

IMPLEMENTASI METODE SARIMA DALAM MEMPREDIKSI JUMLAH PELANGGARAN LALU LINTAS DI KABUPATEN BULELENG

Ni Ketut Rika Suryani^{1*}, I Gusti Ayu Agung Datri Indradewi², Ida Bagus Nyoman Pascima³

^{1,2,3} Jurusan Teknik Informatika, Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha; Jl. Udayana No.11, Singaraja, Bali 81116; Telp/Fax (0362) 22570

Keywords:

Prediksi; Pelanggaran Lalu Lintas; Deret Waktu; SARIMA; CRISP-DM

Corespondent Email:

rika.suryani@undiksha.ac.id

Abstrak. Penelitian ini bertujuan untuk membangun model peramalan jumlah pelanggaran lalu lintas di Kabupaten Buleleng sebagai upaya mendukung perencanaan pengawasan yang lebih proaktif. Permasalahan penelitian didasarkan pada keterbatasan pengawasan di lapangan serta belum optimalnya pemanfaatan data historis, sehingga pihak kepolisian belum memiliki gambaran prediktif mengenai tren pelanggaran di masa mendatang. Metode yang digunakan adalah *Seasonal Autoregressive Integrated Moving Average*, yaitu metode prediksi deret waktu yang mampu menganalisis pola tren dan musiman. Data yang digunakan berupa data bulanan jumlah pelanggaran lalu lintas periode 2019 hingga 2024. Proses penelitian dilakukan mengikuti tahapan *Cross-Industry Standard Process for Data Mining* yang meliputi pemahaman masalah, pemahaman data, persiapan data, pemodelan, evaluasi, dan implementasi. Hasil penelitian menunjukkan bahwa model peramalan yang dibangun menghasilkan tingkat kesalahan peramalan sebesar 24,23% serta kemampuan mengikuti arah pergerakan data aktual sebesar 54,5%. Model juga mampu menghasilkan prediksi jumlah pelanggaran untuk 12 periode ke depan.



Copyright © [JITET](#) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. Traffic violations in Buleleng Regency remain a significant issue due to limited field supervision and the underutilization of historical data for planning purposes. As a result, law enforcement agencies lack predictive information regarding future violation patterns. This study aims to develop a forecasting model for the number of traffic violations using the Seasonal Autoregressive Integrated Moving Average method. The data used consist of monthly traffic violation records from 2019 to 2024. The research process follows the Cross-Industry Standard Process for Data Mining, including problem understanding, data understanding, data preparation, modeling, evaluation, and deployment. The results indicate that the proposed model achieves a satisfactory level of accuracy, with a forecasting error rate of 24.23% and a directional accuracy of 54.5%. The model also produces forecasts for the next twelve months.

1. PENDAHULUAN

Tingginya mobilitas masyarakat dan pertumbuhan jumlah kendaraan bermotor menjadi salah satu faktor utama meningkatnya kompleksitas permasalahan lalu lintas di Indonesia, termasuk di Kabupaten Buleleng. Salah satu permasalahan utama yang sering

terjadi adalah meningkatnya pelanggaran lalu lintas, seperti pelanggaran rambu, kecepatan berlebih, serta penggunaan kendaraan tanpa kelengkapan dokumen yang sah [1]. Kondisi ini berimplikasi pada meningkatnya angka pelanggaran lalu lintas yang berdampak pada risiko kecelakaan, kemacetan, serta rendahnya

kepatuhan pengguna jalan terhadap regulasi yang berlaku [2]. Di sisi lain, berbagai informasi terkait pelanggaran lalu lintas yang dicatat oleh Satlantas Polres Buleleng belum sepenuhnya diolah menjadi informasi yang mampu menggambarkan pola dan kecenderungan pelanggaran lalu lintas di Kabupaten Buleleng.

Keterbatasan pemanfaatan informasi ini membuat Satlantas Polres Buleleng sulit memprediksi pola pelanggaran pada masa mendatang dan menyebabkan strategi pengawasan yang diterapkan masih bersifat reaktif, bergantung pada kegiatan penjagaan langsung personel di lapangan. Keterbatasan sumber daya serta minimnya penerapan sistem *Electronic Traffic Law Enforcement* (ETLE) semakin memperkuat urgensi kebutuhan akan suatu pendekatan analitis yang mampu memberikan informasi prediktif sebagai dasar penyusunan strategi dan perencanaan pengawasan yang lebih efektif. Kondisi tersebut menunjukkan bahwa permasalahan pelanggaran lalu lintas tidak hanya terkait pada aspek operasional di lapangan, tetapi juga pada belum optimalnya pemanfaatan informasi termasuk data historis yang dimiliki sebagai dasar pengambilan keputusan. Oleh karena itu, diperlukan pendekatan analitis yang mampu menggali pola dan karakteristik data pelanggaran secara sistematis, salah satunya melalui analisis deret waktu.

Analisis deret waktu adalah pendekatan statistik yang digunakan untuk mengkaji data yang tersusun berdasarkan urutan waktu dengan tujuan mengenali pola tren, komponen musiman dan fluktuasi acak yang terdapat dalam data [3]. Salah satu metode yang umum digunakan untuk analisis deret waktu yaitu metode ARIMA. Metode ini memiliki perluasan model yaitu *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dimana model ini lebih efektif untuk menangani data dengan pola musiman, mengakomodasi komponen musiman melalui parameter tambahan, sehingga mampu menangkap pola pada komponen non-musiman dan musiman [4]. Keunggulan metode ini terletak pada kemampuannya menghasilkan prediksi yang akurat sekaligus memberikan interpretasi yang jelas terhadap struktur data melalui parameter model yang digunakan. Efektivitas metode ini telah ditunjukkan dalam berbagai studi, antara

lain pada peramalan penjualan kendaraan [5], inflasi [6], nilai ekspor [7], penjualan retail [8], tingkat polutan udara [9], dan jumlah pengunjung wisata [10].

Berbagai penelitian menunjukkan bahwa metode SARIMA memiliki kinerja yang baik dalam memodelkan dan memprediksi data musiman. Beberapa studi menyebutkan bahwa SARIMA mampu memberikan tingkat akurasi yang lebih stabil dibandingkan metode lain seperti *Extreme Learning Machine*, *Prophet*, dan *Holt-Winters* dalam prediksi data berpolai musiman [11], [12], [13]. Selain itu, dibandingkan dengan metode berbasis *deep learning*, SARIMA memiliki kelebihan dalam hal interpretabilitas model dan kebutuhan sumber daya komputasi yang relatif lebih rendah, sehingga lebih sesuai untuk analisis data dengan jumlah yang terbatas [14].

Berdasarkan kajian penelitian terkait, belum ditemukan penelitian yang secara khusus menerapkan metode SARIMA untuk memodelkan dan memprediksi jumlah pelanggaran lalu lintas di Kabupaten Buleleng. Celaah penelitian ini menunjukkan pentingnya pengembangan model prediksi yang dapat memberikan gambaran prediktif mengenai pelanggaran lalu lintas ke masa yang akan datang. Oleh karena itu, penelitian ini bertujuan untuk membangun model prediksi jumlah pelanggaran lalu lintas di Kabupaten Buleleng menggunakan metode SARIMA. Hasil dari penelitian ini diharapkan dapat mendukung Satlantas Polres Buleleng dalam merumuskan strategi pengawasan secara proaktif dan berbasis data.

2. TINJAUAN PUSTAKA

2.1 Prediksi

Prediksi merupakan proses memperkirakan nilai suatu variabel di masa mendatang berdasarkan pola dan informasi yang terkandung dalam data historis [15]. Prediksi bertujuan untuk mendukung pengambilan keputusan dengan menyediakan gambaran mengenai kondisi yang mungkin terjadi di masa depan, sehingga perencanaan dan pengendalian dapat dilakukan secara lebih efektif.

2.2 Analisis Deret Waktu

Analisis deret waktu merupakan pendekatan statistik yang digunakan untuk memahami pola atau struktur hubungan antara

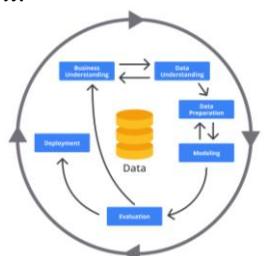
data yang dikumpulkan secara berurutan dalam satuan waktu, seperti harian, mingguan, bulanan, atau tahunan. Analisis deret waktu dilakukan untuk mengidentifikasi pergerakan waktu, pola, musiman, siklus, serta fluktuasi acak yang terjadi dari waktu ke waktu. Terdapat beberapa jenis pola yang umum ditemukan dalam data deret waktu, diantaranya adalah pola mendatar (*horizontal*), tren (*trend*), musiman (*seasonality*), serta siklikal (*cyclical*) [16].

2.3 SARIMA

SARIMA menggabungkan komponen non-musiman (p, d, q) serta komponen musiman (P, D, Q) dengan periode musiman s . Komponen p menunjukkan orde *autoregressive* (AR) non-musiman yang merepresentasikan pengaruh nilai masa lalu terhadap nilai saat ini. Komponen d merupakan tingkat *differencing* non-musiman untuk membuat data menjadi stasioner. Komponen q menunjukkan orde *moving average* (MA) non-musiman yang merepresentasikan ketergantungan antara nilai saat ini dan residual masa lalu [17]. Pada sisi musiman, komponen P adalah orde *autoregressive* musiman (SAR), sedangkan D adalah tingkat *differencing* musiman yang digunakan untuk menghilangkan pola berulang secara berkala. Komponen Q adalah orde *moving average* musiman (SMA), dan s menunjukkan panjang periode musiman, misalnya $s = 12$ untuk data bulanan.

2.4 CRISP-DM

Cross Industry Standard Process for Data Mining merupakan suatu kerangka kerja standar yang digunakan dalam pelaksanaan proyek data mining [18]. CRISP-DM terdiri dari 6 tahapan terstruktur yaitu, *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*.



Gambar 1. Kerangka Kerja CRISP-DM

2.5 Evaluasi Model

2.5.1 MAPE

Perhitungan MAPE dilakukan dengan membagi selisih nilai mutlak antara nilai prediksi dan nilai aktual pada setiap periode, kemudian menghitung rata – rata dari seluruh persentase kesalahan absolut tersebut. MAPE menunjukkan seberapa besar kesalahan peramalan dibandingkan dengan data sebenarnya [6].

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

Adapun skala penilaian MAPE ditunjukkan oleh tabel 1.

Tabel 1. Skala penilaian MAPE

Rentang MAPE	Keterangan
<10%	Sangat Baik
10% - 20%	Baik
20% - 50%	Cukup Baik
>50%	Rendah

2.5.2 Dstat

Dstat bekerja dengan membandingkan arah pergerakan data aktual dan hasil prediksi dari satu periode ke periode berikutnya. Jika keduanya bergerak dalam arah yang sama, maka dianggap sesuai, sedangkan jika berlawanan arah dianggap tidak sesuai. Rentang nilai Dstat yaitu 0 atau 1, jika nilainya adalah 1, maka arah pergerakan hasil prediksi sangat sesuai dengan arah aktual, sedangkan nilainya 0 menunjukkan arah pergerakan peramalan sering bertentangan dengan arah data sebenarnya [19].

$$Dstat = \frac{1}{n} \sum_{t=1}^n a_t * 100\% \quad (2)$$

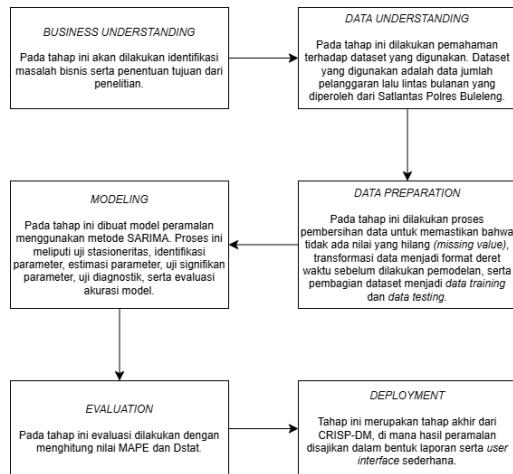
Dimana,

$$a_t = \begin{cases} 1, & (d_{t+1} - d_t)(y_{t+1} - d_t) \geq 0 \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

3. METODE PENELITIAN

Dalam penelitian ini, tahapan dan metode penelitian yang digunakan mengacu pada CRISP-DM yang dirancang agar proses pengolahan data diproses melalui tahapan tahapan yang jelas, terstruktur, dan efisien.

Tahapan penelitian dijelaskan sesuai pada Gambar 2.



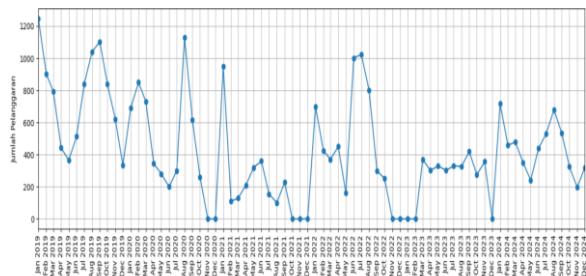
Gambar 2. Tahap Penelitian CRISP-DM

3.1 Business Understanding

Pada tahap ini dilakukan observasi dan wawancara secara langsung pada Satlantas Polres Buleleng untuk mengetahui dan mengidentifikasi permasalahan yang ada. Berdasarkan hasil observasi, diketahui bahwa masih banyak pelanggaran lalu lintas yang terjadi belum dapat terpantau secara menyeluruh. Kondisi ini disebabkan oleh berkurangnya intensitas razia serta penjagaan di lapangan sejak masa pandemi COVID-19, ditambah dengan penerapan sistem ETL yang belum berjalan optimal. Selain itu, belum tersedia informasi berbasis data yang dapat digunakan untuk meramalkan jumlah pelanggaran lalu lintas di masa mendatang. Hal tersebut berdampak pada sulitnya pihak berwenang dalam menyusun strategi pengawasan dan penegakan hukum yang efektif.

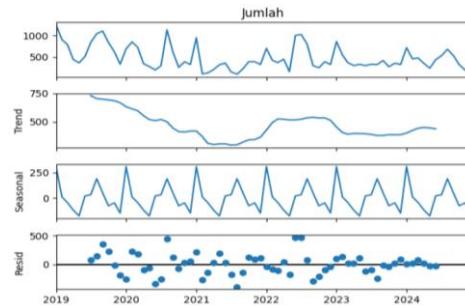
3.2 Data Understanding

Proses pemahaman dan eksplorasi terhadap data untuk proses pemodelan dilakukan pada tahapan ini. Dataset yang digunakan diperoleh dari Satlantas Polres Buleleng dalam rentang waktu Januari 2019 hingga Desember 2024. Data yang digunakan merupakan data jumlah pelanggaran lalu lintas di Kabupaten Buleleng yang dikumpulkan berbentuk data deret waktu dengan periode bulanan. Pola jumlah pelanggaran lalu lintas di Kabupaten Buleleng ditunjukkan oleh gambar berikut:



Gambar 3. Pola Jumlah Pelanggaran

Selanjutnya dilakukan eksplorasi data untuk memahami karakteristik data. Kemudian dilakukan visualisasi data untuk memudahkan proses analisis serta mendukung proses identifikasi pola-pola yang ada dalam data. Visualisasi pola data jumlah pelanggaran lalu lintas ditunjukkan oleh plot dekomposisi berikut:



Gambar 4. Plot Dekomposisi

Berikut merupakan tabel data pelanggaran lalu lintas yang menampilkan jumlah pelanggaran per bulan. Data ini berfungsi sebagai dasar dalam identifikasi pola data deret waktu yang diperlukan untuk membangun model prediksi.

Tabel 2. Data Pelanggaran

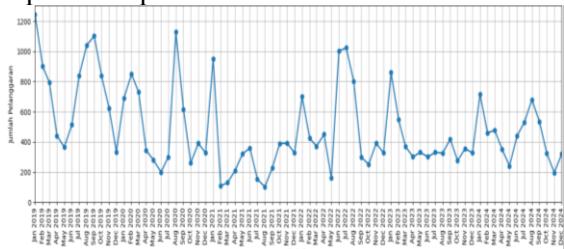
Tahun	Bulan	Jumlah
2019	Januari	1246
	Februari	904
	Maret	793
	April	442
	Mei	365
	Juni	513
	Juli	839
	Agustus	1040
	September	1103
	Oktober	838
	November	622

Tahun	Bulan	Jumlah
	Desember	334
.....
2024	Januari	717
	Februari	458
	Maret	479
	April	350
	Mei	241
	Juni	439
	Juli	530
	Agustus	680
	September	534
	Oktober	325
	November	196
	Desember	320

3.3 Data Preparation

3.3.1 Data Cleaning

Dilakukan pembersihan data untuk memastikan bahwa data yang digunakan dalam pemodelan sudah bersih dan bebas dari masalah kualitas, terutama terkait dengan keberadaan nilai null yang mencerminkan ketidadaan data (*missing value*) pada periode tertentu. Untuk mengatasi *missing value* tersebut maka dilakukan proses imputasi terhadap nilai null. Proses imputasi dilakukan dengan menghitung rata-rata dari nilai pelanggaran pada bulan yang sama di tahun-tahun lainnya. Berikut merupakan pola jumlah pelanggaran lalu lintas setelah dilakukan proses imputasi:



Gambar 5. Pola Setelah Imputasi

3.3.2 Data Transformation

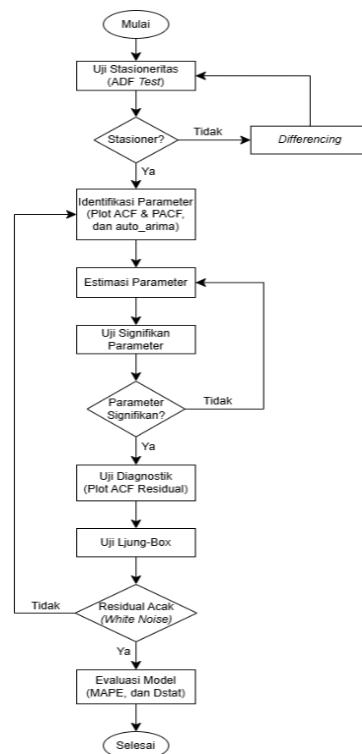
Dilakukan dengan cara mengubah format data jumlah pelanggaran lalu lintas menjadi format deret waktu. Proses transformasi dilakukan dengan menyusun data berdasarkan urutan waktu yang konsisten, yaitu dalam interval bulanan dari tahun ke tahun. Penyusunan ini dilakukan agar setiap nilai data memiliki indeks waktu yang tepat.

3.3.3 Pembagian Dataset

Dalam pembagian dataset, dataset dibagi menjadi dua bagian, yaitu data latih dan data uji. Data yang dimiliki berjumlah 72 data yang kemudian akan dibagi, dimana sebanyak 60 data pertama digunakan sebagai data latih dan 12 data terakhir digunakan sebagai data uji.

3.4 Modeling

Tahap modeling merupakan proses pembangunan model prediksi jumlah pelanggaran lalu lintas menggunakan metode SARIMA. Alur kerja metode SARIMA ditunjukkan oleh gambar berikut:



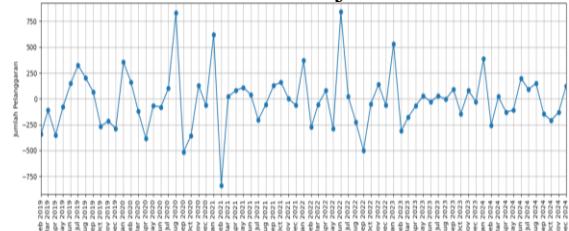
Gambar 6. Alur Kerja Model SARIMA

Tahapan ini diawali dengan uji stasioneritas menggunakan ADF test untuk memastikan data sudah stasioner dengan nilai *p-value* < 0,05. Sebaliknya jika nilai *p-value* > 0,05 data dinyatakan tidak stasioner, maka dilakukan proses differencing, hasil ADF test ditunjukkan oleh gambar berikut:

Hasil Test ADF		Hasil Test ADF	
Test statistic	-2.306804	Test statistic	-9.522226e+09
p-value	0.169783	p-value	3.0493213e-16
Lags used	4.000000	Lags used	3.000000e+00
Number of observations used	67.000000	Number of observations used	6.700000e+01
Critical value (1%)	-3.531955	Critical value (1%)	-3.531955e+00
Critical value (5%)	-2.905755	Critical value (5%)	-2.905755e+00
Critical value (10%)	-2.598357	Critical value (10%)	-2.598357e+00

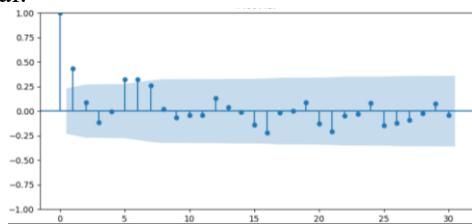
Gambar 7. (a) Uji ADF Data Awal; (b) Uji ADF Data Setelah Differencing

Berikut grafik pola data jumlah pelanggaran lalu lintas setelah dilakukan *differencing* untuk menghilangkan komponen tren dan membuat data menjadi lebih stasioner.



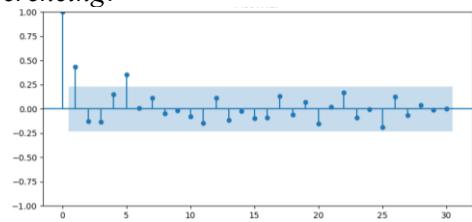
Gambar 8. Grafik Data Setelah *Differencing*

Selanjutnya plot ACF yang menunjukkan pola autokorelasi yang menurun secara cepat pada lag awal, dengan sebagian besar nilai berada dalam batas interval kepercayaan. Hal ini mengindikasikan bahwa komponen *moving average* (MA) berperan dalam struktur data setelah dilakukan *differencing*, karena karakteristiknya cenderung menunjukkan *cut-off* atau penurunan cepat pada beberapa lag awal.



Gambar 9. Plot ACF

Plot PACF pada grafik berikut menunjukkan adanya satu atau dua lag signifikan pada bagian awal, kemudian nilai autokorelasi parsial menurun dan berada dalam batas interval kepercayaan. Pola ini menunjukkan bahwa komponen *autoregressive* (AR) memiliki peran pada struktur data setelah *differencing*.



Gambar 10. Plot PACF

Selanjutnya tabel dibawah menyajikan hasil estimasi parameter dari tiga model SARIMA terbaik yang diperoleh berdasarkan proses pemodelan. Setiap model terdiri dari kombinasi komponen non-musiman dan

musiman yang direpresentasikan oleh koefisien, nilai standar error, nilai z, dan nilai *p-value*. Parameter dinyatakan signifikan jika memiliki nilai *p-value* <0,05, yang menunjukkan bahwa parameter tersebut berkontribusi secara statistik terhadap pembentukan model. Berdasarkan hasil estimasi parameter, terdapat beberapa parameter pada setiap model yang tidak signifikan dengan nilai *p-value* >0,05. Ketidaksignifikansi parameter ini menunjukkan bahwa kontribusinya terhadap struktur model relatif kecil.

Tabel 3. Estimasi Parameter

Model	Parameter	P > z	Keterangan
SARIMA (0,1,2) (1,0,2,12)	MA (1)	0.001	Signifikan
	MA (2)	0.001	Signifikan
	SAR (1)	0.000	Signifikan
	SMA (1)	0.000	Signifikan
	SMA (2)	0.510	Tidak Signifikan
SARIMA (0,1,2) (2,0,1,12)	MA (1)	0.001	Signifikan
	MA (2)	0.000	Signifikan
	SAR (1)	0.000	Signifikan
	SAR (2)	0.483	Tidak Signifikan
	SMA (1)	0.000	Signifikan
SARIMA (2,1,1) (2,0,0,12)	AR (1)	0.003	Signifikan
	AR (2)	0.110	Tidak Signifikan
	MA (1)	0.000	Signifikan
	SAR (1)	0.129	Tidak Signifikan
	SAR (2)	0.014	Signifikan

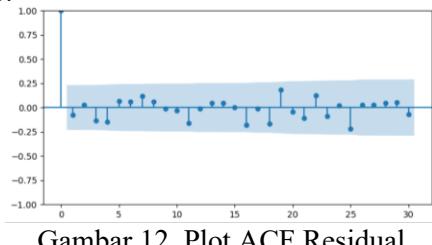
Berdasarkan hasil uji signifikan parameter, ketidaksignifikansi beberapa parameter model tidak mengurangi kualitas model secara keseluruhan, meskipun terdapat parameter yang tidak signifikan model terbaik tetap dipilih berdasarkan performa keseluruhan. Model SARIMA (2,1,1)(2,0,0,12) dipilih karena secara keseluruhan mampu memberikan hasil prediksi yang paling baik dibandingkan model lainnya.

	coef	std err	z	P> z	[0 .025	0.975]
ar.L1	0.4545	0.152	2.985	0.003	0.156	0.753
ar.L2	-0.2854	0.178	-1.600	0.110	-0.635	0.064
ma.L1	-0.8199	0.117	-6.990	0.000	-1.050	-0.590
ar.S.L12	0.1833	0.121	1.517	0.129	-0.054	0.420
ar.S.L24	0.3319	0.135	2.452	0.014	0.067	0.597
sigma2	4.797e+04	6262.072	7.661	0.000	3.57e+04	6.02e+04

Gambar 11. Uji Signifikan Parameter

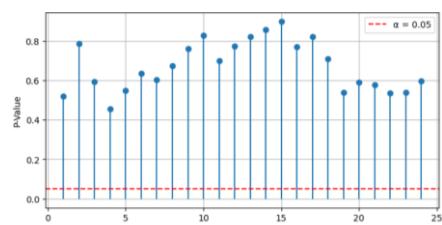
Plot ACF residual pada grafik dibawah menunjukkan bahwa seluruh titik autokorelasi berada di sekitar garis 0 dan tetap berada dalam batas kepercayaan. Tidak ada lag yang muncul secara signifikan, sehingga tidak terlihat pola

autokorelasi yang tersisa. Ini menunjukkan bahwa residual sudah bersifat acak atau *white noise*.



Gambar 12. Plot ACF Residual

Hasil uji Ljung-Box menunjukkan bahwa seluruh nilai *p-value* pada berbagai lag berada di atas garis batas signifikan 0,05. Ini berarti tidak ada autokorelasi yang signifikan pada residual model, artinya residual bersifat acak dan tidak menyimpan pola tertentu yang belum ditangkap oleh model. Residual telah memenuhi karakteristik *white noise*, sehingga model dapat dianggap telah sesuai dan mampu merepresentasikan struktur data dengan baik.



Gambar 13. Uji Ljung-Box

3.5 Evaluation

Evaluasi dilakukan berdasarkan MAPE dan Dstat. Nilai MAPE dihitung dengan membandingkan rata-rata kesalahan absolut terhadap nilai aktual. Sementara itu, nilai Dstat digunakan untuk mengevaluasi kemampuan model dalam meramalkan arah pergerakan data, apakah hasil peramalan menunjukkan kenaikan atau penurunan yang searah dengan data aktual.

3.6 Deployment

Pada tahap ini dilakukan proses penyampaian hasil peramalan dalam bentuk yang mudah dipahami. Hasil peramalan disajikan dalam bentuk laporan yang terstruktur, sehingga informasi yang dapat bermanfaat untuk mendukung evaluasi strategi pengawasan lalu lintas.

4. HASIL DAN PEMBAHASAN

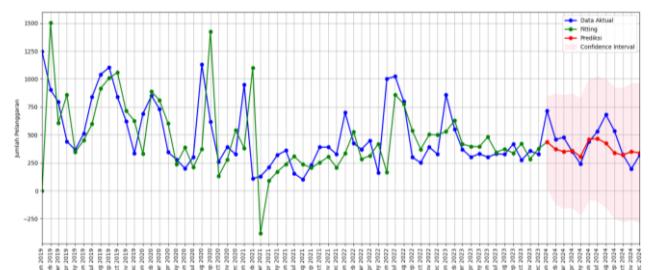
4.1 Tingkat Akurasi Metode SARIMA dalam Memprediksi Jumlah Pelanggaran Lalu Lintas

Tingkat akurasi metode SARIMA dalam memprediksi jumlah pelanggaran lalu lintas di Kabupaten Buleleng dapat dilihat pada Tabel 4.

Tabel 4. Perbandingan Data Aktual & Prediksi

Tahun	Bulan	Data Aktual	Data Prediksi	Selisih Absolut	Nilai Dstat
2024	Januari	717	437	280	-
2024	Februari	458	372	86	1
2024	Maret	479	351	128	0
2024	April	350	359	9	0
2024	Mei	241	306	65	1
2024	Juni	439	460	21	1
2024	Juli	530	467	63	1
2024	Agustus	680	425	255	0
2024	September	534	339	195	1
2024	Okttober	325	320	5	1
2024	November	196	351	155	0
2024	Desember	320	337	17	0

Grafik tingkat akurasi metode SARIMA dalam memprediksi jumlah pelanggaran lalu lintas di Kabupaten Buleleng ditunjukkan oleh gambar berikut:



Gambar 14. Grafik Perbandingan Data Aktual & Prediksi

$$MAPE = \frac{290.70}{12} \times 100\% = 24,23\%$$

Berdasarkan hasil pengujian akurasi, model SARIMA yang dikembangkan menunjukkan performa dengan nilai akurasi sebesar 24,23%. Nilai MAPE mengindikasikan bahwa selisih rata-rata antara hasil prediksi dan data aktual berada pada tingkat kesalahan yang masih dapat diterima untuk data deret waktu dengan fluktuasi tinggi seperti jumlah pelanggaran lalu lintas.

$$Dstat = \frac{6}{11} \times 100\% = 54,5\%$$

Sementara itu, nilai Dstat yang diperoleh yaitu sebesar 54,5% menunjukkan bahwa kemampuan model dalam mengikuti arah perubahan data aktual masih relatif rendah dan hanya sedikit lebih baik dibandingkan tebakan acak.

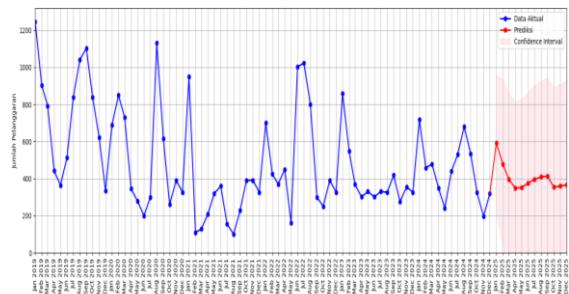
4.2 Hasil Prediksi dalam 12 Periode ke Depan

Berdasarkan hasil peramalan jumlah pelanggaran lalu lintas di Kabupaten Buleleng untuk 12 periode ke depan dapat memberikan estimasi jumlah pelanggaran yang dapat dijadikan acuan untuk merencanakan tindakan pengawasan oleh Satlantas Polres Buleleng.

Tabel 5. Hasil Prediksi Jumlah Pelanggaran 12 Periode ke Depan

Tahun	Bulan	Prediksi Jumlah Pelanggaran
2025	Januari	592
2025	Februari	479
2025	Maret	397
2025	April	349
2025	Mei	351
2025	Juni	377
2025	Juli	396
2025	Agustus	409
2025	September	413
2025	Okttober	354
2025	November	360
2025	Desember	367

Dengan grafik yang ditampilkan, pihak Satlantas dapat mempertimbangkan skenario optimis maupun konservatif dalam pengambilan keputusan. Hasil ini memberikan gambaran awal yang sistematis dan berbasis data untuk strategi pengendalian lalu lintas dan penanganan pelanggaran secara proaktif.



Gambar 15. Grafik Hasil Prediksi 12 Periode ke Depan

5. KESIMPULAN

- Berdasarkan hasil pengujian akurasi, model SARIMA yang dikembangkan menunjukkan kinerja yang cukup baik dalam meramalkan jumlah pelanggaran lalu lintas di Kabupaten Buleleng dengan nilai MAPE sebesar 24,23%, yang mengindikasikan bahwa tingkat kesalahan prediksi masih berada dalam batas yang dapat diterima untuk data deret waktu yang memiliki fluktuasi tinggi. Namun, nilai *Directional Statistic* (Dstat) sebesar 54,5% menunjukkan bahwa kemampuan model dalam mengikuti arah perubahan data aktual masih terbatas dan hanya sedikit lebih baik dibandingkan tebakan acak. Oleh karena itu, model SARIMA dalam penelitian ini lebih sesuai digunakan untuk memberikan gambaran umum mengenai tren dan pola musiman pelanggaran lalu lintas, serta sebagai dasar pendukung perencanaan pengawasan lalu lintas secara makro.
- Hasil peramalan jumlah pelanggaran lalu lintas untuk 12 periode ke depan menunjukkan bahwa model SARIMA mampu menghasilkan pola prediksi yang konsisten dengan karakteristik data historis, terutama dalam mengikuti tren dan pola musiman tahunan yang telah terbentuk sebelumnya. Dengan demikian, hasil prediksi ini diharapkan bermanfaat sebagai evaluasi strategi pengawasan lalu lintas secara lebih terarah dan proaktif.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada seluruh pihak yang telah memberikan bantuan dalam proses penyusunan dan penyelesaian penelitian ini, baik berupa bimbingan, masukan, motivasi, maupun bantuan teknis yang sangat

berarti sehingga penelitian ini dapat terselesaikan dengan baik.

DAFTAR PUSTAKA

- [1] K. T. Saniartini, M. S. Hartono, and M. J. Setianto, "IMPLEMENTASI TILANG ELEKTRONIK ATAU E-TLE DALAM PENYELESAIAN PELANGGARAN LALU LINTAS DI KABUPATEN BULELENG," *Komunikasi Yustisia Universitas Pendidikan Ganesha*, vol. 7, no. 3, 2024.
- [2] B. Amyrulloh and Samuji, "ANALISIS PENYEBAB PELANGGARAN LALU LINTAS OLEH PENGENDARA KENDARAAN BERMOTOR," *Kultura Jurnal Ilmu Sosial dan Humaniora*, vol. 2, pp. 81–103, Jan. 2024, Accessed: Jun. 23, 2025. [Online]. Available: <https://jurnal.kolibri.org/index.php/kultura/article/view/963/896>
- [3] S. Deviana, D. Azis, dan Pandri Ferdias, J. Ir Sumantri Brojonegoro No, G. Meneng, and B. Lampung, "Analisis Model Autoregressive Integrated Moving Average Data Deret Waktu Dengan Metode Momen Sebagai Estimasi Parameter," *Jurnal Siger Matematika*, vol. 02, no. 02, pp. 57–67, 2021, Accessed: Jun. 27, 2025. [Online]. Available: <https://jurnal.fmipa.unila.ac.id/JSM/article/view/2812>
- [4] K. R. Arunika and L. J. E. Dewi, "PERBANDINGAN MODEL SARIMA, EXPONENTIAL SMOOTHING, DAN XGBOOST UNTUK PREDIKSI PENJUALAN SUPER STORE," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 3S1, pp. 2021–2032, Oct. 2025, doi: 10.23960/jitet.v13i3S1.8173.
- [5] M. Heru Widiyanto and R. Mayasari, "IMPLEMENTASI TIME SERIES PADA DATA PENJUALAN DI GAIKINDO MENGGUNAKAN ALGORITMA SEASONAL ARIMA," *Jurnal Mahasiswa Teknik Informatika*, vol. 7, no. 3, pp. 1501–1506, 2023, doi: <https://doi.org/10.36040/jati.v7i3.6879>.
- [6] A. Aulia, ainul Miftahul Huda, and S. Rofatunnisa, "Peramalan Inflasi Kota Pontianak dengan Metode Seasonal Autoregressive Integrated Moving Average," *Jurnal Forum Analisis Statistik (FORMASI)*, vol. 4, no. 2, pp. 109–120, 2024, doi: <https://doi.org/10.57059/formasi.v4i2.99>.
- [7] N. L. I. R. Sari, I. W. P. Astawa, and I. G. P. Suharta, "Peramalan Nilai Ekspor Di Provinsi Bali Dengan Metode Seasonal Autoregressive Integrated Moving Average," *Wahana Matematika dan Sains: Jurnal Matematika, Sains, dan Pembelajarannya*, vol. 17, no. 3, pp. 1858–0629, 2023, doi: <https://doi.org/10.23887/wms.v17i3.49740>.
- [8] K. Pratama, D. Putra, A. Hermawan, and D. Avianto, "PREDIKSI LONJAKAN PENJUALAN TOKO RETAIL ONLINE SAAT HARBOLNAS DENGAN MODEL SARIMA," vol. 13, no. 1, 2025.
- [9] H. F. Rabani and R. Aditya, "Analisis Peramalan Polutan PM 2.5 Dan PM 10 Di DKI Jakarta Timur Dengan SARIMA," 2024, doi: 10.13140/RG.2.2.10480.16646.
- [10] D. Bagus Wibowo, T. Purwaningsih, and R. Artikel, "Analisis Peramalan Jumlah Pengunjung Daya Tarik Wisata Kabupaten Bantul Dengan Metode Seasonal Autoregressive Integrated Moving Average (Sarima)," *Emerging Statistics and Data Science Journal*, vol. 1, no. 1, pp. 117–127, 2023, [Online]. Available: <https://visitingjogja.jogjaprov.go.id/>,
- [11] B. G. Prianda and E. Widodo, "PERBANDINGAN METODE SEASONAL ARIMA DAN EXTREME LEARNING MACHINE PADA PERAMALAN JUMLAH WISATAWAN MANCANEGARA KE BALI," *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, vol. 15, no. 4, pp. 639–650, Dec. 2021, doi: 10.30598/barekengvol15iss4pp639-650.
- [12] W. Gunawan and M. Ramadani, "Analisa Perbandingan Penerapan Metode SARIMA dan Prophet dalam Memprediksi Persediaan Barang PT XYZ," *Faktor Exacta*, vol. 16, no. 2, pp. 88–97, Jul. 2023, doi: 10.30998/faktorexacta.v16i2.13803.
- [13] N. E. Susanti, R. Saputra, and I. A. Situmorang, "Perbandingan Metode SARIMA, Double Exponential Smoothing dan Holt-Winter Additive dalam Peramalan Retail Sales Mobil Honda," *Jurnal Sains Matematika dan Statistika*, vol. 10, no. 1, pp. 58–70, Mar. 2024, doi: 10.24014/jsms.v10i1.26375.
- [14] I. B. N. Pascima and I. M. E. Listartha, "PERBANDINGAN METODE DEEP LEARNING PADA PERAMALAN DATA PENJUALAN," *Kumpulan Artikel Mahasiswa Pendidikan Teknik Informatika (KARMAPATI)*, vol. 14, no. 2, pp. 265–273, 2025.

- [15] W. Alwi and K. Nurfadilah, “Penerapan Metode SARIMA untuk Peramalan Jumlah Pengunjung Wisata Taman Nasional Bantimurung Bulusaraung Maros,” *JOMTA Journal of Mathematics: Theory and Applications*, vol. 3, no. 1, pp. 1–7, 2021, Accessed: Jun. 27, 2025. [Online]. Available: <https://ojs.unsulbar.ac.id/index.php/Mathematics/article/view/1221?d=2>
- [16] B. M. N. Malik R, “Prediksi Hasil Tangkap Ikan Laut di Kota Tanjungpinang Menggunakan Metode SARIMA,” *Jurnal Ilmiah KOMPUTASI*, vol. 22, no. 4, pp. 485–492, Dec. 2023, doi: <https://doi.org/10.32409/jikstik.22.4.3448>.
- [17] C. A. Soekendro, “PREDIKSI CURAH HUJAN DI KAB.BANDUNG DENGAN ANALISIS TIME SERIES, MENGGUNAKAN MODEL SARIMA (Seasonal Autoregressive Integrated Moving Average),” 2021.
- [18] I. K. R. Arthana, I. M. D. Maysanjaya, G. A. Pradnyana, and G. R. Dantes, “Optimizing Dropout Prediction in University Using Oversampling Techniques for Imbalanced Datasets,” *International Journal of Information and Education Technology*, vol. 14, no. 8, pp. 1052–1060, 2024, doi: [10.18178/ijiet.2024.14.8.2133](https://doi.org/10.18178/ijiet.2024.14.8.2133).
- [19] W. C. Utomo, “Prediksi Pergerakan Saham BBRI ditengah Issue Ancaman Resesi 2023 dengan Pendekatan Machine Learning Article Info ABSTRACT,” vol. 9, no. 1, pp. 20–27, 2023, [Online]. Available: <http://http://jurnal.unmer.ac.id/index.php/jtmi>