

Pemodelan Arima Intervensi untuk Meramalkan Jumlah Kendaraan Masuk Melalui Tol Pasteur Tahun 2014-2023

Winda Aya Haliza*, Nusar Hajarisman

Prodi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Bandung, Indonesia.

*windaah53@gmail.com, nusarhajarisman@unisba.ac.id

Abstract. Intervention modeling analysis is a time series data analysis model used to forecast data containing interventions or unexpected events from both internal and external factors. In general, there are two types of functions in intervention analysis, namely *step* and *pulse*. During the Covid-19 pandemic, various policies implemented by the government, one of which is PPKM. Based on the time series data pattern of the number of vehicles entering through the Pasteur Toll Road, it can be seen that there was a significant decrease when the PPKM policy was implemented due to the Covid-19 pandemic. The data used in this study is data on the number of vehicles entering through the Pasteur Toll gate in the period January 1, 2014 to December 31, 2023. The purpose of this study is to assess the effect of the PPKM policy intervention due to the emergence of the Covid-19 pandemic in Indonesia on the number of vehicles entering through the Pasteur Toll Road. The results of this study indicate that the ARIMA modeling for forecasting the number of vehicles, considering the intervention, is best represented by the ARIMA (0,0,1) model with an intervention order of $(b = 1, r = 3, s = 0)$, which shows that the intervention effect occurred one period, or one month since the intervention event with a negative influence, leading to a notable decrease in the number of vehicles entering through the Pasteur Toll Road over the 2014-2023 period.

Keywords: *Forecasting, Time Series, Covid-19.*

Abstrak. Analisis pemodelan intervensi adalah suatu model analisis data deret waktu yang digunakan untuk meramalkan data yang mengandung intervensi atau kejadian yang tidak terduga baik dari faktor internal maupun eksternal. Secara umum, terdapat dua jenis fungsi pada analisis intervensi yaitu *step* dan *pulse*. Selama pandemi Covid-19, terdapat kebijakan yang diterapkan pemerintah salah satunya adalah PPKM. Berdasarkan pola data deret waktu jumlah kendaraan yang masuk melalui Tol Pasteur terlihat bahwa terdapat penurunan yang signifikan pada saat diterapkan kebijakan PPKM karena pandemi Covid-19. Data yang digunakan dalam penelitian ini adalah data jumlah kendaraan masuk melalui gerbang Tol Pasteur pada periode 1 Januari 2014 sampai dengan 31 Desember 2023. Tujuan dari penelitian ini adalah untuk melihat pengaruh intervensi adanya kebijakan PPKM karena munculnya pandemi Covid-19 di Indonesia pada jumlah kendaraan yang masuk melalui Tol Pasteur. Hasil dari penelitian ini adalah pemodelan ARIMA Intervensi untuk meramalkan jumlah kendaraan yang masuk melalui Tol Pasteur adalah model ARIMA (0,0,1) dengan orde intervensi $(b=1,r=3,s=0)$ yang menunjukkan bahwa adanya efek intervensi terjadi satu periode atau 1 bulan sejak terjadinya kejadian intervensi dengan pengaruh negatif yaitu penurunan pada jumlah kendaraan yang masuk melalui Tol Pasteur pada data tahun 2014-2023.

Kata Kunci: *Peramalan, Deret Waktu, Covid-19.*

A. Pendahuluan

Pengertian dari jalan tol menurut PP No. 15 Tahun 2005 adalah jalan umum yang merupakan bagian sistem jaringan jalan dan sebagai jalan nasional yang penggunaannya diwajibkan membayar (1). Singkatan dari tol itu sendiri adalah *tax on location* yang bisa diartikan juga dengan penggunaannya diwajibkan membayar saat menggunakan atau melintasi akses jalan tol.

Jalan tol merupakan salah satu akses yang terdampak dikarenakan pandemi *Covid-19*. Sebagaimana adanya kebijakan-kebijakan yang ditetapkan oleh pemerintah untuk membatasi aktivitas masyarakat di luar rumah sebagai upaya menekan angka kasus *Covid-19* seperti PPKM (Pemberlakuan Pembatasan Kegiatan Masyarakat) Jawa Bali, larangan pra-mudik, larangan mudik, dan larangan pasca mudik yang menyebabkan banyaknya masyarakat tidak menggunakan akses jalan tol seperti biasanya. Hal ini menyebabkan penurunan pendapatan tol yang mencapai 50% dibandingkan kondisi normal (2). Diberlakukannya kebijakan PPKM pada pertengahan bulan Maret menyebabkan menurunnya jumlah kendaraan yang masuk Tol Pasteur.

Peristiwa penurunan jumlah kendaraan yang masuk Tol Pasteur terjadi dikarenakan adanya peristiwa yang tidak terduga yang terjadi secara tiba-tiba yaitu pandemi *Covid-19*. Metode analisis yang dapat digunakan untuk mengidentifikasi peristiwa tidak terduga yang mengakibatkan penurunan jumlah kendaraan yang masuk tol pasteur adalah dengan metode intervensi (3). Model intervensi merupakan suatu model *time series* yang digunakan untuk mengeksplorasi dampak dari kejadian-kejadian di luar dugaan terhadap variabel yang menjadi objek pengamatan (4). Terdapat dua macam fungsi pada model intervensi yaitu model dengan fungsi *step* dan fungsi *pulse*. Fungsi *step* adalah model yang bersifat jangka panjang seperti kenaikan kurs *dollar*, kenaikan harga BBM, dan lain sebagainya. Sedangkan model fungsi *pulse* adalah model intervensi yang terjadi hanya dalam waktu tertentu dan bersifat sementara seperti kasus pengeboman, bencana alam, demonstrasi, dan peristiwa lainnya. Kejadian di luar dugaan seperti pandemi *Covid-19* dapat menjadi intervensi fungsi *step* dikarenakan pandemi ini terjadi pada jangka waktu yang cukup panjang (5).

Berdasarkan penjelasan uraian latar belakang, maka didapat rumusan masalah dalam penelitian ini sebagai berikut: “Bagaimana pemodelan intervensi ARIMA (*Autoregressive Integrated Moving Average*) dalam meramalkan jumlah kendaraan yang masuk tol pasteur dan bagaimana hasil peramalan data jumlah kendaraan yang masuk tol pasteur?”. Selanjutnya, tujuan dalam penelitian ini diuraikan dalam pokok-pokok berikut.

1. Untuk mengetahui pemodelan intervensi ARIMA (*Autoregressive Integrated Moving Average*) dalam meramalkan jumlah kendaraan yang masuk tol pasteur.
2. Untuk mengetahui hasil peramalan jumlah kendaraan yang masuk tol pasteur dengan menggunakan metode intervensi ARIMA (*Autoregressive Integrated Moving Average*)

B. Metodologi Penelitian

Data yang digunakan dalam penelitian ini adalah berupa data sekunder dalam bentuk bulanan yaitu data kendaraan yang masuk melalui Tol Pasteur periode waktu dari 1 Januari 2014 sampai dengan 31 Desember 2023. Data diperoleh dari PT Jasa Marga Purbaleunyi Bandung.

Data dibagi menjadi 2 bagian yaitu data sebelum intervensi pada Januari 2014 ($T=1$) sampai dengan Februari 2020 ($T=74$) serta data pada saat dan setelah terjadinya intervensi pada Maret 2020 ($T=75$) sampai dengan Desember 2023 ($T=120$). Teknik analisis data yang digunakan dalam penelitian ini adalah teknik analisis ARIMA Intervensi.

Autoregressive Integrated Moving Average (ARIMA)

Stasioneritas

Peran penting dalam analisis deret waktu yaitu terdapat pada proses dari komponennya atau beberapa di antaranya tidak berubah seiring waktu (6). Dimana suatu deret waktu dapat dikatakan stasioner apabila dalam prosesnya tidak berubah seiring waktu. Dikatakan stasioner jika memenuhi kriteria, yaitu apabila rata-rata dan ragamnya konstan seiring waktu, serta peragam antara dua data deret waktu hanya bergantung dari periode waktu (*lag*).

Apabila data yang digunakan tidak stasioner dalam rata-rata maka dapat dilakukan proses *differencing*. Stasioneritas dalam *varians* dapat dilihat dengan menggunakan

transformasi *Box-Cox* dengan melihat nilai pada lambda (λ). Berikut ini adalah beberapa nilai umum yang digunakan beserta transformasinya:

Tabel 1. Pendekatan Nilai Transformasi *Box-Cox*

Nilai lambda (λ)	-1	-0,5	0	0,5	1
Transformasi	$1/Z_t$	$1/\sqrt{Z_t}$	$\ln Z_t$	$\sqrt{Z_t}$	Z_t

Identifikasi Model ARIMA

Identifikasi model dilakukan dengan melihat *correlogram* ACF dan PACF. Model ARIMA dinotasikan dengan ARIMA (p, d, q). Terdiri dari 3 bagian atau 3 notasi pada model yaitu notasi (p) menunjukkan orde untuk proses *autoregressive* atau AR, notasi (d) menunjukkan perbedaan atau *differencing* yang dilakukan pada data untuk membuat data menjadi stasioner, dan notasi (q) menunjukkan orde untuk proses *moving average* (MA). Bentuk umum dari model ARIMA (p, d, q) adalah sebagai berikut:

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B)a_t \tag{1}$$

Berikut ini merupakan teori umum ACF dan PACF yang dapat membantu dalam menentukan model ARIMA (7).

Tabel 2. Teori Umum ACF dan PACF Model ARIMA

Order	ACF	PACF
AR (p)	Autokorelasi turun secara eksponensial mengikuti nilai lag	Terdapat lag yang <i>cut off</i> setelah lag p
MA (q)	Terdapat lag <i>cut off</i> setelah lag q	Autokorelasi turun secara eksponensial mengikuti nilai lag
ARMA(p,q)	Autokorelasi turun secara eksponensial mengikuti nilai lag	Autokorelasi turun secara eksponensial mengikuti nilai lag
AR(p) atau MA(q)	Terdapat lag <i>cut off</i> setelah lag q	Terdapat lag yang <i>cut off</i> setelah lag p

Estimasi Parameter Model ARIMA

Metode yang digunakan untuk mengestimasi parameter pada model ARIMA adalah dengan menggunakan metode *Maximum Likelihood Estimation* (MLE). Estimasi parameter menggunakan metode MLE diperoleh dengan mencari nilai-nilai parameter yang membuat fungsi kemungkinan maksimum (8). Asumsi dalam metode ini adalah nilai *error* atau residu atau *white noise* mengikuti distribusi normal $e_t \sim N(0, \sigma_e^2)$ dan *independent*. Berikut ini adalah rumusan hipotesis dari uji signifikansi parameter:

$H_0: \phi = 0$ (parameter ϕ tidak signifikan) vs $H_1: \phi \neq 0$ (parameter ϕ signifikan)

$H_0: \theta = 0$ (parameter θ tidak signifikan) vs $H_1: \theta \neq 0$ (parameter θ signifikan)

Dengan statistik uji *t* yang digunakan dalam pengujian sebagai berikut:

$$t_{hitungAR} = \frac{\hat{\phi}}{SE(\hat{\phi})} \tag{2} \quad \Bigg| \quad t_{hitungMA} = \frac{\hat{\theta}}{SE(\hat{\theta})} \tag{3}$$

Kriteria keputusan pengujian yaitu jika nilai $|t| > t_{\frac{\alpha}{2}, df}$, dengan $df = n - p$ atau jika nilai *p-value* $< \alpha$ maka H_0 ditolak maka parameter yang diestimasi signifikan kedalam model. Dengan *p* banyaknya parameter dan *n* adalah banyaknya pengamatan.

Diagnostik Model

Normalitas

Normalitas adalah uji asumsi untuk melihat apakah residu dari model berdistribusi normal. Pada penelitian ini, pengujian normalitas menggunakan uji *Kolmogorov-Smirnov*. Dengan hipotesis sebagai berikut:

$H_0: F(a_t) = F_0(a_t)$ (residu berdistribusi normal) vs $H_1: F(a_t) \neq F_0(a_t)$ (residu tidak berdistribusi normal)

Dengan statistik uji sebagai berikut:

$$D = \max|F_0(a_t) - S_n(a_t)| \quad (4)$$

Dengan kriteria keputusan yaitu jika nilai p -value $< \alpha$ atau $D_{hitung} > D_{(1-\alpha, n)}$, dengan n adalah banyaknya pengamatan dan α adalah taraf signifikansi yang berarti H_0 ditolak sehingga residu $\{e_t\}$ tidak berdistribusi normal.

Uji Non Autokorelasi Residu

White noise adalah istilah yang digunakan untuk menjelaskan bahwa suatu data memiliki residu yang bersifat *non* autokorelasi. *White noise* dinotasikan juga dengan $\{a_t\} \sim WN(0, \sigma_a^2)$. Pengujian *Ljung-Box* (LB) yang merupakan modifikasi dari statistik uji Q dapat digunakan untuk melihat apakah residu bersifat *white noise*. Dengan hipotesis uji LB sebagai berikut:

$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$ (Residu tidak berautokorelasi) vs $H_1: \exists \rho_k \neq 0, k = 1, 2, \dots, K$ (Residu berautokorelasi).

Dengan statistik uji sebagai berikut:

$$Q = n(n+2) \sum_{k=1}^K \frac{(\hat{\rho}_k)^2}{(n-k)} \quad (5)$$

Dengan kriteria keputusan yaitu jika nilai p -value $< \alpha$ atau $Q \leq X_{(\alpha, db)}^2$ maka terima H_0 sehingga residu tidak berautokorelasi atau asumsi *white noise* terpenuhi dengan derajat bebas $db = K - p - q$ dengan p adalah orde AR dan q adalah orde MA (9).

Kriteria Pemilihan Model

Pemilihan model terbaik dilakukan berdasarkan kriteria tertentu. Pada penelitian ini, kriteria yang digunakan adalah berdasarkan nilai *Root Mean Square Error* (RMSE). Berikut ini adalah rumus RMSE (10):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Z_t - f_t)^2}{n}} \quad (6)$$

Model Intervensi

Model intervensi adalah suatu model analisis data deret waktu yang banyak digunakan untuk mengeksplorasi dampak dari kejadian atau peristiwa yang terjadi di luar dugaan terhadap variabel yang menjadi objek pengamatan. Bentuk umum dari model intervensi adalah sebagai berikut (11).

$$Z_t = f(I_t) + N_t \quad (7)$$

Fungsi peubah intervensi $f(I_t)$ menjelaskan besar dan lamanya pengaruh intervensi terhadap data deret waktu. Fungsi intervensi dirumuskan sebagai berikut:

$$f(I_t) = \frac{\omega_s(B)}{\delta_r(B)} B^b I_t \quad (8)$$

Dimana:

- I_t = peubah intervensi
- ω = besarnya kenaikan atau penurunan *lag*
- δ = kerusakan akibat pengaruh intervensi
- b, r, s = orde intervensi

Secara umum, intervensi terbagi menjadi 2 jenis fungsi, yaitu fungsi *step* dan fungsi *pulse*. Fungsi *step* adalah fungsi dengan kejadian intervensi terjadi sejak waktu T dan seterusnya dalam jangka waktu yang panjang. Sedangkan fungsi *pulse* adalah fungsi dengan kejadian intervensi hanya terjadi pada waktu T saja dan tidak berlanjut pada waktu selanjutnya. Berikut ini adalah bentuk fungsi *step* dan fungsi *pulse* (9).

$$\text{Fungsi Step} \quad I_t = S_t^{(T)} = \begin{cases} 0, & t < T \\ 1, & t \geq T \end{cases} \quad (9) \quad \left| \quad \text{Fungsi Pulse} \quad I_t = P_t^{(T)} = \begin{cases} 0, & t = T \\ 1, & t \neq T \end{cases} \quad (10)$$

Dimana, t adalah periode waktu sedangkan T adalah waktu mulainya intervensi.

Dalam mengidentifikasi orde pada model intervensi diperoleh dari *plot* respons model ARIMA pada data sebelum terjadinya intervensi. Selisih antara nilai peramalan dan nilai aktual adalah kekeliruan yang dapat digunakan dalam mengidentifikasi respons pada intervensi. *Plot* respons atau residu pada pemodelan ARIMA data sebelum intervensi menggunakan taraf signifikansi 95% dimana batas atas dan batas bawahnya adalah $\pm 2\sigma$ atau ± 2 kali dari akar MSE (RMSE) dari ARIMA data sebelum intervensi. Dimana orde b dapat ditentukan dengan melihat efek atau waktu mulai terjadinya intervensi terhadap respons. Orde s ditentukan dengan melihat residu data kembali stabil dihitung dari mulainya intervensi. Sedangkan orde r ditentukan pada saat residu dari data sudah membentuk pola yang jelas. Beberapa fungsi *impulse response* sebagai berikut (9).

1. Jika $r = 0$, maka residu tidak membentuk pola gelombang sinus ataupun pola eksponensial.
2. Jika $r = 1$, maka residu akan cenderung membentuk pola eksponensial.
3. Jika $r = 2$, maka residu akan cenderung membentuk pola gelombang sinus terendam.

Estimasi Parameter Model Intervensi

Estimasi parameter model intervensi diperoleh dari bentuk umum model intervensi dan metode estimasi parameter yang digunakan adalah metode *Maximum Likelihood Estimation* (MLE). Asumsi dalam metode ini adalah nilai *error* atau residu atau *white noise* mengikuti distribusi normal $e_t \sim N(0, \sigma_e^2)$ dan *independent*.

Setelah melakukan estimasi parameter maka langkah selanjutnya adalah melakukan pengujian signifikansi untuk melihat apakah parameter yang telah diestimasi signifikan dan dapat dimasukkan ke dalam model. Berikut ini adalah rumusan hipotesis dari uji signifikansi parameter.

$H_0: \delta = 0$ (parameter δ tidak signifikan) vs $H_1: \delta \neq 0$ (parameter δ signifikan)
 $H_0: \omega = 0$ (parameter ω tidak signifikan) vs $H_1: \omega \neq 0$ (parameter ω signifikan)

Dengan statistik uji t yang digunakan dalam pengujian sebagai berikut:

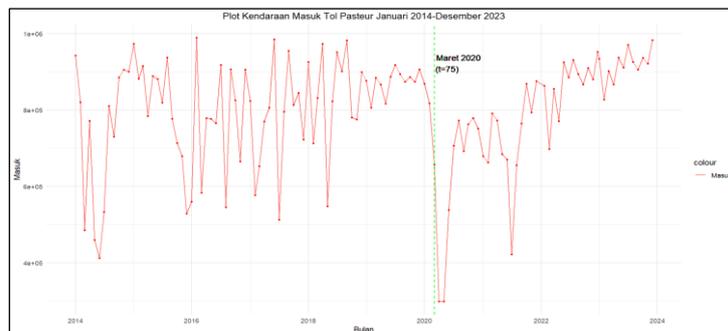
$$t_{hitung\hat{\phi}_r} = \frac{\hat{\phi}_r}{SE(\hat{\phi}_r)} \quad (11) \quad \left| \quad t_{hitung\hat{\omega}_s} = \frac{\hat{\omega}_s}{SE(\hat{\omega}_s)} \quad (12)$$

Kriteria keputusan pengujian yaitu jika nilai $|t| > t_{\frac{\alpha}{2}, df}$, dengan $df = n - p$ atau jika nilai *p-value* $< \alpha$ maka H_0 ditolak maka parameter yang diestimasi signifikan kedalam model. Dengan p banyaknya parameter dan n adalah banyaknya pengamatan.

C. Hasil Penelitian dan Pembahasan

Identifikasi Pola Data dengan *Plot Data Time Series*

Berikut adalah penelitian mengenai pemodelan dan peramalan menggunakan metode intervensi ARIMA untuk meramalkan jumlah kendaraan yang masuk tol pasteur. Berikut ini adalah *plot* data kendaraan yang masuk Tol Pasteur Januari 2014 sampai dengan Desember 2023 untuk mengidentifikasi pola data yang terlampir pada Gambar 1.



Gambar 1. Plot Data Time Series Januari 2014-Desember 2023

Berdasarkan Gambar 1 di atas, terlihat bahwa terdapat penurunan yang signifikan pada bulan Maret 2020 dikarenakan adanya peristiwa yang tidak terduga yaitu virus *Covid-19* yang pertama kali muncul dan menyebar di Indonesia. Hal ini mengindikasikan bahwa data mengandung intervensi. Berdasarkan informasi ini, dilakukan analisis intervensi pada data jumlah kendaraan yang masuk melalui Tol Pasteur ini.

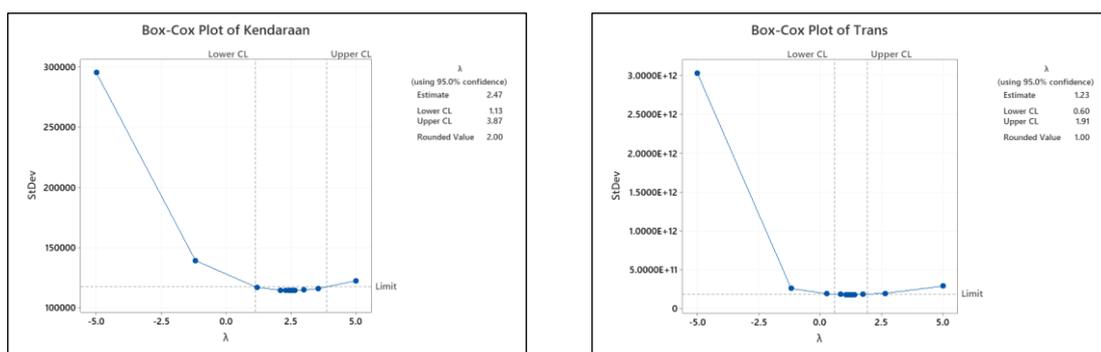
Identifikasi Model ARIMA Sebelum Intervensi
Kestasioneran Data

Syarat dalam melakukan pemodelan menggunakan analisis ARIMA adalah data harus stasioner dalam rata-rata dan *varians*. Pengecekan kestasioneran dilakukan dengan melihat pola data *time series* dan dapat dilakukan juga dengan menggunakan pengujian *Augmented Dickey Fuller* (ADF). Berikut ini adalah hasil pengujian menggunakan ADF:

Tabel 3. Uji Augmented Dickey Fuller (ADF)

<i>ADF Test</i>	$t_{0,05;n=74}$	<i>p-value</i>
-3,2444	1,665707	0,08742

Berdasarkan Tabel 3 didapat bahwa berdasarkan taraf signifikansi sebesar 5% dengan nilai *p-value* sebesar $0,08742 > \alpha = 0,05$ dan $|t_{\delta}| = 3,2444 > t_{\alpha;n} = 1,67065$ sehingga dapat disimpulkan bahwa data belum stasioner dalam rata-rata sehingga perlu dilakukan *differencing*. Berikutnya pengecekan stasioneritas berdasarkan *varians* dapat dilihat menggunakan Transformasi *Box-Cox* seperti pada Gambar 2.



Gambar 2. Tranformasi Box-Cox

Berdasarkan Gambar 2 didapat bahwa nilai *rounded value* atau nilai parameter lambda bernilai 2,00 yang artinya data belum stasioner dalam *varians* sehingga perlu dilakukan transformasi $(Z_t)^2$. Setelah dilakukan transformasi, didapat bahwa nilai parameter lambda bernilai 1,00 artinya data sebelum intervensi yang telah ditransformasi sudah stasioner dalam *varians*. Selanjutnya dilakukan proses *differencing* agar data stasioner dalam rata-rata. Berikut ini adalah hasil pengujian menggunakan *Augmented Dickey Fuller* (ADF) setelah dilakukan *differencing* atau pembedaan pada data yang telah ditransformasi sebelumnya:

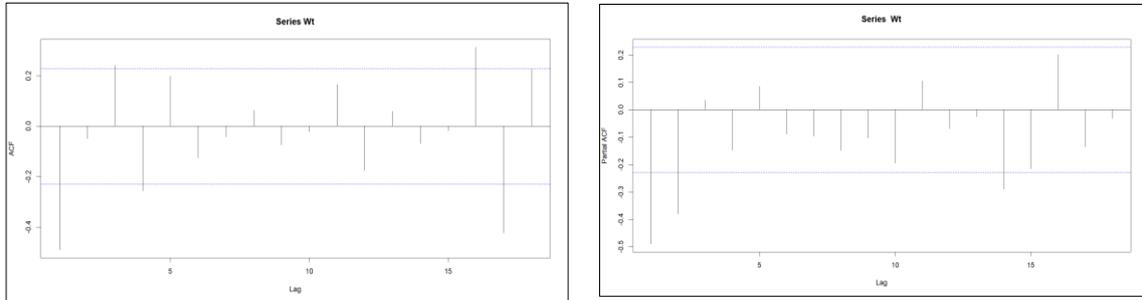
Tabel 4. Uji Augmented Dickey Fuller (ADF) Setelah Differencing

<i>Differencing</i>	<i>ADF Test</i>	$t_{0,05;n=73}$	<i>p-value</i>
<i>Pertama (d = 1)</i>	-5,245	1,665996	0,01

Berdasarkan Tabel 4 didapat bahwa berdasarkan taraf signifikansi sebesar 5% dengan nilai *p-value* setelah dilakukan *differencing* sebanyak satu kali sebesar $0,01 < \alpha = 0,05$ dan $|t_{\delta}| = 5,245 > t_{\alpha;n} = 1,665996$ sehingga dapat disimpulkan bahwa data sudah stasioner dalam rata-rata dan *varians*.

Identifikasi Model ARIMA Sebelum Intervensi

Berdasarkan tahapan stasioneritas sebelumnya didapat informasi bahwa data telah stasioner dalam *varians* dan rata-rata setelah dilakukan transformasi *Box-Cox* dan proses *differencing* sebanyak satu kali maka dapat diketahui bahwa orde *d* bernilai 1. Sehingga langkah selanjutnya adalah mengidentifikasi orde *AR(p)* dan *MA(q)* dengan melihat pola *ACF* dan *PACF* pada data yang telah dilakukan proses *differencing* sebelumnya.



Gambar 3. Plot ACF dan PACF Data Setelah Proses Differencing

Berdasarkan Gambar 3 dapat dilihat bahwa *plot ACF* menunjukkan adanya *spike yang cut off* pada *lag 1, lag 3, lag 4, lag 16, dan lag 17* sedangkan pada *plot PACF* menunjukkan adanya *spike yang cut off* pada *lag 1, lag 2, dan lag 14*. Selain itu *plot ACF* dan *PACF* tidak membentuk pola sinus maupun pola yang menurun atau menaik. Sehingga beberapa model tentatif yang terbentuk adalah *ARIMA (1,1,0)*, *ARIMA (0,1,1)*, *ARIMA (1,1,1)*, dan *ARIMA (2,1,0)*.

Estimasi Parameter Model ARIMA Sebelum Intervensi

Estimasi parameter dilakukan pada model tentatif yang terbentuk pada langkah sebelumnya dengan melakukan uji signifikansi pada setiap parameter. Berikut ini adalah hasil pengujian estimasi parameter untuk setiap kemungkinan model tentatif yang terbentuk.

Tabel 5. Uji Signifikansi Parameter Model ARIMA Sebelum Intervensi

Model	Estimate	t-value	t _{0,025,df}	p-value	Kesimpulan
ARIMA (1,1,0)	$\hat{\phi}_1 = -0,5010$	4,99	1,992997	0,0000	Signifikan
ARIMA (0,1,1)	$\hat{\theta}_1 = -0,8937$	10,13	1,992997	0,0000	Signifikan
ARIMA (1,1,1)	$\hat{\phi}_1 = 0,0842$	0,61	1,993464	0,5418	Tidak Signifikan
	$\hat{\theta}_1 = -0,9233$	13,42	1,993464	0,0000	Signifikan
ARIMA (2,1,0)	$\hat{\phi}_1 = -0,7370$	6,84	1,993464	0,0000	Signifikan
	$\hat{\phi}_2 = -0,4419$	4,08	1,993464	0,000045	Signifikan

Berdasarkan taraf signifikansi sebesar 5%, nilai estimasi parameter yang signifikan untuk seluruh parameter adalah model *ARIMA (1,1,0)*, *ARIMA (0,1,1)*, *ARIMA (2,1,0)*.

Diagnostik Model ARIMA Sebelum Intervensi

Uji Normalitas dan Non-Autokorelasi Residu

Berikut ini adalah hasil pengujian normalitas menggunakan uji *Kolmogorov-Smirnov* dan pengujian *white noise* menggunakan uji *Ljung-Box* pada model *ARIMA*:

Tabel 6. Hasil Pengujian Normalitas dan Non-Autokorelasi Residu ARIMA Sebelum Intervensi

	Model	p-value	KS hitung	KS tabel	Kesimpulan
Normalitas	ARIMA (0,1,1)	0,3756	0,10389	0,157	Normal
	ARIMA (1,1,0)	0,9226	0,061894	0,157	Normal

	ARIMA (2,1,0)	0,9072	0,063576	0,157	Normal
Non-Autokorelasi Residu	ARIMA (0,1,1)	0,5592	0,34118	3,8415	Tidak Berautokorelasi
	ARIMA (1,1,0)	0,07047	3,272	3,8415	Tidak Berautokorelasi
	ARIMA (2,1,0)	0,7959	0,06692	3,8415	Tidak Berautokorelasi

Berdasarkan taraf signifikansi sebesar 5% bahwa residu pada ketiga model ARIMA tersebut berdistribusi normal dan tidak berautokorelasi dan memenuhi asumsi *white noise*..

Pemilihan Model ARIMA Sebelum Intervensi Terbaik

Berikut ini adalah nilai RMSE pada model ARIMA (1,1,0), ARIMA (0,1,1), dan ARIMA (2,1,0):

Tabel 7. Kriteria Pemilihan Model ARIMA Terbaik

Model	RMSE
ARIMA (0,1,1)	450788,4
ARIMA (1,1,0)	477633,1
ARIMA (2,1,0)	453368,2

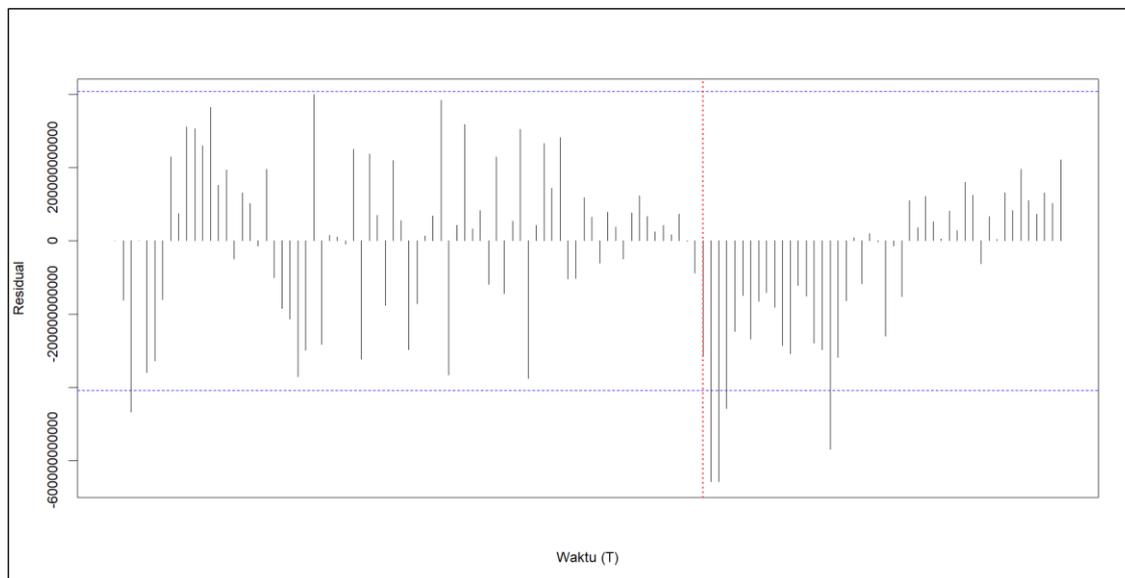
Berdasarkan Tabel 7 dapat dilihat bahwa nilai RMSE terkecil adalah pada model ARIMA (0,1,1) sehingga model ARIMA yang terbentuk adalah model dengan persamaan sebagai berikut:

$$\begin{aligned}
 Z_t - Z_{t-1} &= a_t - \theta_1 a_{t-1} \\
 Z_t - Z_{t-1} &= a_t - (-0,8937)a_{t-1} \\
 Z_t &= Z_{t-1} + a_t + 0,8937a_{t-1}
 \end{aligned}
 \tag{13}$$

Identifikasi Model Intervensi Akibat Pandemi Covid-19

Identifikasi Orde Model Intervensi

Identifikasi orde dari b, s, dan r dari model intervensi dilakukan dengan mengamati pola pada *plot* residu respons intervensi. *Plot* ini menampilkan nilai residu pada model ARIMA (0,1,1). Berikut ini adalah *plot* residu respons yang ditunjukkan pada Gambar 4.



Gambar 4. Plot Residu Respons Intervensi

Berdasarkan Gambar 4, dapat dilihat bahwa pada saat T+1 terlihat bahwa garis keluar

dari batas bawah dimana artinya orde $b=1$. Terlihat juga pada pola tidak membentuk pola gelombang sinus ataupun eksponensial sehingga diduga orde $r=0$. Selanjutnya identifikasi orde s dilihat dari garis yang keluar dari batas signifikansi dimana banyaknya garis yang keluar dari batas adalah 4 sehingga diperoleh dugaan orde $s=4$. Sehingga diperlukan proses *trial* sebanyak 4 kali untuk mendapatkan model yang paling baik digunakan dalam analisis intervensi.

Estimasi Parameter Model Intervensi

Pada tahapan sebelumnya dilakukan *trial* orde intervensi sebanyak 4 kali. Berikut ini adalah hasil pengujian parameter untuk 4 model yang dilakukan.

Tabel 8. Uji Signifikansi Parameter Model Intervensi

<i>Model</i>	<i>Estimate</i>	<i> t-value </i>	<i> t_{0,025;df} </i>	<i>p-value</i>	<i>Kesimpulan</i>
$b=1, s=1, r=0$	$\hat{\omega}_0 = -754665,49$ $\hat{\omega}_1 = -521430,72$	3,03 1,51	1,9802	0,0025 0,1320	Tidak Signifikan
$b=1, s=2, r=0$	$\hat{\omega}_0 = -763472,33$ $\hat{\omega}_2 = -622141,46$	5,23 3,96	1,9802	<0,0001 <0,0001	Signifikan
$b=1, s=3, r=0$	$\hat{\omega}_0 = -716644,96$ $\hat{\omega}_3 = -608194,05$	4,61 3,65	1,9802	<0,0001 0,0003	Signifikan
$b=1, s=4, r=0$	$\hat{\omega}_0 = -676653,53$ $\hat{\omega}_4 = -533029,08$	4,35 2,93	1,9802	<0,0001 0,0034	Signifikan

Berdasarkan taraf signifikansi sebesar 5%, nilai estimasi parameter yang signifikan untuk seluruh parameter adalah model dengan orde intervensi $s=1, 2$, dan 3 . Untuk melihat model yang paling baik digunakan maka perlu dilakukan diagnostik pada ketiga model tersebut.

Diagnostik Model Intervensi

Uji Normalitas dan Non-Autokorelasi Residu

Berikut ini adalah hasil pengujian normalitas menggunakan uji *Kolmogorov-Smirnov* dan pengujian *white noise* menggunakan uji *Ljung-Box* pada model Intervensi:

Tabel 9. Hasil Pengujian Normalitas dan Non-Autokorelasi Residu Model Intervensi

	<i>Model</i>	<i>p-value</i>	<i>KS hitung</i>	<i>KS tabel</i>	<i>Kesimpulan</i>
<i>Normalitas</i>	$b=1, s=2, r=0$	<0,0100	0,112462	0,12644	Tidak Normal
	$b=1, s=3, r=0$	0,0769	0,079133	0,12644	Normal
	$b=1, s=4, r=0$	<0,0100	0,096853	0,12644	Tidak Normal
<i>Non-Autokorelasi Residu</i>	$b=1, s=2, r=0$	0,9156	0,011232	3,8415	Tidak Berautokorelasi
	$b=1, s=3, r=0$	0,6985	0,15002	3,8415	Tidak Berautokorelasi
	$b=1, s=4, r=0$	0,8287	0,046832	3,8415	Tidak Berautokorelasi

Berdasarkan taraf signifikansi sebesar 5% bahwa hanya model intervensi dengan orde $b=1, s=3, r=0$ yang memiliki residu berdistribusi normal. Selain itu, ketiga model intervensi tidak berautokorelasi dan memenuhi asumsi *white noise*. Sehingga model intervensi yang terbentuk dan memenuhi asumsi adalah model intervensi dengan orde $b=1, s=3, r=0$.

Pemilihan Model Terbaik

Berikut ini adalah nilai RMSE pada model ARIMA dan model intervensi yang terbentuk.

Tabel 10. Kriteria Pemilihan Model Terbaik

<i>Model</i>	<i>RMSE</i>
<i>ARIMA (0,1,1)</i>	450.788,4

<i>ARIMA (0,1,1) b=1, s=3, r=0</i>	425.851,9
------------------------------------	-----------

Berdasarkan Tabel 10 dapat dilihat bahwa nilai RMSE terkecil adalah pada model Intervensi ARIMA (0,1,1) b=1, s=3, r=0 sehingga model intervensi yang terbentuk adalah model dengan persamaan sebagai berikut:

$$\begin{aligned} \hat{Z}_t &= f(I_t) + N_t \\ \hat{Z}_t &= (\omega_0 - \omega_3 B)BS_t^{(75)} + N_t \\ \hat{Z}_t &= \omega_0 BS_t^{(75)} - \omega_3 B^2 S_t^{(75)} + N_t \\ \hat{Z}_t &= \omega_0 BS_t^{(75)} - \omega_3 B^2 S_t^{(75)} + (Z_{t-1} + a_t - 0,72642a_{t-1}) \\ \hat{Z}_t &= -716.644,96S_{t-1} + 608.194,05S_{t-2} + Z_{t-1} + a_t - 0,72642a_{t-1} \end{aligned} \tag{14}$$

dengan,

$$I_t = S_t^{(75)} = \begin{cases} 0, & t < 75 \\ 1, & t \geq 75 \end{cases}$$

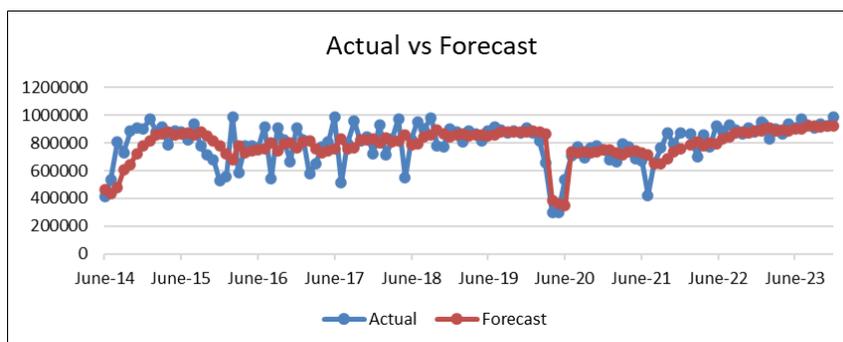
Hasil Peramalan Model Intervensi ARIMA

Berikut ini adalah hasil peramalan kendaraan yang masuk melalui Tol Pasteur melalui model intervensi ARIMA (0,1,1) b=1, s=3, r=0:

Tabel 11. Hasil Peramalan Jumlah Kendaraan yang Masuk Tol Pasteur Januari 2024-Juni 2024

<i>Bulan</i>	<i>Peramalan</i>
<i>Januari-24</i>	940.109
<i>Februari-24</i>	940.103
<i>Maret-24</i>	940.100
<i>April-24</i>	940.097
<i>Mei-24</i>	940.095
<i>Juni-24</i>	940.094

Berikut ini adalah *plot* perbandingan antara nilai ramalan dan nilai aktual dari data jumlah kendaraan yang masuk melalui Tol Pasteur pada Gambar 5.



Gambar 5. Plot Hasil Peramalan vs Aktual

D. Kesimpulan

Berdasarkan pembahasan dalam penelitian ini, peneliti menyimpulkan beberapa hasil penelitian sebagai berikut:

1. Model terbaik analisis intervensi ARIMA menggunakan fungsi *step* untuk meramalkan jumlah kendaraan yang masuk tol pasteur adalah model ARIMA (0,0,1) dengan orde intervensi (b=1, s=3, r=0). Dengan persamaan model sebagai berikut:

$$\hat{Z}_t = -716.644,96S_{t-1} + 608.194,05S_{t-2} + Z_{t-1} + a_t - 0,72642a_{t-1}$$

dengan,

$$I_t = S_t^{(75)} = \begin{cases} 0, & t < 75 \\ 1, & t \geq 75 \end{cases}$$

2. Efek dari intervensi terjadi satu periode setelah kejadian intervensi yaitu pada bulan April 2020. Intervensi ini menyebabkan perubahan secara perlahan. Selain itu, diperlukan waktu selama 3 bulan agar kondisi kembali stabil. Pengaruh dari intervensi menyebabkan pengaruh negatif penurunan sebesar 608.194 jumlah kendaraan yang masuk melalui Tol Pasteur.
3. Hasil peramalan jumlah kendaraan yang masuk melalui tol pasteur memiliki nilai *error* yang diukur dengan ukuran RMSE sebesar 425.851,9.

Acknowledge

Penulis mengucapkan terima kasih kepada Bapak Nusar Hajarisman, S.Si., M.Si., selaku dosen pembimbing atas saran dan bimbingannya selama ini. Penulis juga mengucapkan terima kasih kepada keluarga dan teman seperjuangan yang telah memberikan dukungan dan dorongannya.

Daftar Pustaka

- [1] Republik Indonesia PP. Peraturan Pemerintah Republik Indonesia PP No. 15 Tahun 2005 tentang Jalan Tol. Deputi Sekretaris Kabinet Bidang Hukum dan Perundang-Undangan. Jakarta; 2005. 1–23 p.
- [2] Wibowo GS. Jalan Tol Sepi Selama Pandemi, Pendapatan Anjlok Sampai 50 Persen, Pengusaha Minta Stimulus dari Pemerintah. *gridoto.com*. 2020;
- [3] Darwis S, Hajarisman N, Suliadi, Widodo A, Diahsty Marasabessy M, Arya Ramadhan I. Monte Carlo Based Sampling Distribution of Annual Rate of Exceedance for Earthquake Insurance. *Statistika* [Internet]. 2024 May 29;24(1):40–6. Available from: <https://journals.unisba.ac.id/index.php/statistika/article/view/3173>
- [4] Sitepu E, Juliana Tampubolon, Sudianto Manulang, Sisti Nadia Amalia. Analisis Faktor-Faktor yang Berhubungan dengan Kejadian Stres Pada Mahasiswa Tingkat Akhir S1 Matematika di Universitas Negeri Medan. *Statistika* [Internet]. 2024 May 29;24(1):93–101. Available from: <https://journals.unisba.ac.id/index.php/statistika/article/view/3257>
- [5] Irfan Rizki M, Yenny Maya Dora, Wahidiyat Suyudi, Yanthy Mardiana. Forecasting Spare Part pada Commercial Vehicle PT XYZ dengan Klasifikasi ADI-CV. *Statistika* [Internet]. 2024 May 29;24(1):75–82. Available from: <https://journals.unisba.ac.id/index.php/statistika/article/view/3546>
- [6] Brockwell PJ, Davis RA. *Introduction to Time Series and Forecasting Second Edition*. Second. New York: Springer; 2002.
- [7] Chernick M, Bowerman BL, O’Connell RT. *Forecasting and Time Series: An Applied Approach*. 3 rd. Vol. 48, *The American Statistician*. California: Duxbury Press; 1994. 347 p.
- [8] Box GEP, Jenkins GM, Reinsel GC, Ljung GM. *Time Series Analysis: Forecasting and Control*, 5th Edition. Canada: John Wiley and Sons, Inc; 2015.
- [9] Wei WW. S. *Time Series Analysis : Univariate and Multivariate Methods (2nd Edition)*. New York: Pearson Addison Wesley; 2006.
- [10] Montgomery DC, Jennings CL, Kulahci M. *Introduction To Time Series Analysis And Forecasting*. New Jersey: John Wiley & Sons; 2016.
- [11] DeLurgio SA. *Forecasting principles and applications*. New York: McGrawHill; 1998. 802 p.