

Bangkitan Perjalanan *Rest Area* Jalan Tol: Model Regresi Multivariat pada Delapan Lokasi Trans-Jawa

Joko Sutrisno*,¹, Pratikso¹, Alfa Narendra²

¹Program Doktor Teknik Sipil, Fakultas Teknik, Universitas Islam Sultan Agung Semarang
Jl. Raya Kaligawe Km. 4, Jawa Tengah, Semarang, Jawa Tengah, 50112, Indonesia

²Fakultas Teknik, Universitas Negeri Semarang
Kampus UNNES Sekaran Gunungpati, Jawa Tengah, Semarang, 50229, Indonesia

*E-mail: 102023300010@std.unissula.ac.id

Diterima: 13 Mei 2025, direvisi: 17 Juli 2025, disetujui: 22 September 2025,
tersedia daring: 22 Desember 2025, diterbitkan: 29 Desember 2025

Abstrak

Penelitian ini bertujuan mengembangkan model prediktif bangkitan perjalanan pada Tempat Istirahat dan Pelayanan (TIP) atau *rest area* di jalan tol Indonesia. Data primer dikumpulkan dari delapan *rest area* aktif di koridor tol Trans-Jawa selama enam hari pada tahun 2024, yang mencakup dua periode berbeda, yaitu Lebaran (arus puncak) dan non-Lebaran (arus reguler). Pendekatan regresi multivariat digunakan untuk mengidentifikasi variabel signifikan yang memengaruhi volume kendaraan dan durasi lama singgah pengunjung, dengan membedakan variabel deterministik seperti luas lahan, jumlah nozel pompa SPBU, jumlah fasilitas standar dan tambahan, konektivitas, serta arah perjalanan dan karakteristik stokastik berupa ketidakpastian waktu kedatangan kendaraan pengunjung. Model prediktif dibangun terpisah untuk kedua periode guna menangkap variasi musiman perilaku pengguna jalan tol. Selain itu, dilakukan analisis fungsi distribusi probabilitas untuk menentukan distribusi statistik paling sesuai dalam memodelkan karakteristik stokastik lalu lintas pengunjung. Model divalidasi menggunakan uji chi-square, AIC, BIC, RMSE, MAE, dan MAPE untuk mendapatkan model terbaik masing-masing periode, serta dibandingkan dengan literatur dan standar teknis sebelumnya. Hasil penelitian menunjukkan bahwa pada periode Lebaran, keputusan singgah di *rest area* lebih dipengaruhi oleh ketersediaan SPBU bersubsidi dan kapasitas pompanya, sedangkan pada periode non-Lebaran lebih dipengaruhi oleh kelengkapan fasilitas di *rest area*. Pola kedatangan kendaraan ke *rest area* pada periode Lebaran menunjukkan fluktuasi yang jauh lebih tinggi dan mengikuti distribusi log-normal, sedangkan pada periode non-Lebaran pola kedatangan relatif stabil dengan sebaran yang lebih seragam (*uniform*). Model yang dihasilkan lebih akurat untuk kondisi di Indonesia dibandingkan dengan standar dan literatur sebelumnya. Model ini diharapkan menjadi dasar bagi standarisasi bangkitan perjalanan dan menjadi dasar pengambilan keputusan berbasis data untuk desain, pengelolaan, dan mitigasi *rest area* tol nasional.

Kata kunci: Bangkitan perjalanan, distribusi statistik, lama singgah, regresi multivariat, *rest area* tol.

Abstract

Trip Generation at Toll Road Rest Areas: A Multivariate Regression Model Across Eight Locations on the Trans-Java Corridor: This study aims to develop a predictive model of trip generation at rest areas along toll roads in Indonesia. Primary data were collected from eight active rest areas along the Trans-Java toll corridor over six consecutive days in 2024, encompassing two distinct traffic periods: the Lebaran (peak) season and the non-Lebaran (regular) period. A multivariate regression approach was employed to identify significant factors influencing vehicle volume and dwell time, distinguishing between deterministic variables such as land area, number of nozzle fuel pumps, standard and additional facilities, connectivity, and travel direction and stochastic characteristics representing the uncertainty of vehicle arrival times. Separate predictive models were developed for each traffic period to capture the seasonal dynamics of toll road user behavior. Furthermore, probability distribution analysis was conducted to determine the most appropriate statistical distribution for modeling traffic-related stochastic characteristics. Model validation was performed using chi-square tests, AIC, BIC, RMSE, MAE, and MAPE to identify the best-fitting regression models for each period and benchmark them against prior literature and established technical standards. The results indicate that during the Lebaran period, stopover decisions are primarily influenced by the availability of subsidized fuel and the pump capacity, whereas in the non-Lebaran period, facility completeness plays a more dominant role. Vehicle arrival patterns during the Lebaran period exhibited higher variability and aligned with a log-normal distribution, while in the non-Lebaran period, patterns were more stable and approached a uniform distribution. The proposed models demonstrated superior predictive performance under Indonesian conditions compared to existing models, offering a robust empirical foundation for future standardization of trip generation estimation and data-driven decision-making in the planning, management, and seasonal congestion mitigation of toll road rest areas.

Keywords: Dwell time, multivariate regression, probability distribution, toll road rest area, trip generation.

1. Pendahuluan

Indonesia mengalami peningkatan jumlah kendaraan bermotor yang signifikan, dengan 159 juta unit kendaraan tercatat pada tahun 2023, termasuk 16,39% di antaranya merupakan kendaraan penumpang [1]. Jumlah ini telah melampaui separuh populasi Indonesia yang mencapai 275,80 juta jiwa [2] dan volume kendaraan yang melintasi jalan tol juga konsisten mengalami peningkatan, seperti koridor Trans-

Jawa pada periode musim Lebaran 2024 yang mencapai 61 ribu kendaraan per hari, menunjukkan adanya kenaikan 38% dibandingkan pada periode non-Lebaran [3]. Hal ini memicu kepadatan ekstrem dan penumpukan kendaraan di *rest area* yang mengganggu kelancaran arus lalu lintas, juga menurunkan efisiensi operasional dan kenyamanan pengguna jalan tol akibat keterbatasan kapasitas parkir, antrean pengisian bahan bakar, dan durasi singgah yang tidak terkendali. Peningkatan jumlah kendaraan akan menambah beban infrastruktur jalan dan meningkatkan kebutuhan Tempat Istirahat dan Pelayanan (TIP) atau *rest area* [4]. *Rest area* memegang peranan penting dalam mendukung keselamatan dan kenyamanan pengguna jalan dengan ketersediaannya berbagai fasilitas [5][6][7].

Dalam perencanaan sistem transportasi empat tahap, bangkitan perjalanan merupakan tahap pertama untuk memprediksi jumlah perjalanan yang dihasilkan dari suatu wilayah atau fasilitas [8][9]. Hingga saat ini, Indonesia belum memiliki standar baku untuk memprediksi bangkitan perjalanan di *rest area*. Hal ini berbeda dengan negara-negara lain seperti Amerika Serikat dan Malaysia yang telah menerapkan standar melalui *Institute of Transportation Engineers Trip Generation Manual (ITE TGM)* dan *Malaysia Trip Generation Manual (MTGM)* [10]. Di Indonesia, *rest area* belum secara khusus diatur dalam kategori tersendiri oleh Kementerian Perhubungan, tetapi digolongkan sebagai pusat kegiatan yang menghasilkan bangkitan dan/atau tarikan lalu lintas, dengan bangkitan dihitung berdasarkan jumlah dispenser, luas lantai, atau volume lalu lintas.

Dalam ITE [11], kategori yang paling mendekati untuk *rest area* adalah *convenience store/gas station* (kode 945), dengan persamaan regresi menggunakan *gross floor area* sebagai variabel prediktor untuk memodelkan jumlah kendaraan yang masuk dan keluar (*trip ends*). Sementara itu, MTGM 2010 [12] dengan kategori *commercial areas, petrol service stations, and petrol stations with convenience stores* (kode 0707) menggunakan variabel seperti *thousand square feet* dan jumlah pompa, untuk memodelkan bangkitan perjalanan. Estimasi pada model prediktif yang dikeluarkan oleh ITE TGM dan MTGM dinilai berlebihan dan mempunyai perbedaan antara negara maju dan berkembang [13][14][15]. Pada penelitian sebelumnya menunjukkan bahwa pendekatan prediksi volume kendaraan yang menggunakan variabel GFA dan jumlah pompa menghasilkan perkiraan yang lebih rendah dibandingkan dengan standar MTGM sehingga memerlukan penyesuaian model dengan kondisi faktual [15].

Pemerintah Indonesia telah membangun lebih dari 2.800 Km jalan tol hingga tahun 2024, dengan lebih dari 132 *rest area* tersebar di berbagai ruas tol [2][16]. *Rest area* kini berkembang menjadi fasilitas multifungsi, sebagai tempat wisata dan pusat layanan [5]. *Rest area* juga menyediakan lebih dari sekadar fasilitas standar [5][17] sehingga memerlukan pendekatan yang lebih tepat dalam memprediksi jumlah kendaraan pengunjung. Evaluasi kelayakan fungsi jalan juga dinilai dari ketersediaan *rest area* dan kualitas permukaan jalan yang berpengaruh terhadap perilaku pengemudi [18][19].

Berdasarkan latar belakang tersebut, pertanyaan utamanya adalah variabel apa saja yang memengaruhi kedatangan kendaraan dan durasi lama singgah (*dwelt time*) pengunjung di *rest area* jalan tol di Indonesia. Selanjutnya, bagaimana model prediktif yang tepat dapat dirumuskan berdasarkan kondisi aktual di lapangan. Untuk menjawab pertanyaan tersebut, penelitian ini bertujuan membangun model deterministik melalui regresi multivariat untuk volume kendaraan dan lama singgah pengunjung secara terpisah untuk periode Lebaran dan non-Lebaran, dengan menggunakan data primer. Selain mengidentifikasi variabel deterministik (seperti luas lahan, jumlah nozel pompa, ketersediaan fasilitas, dll.) dan karakteristik stokastik (ketidakpastian) yaitu waktu kedatangan pengunjung, penelitian ini juga mengembangkan model terbaik yang dibandingkan dengan literatur dan standar sebelumnya. Dengan demikian, penelitian ini diharapkan berkontribusi terhadap pengembangan standar *trip generation* di *rest area* dan menjadi acuan dalam perencanaan fasilitas, kapasitas, dan mitigasi kemacetan musiman.

2. Metodologi

2.1. Metode Pengumpulan Data

Penelitian ini menggunakan metode survei primer dengan tujuan mengumpulkan data volume kendaraan pengunjung dan durasi lama singgah (*dwelt time*) selama periode Lebaran dan non-Lebaran sebagai dasar untuk membangun model prediksi bangkitan perjalanan (*trip generation*) di *rest area*.

Pemilihan sampel *rest area* menggunakan teknik *purposive sampling* [20] dengan mempertimbangkan kriteria dengan representasi dari tiga kategori *rest area* (tipe A, B, dan C) sesuai klasifikasi yang diatur dalam Permen PUPR No. 28/2021. *Rest area* yang dipilih berada pada koridor Trans-Jawa yang mencakup sekitar 72% dari total populasi *rest area* di Indonesia dan secara spasial terdapat pada klaster di Provinsi Jawa Tengah sebagai wilayah yang diyakini sebagai titik henti utama dan titik kumpul arus mudik terbesar di Indonesia. Kriteria lokasi penelitian *rest area* yaitu mempunyai kinerja pelayanan yang terbaik dan tentunya telah mendapatkan perizinan dari pengelola untuk dilakukan survei lapangan. Survei dilaksanakan pada tahun 2024 selama 6 hari di delapan *rest area* pada ruas Jalan Tol Trans-Jawa, khususnya segmen antara Kabupaten Batang hingga Kota Surakarta. Tabel 1 menampilkan delapan titik *rest area* yang disurvei, lengkap dengan tipenya, arah perjalanan, dan pengelolanya.

Pengumpulan data dilakukan dengan pemasangan tiga unit kamera 360° pada setiap *rest area*, yang ditempatkan pada pintu masuk, pintu keluar, dan area parkir. Setiap kamera merekam secara *real-time* selama 24 jam dan menghasilkan data visual yang dikumpulkan melalui *time-stamped video-based data acquisition system* untuk aktivitas kendaraan masuk-keluar serta pengunjung yang menggunakan fasilitas parkir, toilet, tempat ibadah, tempat makan dan minum, serta istirahat. Data visual kemudian diolah dengan cara mengidentifikasi nomor kendaraan, waktu kedatangan (masuk), dan waktu keberangkatan (keluar), serta mendeteksi fasilitas yang digunakan termasuk lokasi parkir di dalam *rest area*. Pembacaan nomor kendaraan dimaksudkan untuk menghindari pengulangan pembacaan data kendaraan sekaligus untuk pemilihan jenis kendaraan sesuai kategori Pedoman Kapasitas Jalan Indonesia 2023 [21].

Survei ini dilakukan selama periode arus mudik dan arus balik Lebaran tahun 2024 dan periode non-Lebaran (hari biasa), termasuk pada akhir pekan (*weekend*) dan hari kerja (*weekdays*). Pendekatan ini dirancang untuk menangkap variasi volume kendaraan pengunjung, durasi lama singgah, dan pola kecenderungan penggunaan fasilitas *rest area* yang berbeda secara musiman dan temporal.

2.2. Pengolahan Data

Pengolahan data penelitian ini diawali dengan proses ekstraksi dari rekaman video menggunakan perangkat lunak pemutar video (*media player*) dan pencatatan manual terstruktur melalui Google Sheets. Proses pencacahan data dibuat berdasarkan lokasi *rest area*, periode survei (Lebaran atau non-Lebaran), arah perjalanan (menuju atau meninggalkan Jakarta), jenis kendaraan, waktu kedatangan dan keberangkatan, serta penggunaan fasilitas. Data ini kemudian disusun untuk menghasilkan data volume kendaraan dengan agregasi 15 menit dan estimasi lama singgah tiap pengunjung dengan parameter data kunci yaitu nomor kendaraan dan jam masuk-keluar *rest area*.

Setelah data tersusun, proses dilanjutkan dengan meningkatkan akurasi dan validitas data dengan proses *cleansing* dan *grouping* berdasarkan acuan Pedoman Kapasitas Jalan Indonesia 2023 [21][22]. Tahap *cleansing* bertujuan untuk menghapus data anomali atau *outlier* yang mungkin terjadi selama perekaman dan memastikan bahwa data yang digunakan untuk analisis merepresentasikan kondisi di lapangan. Sementara itu, *grouping* dilakukan untuk mengagregasi data ke dalam interval waktu 15 menit guna meningkatkan jumlah observasi, memperbaiki kualitas statistik dataset, dan mengurangi risiko *overfitting* dalam proses pemodelan regresi nantinya.

Tabel 1. Lokasi *rest area* yang disurvei

No.	Lokasi <i>Rest area</i>	Kabupaten/Kota	Arah	Tipe TIP	BUJT
1	KM 379, Gringsing	Kab. Batang	A	A	Jasa Marga Batang Semarang
2	KM 389, Jatirejo	Kab. Kendal	B	A	
3	KM 391, Rowoaking	Kab. Kendal	A	B	
4	KM 429, Ungaran	Kab. Semarang	A	A	Transmarga Jateng
5,6	KM 456, Pabelan	Kota Salatiga	B/A	B	
7,8	KM 487, Gumuk Rejo	Kab. Boyolali	B/A	B	

Keterangan: KM = Kilometer; Arah A meninggalkan Jakarta dan B menuju Jakarta; TIP = Tempat Istirahat dan Pelayanan (*rest area*); BUJT = Badan Usaha Jalan Tol; BPJT = Badan Pengatur Jalan Tol.

Dataset yang dianalisis dalam penelitian ini berjumlah 1.536 observasi yang merupakan hasil pengolahan dari 8 lokasi *rest area* $\times$ 2 periode waktu (Lebaran dan non-Lebaran atau *weekend* dan *weekdays*) $\times$ 24 jam $\times$ 4 agregasi per jam, dengan interval waktu setiap 15 menit. Setiap observasi mencatat volume kendaraan dan estimasi durasi lama singgah pengunjung berdasarkan identifikasi waktu kedatangan dan keberangkatan kendaraan yang tercatat melalui rekaman visual.

Seluruh data observasi yang merupakan data kuantitatif diklasifikasikan ke dalam dua kategori analisis utama yaitu (1) kategori musiman, yang membedakan antara periode Lebaran dan non-Lebaran; dan (2) kategori temporal, yang membedakan antara *weekend* (akhir pekan) dan *weekdays* (hari kerja). Setelah data dikelompokkan, dilakukan analisis statistik deskriptif untuk masing-masing lokasi *rest area* dan kategori periode Lebaran dan non-Lebaran. Volume kendaraan dan lama singgah disajikan dalam bentuk rerata per interval waktu 15 menit untuk menyederhanakan kompleksitas variasi data dan mendukung proses pemodelan regresi multivariat.

2.2.1. Uji Normalitas dan Uji Beda Kelompok Data Antar periode

Dalam penelitian ini, uji normalitas diterapkan pada variabel utama, yaitu volume kendaraan pengunjung *rest area*. Pengujian dilakukan menggunakan metode *shapiro-wilk test* pada tingkat signifikansi (α) sebesar 5%. Metode ini dipilih karena memiliki sensitivitas tinggi dan direkomendasikan untuk ukuran sampel kecil hingga menengah sebagaimana karakteristik data penelitian ini. Hasil pengujian dengan sebagian besar data memiliki *p-value* $< 0,05$, artinya data tidak mengikuti distribusi normal secara statistik. Maka, analisis uji beda antarkelompok dilakukan menggunakan pendekatan non-parametrik.

Metode non-parametrik yang digunakan yaitu *wilcoxon rank-sum test* untuk membandingkan dua kelompok data yang tidak berpasangan (independen) dan *wilcoxon signed-rank test* untuk dua kelompok data berpasangan (dependen) [23]. Pemilihan metode ini didasarkan pada keunggulannya dalam mengatasi distribusi data yang tidak normal dan sensitivitasnya terhadap median perbedaan antar kelompok data. Sebagai pelengkap, visualisasi grafis *boxplot* dan histogram digunakan untuk menggambarkan sebaran dan potensi *outlier* dalam data. Kriteria pengambilan keputusan didasarkan pada *p-value* $< 0,05$ sebagai ambang signifikansi. Jika hasil pengujian menghasilkan *p-value* $< 0,05$, maka dapat disimpulkan bahwa terdapat perbedaan yang signifikan secara statistik antara kedua kelompok data yang dibandingkan. Secara metodologis, uji beda ini memberikan justifikasi yang kuat untuk melakukan pemisahan model prediktif antara periode Lebaran dan non-Lebaran.

2.2.2. Uji Statistik Deskriptif

Analisis statistik deskriptif digunakan untuk menggambarkan karakteristik distribusi volume kendaraan pada interval 15 menit di *rest area* yang dikelompokkan ke dalam dua periode, yaitu periode Lebaran dan non-Lebaran. Parameter statistik yang dianalisis mencakup *mean* (rerata), median, simpangan baku, varian, *skewness*, dan *kurtosis* [24][25]. Interpretasi gabungan antara nilai *skewness* dan *kurtosis* digunakan untuk mengidentifikasi pola distribusi seperti distribusi simetris dengan kurtosis negatif (*platykurtic*) atau distribusi miring dengan puncak tajam (*leptokurtic*) sehingga memungkinkan penilaian terhadap sebaran data di setiap periode observasi.

Untuk memeriksa bentuk distribusi data, dilakukan uji normalitas *kolmogorov-smirnov* dan *shapiro-wilk* dengan tingkat signifikansi 5% ($\alpha = 0,05$). Hipotesis nol (H_0) pada kedua uji tersebut menunjukkan bahwa data mengikuti distribusi normal. Keputusan statistik diambil berdasarkan *p-value* $< 0,05$, di mana H_0 ditolak sehingga data tidak terdistribusi normal, maka dilanjutkan dengan pendekatan non parametrik untuk mendapatkan peluang distribusi data (*probability data function/PDF*).

2.2.3. Uji Kecocokan Peluang Distribusi Data

Uji kecocokan distribusi statistik dilakukan untuk menentukan model probabilitas terbaik yang merepresentasikan pola kedatangan kendaraan ke *rest area* per interval 15 menit pada periode Lebaran dan non-Lebaran. Data awal dieksplorasi menggunakan grafis histogram dan *boxplot* untuk melihat pola sebaran dan nilai ekstrem.

Berbagai jenis distribusi diuji, termasuk distribusi Normal, Log-Normal, Poisson, Eksponensial, Gamma, Negatif Binomial, Geometrik, Uniform, Logistik), Cauchy, dan Weibull, terhadap data aktual. Evaluasi dilakukan menggunakan *Goodness-of-Fit Test* (uji *Chi-Square*) dan kriteria informasi AIC (*Akaike Information Criterion*) dan BIC (*Bayesian Information Criterion*), yang menilai keseimbangan antara tingkat kecocokan dan kesederhanaan model. Model terbaik ditentukan berdasarkan nilai AIC dan BIC terendah serta $p\text{-value Chi-Square} > 0,05$. Metode ini mendukung validasi pemilihan model stokastik yang akurat untuk menggambarkan pola distribusi kedatangan pengunjung.

2.2.4. Pemilihan Variabel Signifikan

Variabel-variabel yang digunakan berdasarkan hasil telaah literatur sebelumnya, yaitu standar teknis (ITE TGM, MTGM, Permenhub), termasuk variabel GFA [26], jumlah pompa bahan bakar [12], jumlah fasilitas layanan [5], serta temuan faktual di lapangan (*connecting*, fasilitas tambahan, jarak antar *rest area*, dll.). Dalam pengambilan keputusan untuk membuat *rest area* baru, variabel yang penting adalah variabel yang bisa dipengaruhi oleh calon investor *rest area*.

Pemilihan variabel independen (prediktor) terbaik yang menjelaskan variabel dependen (volume kendaraan dan lama singgah) [27]. Pendekatan yang digunakan yaitu: (1) validasi pakar dalam *focus group discussion* dengan akademisi transportasi, BUJT dan BPJT; (2) metode *stepwise regression* dengan memasukkan atau mengeluarkan variabel berdasarkan signifikansi statistik; (3) uji multikolinearitas dengan nilai *variance inflation factor* (*VIF*), untuk mengeliminasi prediktor yang memiliki hubungan linear tinggi dan redundansi antarprediktor yang dapat mengganggu stabilitas model; (4) uji determinasi (R^2 dan *adjusted R*²) untuk mengetahui kinerja model melalui besarnya variasi-variabel dependen dapat dijelaskan oleh prediktor yang dipilih. $p\text{-value}$ berfungsi sebagai alat untuk memvalidasi hipotesis statistik terhadap data yang diamati, di mana $p\text{-value} < 0,05$ dianggap signifikan, menandakan bahwa variabel-variabel bebas memiliki kekuatan prediktif yang signifikan terhadap volume kendaraan di *rest area* [28][29][30].


2.2.5. Model Deterministik melalui Regresi Multivariat

Model deterministik dalam penelitian ini dikembangkan untuk memprediksi volume kendaraan dan lama singgah pengunjung *rest area* pada jalan tol, meliputi variabel-variabel prediktor yang bersifat terukur dan dapat dikendalikan. Pemodelan dilakukan dengan pendekatan regresi linear multivariat berbasis data panel, yang dianalisis menggunakan perangkat lunak SPSS dan R Studio. Struktur panel dibentuk dari klaster lokasi *rest area* dan periode Lebaran dan non-Lebaran.

Proses estimasi model dilakukan dalam dua skema, yaitu *OLS* (*ordinary least squares*) untuk pendekatan *baseline* dan *mixed-effects models* untuk mempertimbangkan variansi antar lokasi dan perbedaan temporal antar periode [23][31]. Variabel independen yang digunakan mencakup indikator deterministik seperti GFA, jumlah nozel pompa SPBU, jumlah fasilitas standar dan tambahan, status konektivitas, serta arah perjalanan. Pemilihan variabel dilakukan dengan metode *stepwise regression* berbasis nilai signifikansi dan *VIF* untuk menghindari multikolinearitas. Meskipun jumlah data analisis terbatas pada delapan *rest area*, akan tetapi volume observasi ditingkatkan melalui agregasi data per 15 menit, menghasilkan dataset yang memungkinkan model menangkap dinamika lalu lintas harian.

2.2.6. Validasi Model dan Evaluasi Kinerja Prediktif

Validasi model dilakukan untuk mengevaluasi kualitas dan reliabilitas prediksi dari model regresi multivariat yang dikembangkan. Beberapa pendekatan evaluasi digunakan secara komplementer, yaitu pertama, koefisien determinasi (R^2 dan *adjusted R*²) digunakan untuk mengukur proporsi variasi variabel dependen yang dijelaskan oleh variabel independen dalam model linear. Nilai R^2 yang tinggi mengindikasikan kecocokan model yang baik, namun perlu dikombinasikan dengan metrik lainnya karena R^2 cenderung meningkat seiring dengan bertambahnya jumlah variabel. Kedua, pemilihan model terbaik dilakukan dengan membandingkan nilai AIC dan BIC. AIC menyeimbangkan antara kecocokan dan kompleksitas model, sedangkan BIC memberikan penalti lebih tinggi terhadap kompleksitas sehingga cenderung memilih model yang lebih sederhana. Model dengan nilai AIC dan BIC yang lebih rendah dipilih sebagai model yang paling optimal [32][33][34].



Gambar 1. Boxplot volume kendaraan setiap rest area

Ketiga, untuk menilai akurasi prediktif secara kuantitatif digunakan metrik kesalahan prediksi yaitu: *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE) [35]. RMSE mengukur rata-rata kesalahan kuadrat dan sensitif terhadap *outlier*, sementara MAE memberikan ukuran kesalahan rata-rata absolut yang lebih *robust*. MAPE digunakan untuk menyampaikan kesalahan dalam bentuk persentase. Model yang dipilih adalah yang menunjukkan nilai RMSE dan MAE terendah, nilai R^2 tertinggi, serta keseimbangan optimal antara AIC dan BIC [36].

2.3. Analisis Data


2.3.1. Volume Kendaraan Pengunjung Selama Interval 15 Menit

Data volume kendaraan yang memasuki *rest area* dianalisis dengan interval 15 menit selama 24 jam. Pola kedatangan ini divisualisasikan dalam grafik *boxplot* pada Gambar 1, yang menggambarkan distribusi dan fluktuasi volume kendaraan per interval waktu di masing-masing *rest area*. Sumbu horizontal menunjukkan interval waktu dan lokasi *rest area* pengamatan, dimulai dari pukul 00:00 hingga 23:45, sedangkan sumbu vertikal menunjukkan volume kendaraan yang tercatat.

Secara konsisten, *rest area* KM 389 menunjukkan volume kunjungan kendaraan tertinggi. Hal ini dipengaruhi posisi strategisnya di jalur utama arus mudik arah barat menuju Semarang dan Surakarta, serta kelengkapan fasilitasnya sebagai *rest area* tipe A. Keberadaan *outlier* pada grafik *boxplot*, khususnya pada periode Lebaran, mengindikasikan adanya lonjakan volume kendaraan yang secara statistik dikategorikan sebagai anomali. Namun, dalam konteks di Indonesia, lonjakan ini merupakan pola yang konsisten dan terprediksi sebagai respons terhadap arus mudik tahunan sehingga dapat dikatakan sebagai anomali yang bersifat sistemik dan bukan kejadian acak.

2.3.2. Lama Singgah (Dwell Time)

Analisis lama singgah kendaraan di *rest area* bertujuan untuk memahami pola perilaku istirahat pengunjung berdasarkan jenis kendaraan dan waktu kunjungan. Grafik visualisasi pada Gambar 2 dengan absis jenis kendaraan di *rest area* dan ordinatnya yaitu lama singgah (jam), menunjukkan bahwa truk berat memiliki durasi singgah terpanjang di sebagian besar lokasi *rest area*. Secara keseluruhan, rerata kebutuhan lama singgah antara 1 sampai 2 jam.



Keterangan: WE: *Weekend* (Akhir pekan); WD: *Weekdays* (hari kerja); MP: Mobil Penumpang, KS: Kendaraan Sedang, BB: Bus Besar, dan TB: Truk Berat

Gambar 2. Grafik lama singgah berbagai jenis kendaraan di setiap *rest area*


2.3.3. Uji Normalitas dan Uji Beda Kelompok Data

Grafik visualisasi dan statistik deskriptif untuk mendukung uji normalitas dan uji beda kelompok data disajikan pada Gambar 3, dan Tabel 2. *Boxplot* menunjukkan distribusi data lebaran memiliki rentang lebih luas dan kemunculan nilai ekstrem, mengindikasikan lonjakan yang signifikan selama masa puncak arus mudik dan balik. Histogram juga mendukung temuan ini dengan menunjukkan *skewness* ke kanan (positif), khas dari distribusi log normal yang sering digunakan dalam model stokastik lalu lintas.



Analisis statistik deskriptif pada Tabel 2 menunjukkan rerata kedatangan kendaraan per 15 menit tercatat sebesar 28,80 kendaraan pada periode Lebaran, dengan jumlah maksimum 79 kendaraan dan *skewness* sebesar 1,13 artinya sebaran yang tidak simetris. Sebaliknya, rerata kedatangan kendaraan

Tabel 2. Statistik deskriptif periode Lebaran dan non-Lebaran

Deskriptif Statistik	Lebaran	Non-Lebaran
Vars	1,00	1,00
N	96,00	96,00
Mean	28,80	30,34
Min	7,00	10,00
Max	79,00	52,00
Skew	1,13	0,02
Kurtosis	0,42	-1,26



Gambar 3. *Boxplot* perbedaan volume kendaraan per 15 Menit

Gambar 5. Grafik *skewness-kurtosis* periode LebaranGambar 6. Grafik *skewness-kurtosis* periode non-LebaranTabel 3. Distribusi *fitting* data lebaran

No.	Distribusi	AIC	BIC
1	norm	803,9643	809,0930
2	lnorm	766,3358	771,4645
3	exp	839,2060	841,7703
4	pois	1222,6663	1225,2306
5	cauchy	802,4030	807,5317
6	gamma	772,4869	777,6156
7	unif	825,1199	830,2486
8	logis	801,1346	806,2633
9	nbinom	774,3314	779,4601
10	geom	842,5011	845,0655
11	weibull	782,8453	787,9740

Tabel 4. Distribusi *fitting* data non-Lebaran

No.	Distribusi	AIC	BIC
1	norm	751,3017	756,4304
2	lnorm	757,9875	763,1162
3	exp	849,2174	851,7817
4	pois	965,3095	967,8738
5	cauchy	806,6742	811,8029
6	gamma	751,9859	757,1146
7	unif	721,6326	726,7613
8	logis	760,0746	765,2033
9	nbinom	751,7010	756,8297
10	geom	852,3469	854,9113
11	weibull	746,8088	751,9375

mencapai 30,34 kendaraan per 15 menit pada periode non-Lebaran, dengan distribusi yang lebih simetris (*skewness* = 0,02) dan lebih terkendali (*kurtosis* = -1,26).

2.3.4. Persamaan Distribusi Data (PDF)

Grafik *cullen and frey* yang disajikan pada Gambar 5 menunjukkan bahwa sebaran data mendekati garis log normal pada periode Lebaran, sedangkan pada Gambar 6 mendekati garis *uniform* (seragam) pada periode non-Lebaran. Pada Tabel 3 menunjukkan hasil *fitting* distribusi untuk data volume kendaraan per 15 menit pada periode Lebaran, distribusi log normal terpilih sebagai model paling sesuai,

dengan nilai AIC = 766,34 dan BIC = 771,46 yang terendah di antara semua kandidat distribusi. Persamaan log normal yang dihasilkan berdasarkan yaitu $meanlog(\mu) = 3,2285987$, dan $sdlog(\sigma) = 0,5081197$, dengan formulasi:

$$f(x) = \frac{1}{x \times 0.5081197 \sqrt{2\pi}} \exp\left(-\frac{(\ln x - 3.2285987)^2}{2 \times (0.5081197)^2}\right) \quad (1)$$

Nilai $f(x)$ pada persamaan (1) memberikan peluang relatif terjadinya jumlah kendaraan sebesar x , di mana fungsi ini bersifat positif *skewed* dan cocok untuk data dengan distribusi tidak simetris, seperti yang umum terjadi pada volume lalu lintas musiman seperti Lebaran.

Pada Tabel 4 menunjukkan hasil uji distribusi pada periode non-Lebaran, dengan nilai AIC = 721,63 dan BIC = 726,76 yang terendah sehingga terpilih distribusi *uniform*. Model ini menunjukkan bahwa data tersebar secara relatif merata dalam rentang tertentu. Persamaan *pdf uniform* dengan nilai min 10, max 52, dengan formulasi:

$$f(x; 10; 52) = \left\{ \frac{1}{52-10}, 0 \leq x \leq 52 \right\} \quad (2)$$

Fungsi distribusi probabilitas *uniform* (seragam) pada persamaan (2) menunjukkan peluang kehadiran kendaraan sebanyak x dalam interval 15 menit adalah sama besar untuk semua nilai antara 10 dan 52 kendaraan. Nilai probabilitasnya konstan, yaitu $1/(52-10) = 1/42$, selama x berada dalam rentang tersebut. Di luar rentang ini, probabilitasnya adalah nol.

2.3.5. Variabel Penelitian

Variabel prediktor yang memengaruhi prediksi volume kendaraan dan lama singgah pada periode Lebaran dan non-Lebaran disajikan pada Tabel 5, mencakup X_1 : GFA dalam hektar; X_2 : Jumlah *nozle* pompa SPBU; X_3 : Jumlah fasilitas standar; X_4 : Jumlah fasilitas tambahan; X_5 : Status konektivitas; X_6 : Arah ke Jakarta; X_7 dan X_8 : Jarak sebelum dan sesudah *rest area* - dalam kilometer; X_9 : Kapasitas parkir dalam satuan ruang parkir.

Periode Lebaran, korelasi variabel sesuai Tabel 6 menunjukkan bahwa dari 9 variabel yang diuji, hanya 2 variabel yang signifikan, yaitu GFA (X_1) dan jumlah *nozle* pompa SPBU (X_2). GFA memiliki korelasi positif yang kuat dengan volume kendaraan, dengan nilai Pearson sebesar 0.92 dan *p-value* sebesar 0,01 ($p < 0,05$). Sementara itu, jumlah *nozle* pompa SPBU (X_2) berkorelasi sangat kuat dengan volume kendaraan, dengan nilai Pearson sebesar 0.96 dan *p-value* = 0,000 ($p < 0,05$).

Tabel 5. Variabel model deterministik (X_1 sampai dengan X_9)

Lokasi	Kode	Kota/Kab	Lebaran	Σ Kendaraan Rerata	Lama Singgah Rerata
KM	TIP		L/NL	Y_1 (Kend./hari)	Y_2 (detik)
KM 379, Gringsing	B 379	Kab. Batang	Lebaran	1718	4103,11
KM 379, Gringsing	B 379	Kab. Batang	Lebaran	1650	4902,67
KM 389, Jatirejo	A 389	Kab. Kendal	Lebaran	2257	27547,32
KM 389, Jatirejo	A 389	Kab. Kendal	Non-Lebaran	5123	22149,28
KM 391, Rowoaking	B 391.4	Kab. Kendal	Lebaran	337	5772,03
KM 391, Rowoaking	B 391.4	Kab. Kendal	Lebaran	289	3317,77
KM 429, Ungaran	A 429	Kab. Semarang	Non-Lebaran	1395	5434,23
KM 429, Ungaran	A 429	Kab. Semarang	Non-Lebaran	2249	6190,57
KM 456, Pabelan	B 456	Kota Salatiga	Non-Lebaran	729	2805,50
KM 456, Pabelan	B 456	Kota Salatiga	Non-Lebaran	726	4731,42
KM 456, Pabelan	A 456	Kota Salatiga	Non-Lebaran	1480	2508,45
KM 456, Pabelan	A 456	Kota Salatiga	Non-Lebaran	709	4296,94
KM 487, Gumukrejo	B 487	Kab. Boyolali	Non-Lebaran	390	2627,22
KM 487, Gumukrejo	B 487	Kab. Boyolali	Non-Lebaran	577	4938,58
KM 487, Gumukrejo	A 487	Kab. Boyolali	Non-Lebaran	546	2905,06
KM 487, Gumukrejo	A 487	Kab. Boyolali	Non-Lebaran	294	1955,63

Lokasi	GFA	Jumlah Nozel	Σ Fasilitas Standar	Σ Fasilitas Tambahan	Connecting	Menuju Jakarta	Jarak Sebelum	Jarak Sesudah	Kapasitas Parkir
KM	X ₁ (Ha)	X ₂ (Unit)	X ₃ (Jenis)	X ₄ (Jenis)	X ₅ (C/NC)	X ₆ (B/A)	X ₇ (Km)	X ₈ (Km)	X ₉ (SRP)
KM 379, Gringsing	7,30	8	5	6	0	0	35,0	12,0	100
KM 379, Gringsing	7,30	8	5	6	0	0	35,0	12,0	100
KM 389, Jatirejo	6,20	10	5	6	0	1	29,0	40,3	100
KM 389, Jatirejo	6,20	10	5	6	0	1	29,0	40,3	100
KM 391, Rowoaking	0,40	0	3	2	0	0	12,0	32,0	35
KM 391, Rowoaking	0,40	0	3	2	0	0	12,0	32,0	35
KM 429, Ungaran	5,88	11	5	5	0	0	5,0	27,0	100
KM 429, Ungaran	5,88	11	5	5	0	0	5,0	27,0	100
KM 456, Pabelan	2,17	0	3	5	0	0	27,0	31,0	30
KM 456, Pabelan	2,17	0	3	5	1	0	27,0	31,0	30
KM 456, Pabelan	1,06	0	3	5	1	1	26,7	31,0	30
KM 456, Pabelan	1,06	0	3	5	0	1	26,7	31,0	30
KM 487, Gumukrejo	1,30	0	3	4	0	0	31,0	32,0	21
KM 487, Gumukrejo	1,30	0	3	4	0	0	31,0	32,0	21
KM 487, Gumukrejo	1,17	0	3	4	0	1	31,0	32,0	21
KM 487, Gumukrejo	1,17	0	3	4	0	1	31,0	32,0	21

Keterangan: KM = Kilometer; TIP = Tempat Istirahat dan Pelayanan (*rest area*) tipe A atau B; *Connecting* (1); Arah A= meninggalkan Jakarta, dan B = menuju Jakarta (1); SRP = Satuan Ruang Parkir;

Tabel 6. Korelasi variabel model jumlah kendaraan periode Lebaran

	Jumlah_Kendaraan (Kend/hari)	GFA (Ha)	Jumlah_Nozel_ SPBU (unit)
<i>Pearson Correlation</i>	Jumlah_Kendaraan (Kend/hari)	1,00	0,92
	GFA (Ha)	0,92	1,00
	Jumlah_Nozel_SPBU (unit)	1,00	0,96
<i>Sig. (1-tailed)</i>	Jumlah_Kendaraan (Kend/hari)	-	0,01
	GFA (Ha)	0,01	-
	Jumlah_Nozel_SPBU (unit)	0,00	0,01

Tabel 7. Korelasi variabel model jumlah kendaraan periode non-Lebaran

<i>Correlations</i>								
	Jml_Kend. (Kend/hari)	GFA (Ha)	Nozel (unit)	Fasilitas Standar	Fasilitas Tambahan	Connecting	Ke- Jakarta	
<i>Pearson Correlation</i>	Jumlah_Kendaraan (Kend/hari)	1,000	0,758	0,717	0,750	0,797	-0,067	0,232
	GFA (Ha)	0,758	1,000	0,979	0,983	0,661	-0,240	-0,237
	Jumlah_Nozel_SPBU (unit)	0,717	0,979	1,000	0,999	0,580	-0,288	-0,174
	Jumlah_Fasilitas_Standar	0,750	0,983	0,999	1,000	0,602	-0,289	-0,149
	Jumlah_Fasilitas_Tambahan	0,797	0,661	0,580	0,602	1,000	0,209	0,108
	Connecting	-0,067	-0,240	-0,288	-0,289	0,209	1,000	0,043
	Ke_Jakarta	0,232	-0,237	-0,174	-0,149	0,108	0,043	1,000

Periode non-Lebaran, korelasi variabel sesuai Tabel 7 menunjukkan bahwa GFA (X₁) memiliki korelasi positif yang kuat dengan *Pearson coefficient* sebesar 0,758 dan *p-value* = 0,003; jumlah nozel pompa SPBU (X₂) juga memiliki korelasi signifikan (*r* = 0,717; *p* = 0,006); jumlah fasilitas standar (X₃) seperti toilet dan tempat makan menunjukkan pengaruh positif signifikan (*r* = 0,750; *p* = 0,004), dan fasilitas tambahan (X₄) seperti kafe, taman bermain, dan layanan lainnya juga berkorelasi positif signifikan (*r* = 0,797; *p* = 0,002). Sebaliknya, variabel *connecting* (X₅) dan arah ke Jakarta (X₆) tidak menunjukkan hubungan yang signifikan secara statistik, dengan *p-value* masing-masing 0,422 dan 0,247.

Tabel 8. Hasil uji normalitas

Variabel	All		Periode Lebaran		Periode Non-Lebaran	
	<i>Statistic</i>	<i>p-value</i>	<i>Statistic</i>	<i>p-value</i>	<i>Statistic</i>	<i>p-value</i>
jml_kendaraan	0,7496576	0,0006292732	0,8551807	0,2114564	0,6835729	0,0002879872
lama_singgah	0,5786407	1,024858e-05	0,6375167	0,001886465	0,570984	1,111653e-05
gfa	0,7937246	0,002250722	0,7511328	0,03048974	0,7020926	0,000497661
jml_nozel_spbu	0,6767157	9,455032e-05	0,7927759	0,0706688	0,5849909	1,655667e-05
jml_fasilitas_standar	0,6208873	2,56574e-05	0,6840289	0,006470001	0,5724059	1,157433e-05
jml_fasilitas_tambahan	0,8436842	0,01101484	0,6840289	0,006470001	0,7928366	0,007571988
connecting	0,3984564	3,40816e-07	-	-	0,4857203	1,020857e-06
ke_jkt	0,6208873	2,56574e-05	0,5521817	0,0001309782	0,6491718	0,0001051734
jrk_sblm	0,7929606	0,002199438	0,7862422	0,06229973	0,638331	7,675061e-05
jrk_ssdh	0,7728612	0,001214407	0,8290783	0,1369214	0,7596114	0,002775313
kapasitas_parkir	0,7023267	0,0001790257	0,6840289	0,006470001	0,6538382	0,0001204912

2.3.6. Uji Normalitas dan Uji Beda Kelompok Data

Uji normalitas disajikan pada Tabel 8, menunjukkan bahwa beberapa variabel, baik untuk periode Lebaran dan non-Lebaran memiliki $p\text{-value} \leq 0,05$ sehingga asumsi distribusi normal tidak terpenuhi. Hasil uji beda dengan *Wilcoxon signed rank test* terhadap median menunjukkan bahwa $p\text{-value} > 0,05$, mengindikasikan bahwa tidak terdapat perbedaan signifikan pada median data antara kategori awal pekan Lebaran, akhir pekan Lebaran, awal pekan non -Lebaran, dan akhir pekan non-Lebaran. Pola median data pada kategori tersebut dianggap serupa secara statistik.

Namun, dengan $p\text{-value} > 0,05$ dan median data terlihat serupa, analisis visual melalui *boxplot* yang ditunjukkan pada Gambar 3, menegaskan bahwa terdapat perbedaan pada kelompok data tersebut. Secara kualitatif, terbatasnya jumlah data membuat model menjadi kurang representatif jika data dibagi ke dalam kelompok yang lebih kecil, seperti awal pekan dan akhir pekan pada periode Lebaran. Oleh karena itu, langkah berikutnya adalah membangun model regresi multivariat berdasarkan data agregat untuk periode Lebaran dan non-Lebaran.

2.3.7. Model Deterministik melalui Regresi Multivariat Periode Lebaran

Tabel 9 menunjukkan model regresi multivariat untuk prediksi volume kendaraan pada periode Lebaran, dengan variabel yang berpengaruh yaitu GFA dan jumlah pompa SPBU. Model deterministik ini dapat dirumuskan sebagai berikut:

$$Y = 345.60 - 81.50X_1 + 241.67X_2 \quad (3)$$

Persamaan (3) dengan Y sebagai volume kendaraan per hari yang mengunjungi *rest area*, X_1 yaitu variabel GFA, dan X_2 yaitu jumlah nozel pompa SPBU. Model prediksi volume kendaraan periode Lebaran memiliki hubungan yang sangat kuat dengan variabel prediktor yaitu GFA dan jumlah nozel pompa SPBU, dengan nilai *adjusted R-squared* sebesar 0,999. Variabel lainnya dari hasil uji coba model seperti fasilitas, jarak, konektivitas, arah perjalanan dan kapasitas parkir menyebabkan model tidak stabil karena menghasilkan R^2 kecil dan VIF tinggi sehingga mengakibatkan multikolinearitas.

Interval kepercayaan 95% (CI) untuk jumlah pompa SPBU berada pada rentang 177,78 hingga 305,57, yang menunjukkan pengaruh positif dan signifikan secara statistik terhadap jumlah kendaraan yang berkunjung ke *rest area*. Sebaliknya, variabel GFA memiliki interval kepercayaan -166,84 hingga 3,83, yang melintasi nol, menandakan bahwa pengaruh negatifnya bersifat marginal ($p = 0,054$) dan tidak signifikan secara statistik pada tingkat kepercayaan $\alpha = 0,05$.

Interpretasi model menunjukkan bahwa ketika semua variabel prediktor bernilai nol, maka volume kendaraan pengunjung diprediksi sebesar 345,6 kendaraan per hari. Jumlah pompa SPBU menjadi variabel signifikan ($p = 0,004$) dengan koefisien positif (241,673), yang berarti penambahan 1 nozel jumlah pompa akan menambah volume kendaraan sekitar 241 unit per hari.

Tabel 10 menunjukkan model regresi multivariat untuk lama singgah di *rest area* selama periode lebaran dengan formulasi:

$$Y = 7809,3 - 81,61X_1 + 7033,6X_2 \quad (4)$$

Tabel 9. Hasil model regresi multivariat untuk jumlah kendaraan pada periode lebaran

Model Summary								
R		R Square	Adjusted R Square	Std. Error	Change Statistics			
Lebaran (Selected)	Lebaran (Unselected)				R Square Change	F Change	Sig. F Change	Lebaran (Selected)
0,999 ^a	0,707	0,999	0,998	41,617	0,999	908,4	0,001	3,305
Coefficients								
Model	Unstandardized Coefficients		Standardized Coeff	t	Sig.	95,0% Confidence Interval for B		
	B	Std. Error	Beta			Lower Bound	Upper Bound	
(Constant)	345,602	31,468	-	10,983	0,008	210,205	480,998	
GFA (Ha)	-81,504	19,833	-0,331	-4,109	0,054	-166,84	3,831	
Nozzle (unit)	241,673	14,85	1,312	16,274	0,004	177,776	305,569	

Tabel 10. Hasil model regresi untuk lama singgah pada periode lebaran

Variable	Coefficient	Std.Error	t-Static	Prob.
(Intercept)	7809,3	975,9	8,002	0,01526
GFA	-8161,0	615,1	-13,269	0,00563
Jumlah Pompa SPBU	7033,6	460,5	15,273	0,00426
R-squared	0,9922	Adjusted R-squared		0,9844
F-statistic	127,3	p-value		0,007795

Persamaan (4) dengan Y sebagai lama singgah kendaraan yang mengunjungi *rest area*, X_1 sebagai variabel GFA, dan X_2 yaitu jumlah pompa SPBU. Model deterministik untuk lama singgah di *rest area* pada periode lebaran sangat kuat ditunjukkan dengan nilai *adjusted R-squared* sebesar 0,9844. Ketika semua variabel prediktor bernilai nol, lama singgah yang diprediksi adalah 7809,3 detik atau sekitar 2,17 jam. Jumlah nozel pompa SPBU secara signifikan (7033,6) memengaruhi lamanya singgah, berarti penambahan 1 nozel pompa akan menambah waktu singgah sekitar 1,95 jam.

2.3.8. Model Deterministik melalui Regresi Multivariat Periode non-Lebaran

Pada Tabel 11 menunjukkan model regresi untuk jumlah kendaraan pada periode non-Lebaran, dengan model deterministik ini dapat dirumuskan:

$$Y = -56668,5 - 439,3X_1 - 3128,0X_2 + 18662,1X_3 + 434,2X_4 + 384,0X_5 - 120,6X_6 \quad (5)$$

Persamaan (5) dengan Y sebagai volume kendaraan per hari yang mengunjungi *rest area*; X_1 yaitu variabel GFA; X_2 yaitu jumlah pompa SPBU; X_3 yaitu jumlah fasilitas; X_4 yaitu fasilitas non standar; X_5 yaitu *connecting*; dan X_6 yaitu arah menuju Jakarta. Model ini memiliki kinerja yang sangat baik, dengan nilai *Adjusted R-squared* sebesar 0,928. Dengan CI 95%, jumlah fasilitas standar berpengaruh paling signifikan ($p = 0,013$), yang berarti penambahan 1 jenis fasilitas standar akan menambah volume kendaraan sekitar 18.662 unit per hari. Fasilitas tambahan dan *connecting* menunjukkan efek positif, tetapi tidak signifikan secara statistik.

Hasil analisis interval kepercayaan 95% menunjukkan bahwa dua variabel yang berpengaruh signifikan terhadap volume kendaraan pada periode non-Lebaran adalah jumlah fasilitas standar dan jumlah pompa SPBU. Variabel fasilitas standar memiliki CI antara 6.536 hingga 30.788, yang seluruhnya positif dan menunjukkan pengaruh yang kuat terhadap peningkatan jumlah pengunjung *rest area*. Sebaliknya, jumlah pompa SPBU memiliki CI antara -5.050 hingga -1.205, seluruhnya negatif, menandakan hubungan berlawanan di mana semakin sedikit jumlah pompa, semakin menurun pula jumlah kendaraan yang berhenti. Variabel lain seperti GFA, fasilitas tambahan, konektivitas, dan arah perjalanan memiliki rentang CI yang melintasi nol sehingga pengaruhnya tidak signifikan secara statistik. Secara keseluruhan, hasil ini menegaskan bahwa pada periode non-Lebaran, perilaku kunjungan ke *rest area* lebih dipengaruhi oleh kelengkapan fasilitas inti dibandingkan faktor fisik atau arah lalu lintas.

Tabel 11. Hasil model regresi untuk jumlah kendaraan pada periode non-Lebaran

Model Summary							
R		R-squared	Adjusted R-squared	Std. Error	Change Statistics		
Non-Lebaran (<i>Selected</i>)	Non-Lebaran (<i>Unselected</i>)				R-squared Change	F Change	Sig. F Change
0,985a	0,752	0,971	0,928	375,388	0,971	22,388	0,005
Coefficients							
Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
	B	Std. Error	Beta			Lower Bound	Upper Bound
(Constant)	-56.668,5	12506,15	-	-4,53	0,011	-91.391	-2.1945,9
GFA (Ha)	-439,28	541,71	-0,682	-0,81	0,463	-1.943	1.064,74
Nozel SPBU (unit)	-3128	692,49	-11,178	-4,51	0,011	-5.050	-120.533
Fasilitas Standar	18.662,13	4.367,41	12,487	4,27	0,013	6.536	30.788,02
Fasilitas Tambahan	434,17	384,78	0,201	1,12	0,322	-634	1.502,52
Connecting	384	375,38	0,111	1,02	0,364	-658	1.426,24
Ke Jakarta	-120,60	428,09	-0,045	0,28	0,792	-1.309	1.067,961

Tabel 12. Hasil model regresi untuk lama singgah pada periode non-Lebaran

<i>Variable</i>	<i>Coefficient</i>	<i>Std.Error</i>	<i>t-Static</i>	<i>Prob.</i>
(Intercept)	-292.640,84	43.619,94	-6,709	0,00257
GFA	-1.006,93	1.889,43	-0,533	0,62232
Jumlah Pompa SPBU	-17.315,32	2415,33	-7,169	0,00200
Tipe Fasilitas Standar	98.141,27	15.233,02	6443	0,00299
Fasilitas Tambahan	827,23	1.342,09	0,616	0,96066
Connecting	68,72	375,4	0,052	0,3642
Arah ke Jakarta	-1.483,46	1.493,13	-0,994	0,37669
R-squared	0,9788		Adjusted R-squared	0,9471
F-statistic	30,81		<i>p-value</i>	0,002616

Sementara itu, model regresi multivariat untuk lama singgah di *rest area* selama periode non-Lebaran ditunjukkan pada Tabel 12, dengan model deterministik ini dapat dirumuskan:

$$Y = -292.640,84 - 1.006,93X_1 - 17.315,32X_2 + 98.141,27X_3 + 827,23X_4 + 68,72X_5 - 1.483,46X_6 \quad (6)$$

Persamaan (6) dengan Y sebagai lama singgah kendaraan per hari yang mengunjungi *rest area*; X_1 yaitu variabel GFA; X_2 yaitu jumlah pompa SPBU; X_3 yaitu jumlah fasilitas standar; X_4 yaitu fasilitas tambahan; X_5 yaitu *connecting*; dan X_6 yaitu arah menuju Jakarta.

Hasil model regresi untuk lama singgah di *rest area* pada periode non-Lebaran sangat baik dengan nilai *R-squared* sebesar 0,9788 dan *adjusted R-squared* sebesar 0,9471 yang masih tergolong tinggi. Pada periode non-Lebaran. Jumlah fasilitas berpengaruh secara signifikan ($p = 0,0029$), maka penambahan 1 jenis fasilitas akan meningkatkan durasi singgah di *rest area* sebesar 98.141,27 detik.

2.3.9. Validasi Kinerja Model Deterministik

Uji kinerja model deterministik untuk volume kendaraan pengunjung dilakukan dengan pendekatan RMSE, MAE, dan MAPE seperti ditunjukkan pada Tabel 13, bahwa periode Lebaran untuk model sangat akurat dan layak digunakan karena nilai kesalahan prediksi sangat rendah ($MAPE < 5\%$). Sedangkan pada periode non-Lebaran, model tersebut memiliki akurasi sedang ($MAPE$ antara 20%–50%) sehingga nantinya dapat dilakukan penambahan variabel yang lebih representatif.

Tabel 13. Hasil validasi dengan RMSE, MAE, dan MAPE

Periode	Persamaan Regresi Multivariat	RMSE	MAE	MAPE(%)
Lebaran	$Y = 345,6 + 241,67 \cdot (\text{Pompa SPBU}) - 81,5 \cdot (\text{GFA})$	26,34	23,40	3,91
Non-Lebaran	$Y = -56668,5 + 18662,1 \cdot (\text{Fasilitas Standar}) + 434,2 \cdot (\text{Fasilitas Tambahan}) + 384 \cdot (\text{Connecting}) - 439,3 \cdot (\text{GFA}) - 3128 \cdot (\text{Pompa SPBU}) - 120,6 \cdot (\text{Arah ke JKT})$	226,32	188,00	22,66

3. Hasil dan Pembahasan

3.1. Interpretasi Model Stokastik melalui Peluang Distribusi Data

Pada periode Lebaran, formulasi distribusi log-normal yang mewakili volume kendaraan yang singgah di *rest area* pada interval 15 menit, yaitu *meanlog* (μ) sebesar 3,23 dan *sdlog* (σ) sebesar 0,50. Distribusi ini cocok menggambarkan lonjakan arus kendaraan yang tinggi dalam waktu singkat (*positive skewness*), seperti yang umum terjadi pada masa mudik dan balik periode lebaran. Adanya “ekor panjang” (*long tail*) pada distribusi ini menunjukkan bahwa sebagian kendaraan tiba di tujuan dengan lebih lambat atau lebih awal mencapai puncak waktu kedatangan (terkena macet). Oleh karena itu, log-normal memberikan gambaran realistis terhadap distribusi waktu dan volume kunjungan.

Pada periode non-Lebaran, yaitu persamaan seragam (*uniform*), minimum kendaraan pengunjung (a) = 10 dan maksimal kendaraan pengunjung (b) = 52 setiap interval waktu per 15 menit. Pada hari biasa, jumlah pengunjung cenderung berkurang berdasarkan kebiasaan atau kebutuhan pribadi yang lebih stabil.

3.2. Model Deterministik melalui Regresi Multivariat untuk Periode Lebaran

Pada periode Lebaran, dengan konsep fokus layanan inti, mempunyai variabel utama jumlah nozel pompa SPBU. Variabel jumlah nozel pompa SPBU memiliki koefisien positif terbesar, yaitu menambah 241,67 unit jumlah kendaraan per hari dan menambah waktu 7.033,6 detik untuk lama singgah. Hal ini menunjukkan bahwa keberadaan SPBU terutama dengan jumlah nozel lebih banyak dan bahan bakar jenis subsidi merupakan magnet utama bagi kendaraan untuk berhenti. Secara kualitatif, hal ini sesuai dengan persepsi dari BUJT selaku pengelola *rest area*, bahwa periode Lebaran yang terpenting adalah tersedianya SPBU bersubsidi.

3.3. Model Deterministik melalui Regresi Multivariat untuk Periode Non-Lebaran

Pada periode non-Lebaran, konsep daya tarik fasilitas berbeda dari periode Lebaran, di mana variabel yang paling dominan adalah ketersediaan fasilitas standar yang akan menambah 18.662,1 unit jumlah kendaraan per hari dan meningkatkan waktu 98.141,3 detik untuk lama singgah. Ini menandakan bahwa dalam kondisi lalu lintas reguler, pengunjung lebih memilih *rest area* dengan kenyamanan fasilitas seperti toilet, tempat ibadah, dan tempat makan. Jumlah fasilitas tambahan, seperti kafe, hotel, area bermain, dan stasiun pengisian kendaraan listrik juga memiliki pengaruh positif meskipun tidak signifikan. Variabel *connecting* juga memiliki koefisien positif dan lebih disukai oleh pengunjung.

3.4. Validasi Model dengan Literatur Sebelumnya

Analisis komparatif menunjukkan bahwa model penelitian ini yaitu Model 1 (R Studio) dan 2 (SPSS) mempunyai hasil yang paling mendekati nilai aktual dibandingkan dengan model 3 (Mohd. Syafie) dan model 4 (MTGM). Bahkan selisih nilai antara hasil prediksi dan data aktual sangat kecil, dalam beberapa kasus nyaris identik, seperti pada KM 389 periode non-Lebaran yaitu 5.123 aktual terhadap 5.123 SPSS dan 5.124 R-Studio. Sebaliknya, model Mohd. Syafie dan MTGM lebih cenderung *underestimate* atau *overestimate*, seperti pada KM 487 periode non-Lebaran, model Mohd. Syafie memprediksi 834 kendaraan/hari, sedangkan data aktual hanya 546 kendaraan/hari.

4. Kesimpulan

Penelitian ini berhasil mengembangkan model bangkitan perjalanan untuk *rest area* jalan tol Indonesia, dengan pendekatan stokastik dan deterministik, menggunakan data primer dari delapan lokasi aktif selama 6 hari di tahun 2024. Model stokastik untuk peluang distribusi data kunjungan kendaraan ke *rest area* dan model deterministik dengan regresi multivariat untuk volume kendaraan dan lama singgah pengunjung di *rest area*. Model dipisahkan menjadi dua periode yaitu Lebaran (musiman) dan non-Lebaran (reguler), yang menggambarkan arus puncak dan biasa.

Secara deterministik, temuan menunjukkan bahwa keputusan bagi pengendara jalan tol untuk berkunjung dan lama singgah di *rest area* dipengaruhi oleh adanya SPBU bersubsidi dan jumlah nozel pompanya pada saat Lebaran. Sedangkan fasilitas standar seperti toilet, tempat makan, tempat ibadah dan istirahat menjadi kunci pada periode non-Lebaran. Fasilitas tambahan yang bervariasi seperti kafe, hotel, tempat bermain, tempat pertemuan, dll. serta konektivitas dengan *rest area* di seberang menjadi daya tarik

bagi pengunjung. Sementara itu, untuk arah perjalanan menuju Jakarta dan *rest area* yang luas menjadi alasan pengunjung untuk tidak berhenti di *rest area*. Model prediktif dengan regresi multivariat untuk volume kendaraan (jumlah per hari) dan lama singgah (detik) pengunjung di *rest area* jalan tol, baik pada periode Lebaran dan non-Lebaran, mempunyai kinerja yang baik dan mendekati kondisi aktual terkini.

Dalam pendekatan stokastik, model distribusi kunjungan di *rest area* pada periode Lebaran mengikuti pola log normal yang fluktuatif, sedangkan non-Lebaran lebih stabil, tersebar merata dan menyerupai distribusi *uniform* (seragam).

Kebaruan model ini terletak pada penggunaan data primer musiman, pemisahan model berdasarkan periode arus puncak dan normal, serta identifikasi variabel yang dapat diintervensi langsung untuk mendukung pengembangan *rest area* baru. Model ini menjadi dasar awal untuk penyusunan standar nasional *trip generation rest area* di Indonesia, dengan mempertimbangkan kondisi aktual perilaku pengguna jalan tol di saat puncak dan reguler yang tidak tercakup dalam ITE TGM maupun MTGM.

Secara operasional, hasil model dapat digunakan oleh BUJT dan Kementerian PUPR untuk menetapkan kebutuhan minimum fasilitas dan mitigasi kemacetan musiman. Untuk target pengunjung *rest area* sebanyak 1.000 kendaraan per hari, maka diperlukan minimal empat jenis fasilitas standar per 1.000 m² GFA pada arus normal dan 3 nozel pompa per 1.000 m² GFA pada arus puncak. Intensitas kendaraan saat Lebaran yang masuk *rest area* antara 20–30 kendaraan per 15 menit, menunjukkan perlunya antisipasi penumpukan kendaraan dengan pemberlakuan batasan waktu singgah.

Keterbatasan penelitian ini meliputi jumlah observasi yang terbatas (n=16) di koridor tol Trans-Jawa dan belum digunakannya pendekatan model dengan data *time series*, serta penggunaan kamera masih rentan terhadap faktor cuaca. Studi lanjutan direkomendasikan menggunakan data longitudinal multi-tahun serta eksplorasi model regresi spasial untuk peningkatan akurasi prediktif, generalisasi model, dan kebijakan tata kelola *rest area* yang adaptif.

Daftar Pustaka

- [1] K. Polri, "Electronic Registration Identification," <http://rc.korlantas.polri.go.id:8900/eri2017/index.php>.
- [2] Badan Pusat Statistik, *Statistik Indonesia (Statistical Yearbook of Indonesia) 2023*, 03200.2303., vol. 11010001. 2023.
- [3] J. Sutrisno, "Hasil FGD Model Bangkitan Perjalanan *Rest area* di Jalan Tol Indonesia (Studi Kasus: Ruas Tol Batang - Surakarta)," Semarang, Feb. 2025.
- [4] E. Darmawan, S. R. Sari, H. Werdiningsih, and A. S. Enis, "Rest area Development in Central Java (Case Study: Rest area on Semarang-Solo Toll Road)," *International Journal of Sustainable Transportation Technology*, vol. 4, no. 1, pp. 1–8, 2021.
- [5] Menteri Pekerjaan Umum dan Perumahan Rakyat Republik Indonesia, "Peraturan Menteri Pekerjaan Umum dan Perumahan Rakyat Republik Indonesia Nomor 28 Tahun 2021 Tentang Tempat Istirahat dan Pelayanan Pada Jalan Tol," 2021.
- [6] R. Fredi Saputro, A. Dian Susanti, and G. Wardianto, "Arrangement of Spatial Relationships in Toll Road Rest area Case Study: Rest area km," 2022.
- [7] G. W. Laskara, "Prinsip Perencanaan dan Kriteria Pengendalian Pengembangan Fasilitas Rest-Area pada Jalan Tol di Indonesia," *Journal of Regional and Rural Development Planning*, vol. 5, no. 2, pp. 123–133, Jun. 2021, doi: 10.29244/jp2wd.2021.5.2.123-133.
- [8] O. Z. Tamin, *Perencanaan dan pemodelan transportasi*. Penerbit ITB, 2000. [Online]. Available: <https://books.google.co.id/books?id=AKNLAQAACAAJ>
- [9] F. D. Hanggara and R. D. E. Putra, "Analisis Sistem Antrian Pelanggan SPBU dengan Pendekatan Simulasi Arena," *Jurnal INTECH Teknik Industri Universitas Serang Raya*, vol. 6, no. 2, pp. 155–162, Dec. 2020, doi: 10.30656/intech.v6i2.2543.
- [10] R. I. Kementerian Perhubungan, "Peraturan Menteri Perhubungan Republik Indonesia Nomor PM 17 Tahun 2021 Tentang Penyelenggaraan Analisis Dampak Lalu Lintas," Jakarta, May 2021. [Online]. Available: www.peraturan.go.id
- [11] Institute of Transportation Engineers, *Trip Generation Manual 10 th Edition • Volume 1: Desk Reference Institute of Transportation Engineers*, vol. 1. 2017.
- [12] H. P. U. Ministry of Works Malaysia, *Malaysian-Trip-Generation-Manual-2010*, vol. 1. 2010.
- [13] S. Monahan, "Does the ITE Trip Generation Manual Overestimate the Trip Does the ITE Trip Generation Manual Overestimate the Trip Generation of Stores in Northeast Ohio?," University of Akron, Ohio, USA, 2023. [Online]. Available: https://ideaexchange.uakron.edu/honors_research_projectshttps://ideaexchange.uakron.edu/honors_research_projects/1663
- [14] S. Meena, "Trip Generation for shopping malls in Developing Cities," *European Transport/Trasporti Europei*, no. 86, pp. 1–16, Mar. 2022, doi: 10.48295/ET.2022.86.2.
- [15] S. A. Mohd Shafie, L. V. Leong, and A. F. Mohd Sadullah, "A Trip Generation Model for a Petrol Station with a Convenience Store and a Fast-Food Restaurant," *Sustainability*, vol. 13, no. 22, p. 12815, Nov. 2021, doi: 10.3390/su132212815.
- [16] D. J. B. M. P. Satuan Kerja Sekretariat Pengatur Jalan Tol, "Standar Pelayanan Minimum Jalan Tol 2023," 2023.
- [17] PT. Trans Marga Jawa Tengah, "Rencana Pembangunan Tempat Istirahat dan Pelayanan Jalan Tol Semarang - Solo," 2019.
- [18] Departemen Permukiman dan Prasarana Wilayah, "Penentuan Klasifikasi Fungsi Jalan di Kawasan Perkotaan," 2004.
- [19] E. Wahyu Utomo, "Nanotechnology Perceptions ISSN 1660-6795 www," 2024. [Online]. Available: www.nano-ntp.com
- [20] I. Lenaini, "Teknik Pengambilan Sampel Purposive dan Snowball Sampling," vol. 6, no. 1, pp. 33–39, 2021, doi: 10.31764/historis.vXiY.4075.
- [21] P. Direktorat Jenderal Bina Marga, *Pedoman Kapasitas Jalan Indonesia No. 09/ P/ BM 2023*, vol. 1, no. 021. 2023.

- [22] F. Ridzuan and W. M. N. Wan Zainon, "A Review on Data Cleansing Methods for Big Data," *Procedia Comput Sci*, vol. 161, pp. 731–738, 2019, doi: <https://doi.org/10.1016/j.procs.2019.11.177>.
- [23] I. Ghazali, *Aplikasi Analisis Multivariate Dengan Program IBM SPSS 25, Edisi 9*, 9th ed., vol. 9. Semarang: Badan Penerbit Universitas Diponegoro, 2017.
- [24] A. Bluman, *Elementary Statistics: A step by step approach 9e*. McGraw Hill, 2014. Accessed: Sep. 17, 2024. [Online]. Available: [https://books.google.co.id/books?hl=id&lr=&id=EIZvEAAAQBAJ&oi=fnd&pg=PP1&dq=Bluman,+A.+G.+\(2013\).+Elementary+Statistics:+A+Step+by+Step+Approach.+McGraw-Hill+Education.&ots=239FxnAHs&sig=COMrLvGXZz_68nJe_Ehdvs8-NVQ&redir_esc=y#v=onepage&q&f=false](https://books.google.co.id/books?hl=id&lr=&id=EIZvEAAAQBAJ&oi=fnd&pg=PP1&dq=Bluman,+A.+G.+(2013).+Elementary+Statistics:+A+Step+by+Step+Approach.+McGraw-Hill+Education.&ots=239FxnAHs&sig=COMrLvGXZz_68nJe_Ehdvs8-NVQ&redir_esc=y#v=onepage&q&f=false)
- [25] J. F. Hair, *Multivariate Data Analysis*, 7th ed. Prentice Hall, 2010. [Online]. Available: <https://books.google.co.id/books?id=JIRaAAAAYAAJ>
- [26] I. of T. Engineers, "Trip Generation Manual 10 th Edition • Volume 1: Desk Reference Institute of Transportation Engineers," *Institute of Transportation Engineers*, vol. 1, 2017, [Online]. Available: <files/1330/'Institute of Transportation Engineers - 2017 - Trip Generation Manual 10 th Edition • Volume 1 D'.pdf>
- [27] J. F. Hair and J. F. (Jr) Hair, *Multivariate Data Analysis*, 7th ed. in Always learning. Prentice Hall, 2010. [Online]. Available: <https://books.google.co.id/books?id=JIRaAAAAYAAJ>
- [28] A. Ghasemi and S. Zahediasl, *Normality tests for statistical analysis: a guide for non-statisticians*, vol. 10, no. 2. Brieflands, 2012. Accessed: Sep. 18, 2024. [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3693611/>
- [29] S. M. Ross, *A first course in probability*, Tenth edition. Boston: Pearson, 2019. [Online]. Available: https://api.pageplace.de/preview/DT0400.9781292269238_A39514643/preview-9781292269238_A39514643.pdf
- [30] M. L. McHugh, "The chi-square test of independence," *Biochem Med (Zagreb)*, vol. 23, no. 2, pp. 143–149, 2013.
- [31] A. Field, *Discovering Statistics Using IBM SPSS Statistics*, 6th ed. Sage, 2024.
- [32] H. Akaike, "A New Look at the Statistical Model Identification," *IEEE Trans Automat Contr*, vol. AC-19, no. 6, pp. 716–723, Dec. 1974.
- [33] G. James, D. Witten, T. Hastie, and R. Tibshirani, "An Introduction to Statistical Learning with Applications in R Second Edition," Jun. 2023.
- [34] K. P. Burnham and D. R. Anderson, *Model Selection and Multimodel Inference: A Practical Information-Theoretic Approach*, vol. 2. Springer New York, 2003. [Online]. Available: <https://books.google.co.id/books?id=fT1Iu-h6E-oC>
- [35] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," Nov. 2005. [Online]. Available: <http://www.forecasters.org/data/m3comp/m3comp.htm>
- [36] G. Schwarz, "Estimating the Dimension of a Model," *The Annals of Statistics*, vol. 6, no. 2, pp. 461–464, Mar. 1978.