

Pemodelan Pengajuan Klaim Asuransi Sosial Kecelakaan Lalu Lintas Menggunakan Metode ARIMA

Khoirun Nisak Syifana¹, Ade Ima Afifa Himayati², Ivanna Isty Nursani³

^{1,2,3}Program Studi Matematika, FST, Universitas Muhammadiyah Kudus, Kudus-Indonesia 59316
Email: ¹42022130007@std.umku.ac.id, ²adeimaafifa@umkudus.ac.id, ³ivannaisty@umkudus.ac.id

ABSTRAK

Salah satu dampak dari meningkatnya angka kecelakaan lalu lintas adalah peningkatan beban klaim asuransi pada perusahaan asuransi khususnya asuransi sosial kecelakaan lalu lintas. Fluktuasi yang tidak terduga pada jumlah klaim menimbulkan tantangan bagi perusahaan, sehingga diperlukan prediksi untuk mengetahui kecenderungan jumlah klaim periode mendatang. Data jumlah pengajuan klaim tercatat secara periodik sehingga membentuk data *time series* (deret waktu). Hal ini memungkinkan penerapan analisis deret waktu seperti metode *Autoregressive Integrated Moving Average* (ARIMA). Penelitian ini bertujuan untuk memodelkan serta memprediksi jumlah pengajuan klaim asuransi sosial kecelakaan lalu lintas menggunakan metode ARIMA. Penelitian ini memanfaatkan data rekapitulasi pengajuan klaim asuransi sosial kecelakaan lalu lintas sebanyak 120 minggu dari Juli 2023 – Desember 2025. Analisis data dilakukan menggunakan metode ARIMA hingga menghasilkan model ARIMA (p, d, q) yang optimal untuk memodelkan data. Setelah melakukan serangkaian analisis, model ARIMA (3,1,0) terpilih sebagai model prediksi yang paling optimal dengan tingkat akurasi *Mean Squared Error* (MSE) sebesar 150,054 dan *Mean Absolute Percentage Error* (MAPE) sebesar 10,53%. Hasil ramalan menunjukkan jumlah pengajuan klaim asuransi sosial kecelakaan lalu lintas pada 20 minggu ke depan cenderung stabil. Kondisi tersebut memperlihatkan bahwa tidak terjadi peningkatan maupun penurunan yang signifikan pada jumlah pengajuan klaim asuransi selama periode peramalan.

Kata kunci: ARIMA, Klaim Asuransi, Deret Waktu, Kecelakaan Lalu lintas.

ABSTRACT

One consequence of the rising number of traffic accidents is the increase in the burden of insurance claims on insurance companies, especially social insurance for traffic accidents. Unexpected fluctuations in claim numbers create challenges for companies, so forecasting is needed to identify future trends in claim numbers. The number of claims submitted is recorded periodically, thereby forming time series data. This allows for the application of time series analysis, such as the Autoregressive Integrated Moving Average (ARIMA) method. This study aims to model and forecast the number of traffic accident social insurance claims using the ARIMA method. This study utilizes recapitulation data on traffic accident social insurance claim submissions spanning 120 weeks from July 2023 – December 2025. The ARIMA method is employed to identify the optimal ARIMA (p, d, q) model for the data. Analysis results indicate that ARIMA (3,1,0) is the optimal model, with a Mean Squared Error (MSE) of 150,054 and a Mean Absolute Percentage Error (MAPE) of 10,53%. Forecasting results for the next 20 weeks reveals a stable trend in claims. This suggests that there is no significant increase or decrease in insurance claims during the forecast period.

Keywords: ARIMA, Insurance Claims, Time Series, Traffic Accidents

A. Pendahuluan

Kecelakaan lalu lintas menjadi salah satu masalah utama dalam sektor transportasi darat, laut, maupun udara yang berdampak besar terhadap tingkat keselamatan masyarakat dan kondisi perekonomian (Amerta & Safitri, 2025). Mengacu pada data yang dipublikasikan oleh *World Health Organization* (WHO) kecelakaan

lalu lintas secara global menjadi faktor dominan penyebab kematian dan cedera (WHO, 2023). Badan Pusat Statistik (BPS), mencatat bahwa pada tahun 2024 terdapat 150.906 kasus kecelakaan lalu lintas, yang menyebabkan 26.839 korban meninggal dunia, 16.601 korban mengalami luka berat, serta 183.995 korban mengalami luka ringan (BPS, 2025). Angka ini

memperlihatkan bahwa masalah keselamatan transportasi merupakan permasalahan yang cukup serius yang perlu diperhatikan.

Selain menimbulkan korban jiwa, kecelakaan lalu lintas juga berimbas pada kerugian materi. Pada tahun 2018, kerugian yang ditimbulkan oleh kecelakaan lalu lintas di Indonesia mencapai 2,9% – 3,1% dari total PDB nasional, dengan nilai sekitar Rp 430 – 460 triliun (FLLAJ Jateng, 2023). Sebagai upaya perlindungan terhadap risiko tersebut, pemerintah menyelenggarakan program asuransi sosial guna membantu meringankan beban para korban. Salah satu program asuransi sosial di Indonesia adalah asuransi kecelakaan lalu lintas. Program dimaksudkan untuk melindungi korban kecelakaan lalu lintas. Bentuk perlindungan tersebut mencakup penjaminan biaya perawatan korban dan apabila korban meninggal dunia maka ahli waris berhak menerima santunan (Nurhakim et al., 2024). Kasus kecelakaan lalu lintas yang meningkat tentunya berdampak pada meningkatnya jumlah klaim yang diajukan kepada perusahaan asuransi. Situasi tersebut menggambarkan antara meningkatnya kecelakaan dan jumlah klaim saling berkaitan (Susanti et al., 2024). Fluktuasi jumlah klaim yang tidak terduga menimbulkan tantangan tersendiri bagi perusahaan. Prediksi klaim menjadi penting bagi perusahaan untuk membantu dalam operasionalnya.

Data klaim yang tercatat secara berkala dapat dimanfaatkan sebagai sumber data dalam penelitian, seperti untuk menganalisis pola, tren, maupun perkembangan jumlah klaim. Data tersebut dapat menjadi landasan untuk keperluan pemodelan hingga peramalan. Analisis dan peramalan data klaim dapat dilakukan menggunakan berbagai metode, salah satunya menggunakan analisis deret waktu (*time series analysis*). Analisis deret waktu merupakan pendekatan statistik yang dapat diterapkan untuk mengidentifikasi pola dan karakteristik data yang tersusun dalam interval waktu tertentu (Gempati et al., 2025). Analisis deret waktu bermanfaat untuk data yang perubahannya dipengaruhi oleh waktu atau observasi sebelumnya. Analisis deret waktu telah diterapkan secara luas pada berbagai sektor seperti ekonomi, kesehatan, keuangan, transportasi, dan sebagainya.

Metode *Autoregressive Integrated Moving Average* (ARIMA) merupakan salah satu metode yang terdapat dalam ranah analisis

deret waktu yang mampu memodelkan serta memprediksi data deret waktu. Metode ARIMA pertama kali diperkenalkan oleh George Box dan Gwilym Jenkins pada tahun 1970 melalui pendekatan yang dikenal sebagai ARIMA Box-Jenkins (Nahuway et al., 2025). Metode ini banyak digunakan untuk peramalan jangka pendek karena kemampuannya menghasilkan prediksi dengan tingkat akurasi yang tinggi melalui pembentukan hubungan statistik antara nilai historis dan nilai prediksi. Pada penelitian Issan et al. (2025), metode ARIMA diterapkan untuk meramalkan jumlah klaim asuransi Tabungan Hari Tua di PT ASABRI (Persero) Cabang Makassar dengan hasil tingkat akurasi cukup baik. Penelitian lain oleh Brotosaputro et al. (2025) menerapkan metode ARIMA untuk memprediksi dana cadangan klaim asuransi dan menghasilkan prediksi dengan tingkat ketepatan mencapai 97%. Selain itu, penelitian yang dilakukan Cahyani (2023) untuk meramalkan jumlah klaim asuransi kecelakaan di PT Jasa Raharja Perwakilan Malang memanfaatkan metode ARIMA, dan mampu menghasilkan prediksi jumlah klaim untuk 5 hari berikutnya.

Berdasarkan pemaparan latar belakang yang telah dijabarkan, penelitian ini dilaksanakan dengan maksud menghasilkan model prediksi pengajuan klaim asuransi sosial kecelakaan lalu lintas dengan menggunakan metode ARIMA. Metode ARIMA dipilih karena memiliki kesesuaian dengan karakteristik data klaim yang telah teridentifikasi. Data pengajuan klaim asuransi sosial kecelakaan lalu lintas yang bersifat non-stasioner namun tidak memiliki pola musiman yang signifikan, ARIMA dianggap sebagai model yang efisien dan relevan dibandingkan model lain yang lebih kompleks. Pengukuran tingkat akurasi dilakukan menggunakan *Mean Squared Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE) sebagai indikator evaluasi dalam penelitian ini. Model yang paling optimal dipilih berdasarkan hasil MSE dan MAPE yang paling kecil, karena menunjukkan tingkat kesalahan paling minimal (Rosita et al., 2024). Dengan penerapan metode ARIMA serta evaluasi menggunakan MSE dan MAPE, penelitian ini diharapkan menghasilkan model prediksi pengajuan klaim asuransi kecelakaan lalu lintas yang akurat dan dapat mendukung perusahaan asuransi dalam mengelola dana santunan dan manajemen risiko yang baik.

B. Metode Penelitian

Penelitian ini menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) dengan tujuan menghasilkan model dan peramalan pengajuan klaim asuransi sosial kecelakaan lalu lintas. Dalam metode ARIMA, model dituliskan sebagai ARIMA (p, d, q) yang terdiri atas parameter p , d , dan q sebagai penentu struktur model yang digunakan dalam peramalan (Mawaddah, 2023). Model ARIMA terbentuk dari komponen *Autoregressive* (AR), *Integrated* (I) dan *Moving Average* (MA). Dalam notasi ARIMA (p, d, q), p menyatakan orde AR, d menyatakan jumlah *differencing*, sedangkan q menyatakan orde MA (Shahriari et al., 2025). Persamaan model ARIMA dituliskan sebagai berikut:

$$\Phi_p(B)X_t^* = C + \theta_q(B)e_t \quad (1)$$

Dengan

$$X_t^* = (1 - B)^d X_t \quad (1.1)$$

$$\Phi_p(B) = 1 - \Phi_1 B - \dots - \Phi_p B^p \quad (1.2)$$

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q \quad (1.3)$$

Keterangan

X_t^* : data setelah *differencing*

X_t : data pada periode ke- t

B : operator *backshift*

Φ_p : parameter AR orde ke- p

θ_q : parameter MA orde ke- q

1. Uji Stasioneritas Data

Dalam model ARIMA data diasumsikan bersifat stasioner, baik terhadap ragam maupun terhadap rata-rata. Untuk menguji kestasioneran ragam digunakan pendekatan *Box-Cox*. Nilai *rounded value* (λ) = 1,00 pada plot *Box-Cox* menunjukkan kondisi data sudah stasioner terhadap ragam (Mawaddah, 2023). Data yang belum memenuhi kondisi kestasioneran ragam, maka dilakukan transformasi *Box-Cox* hingga mencapai kondisi stasioner. Sementara itu, untuk pengujian kestasioneran rata-rata dilakukan dengan menganalisis *trend analysis plot* dan uji *Augmented Dickey-Fuller* (ADF). Apabila data belum mencapai kriteria stasioner terhadap rata-rata, maka proses *differencing* (pembedaan) diterapkan sampai mencapai kondisi stasioner. Persamaan *differencing* orde pertama, dituliskan sebagai:

$$X' = X_t - X_{t-1} \quad (2)$$

Keterangan:

X' : *differencing* orde pertama

X_t : data pada periode ke t

X_{t-1} : data pada periode ke ($t - 1$)

2. Identifikasi Model

Data yang telah memenuhi asumsi stasioneritas, selanjutnya dianalisis pada tahap identifikasi model untuk menentukan orde p , d , dan q . Orde p adalah *lag* dari variabel dependen sedangkan orde q merupakan *lag* residual (Gempati et al., 2025). Penentuan orde p dan q dilakukan melalui pengamatan pola yang muncul pada grafik *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Sementara itu, orde d menyatakan banyaknya proses *differencing* yang dilakukan (Cahyani, 2023).

3. Estimasi Parameter

Pada tahap identifikasi telah dihasilkan beberapa kemungkinan model-model ARIMA. Selanjutnya dilakukan estimasi terhadap setiap parameter model tersebut. Hasil estimasi parameter dari setiap model akan di uji signifikansinya dengan rumusan hipotesis sebagai berikut:

H_0 : Parameter = 0 (tidak signifikan)

H_1 : Parameter \neq 0 (Signifikan)

Perhitungan statistik uji t dinyatakan dalam bentuk persamaan berikut:

$$t = \frac{\hat{\beta}}{SE(\hat{\beta})} \quad (3)$$

Keterangan:

t : nilai t hitung.

$\hat{\beta}$: nilai estimasi parameter.

$SE(\hat{\beta})$: standar deviasi parameter.

Kriteria pengujian yang digunakan adalah menolak H_0 jika $|t_{hitung}| > t_{\frac{\alpha}{2}, (n-1)}$ atau ketika $p\text{-value} > 0,05$.

4. Diagnostic Checking

Model yang telah memenuhi uji signifikansi, selanjutnya dilakukan *diagnostic checking*. Tahap ini dilakukan melalui analisis residual yang meliputi uji *white noise* dan uji normalitas residual. Uji *white noise* dilakukan dengan menerapkan uji *Ljung-Box* (Lestari et al., 2022). Hipotesis uji *Ljung-Box* sebagai berikut:

H_0 : $\rho_1 = \rho_2 = \dots = \rho_k = 0$ (residual *white noise*).

H_1 : terdapat minimal satu $\rho_i \neq 0$, untuk $i = 1, 2, \dots, k$ (residual tidak *white noise*).

Persamaan uji *Ljung-Box* sebagai berikut:

$$Q^* = n(n + 2) \sum_{k=1}^k \frac{r_k^2}{n - k} \quad (4)$$

Keterangan

Q^* : statistik uji *Ljung-Box*.

r_k : nilai autokorelasi residual lag ke- k .

n : banyak data.

k : lag yang digunakan dalam pengujian.

Dengan ketentuan kriteria keputusan menolak H_0 jika $Q^* > X_{\alpha, df=k-m}^2$ atau ketika p -value $< \alpha$, dengan nilai $\alpha = 0,05$. Nilai m merupakan penjumlahan orde AR (p) dan MA (q), yaitu $m = p + q$.

Untuk uji normalitas residual dilakukan dengan uji *Kolmogorov Smirnov* (Mawaddah, 2023). uji *Kolmogorov Smirnov* dilakukan dengan rumusan hipotesis sebagai berikut:

H_0 : residual berdistribusi normal

H_1 : residual berdistribusi tidak normal

Dengan kriteria keputusan yang ditetapkan yaitu H_0 ditolak jika p -value $< \alpha$, di mana taraf signifikansi $\alpha = 0,05$.

5. Peramalan

Pada tahap ini model yang telah lolos identifikasi, uji signifikansi parameter, dan *diagnostic checking* selanjutnya digunakan untuk meramalkan nilai data pada periode mendatang.

6. Evaluasi Akurasi Model

Evaluasi akurasi model dilakukan untuk mengukur selisih atau kesesuaian antara data hasil peramalan dengan data aktual. Dalam penelitian ini tingkat akurasi model diukur menggunakan dua indikator evaluasi. Indikator pertama adalah *Mean Squared Error* (MSE) yang berfungsi untuk mengukur rata-rata kesalahan kuadrat. Secara umum rumus MSE sebagai berikut:

$$MSE = \frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2 \quad (5)$$

Keterangan:

A_t : nilai aktual

F_t : nilai prediksi

n : banyak data

Nilai MSE menunjukkan seberapa besar kesalahan prediksi yang dihasilkan oleh model, dengan ketentuan model yang optimal adalah model dengan nilai MSE terkecil (Cahyani, 2023). Indikator evaluasi yang kedua adalah *Mean Absolut Percentage Error* (MAPE) yang mengukur rata-rata persentase kesalahan

absolut. Untuk nilai MAPE dapat dihitung menggunakan rumus sebagai:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \left(\frac{A_t - F_t}{A_t} \right) 100 \right| \quad (6)$$

Keterangan:

A_t : nilai aktual

F_t : nilai prediksi

n : banyak data

Kriteria akurasi prediksi dengan MAPE dikategorikan pada tabel di bawah ini.

Tabel 1. Kriteria Akurasi MAPE


Nilai MAPE	Akurasi Prediksi
$\leq 10\%$	Tinggi
$10\% - 20\%$	Baik
$20\% - 50\%$	Sedang
$> 50\%$	Rendah

C. Hasil dan Pembahasan

1. Data Penelitian

Penelitian ini memanfaatkan data rekapitulasi jumlah pengajuan klaim asuransi sosial kecelakaan lalu lintas di wilayah Karesidenan Pati. Data tersusun dalam interval mingguan sebanyak 120 data dari Juli 2023 – Desember 2025. Data di analisis dengan menerapkan metode ARIMA serta memanfaatkan aplikasi perangkat lunak statistik Minitab.

Setelah data diperoleh, selanjutnya yaitu membuat visualisasi plot deret waktu



untuk mengamati pola fluktuasi pada data tersebut.

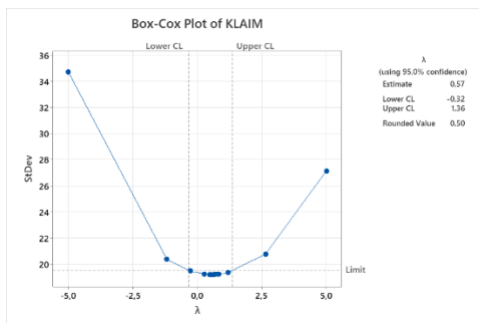
Gambar 1. Plot Deret Waktu Data Jumlah Pengajuan Klaim

Sebagaimana disajikan pada gambar 1 di atas dapat dilihat bahwa jumlah pengajuan klaim asuransi sosial kecelakaan lalu lintas mengalami naik turun yang bervariasi setiap minggunya.

Namun demikian, naik turunnya data tidak terjadi pada waktu yang sama atau adanya pola berulang, sehingga dapat dikatakan bahwa tidak ada unsur musiman pada plot data tersebut.

2. Uji Stasioneritas Data

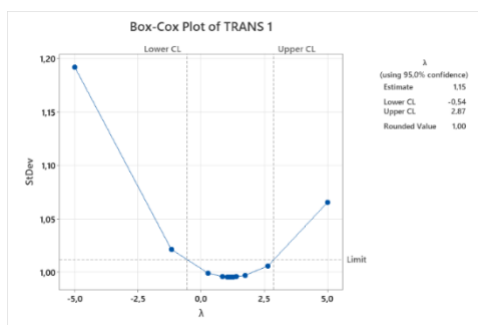
Setelah mengetahui plot data dan memastikan bahwa tidak ada unsur musiman pada data, selanjutnya yaitu melakukan uji kestasioneran data. Pengujian kestasioneran yang dilakukan meliputi uji kestasioneran ragam dan uji kestasioneran rata-rata. Untuk uji kestasioneran ragam dilakukan menggunakan



pendekatan *Box-Cox*.

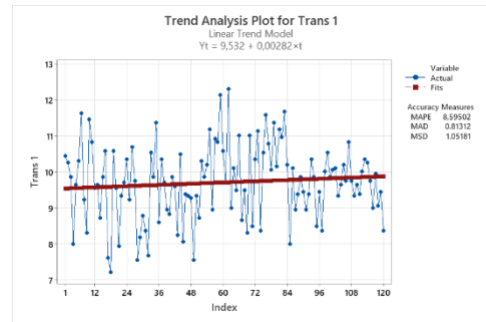
Gambar 2. *Output Box-Cox* Data Jumlah Pengajuan Klaim.

Hasil pengujian *Box-Cox* pada gambar 2 diperoleh nilai *rounded value* (λ) = 0,50. Nilai ini kurang dari 1,00 yang menandakan bahwa kondisi data belum stasioner terhadap ragam. Oleh karena itu, data kemudian di transformasi untuk mencapai kondisi stasioner.



Gambar 3. *Output Box-Cox* Data Transformasi.

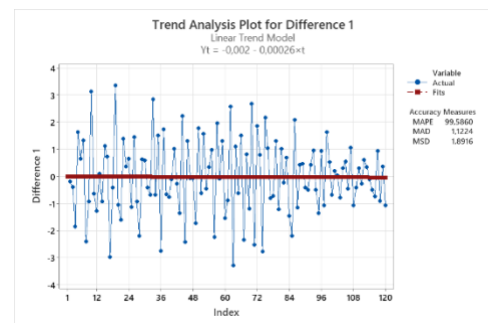
Berdasarkan hasil pada gambar 3 diperoleh nilai *rounded value* (λ) = 1,00 yang menunjukkan data yang telah di transformasi sudah mencapai kondisi stasioner terhadap ragam. Berikutnya adalah pengujian kestasioneran rata-rata. pengujian kestasioneran rata-rata dilakukan dengan



menganalisis *trend analysis plot* dan uji *Augmented Dickey-Fuller* (ADF).

Gambar 4. Grafik *Trend Analysis* Data Transformasi.

Dari gambar 4 di atas terlihat garis tren atau garis merah pada grafik semakin ke atas yang menunjukkan bahwa rata-rata tidak konstan. Karena nilai rata-rata tidak konstan, maka data belum memenuhi asumsi kestasioneran rata-rata sehingga perlu dilakukan *differencing*. Setelah dilakukan *differencing* orde pertama, data diplotkan kembali untuk melihat tren analisisnya.



Gambar 5. Grafik *Trend Analysis* Data *Differencing*.

Hasil plot tren analisis setelah dilakukan proses *differencing* terlihat garis tren mendatar yang artinya nilai rata-rata pada data tersebut sudah konstan. Kondisi tersebut menandakan data telah memenuhi kriteria kestasioneran rata-rata. Guna memastikan kestasioneran data, maka dilakukan pengujian dengan *Augmented Dickey-Fuller* (ADF).

Augmented Dickey-Fuller Test

Null hypothesis: Data are non-stationary
Alternative hypothesis: Data are stationary

Test

Statistic P-Value Recommendation

-11,7369 0,000 Test statistic <= critical value of -2,88680.

Significance level = 0,05

Reject null hypothesis.


Data appears to be stationary, not supporting differencing.

Gambar 6. Output Uji Augmented Dickey-Fuller (ADF).

Pengujian ADF menghasilkan nilai p -value $< \alpha = 0,05$. Kondisi ini membuktikan bahwa data telah memenuhi kriteria kestasioneran. Karena data sudah memenuhi asumsi stasioner, maka proses analisis dilanjutkan ke tahap identifikasi model.


3. Identifikasi Model

Pada tahap identifikasi model, penentuan model akan dilakukan melalui analisis pola pada plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) untuk memperoleh orde p , d , dan q . Untuk plot ACF digunakan dalam penentuan orde *Moving Average* (MA) atau q . Hasil plot ACF disajikan pada gambar di bawah ini.



Gambar 7. Plot ACF Data Differencing.

Sesuai dengan hasil plot ACF pada gambar 7 diketahui garis horizontal atau batas signifikan bawah (*limit confidence lower*) terpotong 1 lag periode pertama. Dari plot ACF ini didapatkan kemungkinan orde $q = 0,1$. Sementara itu, penentuan orde *Autoregressive* (AR) atau p digunakan plot PACF.



Gambar 8. Plot ACF Data Differencing.

Pada gambar 8 di atas, plot PACF terpotong sebanyak 3 lag yang melewati batas signifikan bawah. Dari plot ACF tersebut didapatkan kemungkinan orde $p = 0, 1, 2, 3$. Kemudian penentuan orde d diidentifikasi berdasarkan banyaknya proses *differencing* yang dilakukan sampai data mencapai kondisi stasioner. Pada penelitian ini didapatkan orde $d = 1$ karena kestasioneran data tercapai setelah proses *differencing* pertama. Berdasarkan analisis diperoleh kemungkinan model yang terbentuk adalah ARIMA (0,1,1), ARIMA (1,1,0), ARIMA (1,1,1), ARIMA (2,1,0), ARIMA (2,1,1), ARIMA (3,1,0), dan ARIMA (3,1,1).

4. Estimasi Parameter

Tahap selanjutnya setelah terbentuk beberapa kemungkinan model adalah mengestimasi parameter dari setiap model. Proses estimasi ini bertujuan untuk memperoleh nilai koefisien setiap parameter model. Kemudian setiap parameter model diuji signifikansinya untuk memastikan kelayakan model. Hasil dari uji signifikansi parameter model disajikan pada tabel 2 berikut.

Tabel 2 . Hasil Uji Signifikansi Parameter

Model	Parameter	Coeff	SE Coeff	t_{hitung}	p -value	Signifikansi
ARIMA (0,1,1)	θ_1	0,9113	0,0388	23,50	0,000	Signifikan
ARIMA (1,1,0)	ϕ_1	- 0,5022	0,0798	-6,29	0,000	Signifikan
ARIMA (1,1,1)	ϕ_1	0,1004	0,0947	1,06	0,291	Tidak Signifikan
	θ_1	0,9802	0,0319	30,69	0,000	Signifikan
ARIMA (2,1,0)	ϕ_1	-0,6886	0,0860	-8,01	0,000	Signifikan
	ϕ_2	-0,3720	0,0860	-4,32	0,000	Signifikan
ARIMA	ϕ_1	-1,400	0,115	-12,17	0,000	Signifikan

Model	Parameter	Coeff	SE Coeff	t_hitung	p-value	Signifikansi
(2,1,1)	ϕ_2	-0,5180	0,0814	-6,36	0,000	Signifikan
	θ_1	-0,881	0,103	-8,53	0,000	Signifikan
ARIMA (3,1,0)	ϕ_1	-0,8094	0,0883	-9,16	0,000	Signifikan
	ϕ_2	-0,593	0,102	-5,81	0,000	Signifikan
	ϕ_3	-0,3182	0,0884	-3,60	0,000	Signifikan
ARIMA (3,1,1)	ϕ_1	-0,431	0,243	-1,77	0,079	Tidak Signifikan
	ϕ_2	-0,325	0,194	-1,68	0,096	Tidak Signifikan
	ϕ_3	-0,164	0,144	-1,13	0,259	Tidak Signifikan
	θ_1	0,415	0,239	1,74	0,085	Tidak Signifikan

Berdasarkan hasil pengujian pada tabel 2, model yang semua parameternya signifikan adalah model ARIMA (0,1,1), ARIMA (1,1,0), ARIMA (2,1,0), ARIMA (2,1,1) dan ARIMA (3,1,0).

5. Diagnostic Checking

Model yang telah memenuhi uji signifikansi selanjutnya dilakukan *diagnostic*

checking. Pada tahap ini, residual dianalisis melalui uji *white noise* dan uji normalitas.

Uji *white noise* pada penelitian ini dilakukan dengan menggunakan statistik *Ljung-Box Chi-Square*. Model yang memenuhi kriteria $p\text{-value} > 0,05$ akan dilanjutkan untuk uji normalitas residual.

Tabel 3. Hasil Uji White Noise

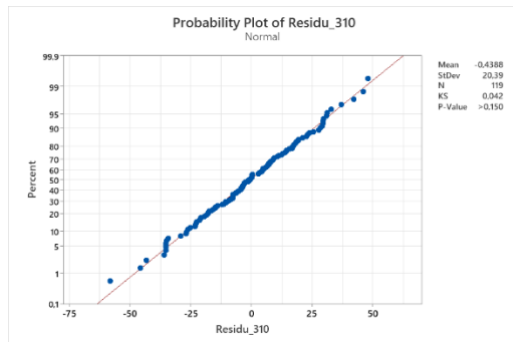
Model	Lag	p-value	Hasil
ARIMA (0,1,1)	12	0,057	<i>White Noise</i>
	24	0,052	<i>White Noise</i>
	36	0,032	Tidak <i>White Noise</i>
	48	0,075	<i>White Noise</i>
ARIMA (1,1,0)	12	0,000	Tidak <i>White Noise</i>
	24	0,001	Tidak <i>White Noise</i>
	36	0,000	Tidak <i>White Noise</i>
	48	0,000	Tidak <i>White Noise</i>
ARIMA (2,1,0)	12	0,008	Tidak <i>White Noise</i>
	24	0,008	Tidak <i>White Noise</i>
	36	0,007	Tidak <i>White Noise</i>
	48	0,024	Tidak <i>White Noise</i>
ARIMA (2,1,1)	12	0,000	Tidak <i>White Noise</i>
	24	0,001	Tidak <i>White Noise</i>
	36	0,000	Tidak <i>White Noise</i>
	48	0,001	Tidak <i>White Noise</i>
ARIMA (3,1,0)	12	0,220	<i>White Noise</i>
	24	0,286	<i>White Noise</i>
	36	0,353	<i>White Noise</i>
	48	0,502	<i>White Noise</i>

Berdasarkan hasil pengujian *white noise* model yang memenuhi kriteria $p\text{-value} > 0,05$ pada setiap *lag*-nya adalah model ARIMA

(3,1,0). Sebagai satu-satunya model yang memiliki residual bersifat *white noise*, model ARIMA (3,1,0) selanjutnya diuji normalitas

residualnya untuk memastikan residual model berdistribusi normal.

Pada penelitian ini, Normalitas residual model ARIMA (3,1,0) diuji menggunakan uji *Kolmogorov Smirnov*. Hasil pengujian normalitas residual pada model ARIMA (3,1,0) disajikan sebagai berikut.



Gambar 9. Uji Normalitas Residual Model ARIMA (3,1,0)

Berdasarkan hasil uji normalitas residual pada gambar 9, diperoleh nilai p -value $> 0,150$. Nilai p -value tersebut tidak melampaui taraf signifikansi yang ditetapkan ($\alpha = 0,05$), maka H_0 diterima. Dengan demikian dapat diartikan residual model ARIMA (3,1,0) terdistribusi normal.

6. Persamaan ARIMA

Setelah dilakukan serangkaian pengujian, model ARIMA (3,1,0) menjadi satu-satunya model yang memenuhi seluruh kriteria pengujian. Dengan demikian, model ARIMA (3,1,0) menjadi model akhir untuk pemodelan jumlah pengajuan klaim asuransi sosial kecelakaan lalu lintas. Persamaan dari model ARIMA (3,1,0) yang terbentuk dituliskan sebagai berikut:

$$X_t = 0,1906X_{t-1} + 0,2164X_{t-2} + 0,2748X_{t-3} + 0,3182X_{t-4} + C + e_t$$

7. Evaluasi Akurasi Model

Tahap berikutnya merupakan evaluasi akurasi model untuk mengetahui seberapa baik model ARIMA (3,1,0) untuk meramalkan data aktual. Dalam penelitian ini, tingkat keakuratan model diukur menggunakan dua indikator evaluasi yaitu *Mean Squared Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE). Dari hasil perhitungan evaluasi model, didapatkan nilai MSE dan MAPE dari model ARIMA (3,1,0) yang ditampilkan pada tabel 4.

Tabel 4. Hasil Akurasi Model

Nilai MSE	Nilai MAPE
150,054	10,53%

Berdasarkan hasil evaluasi, diperoleh nilai MSE sebesar 150,054 menunjukkan tingkat kesalahan peramalan yang dihasilkan model relatif kecil. Sementara itu, menurut kriteria akurasi MAPE, nilai MAPE sebesar 10,53% termasuk dalam kategori baik, sehingga model dianggap layak untuk digunakan dalam peramalan jumlah pengajuan klaim asuransi sosial kecelakaan lalu lintas periode mendatang.

8. Peramalan

Model ARIMA (3,1,0) telah dievaluasi dan terbukti layak digunakan dalam peramalan. langkah berikutnya adalah melakukan peramalan pada periode yang akan datang. Dalam penelitian ini, cakupan peramalan dilakukan untuk 20 minggu ke depan. Seluruh perhitungan dan pemrosesan data dilakukan dengan menggunakan perangkat lunak statistik Minitab. Hasil peramalan menggunakan model ARIMA (3,1,0) ditampilkan seperti tampak pada tabel berikut.

Tabel 5. Hasil Peramalan dengan Minitab

Period	Forecast	95% Limits	
		Lower	Upper
121	86,6390	46,3164	126,962
122	82,2065	41,1581	123,255
123	81,9771	39,6805	124,274
124	79,4954	34,7238	124,267
125	83,0506	34,0357	132,066
126	81,7171	31,1999	132,234
127	81,4787	29,0766	133,881
128	81,3308	26,6979	135,964
129	82,0162	25,1810	138,851
130	81,6250	23,0792	140,171
131	81,5824	21,2080	141,957
132	81,6307	19,4032	143,858
133	81,7414	17,7524	145,730
134	81,6367	15,9974	147,276
135	81,6405	14,3426	148,938
136	81,6642	12,7391	150,589
137	81,6761	11,1767	152,175
138	81,6512	9,6191	153,683
139	81,6568	8,1120	155,201
140	81,6632	6,6371	156,689

Dari tabel 5 di atas, maka diperoleh peramalan jumlah pengajuan klaim asuransi sosial kecelakaan lalu lintas selama 20 minggu ke depan dengan hasil sebagai berikut.

Tabel 6. Hasil Peramalan

Minggu ke-	Jumlah Klaim
121	87
122	82
123	82
124	79
125	83
126	82
127	81
128	81
129	82
130	82
131	82
132	82
133	82
134	82
135	82
136	82
137	82
138	82
139	82
140	82

Berdasarkan tabel 6, hasil peramalan jumlah pengajuan klaim asuransi sosial kecelakaan lalu lintas pada 20 minggu kedepan cenderung stabil. Kondisi tersebut memperlihatkan bahwa tidak terjadi peningkatan maupun penurunan yang signifikan pada jumlah pengajuan klaim asuransi selama periode peramalan. Temuan dari hasil peramalan ini dapat memberikan informasi yang bermanfaat bagi pihak-pihak yang berkepentingan untuk melakukan antisipasi terhadap peningkatan beban klaim pada periode mendatang.

D. Kesimpulan dan Saran

1. Kesimpulan

Setelah dilakukan serangkaian proses penelitian serta analisis, dapat ditarik kesimpulan bahwa metode *Autoregressive Integrated Moving Average* (ARIMA) memiliki kelayakan untuk digunakan dalam memodelkan dan memprediksi data jumlah pengajuan klaim asuransi sosial kecelakaan lalu lintas. Dari hasil analisis pada penelitian ini, model ARIMA

(3,1,0) ditetapkan sebagai model terpilih karena memenuhi seluruh uji pada tahapan pemodelan ARIMA. Evaluasi terhadap model ARIMA (3,1,0) menunjukkan tingkat akurasi yang baik dengan nilai *Mean Squared Error* sebesar (MSE) 150,054 dan *Mean Absolute Percentage Error* (MAPE) sebesar 10,53%. Dengan hasil tersebut, model ARIMA (3,1,0) dapat dinyatakan layak dan mampu meramalkan data pengajuan klaim asuransi sosial kecelakaan lalu lintas. Hasil peramalan jumlah pengajuan klaim asuransi sosial kecelakaan lalu lintas pada 20 minggu ke depan cenderung stabil. Kondisi tersebut memperlihatkan bahwa tidak terjadi peningkatan maupun penurunan yang signifikan pada jumlah pengajuan klaim asuransi selama periode peramalan.

2. Saran

Berdasarkan hasil penelitian, metode ARIMA mampu digunakan untuk memodelkan dan meramalkan jumlah pengajuan klaim asuransi sosial kecelakaan lalu lintas dengan tingkat akurasi yang baik. Hasil studi ini diharapkan dapat dipergunakan sebagai dasar pertimbangan dalam perencanaan dan penyusunan strategi pelayanan klaim pada periode mendatang. Penelitian ini memberikan landasan bagi penelitian selanjutnya dalam mengkaji pola dan peramalan dengan cakupan data dan pendekatan analisis yang lebih luas.

E. Daftar Pustaka

- Amerta, G., & Safitri, E. (2025). Metode Regresi Poisson (Studi Kasus: Jumlah Kecelakaan Lalu Lintas di Indonesia). *Prosiding Seminar Nasional Sains Dan Teknologi Seri IV Fakultas Sains Dan Teknologi*, 2(2), 611–618.
- BPS. (2025). *Jumlah Kecelakaan, Korban Mati, Luka Berat, Luka Ringan, dan Kerugian Materi*, 2024. <https://www.bps.go.id/id/statistics-table/2/NTEzIzI=/jumlah-kecelakaan--korban-mati--luka-berat--luka-ringan--dan-kerugian-materi.html>
- Brotosaputro, G., Windihastuty, W., Japriadi, Y. S., & Ahsani, R. (2025). Prediction of Claim Fund Reserves in Insurance Companies Using the ARIMA Method. *Jurnal SISFOKOM (Sistem Informasi Dan Komputer)*, 14, 1–7.
- Cahyani, Y. D. (2023). Penerapan Metode Arima (Autoregressive Integrated Moving Average) Berbasis Minitab Untuk

- Memprediksi Tingkat Pengajuan Klaim Asuransi Kecelakaan Di PT Jasa Raharja Perwakilan Malang. *Seminar Nasional Pendidikan IPA Dan Matematika 2023 Universitas Negeri Malang*, 8, 301–311.
- FLLAJ Jateng. (2023). Rencana Aksi Keselamatan Lalu Lintas Dan Angkutan Jalan Provinsi Jawa Tengah Tahun 2023-2028. In *Fllaj.Jatengprov.Go.Id*. https://fllaj.jatengprov.go.id/assets/unggah/pdf/RAK_LLAIJ_2023-2028.pdf
- Gempati, A., Fradani, F. A. R., Ibrahim, R. M., Astuti, T. K., Prasetyo, Y. R., & Devi, L. Y. (2025). Peramalan Data IHSG 2021-2025 Di Indonesia Dengan Time Series Modeling Autoregressive Integrated Moving Average (ARIMA). *Jurnal Ilmiah Ekonomi Dan Manajemen*, 3(5), 225–234. <https://doi.org/10.61722/jiem.v3i5.4650>
- Issan, Pagasing, I. M., Harmin, A., & Arni, S. (2025). Analisis Peramalan Klaim Tabungan Hari Tua Menggunakan Metode Arima Pada PT. ASABRI Cabang Makassar. *Jurnal Informatika Progres*, 17(1), 70–76.
- Lestari, I., Sumargo, B., & Ladayya, F. (2022). Pemodelan ARIMA Intervensi Untuk Meramalkan Harga Minyak Mentah Dunia. *STATISTIKA Journal of Theoretical Statistics and Its Applications*, 22(2), 133–146. <https://doi.org/10.29313/statistika.v22i2.1593>
- Mawaddah, E. (2023). Penerapan Model Deret Waktu ARIMA Pada Data Kecelakaan Lalu Lintas di Kabupaten Mempawah. *BIMASTER : Buletin Ilmiah Matematika, Statistika Dan Terapannya*, 12(4), 325–334. <https://jurnal.untan.ac.id/index.php/jbmstr/article/view/68324>
- Nahuway, Y., Ekowati, C. K., & Madu, A. (2025). Analisis data time series menggunakan metode ARIMA untuk meramalkan persentase lulusan tepat waktu di FKIP Undana. *NOTASI: Jurnal Pendidikan Matematika*, 3(1), 46–55. <https://doi.org/10.70115/notasi.v3i1.285>
- Nurhakim, R., Saefullah, A., Arza, Z., & Firdaus, A. (2024). Sosialisasi Santunan Penjaminan PT. Jasa Raharja Akibat Kecelakaan Lalu Lintas. *JCRE: Journal of Community Research and Engagement*, 1(1), 61–74.
- Rosita, M. D., Himayati, A. I. A., & Nursani, I. I. (2024). Perbandingan Prediksi Pergerakan Harga Saham Menggunakan Metode SMA, WMA, dan EMA di PT Bank Central Asia (BCA). *Journal of Mandalika Literature*, 6(2), 324–333.
- Shahriari, S., Sisson, S. A., & Rashidi, T. (2025). Modelling time series with temporal and spatial correlations in transport planning using hierarchical ARIMA-copula Model : A Bayesian approach. *Expert Systems With Applications*, 274(February), 126977. <https://doi.org/10.1016/j.eswa.2025.126977>
- Susanti, D., Maraya, N. S., Sukono, S., & Saputra, J. (2024). Prediction of Motor Vehicle Insurance Claims Using ARIMA-GARCH Models. *Operations Research: International Conference Series*, 5(3), 86–92. <https://doi.org/10.47194/orics.v5i3.331>
- WHO. (2023). *Global status report on road safety 2023*. World Health Organization. <https://www.who.int/teams/social-determinants-of-health/safety-and-mobility/global-status-report-on-road-safety-2023>