)(0,1,1)^{12}$	6,45%	0,049408
$(1,1,2)(0,1,1)^{12}$	6,26%	0,046875

Berdasarkan tabel 5. *Error* terkecil ada pada model  $(1,1,2)(0,1,1)^{12}$ , maka model tersebut yang akan digunakan untuk peramalan periode berikutnya. Berikut ini adalah hasil peramalan untuk periode 2020.

**Tabel 6.** Hasil Peramalan Periode Tahun 2020 (dalam ribu orang)

Bulan	Hasil Peramalan
Januari	39357,18
Februari	36941,51
Maret	40648,45
April	40480,23
Mei	41436,64
Juni	39960,99
Juli	42034,53
Agustus	41543,26
September	41004,85
Oktober	42691,09
November	41864,51
Desember	44267,41

#### 5. Kesimpulan

Identifikasi serta analisis yang telah dilakukan dengan metode SARIMA didapatkan model terbaik untuk peramalan untuk wilayah Jabodetabek, Jawa non-Jabodetabek dan Sumatera adalah model  $(1,1,2)(0,1,1)^{12}$ . Didapatkan hasil peramalan untuk periode 2020 dengan jumlah keseluruhan 36.941.500 orang penumpang. Perhitungan *error* didapatkan MSE sebesar 0,046875, nilai MSE ini mempunyai nilai dibawah 1 sehingga model peramalan mempunyai keakuratan yang baik. Didukung dengan nilai MAPE sebesar 6,26%, nilai ini memiliki range dibawah 10% yang artinya model peramalan sangat baik.

### Daftar Pustaka

- [1] A. Kadir, "Transportasi : Peran dan Dampaknya dalam Pertumbuhan Ekonomi Nasional," *Jurnal Perencanaan dan Pengembangan Wilayah Wahana Hijau*, p. Vol.1 No.1, 2006.
- [2] S. Aminah, "Transportasi Publik dan Aksesibilitas Masyarakat Perkotaan," *Jurnal Teknik Sipil UBL Vol.9 No.1*, pp. 1142-1155, 2018.
- [3] R. Heksantoro, "Penumpang KA Selama Libur Akhir Tahun di Daop 5 Purwokerto Naik 5%," 1 1 2019. [Online]. Available: <https://news.detik.com/berita-jawa-tengah/d-4366951/penumpang-ka-selama-libur-akhir-tahun-di-daop-5-purwokerto-naik-5>. [Accessed 13 10 2019].
- [4] H. Bando and Y. Sri, "Peramalan Produksi Kelapa Sawit Berdasarkan Intensitas Curah Hujan Menggunakan Metode ARIMA Studi Kasus Kabupaten Morowali Sulawesi Tengah," *Artikel Ilmiah*, p. 19, 2012.
- [5] W. Y. Nasir, *Peramalan Jumlah Penumpang Dari Pelayaran Dalam Negeri di Pelabuhan Kota Makassar Menggunakan SARIMA*, Makassar: Universitas Islam Negeri Alaudin Makassar, 2015.
- [6] A. U. Ukhra, "Pemodelan dan Peramalan Data Deret Waktu Dengan Metode Seasonal ARIMA," *Jurnal Matematika UNAND Vol.3 No.3*, pp. 59-67, 2014.
- [7] S. R. Efendi, *Analisis Peramalan Jumlah Penumpang Kereta Api Dengan Metode SARIMA*, Yogyakarta: UIN Sunan Kalijaga Yogyakarta, 2017.
- [8] M. Ilmiah, *Aplikasi Metode SARIMA dan Winter's Exponential Smoothing Untuk Meramalkan Omzet Koperasi Al-Kautsar Universitas Islam Negeri Sunan Ampel Surabaya*, Surabaya: UIN Sunan Ampel Surabaya, 2018.
- [9] H. N. Tantika, *Metode Seasonal ARIMA Untuk Meramalkan Produksi Kopi Dengan Indikator Curah Hujan Menggunakan Aplikasi R Di Kabupaten Lampung Barat*, Lampung: Universitas Lampung, 2018.
- [10] D. A. Lubis, M. B. Johra and G. Darmawan, "Peramalan Indeks Harga Konsumen Dengan Metode Singular Spectral Analysis (SSA) dan Seasonal Autoregressive Integrated Moving Average (SARIMA)," *MANTIK Vol.03 No.02*, pp. 76-82, 2017.
- [11] P. Hendikawati, *Peramalan Data Runtun Waktu Metode Dan Aplikasinya Dengan Minitab & Eviews.*, Semarang: Universitas Negeri Semarang, 2015.