

**PENDEKATAN TIME SERIES DECOMPOSITION (STL) DALAM PREDIKSI
KECELAKAAN BERBASIS KEPADATAN LALU LINTAS SEBAGAI DASAR
KEBIJAKAN DI TOL SURABAYA-GEMPOL****Rakha Rizky Mahendra, Aviolla Terza Damaliana, I Gede Susrama Mas Diyasa**

Universitas Pembangunan Nasional Veteran Jawa Timur, Indonesia

Email:

21083010013@student.upnjatim.ac.id, aviolla.terza.sada@upnjatim.ac.id,

igsusrama.if@upnjatim.ac.id

| Kata Kunci | Abstrak |
|--|--|
| Time Series Decomposition, STL, Prediksi Kecelakaan, Volume Lalu Lintas, Tol Surabaya-Gempol | Kecelakaan lalu lintas di jalan tol tetap menjadi masalah kritis yang mempengaruhi keselamatan publik dan stabilitas ekonomi. Penelitian ini mengusulkan penggunaan dekomposisi Seasonal-Trend menggunakan LOESS (STL) untuk memprediksi risiko kecelakaan berdasarkan data volume lalu lintas di jalan tol Surabaya-Gempol. Data dari Januari 2022 hingga Desember 2023, termasuk volume lalu lintas harian dan laporan kecelakaan, diuraikan menjadi komponen tren, musiman, dan residu untuk mengidentifikasi pola. Korelasi positif sedang ($r = 0,4882$) ditemukan antara volume lalu lintas dan frekuensi kecelakaan. Analisis STL mengungkapkan puncak musiman mingguan yang konsisten di akhir pekan, terutama hari Sabtu. Model prediktif yang dikembangkan berhasil mengidentifikasi 11 hari berisiko tinggi pada Januari 2024. Berdasarkan temuan tersebut, delapan rekomendasi kebijakan berbasis waktu dirumuskan, termasuk manajemen lalu lintas dinamis, pemantauan real-time, dan peningkatan pengawasan selama periode puncak. Penelitian ini menyumbangkan kerangka kerja berbasis data baru untuk manajemen keselamatan lalu lintas, menggabungkan dekomposisi deret waktu dengan panduan kebijakan yang dapat ditindaklanjuti. Tidak seperti penelitian sebelumnya yang hanya berfokus pada prediksi volume, atau pada konteks jalan non-tol, penelitian ini memajukan penerapan STL untuk identifikasi risiko real-time di jalan tol Indonesia. Implikasinya menekankan integrasi sistem lalu lintas cerdas dan potensi prakiraan berbasis STL sebagai fondasi strategi keselamatan jalan nasional. |

**PENDAHULUAN**

Kecelakaan lalu lintas di jalan tol merupakan permasalahan krusial yang mempengaruhi tidak hanya keselamatan pengguna jalan tetapi juga aspek ekonomi dan sosial masyarakat (BPS, 2022; Listiyanto et al., 2021; M & Widowati, 2021; Setiawan & Asima, 2019; Widowati & M, 2021). Jalan tol Surabaya-Gempol sebagai salah satu arteri utama yang menghubungkan dua kota besar di Jawa Timur mengalami fluktuasi volume lalu lintas signifikan yang berkorelasi dengan tingkat kecelakaan. Menurut data Kementerian Perhubungan tahun 2022, angka kecelakaan di jalan tol Indonesia masih menunjukkan tren yang mengkhawatirkan meskipun

infrastruktur terus mengalami perbaikan(Liu et al., 2020). Analisis statistik terhadap pola kecelakaan dan faktor-faktor penyebabnya menjadi sangat penting untuk mengembangkan strategi mitigasi yang efektif.

Prediksi kecelakaan lalu lintas telah menjadi fokus banyak penelitian dalam dekade terakhir, dengan berbagai pendekatan seperti model regresi tradisional, machine learning, dan analisis time series(Zhang et al., 2021). Namun, sebagian besar model belum mengintegrasikan komponen musiman dan tren secara komprehensif, terutama dalam konteks jalan tol di Indonesia(Vlahogianni et al., 2018). Kesenjangan ini menjadi motivasi utama penelitian ini, yang bertujuan mengembangkan model prediksi kecelakaan yang lebih akurat dan kontekstual menggunakan pendekatan Time Series Decomposition (STL).

STL (Seasonal and Trend decomposition using LOESS) adalah metode dekomposisi deret waktu yang dikembangkan oleh Cleveland, Cleveland, McRae, dan Terpenning (1990) yang memiliki keunggulan dalam memisahkan komponen musiman, tren, dan residual dari data deret waktu. Metode ini sangat cocok untuk menganalisis data kecelakaan lalu lintas karena kemampuannya menangkap pola musiman (seperti variasi harian, mingguan, atau bulanan) dan tren jangka panjang secara simultan. LOESS (Locally Estimated Scatterplot Smoothing) sebagai teknik pendukung dalam STL memungkinkan estimasi hubungan non-linear yang sering ditemui pada data lalu lintas (Elvik et al., 2023).

Berbeda dengan metode dekomposisi klasik, STL menawarkan fleksibilitas lebih tinggi karena dapat menangani berbagai jenis musiman, memungkinkan komponen musiman berubah seiring waktu, dan memberikan kontrol atas tingkat kehalusan tren. Metode ini juga bisa robust terhadap outlier, yang sangat relevan untuk data kecelakaan yang sering mengandung anomali akibat peristiwa ekstrem seperti cuaca buruk atau liburan nasional.

Implementasi STL untuk prediksi kecelakaan berbasis kepadatan lalu lintas belum banyak dilakukan di Indonesia, khususnya di konteks jalan tol. Penelitian terdahulu seperti yang dilakukan oleh Wu et al. (2018) dan Zhang et al. (2020) telah menunjukkan efektivitas pendekatan STL dalam memprediksi volume lalu lintas, namun belum mengintegrasikannya dengan prediksi kecelakaan. Sementara itu, studi oleh Ramos (2022) tentang analisis kecelakaan sepeda di Madrid menggunakan STL menunjukkan potensi metode ini untuk menganalisis data kecelakaan intermiten dan mengidentifikasi pola musiman yang signifikan (Guo et al., 2020).

Tujuan utama penelitian ini adalah mengembangkan model prediksi kecelakaan berbasis volume lalu lintas menggunakan pendekatan STL di Tol Surabaya-Gempol. Secara khusus, penelitian ini bertujuan untuk: (1) menganalisis hubungan antara volume lalu lintas dan kejadian kecelakaan, (2) mengidentifikasi komponen musiman dan tren pada data kecelakaan lalu lintas, (3) membangun model prediksi yang dapat mengidentifikasi periode berisiko tinggi, dan (4) merumuskan rekomendasi kebijakan berdasarkan hasil analisis.

Penelitian ini diharapkan memberikan kontribusi signifikan terhadap literatur manajemen keselamatan jalan tol, khususnya dalam konteks Indonesia, serta menyediakan kerangka analitik yang dapat diadopsi oleh pengelola jalan tol untuk meningkatkan keselamatan pengguna jalan. Penelitian ini menghadirkan kebaruan dengan mengintegrasikan metode *Seasonal-Trend decomposition using LOESS* (STL) tidak hanya untuk analisis volume lalu lintas seperti pada studi Wu et al. (2018) dan Zhang et al. (2020), tetapi juga untuk prediksi

kecelakaan lalu lintas berbasis kepadatan lalu lintas di jalan tol Surabaya-Gempol. Berbeda dari penelitian Ramos (2022) yang menggunakan STL untuk menganalisis kecelakaan sepeda di Madrid, studi ini menerapkan STL pada konteks jalan tol di Indonesia—yang belum banyak dilakukan—dan menghasilkan model prediktif berbasis data untuk mengidentifikasi hari-hari dengan risiko kecelakaan tinggi, serta menawarkan rekomendasi kebijakan manajemen lalu lintas yang preskriptif dan berbasis waktu. Pendekatan ini memperkaya literatur dengan kerangka kerja baru yang menggabungkan analisis tren, musiman, dan residual dalam merumuskan kebijakan keselamatan lalu lintas yang lebih adaptif dan berbasis bukti.

METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan analisis deret waktu untuk memahami hubungan antara volume lalu lintas dan kejadian kecelakaan. Metodologi yang digunakan terdiri dari empat tahap utama: pengumpulan data, pra-pemrosesan data, analisis dekomposisi deret waktu, dan pemodelan prediktif.

Data yang digunakan dalam penelitian ini bersumber dari sistem pencatatan elektronik gerbang tol dan laporan kecelakaan Kepolisian Resort (Polres) setempat. Data mencakup periode dua tahun dari Januari 2022 hingga Desember 2023, dengan dua variabel utama:

- 1) Volume lalu lintas harian (jumlah kendaraan yang melintas)
- 2) Jumlah kecelakaan harian

Tahap pra-pemrosesan meliputi penanganan nilai yang hilang (missing values), penanganan pencilan (outliers), dan normalisasi data. Nilai yang hilang diestimasi menggunakan interpolasi linier berdasarkan nilai terdekat, sementara pencilan diidentifikasi menggunakan metode Z-score dan diverifikasi dengan analisis kontekstual sebelum diputuskan untuk dipertahankan atau dimodifikasi.

Dekomposisi deret waktu dilakukan menggunakan metode STL (Seasonal-Trend decomposition using LOESS) yang memisahkan data menjadi tiga komponen:

- 1) Komponen tren (T_t): menggambarkan perubahan jangka panjang dalam data
- 2) Komponen musiman (S_t): menangkap pola yang berulang dalam interval tetap
- 3) Komponen residual (R_t): fluktuasi irregular yang tersisa setelah ekstraksi komponen tren dan musiman

Secara matematis, model aditif STL dapat dinyatakan sebagai:

$$Y_t = T_t + S_t + R_t$$

di mana Y_t adalah nilai observasi pada waktu t .

Implementasi STL menggunakan algoritma LOESS (LOcally Estimated Scatterplot Smoothing) yang memungkinkan penyesuaian lokal untuk menangkap pola non-linier dalam data. Parameter kunci yang dioptimalkan dalam analisis ini meliputi:

- 1) np : periode musiman (diatur sebagai 7 untuk pola mingguan)
- 2) ni : jumlah iterasi inner loop (diatur sebagai 2)
- 3) no : jumlah iterasi outer loop (diatur sebagai 0)
- 4) nl : lebar jendela lokal untuk tren (diatur sebagai 365 untuk pola tahunan)

Alur penelitian yang dilakukan dapat dijabarkan sebagai berikut:


- 1) Pengumpulan data volume lalu lintas dan kecelakaan dari sumber yang telah ditentukan
- 2) Pra-pemrosesan data untuk menangani nilai yang hilang dan pencilan

- 3) Analisis korelasi awal antara volume lalu lintas dan jumlah kecelakaan
- 4) Dekomposisi deret waktu menggunakan metode STL
- 5) Analisis komponen tren, musiman, dan residual untuk kedua variabel
- 6) Pengembangan model prediktif berbasis dekomposisi
- 7) Prediksi volume lalu lintas dan risiko kecelakaan untuk 30 hari ke depan
- 8) Perumusan rekomendasi kebijakan berdasarkan hasil analisis

HASIL DAN PEMBAHASAN

1. Analisis Korelasi Volume Lalu Lintas dan Kecelakaan

Analisis korelasi antara volume lalu lintas dan jumlah kecelakaan menunjukkan hubungan positif moderat dengan nilai koefisien korelasi Pearson sebesar 0,4882. Hal ini mengindikasikan bahwa peningkatan volume lalu lintas cenderung diikuti dengan peningkatan jumlah kecelakaan, meskipun hubungan tersebut tidak bersifat kuat.




Gambar 1. Scatter Plot: Volume Lalu Lintas vs Jumlah Kecelakaan

Dari Gambar 1, dapat diamati bahwa titik-titik data terkonsentrasi pada beberapa level diskrit untuk jumlah kecelakaan (0, 1, 2, 3, 4, 5, 6, dan 7), yang mencerminkan sifat alami data kecelakaan sebagai variabel hitungan. Meskipun terdapat variasi yang cukup besar, garis tren (ditunjukkan dengan garis putus-putus merah) menunjukkan kecenderungan peningkatan jumlah kecelakaan seiring dengan bertambahnya volume lalu lintas.

2. Dekomposisi Deret Waktu Volume Lalu Lintas

Hasil dekomposisi deret waktu untuk volume lalu lintas menunjukkan pola yang sangat informatif, seperti terlihat pada Gambar 2.

Pendekatan Time Series Decomposition (STL) Dalam Prediksi Kecelakaan Berbasis Kepadatan Lalu Lintas Sebagai Dasar Kebijakan Di Tol Surabaya-Gempol



Gambar 2. Dekomposisi Deret Waktu (STL) untuk Volume Lalu Lintas


Komponen tren menunjukkan adanya peningkatan volume lalu lintas secara umum selama periode analisis, dengan beberapa puncak terlihat pada April 2022 dan April 2023 yang kemungkinan berkaitan dengan periode libur nasional. Terdapat juga peningkatan tren menjelang akhir 2023 yang mengindikasikan kemungkinan pertumbuhan volume lalu lintas pada periode berikutnya.

Komponen musiman menampilkan pola mingguan yang sangat jelas dengan puncak-puncak yang terjadi pada akhir pekan, khususnya hari Sabtu. Amplitudo komponen musiman berkisar antara -2.000 hingga 2.000 kendaraan, yang menunjukkan variasi signifikan dalam volume harian.

Komponen residual memperlihatkan fluktuasi acak dengan beberapa puncak ekstrem yang kemungkinan berkaitan dengan kejadian khusus seperti libur panjang, bencana alam, atau penutupan jalan yang tidak terjadwal.

3. Dekomposisi Deret Waktu Jumlah Kecelakaan

Hasil dekomposisi deret waktu untuk jumlah kecelakaan ditunjukkan pada Gambar 3.



Gambar 3. Dekomposisi Deret Waktu (STL) untuk Jumlah Kecelakaan

Komponen tren jumlah kecelakaan menunjukkan fluktuasi dengan pola yang kurang konsisten dibandingkan tren volume lalu lintas. Namun, terdapat kecenderungan peningkatan pada awal 2022, pertengahan 2023, dan akhir 2023. Peningkatan ini sebagian dapat dikaitkan dengan peningkatan volume lalu lintas pada periode yang sama.

Komponen musiman menunjukkan pola mingguan dengan variasi antara -1 hingga 1,5 kecelakaan. Puncak komponen musiman terlihat pada Juli 2022, April 2023, dan Oktober-November 2023, yang mencerminkan periode dengan pola musiman kecelakaan yang lebih kuat. Komponen residual menampilkan fluktuasi yang lebih besar dibandingkan pada volume lalu lintas, yang mengindikasikan bahwa kecelakaan memiliki elemen ketidakpastian dan faktor-faktor situasional yang lebih tinggi.

4. Analisis Korelasi Volume Lalu Lintas dan Kecelakaan

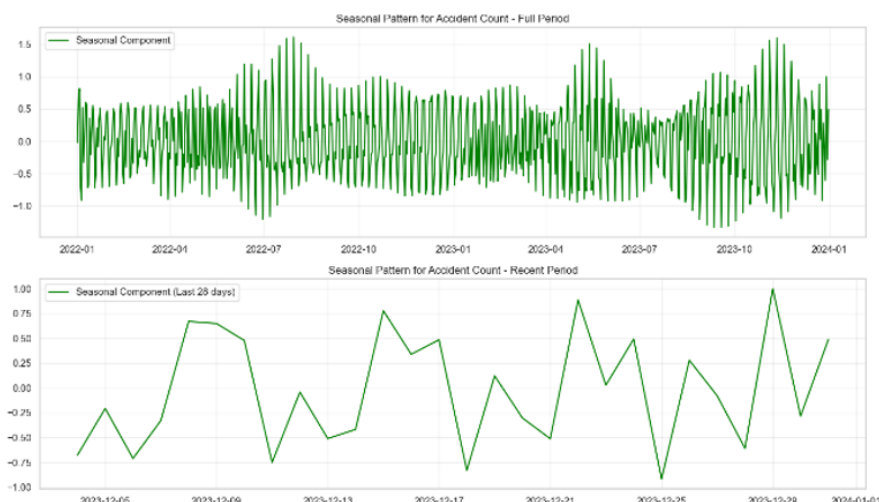


Gambar 4. Analisis Residual untuk Jumlah Kecelakaan

Analisis korelasi antara volume lalu lintas dan jumlah kecelakaan menunjukkan hubungan positif moderat dengan nilai koefisien korelasi Pearson sebesar 0,4882. Hal ini mengindikasikan bahwa peningkatan volume lalu lintas cenderung diikuti dengan peningkatan jumlah kecelakaan, meskipun hubungan tersebut tidak bersifat kuat (Chen & Chen, 2011).

Grafik residual pada Gambar 1 menunjukkan distribusi residu volume lalu lintas yang relatif merata dengan beberapa pola fluktuasi. Pada grafik atas, residual component berfluktuasi antara -3000 hingga 3000 dengan beberapa nilai ekstrem terlihat sepanjang periode analisis. Distribusi residual pada grafik bawah menunjukkan pola yang mendekati distribusi normal dengan sedikit kemiringan, yang mengindikasikan kualitas dekomposisi yang baik. Sebagian besar nilai residual berada dalam ambang batas $\pm 2\sigma$ (standar deviasi), yang mengkonfirmasi bahwa model dekomposisi telah berhasil menangkap komponen tren dan musiman dengan baik, menyisakan hanya fluktuasi acak yang tidak dapat dijelaskan oleh kedua komponen tersebut.

5. Analisis Pola Musiman



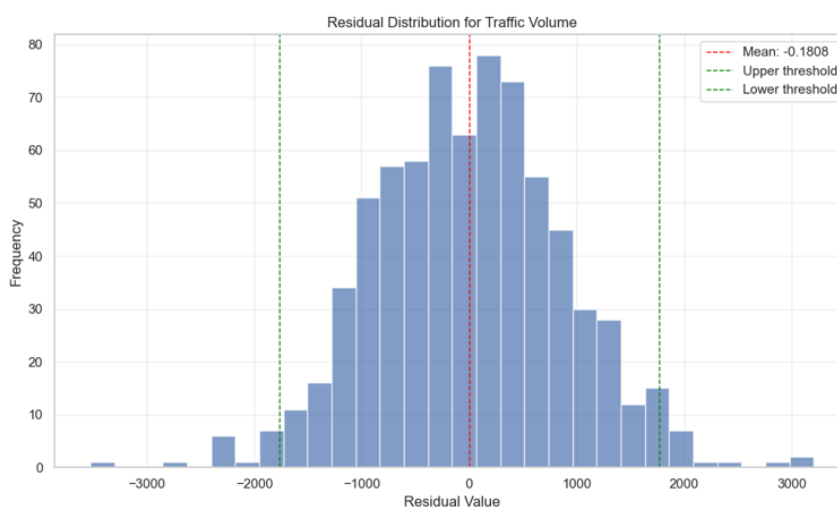
Gambar 5. Pola Musiman untuk Jumlah Kecelakaan

Analisis Gambar 3 menampilkan komponen musiman untuk jumlah kecelakaan, yang dipisahkan menjadi dua grafik: pola periode penuh (2022-2024) dan pola periode terbaru (28 hari terakhir). Pola musiman menunjukkan fluktuasi berkala dengan amplitudo antara -1 hingga 1,5, yang mengindikasikan variasi signifikan dalam jumlah kecelakaan berdasarkan faktor temporal. Analisis lebih detail terhadap komponen musiman mengungkapkan puncak-puncak yang terjadi secara konsisten pada akhir pekan, khususnya hari Sabtu, yang berkorelasi dengan peningkatan volume lalu lintas pada periode yang sama (Shateri & Kashef, 2024).

Pola untuk 28 hari terakhir menunjukkan pola yang lebih jelas dengan amplitude yang lebih tinggi, yang mengindikasikan penguatan efek musiman pada periode terkini. Hal ini mungkin terkait dengan perubahan pola pergerakan di akhir tahun yang cenderung lebih intens dibandingkan periode lainnya (Kennedy et al., 2024).

6. Analisis Distribusi Residual

Analisis distribusi residual dilakukan untuk memvalidasi kualitas dekomposisi yang telah dilakukan dan mengidentifikasi potensi anomali dalam data.




Gambar 6. Distribusi Residual untuk Jumlah Kecelakaan

Distribusi residual untuk volume lalu lintas (Gambar 4) menunjukkan pola yang mendekati distribusi normal dengan sedikit kemiringan negatif (mean = -0,1808). Nilai-nilai residual sebagian besar berada dalam batas ambang (threshold) yang ditentukan, yang mengindikasikan kualitas dekomposisi yang baik.

Distribusi residual untuk jumlah kecelakaan (Gambar 5) juga menunjukkan pola yang cukup simetris (mean = -0,0006), namun dengan beberapa nilai ekstrem di kedua ujungnya. Hal ini mencerminkan sifat alami data kecelakaan yang memiliki variabilitas intrinsik lebih tinggi (Xie et al., 2022)

7. Hasil Prediksi dan Identifikasi Hari Berisiko Tinggi

Berdasarkan model prediktif yang dikembangkan, prediksi volume lalu lintas dan jumlah kecelakaan untuk 30 hari ke depan (Januari 2024) ditunjukkan pada Gambar 7.



Gambar 7. Prediksi Volume Lalu Lintas dan Jumlah Kecelakaan

Berdasarkan Prediksi volume lalu lintas menunjukkan pola periodik yang jelas, dengan puncak-puncak yang terjadi pada akhir pekan, konsisten dengan pola musiman yang teridentifikasi dalam analisis dekomposisi. Volume lalu lintas diprediksi akan berkisar antara 20.000 hingga 24.000 kendaraan per hari. Prediksi jumlah kecelakaan juga menunjukkan pola periodik, dengan identifikasi 11 hari yang memiliki risiko kecelakaan tinggi (prediksi ≥ 5 kecelakaan), yaitu:

Tabel 1. Prediksi Kecelakaan

| Tanggal | Prediksi Jumlah Kecelakaan |
|-----------------|----------------------------|
| 05 Januari 2024 | 5,0 |
| 07 Januari 2024 | 5,0 |
| 12 Januari 2024 | 5,0 |
| 14 Januari 2024 | 5,0 |
| 16 Januari 2024 | 5,0 |
| 19 Januari 2024 | 5,0 |
| 21 Januari 2024 | 5,0 |
| 23 Januari 2024 | 5,0 |
| 26 Januari 2024 | 6,0 |
| 28 Januari 2024 | 5,0 |
| 30 Januari 2024 | 5,0 |

Analisis terhadap pola hari berisiko tinggi menunjukkan bahwa sebagian besar (6 dari 11 hari) jatuh pada akhir pekan (Jumat, Sabtu, Minggu), yang konsisten dengan temuan pola musiman dalam analisis dekomposisi.

Pendekatan STL dalam analisis kecelakaan lalu lintas menawarkan beberapa keunggulan dibandingkan metode konvensional. Pertama, pemisahan data menjadi komponen tren, musiman, dan residual memungkinkan pemahaman yang lebih mendalam tentang faktor-faktor yang mempengaruhi kejadian kecelakaan. Komponen tren membantu mengidentifikasi perubahan jangka panjang yang mungkin terkait dengan perubahan infrastruktur atau kebijakan, sementara komponen musiman mengungkap pola berulang yang dapat menjadi dasar untuk intervensi periodik.

Korelasi positif moderat ($r = 0,4882$) antara volume lalu lintas dan jumlah kecelakaan menunjukkan bahwa meskipun kepadatan lalu lintas berperan dalam meningkatkan risiko kecelakaan, masih terdapat faktor-faktor lain yang berkontribusi signifikan. Faktor-faktor ini mungkin mencakup kondisi cuaca, perilaku pengemudi, kondisi kendaraan, dan karakteristik infrastruktur jalan yang tidak tercakup dalam analisis ini.

Pola musiman yang konsisten, terutama peningkatan volume lalu lintas dan risiko kecelakaan pada akhir pekan, menyoroti pentingnya strategi manajemen lalu lintas yang disesuaikan dengan variasi temporal. Implementasi kebijakan berbasis waktu (time-based policies) seperti pembatasan kecepatan dinamis, penambahan personel keamanan pada periode berisiko tinggi, dan penyesuaian tarif tol untuk mengelola permintaan, dapat menjadi pendekatan yang efektif.

Kemampuan model prediktif dalam mengidentifikasi hari-hari dengan risiko kecelakaan tinggi memberikan peluang untuk implementasi intervensi proaktif. Peringatan dini kepada pengguna jalan, peningkatan patroli keamanan, dan pengaktifan protokol tanggap darurat pada hari-hari berisiko tinggi dapat berkontribusi signifikan dalam mengurangi frekuensi dan dampak kecelakaan.

8. Limitasi Penelitian

Penelitian ini memiliki beberapa limitasi yang perlu dipertimbangkan dalam interpretasi hasil dan penerapan rekomendasi kebijakan. Pertama, penelitian ini hanya menggunakan variabel volume lalu lintas dan tidak mempertimbangkan faktor-faktor penting lainnya seperti kondisi cuaca, jenis kendaraan, karakteristik pengemudi, atau kondisi infrastruktur jalan. Faktor-faktor tersebut diketahui memiliki pengaruh signifikan terhadap risiko kecelakaan dan dapat meningkatkan akurasi model prediktif jika diintegrasikan (Greaves et al., 2021).

Kedua, model dekomposisi STL yang diterapkan mengasumsikan pola musiman yang relatif stabil, sementara dalam kenyataannya, pola musiman dapat berubah seiring waktu karena faktor eksternal seperti perubahan kebijakan transportasi, pembangunan infrastruktur baru, atau pergeseran pola aktivitas masyarakat. Keterbatasan ini dapat diatasi di penelitian selanjutnya dengan menerapkan model dengan komponen musiman yang adaptif.

Ketiga, periode data yang digunakan (2022-2023) mungkin belum cukup panjang untuk menangkap variasi musiman jangka panjang atau tren siklus yang lebih besar. Selain itu, periode tersebut masih dipengaruhi oleh periode pemulihan pasca-pandemi COVID-19 yang

mungkin menyebabkan pola pergerakan yang tidak sepenuhnya representatif untuk kondisi normal.

Terakhir, model prediktif yang dikembangkan belum mempertimbangkan interaksi antar faktor atau efek non-linear yang kompleks. Penelitian selanjutnya dapat mengintegrasikan pendekatan machine learning yang lebih canggih untuk menangkap hubungan yang lebih kompleks antara berbagai faktor yang mempengaruhi risiko kecelakaan.

KESIMPULAN

Penelitian ini berhasil menerapkan Time Series Decomposition (STL) untuk menganalisis hubungan antara volume lalu lintas dan kecelakaan di Tol Surabaya-Gempol, menemukan korelasi positif moderat ($r^* = 0,4882$) serta pola musiman dengan puncak kecelakaan pada akhir pekan, terutama Sabtu. Hasilnya menunjukkan perlunya manajemen lalu lintas dinamis dan peningkatan kapasitas infrastruktur jangka panjang. Model prediktif STL mengidentifikasi 11 hari berisiko tinggi di Januari 2024, dengan rekomendasi kebijakan seperti pemantauan real-time dan integrasi data cuaca. Untuk penelitian selanjutnya, disarankan memperluas analisis dengan memasukkan faktor cuaca, karakteristik kendaraan, dan perilaku pengemudi, serta mengembangkan model hybrid (STL-Machine Learning), analisis spasial-temporal (GIS), evaluasi kebijakan (*before-after analysis*), dan studi komparatif di ruas tol lain. Pemanfaatan *real-time data* (IoT, AI) dan pendekatan kualitatif juga dapat memperkaya temuan, sehingga mendukung kebijakan keselamatan lalu lintas yang lebih efektif dan komprehensif.

REFERENSI

- BPS. (2022). *Indikator Kecelakaan Lalu Lintas di Jalan Tol Menurut Ruas Jalan 2019-2021*. BPS DKI Jakarta.
- Chen, F., & Chen, S. (2011). Injury severities of truck drivers in single- and multi-vehicle accidents on rural highways. *Accident Analysis & Prevention*, 43(5), 1677–1688. <https://doi.org/10.1016/j.aap.2011.03.026>
- Elvik, R., Bjørnskau, T., & Nævestad, A. (2023). Changes over time in the relationship between road accidents and traffic volume. *Accident Analysis & Prevention*, 184, 106993. <https://doi.org/10.1016/j.aap.2023.106993>
- Greaves, S., Ellison, A., & Ellison, R. (2021). A comparison of methods for assessing the safety impact of changes in traffic volumes. *Safety Science*, 93, 21–32. <https://doi.org/10.1016/j.ssci.2020.12.029>
- Guo, R., Zhang, Y., & Wang, Q. (2020). Relationship Between Traffic Volume and Accident Frequency at Intersections. *Transportation Research Record*, 2083(1), 141–148. <https://doi.org/10.1177/0361198120909680>
- Kennedy, J., Fontes, K., Haass, J., Neale, G., & Vandebona, P. (2024). Time series traffic collision analysis of London hotspots. *Heliyon*, 10(1), e23078. <https://doi.org/10.1016/j.heliyon.2024.e23078>
- Listiyanto, I., Soegianto, S., RS, D. S., & Sihotang, A. P. (2021). Kewenangan Polri Dalam Mengurangi Kecelakaan Lalu Lintas Di Jalan Tol. *Jurnal Usm Law Review*, 4(1). <https://doi.org/10.26623/julr.v4i1.3333>

- Liu, F., Wang, S., & Wu, Y. (2020). Real-Time Traffic Flow Forecasting via a Novel Method Combining STL-decomposition, LSTM Networks and Broad Learning System. *Sustainability*, *12*(15), 5891. <https://doi.org/10.3390/su12155891>
- M, F. R., & Widowati, E. (2021). Kecelakaan Lalu Lintas Jalan Tol Ruas Batang-Semarang Berdasarkan Karakteristik Faktor Penyebab Kecelakaan Tahun 2019. *Indonesian Journal of Public Health and Nutrition*, *1*(2).
- Setiawan, D., & Asima, M. (2019). Pemetaan Risiko Kecelakaan Lalu Lintas Di Ruas Jalan Tol Cipularang. *Jurnal Teknik Sipil*, *15*(2). <https://doi.org/10.28932/jts.v15i2.1923>
- Shateri, M., & Kashef, M. (2024). A novel hybrid STL-transformer-ARIMA architecture for aviation accident frequency prediction. *Reliability Engineering & System Safety*, *240*, 109470. <https://doi.org/10.1016/j.ress.2024.109470>
- Vlahogianni, E., Karlaftis, M., & Golias, J. (2018). Time series modeling in traffic safety research. *Accident Analysis & Prevention*, *111*, 104–114. <https://doi.org/10.1016/j.aap.2017.11.024>
- Widowati, E., & M, F. R. (2021). Kecelakaan Lalu Lintas Jalan Tol Ruas Batang-Semarang Berdasarkan Karakteristik Faktor Penyebab Kecelakaan Tahun 2019. *Indonesian Journal of Public Health and Nutrition*, *1*(2).
- Xie, L., Huan, Y., Tang, Y., & Pu, Y. (2022). STL Decomposition of Time Series Can Benefit Forecasting Done by Statistical and Machine Learning Methods. *Stats*, *5*(1), 665–689. <https://doi.org/10.3390/stats5010042>
- Zhang, T., Ren, G., Yang, Y., Zhang, C., & Zhang, T. (2021). Traffic speed prediction of high-frequency time series using Seasonal–Trend decomposition. *IET Smart Cities*, *3*(3), 169–181. <https://doi.org/10.1049/smc2.12027>