

# PREDIKSI KEPADATAN LALU LINTAS MENGGUNAKAN RANDOM FOREST (STUDI KASUS JALAN TOL SEMARANG DEMAK)

Levia Azizah<sup>a1</sup>, Aria Hendrawan<sup>a2</sup>

<sup>a</sup>Teknik Informatika, Universitas Semarang

Jl. Soekarno-Hatta, Tlogosari Kulon, Semarang, Jawa Tengah, Indonesia - 50196

<sup>1</sup>leviaazizah2@email.com

<sup>2</sup>ariahendrawan@usm.ac.id

## Abstract

*Traffic jams are a serious problem in big cities, including on the Semarang-Demak Highway. Increased vehicle volumes, illegal parking, and lack of use of public transportation exacerbate this situation. This research aims to predict traffic density using the Random Forest model, considering that this model can handle data with many variables and provide stable results. The dataset used includes 120 rows of traffic volume data from January to April 2024. The methods applied include data collection, preprocessing, model training, and evaluation. Data were cleaned of missing values and outliers and normalized before being divided into 80% for training and 20% for testing. The evaluation results show that the Random Forest model has a mean square error (MSE) value on the training data of 486235 and a root mean square error (RMSE) of 697, with a coefficient of determination ( $R^2$ ) of 0.9639. However, on the test data, the MSE increases to 4104797, RMSE 2026, and ( $R^2$ ) 0.6167, which indicates potential overfitting. Overall, the Random Forest model shows good performance in predicting the number of vehicles but needs further optimization to increase accuracy on test data. It is hoped that this research will provide insights for better traffic planning in the future.*

**Keywords:** traffic jams, traffic prediction, Random Forest, traffic density, toll roads

## Abstrak

Kemacetan lalu lintas menjadi masalah serius di kota-kota besar, termasuk di Jalan Raya Semarang-Demak. Peningkatan volume kendaraan, parkir liar, dan kurangnya penggunaan transportasi umum memperburuk situasi ini. Penelitian ini bertujuan untuk memprediksi kepadatan lalu lintas dengan menggunakan model Random Forest, mengingat model ini dapat mengatasi data dengan banyak variabel dan memberikan hasil yang stabil. Set data yang digunakan mencakup 120 baris data volume lalu lintas dari Januari hingga April 2024. Metode yang diterapkan mencakup pengumpulan data, prapemrosesan, pelatihan model, dan evaluasi. Data dibersihkan dari nilai yang hilang dan *outliers*, serta dinormalisasi sebelum dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Hasil evaluasi menunjukkan bahwa model Random Forest memiliki nilai *mean square error* (MSE) pada data pelatihan sebesar 486235 dan *root mean square error* (RMSE) sebesar 697, dengan koefisien determinasi ( $R^2$ ) sebesar 0.9639. Namun, pada data pengujian, MSE meningkat menjadi 4104797, RMSE 2026, dan ( $R^2$ ) 0.6167, yang mengindikasikan potensi overfitting. Secara keseluruhan, model Random Forest menunjukkan kinerja yang baik dalam memprediksi jumlah kendaraan, namun perlu optimalisasi lebih lanjut untuk meningkatkan akurasi pada data pengujian. Penelitian ini diharapkan dapat memberikan wawasan untuk perencanaan lalu lintas yang lebih baik di masa depan.

**Kata Kunci:** Kemacetan Lalu Lintas, Prediksi, Random Forest, Kepadatan Lalu Lintas, Jalan Tol

## 1. Pendahuluan

Kemacetan lalu lintas merupakan salah satu masalah utama yang dihadapi oleh banyak kota besar di seluruh dunia [1]. Jalan seringkali tidak mampu menampung volume lalu lintas yang tinggi, terutama pada jam-jam sibuk [2]. Kemacetan ini berdampak pada berbagai aktivitas masyarakat, seperti keterlambatan transportasi dan gangguan produktivitas [3]. elain volume lalu

lintas yang tinggi, faktor lain seperti kapasitas jalan yang terbatas, hambatan samping, serta kondisi geometrik jalan juga berperan dalam terjadinya kemacetan [4]. Pertumbuhan populasi yang pesat meningkatkan mobilitas masyarakat, yang pada akhirnya menyebabkan peningkatan volume lalu lintas dan jumlah kendaraan di jalan, serta meningkatkan risiko kecelakaan lalu lintas [5].

Kemacetan jalan disebabkan oleh peningkatan volume pergerakan [6]. Salah satu lokasi kemacetan terjadi di Jalan Raya Semarang-Demak. Beberapa faktor penyebabnya antara lain jumlah kendaraan pribadi yang terus meningkat, parkir liar, kurangnya penggunaan transportasi umum, serta ketidakseimbangan antara jumlah kendaraan pribadi dengan kapasitas ruas jalan yang tersedia. Selain itu, kecelakaan lalu lintas juga turut memperburuk kemacetan [7]. Pembangunan Jalan Tol Semarang-Demak diharapkan dapat mengurangi kemacetan di kawasan ini, khususnya pada arus lalu lintas di antara Semarang dan Demak.

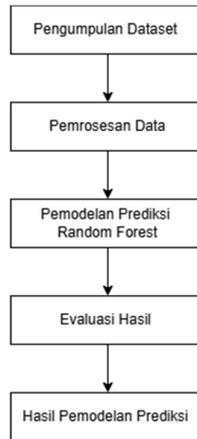
Dengan kondisi ini, penerapan machine learning khususnya Random Forest diperlukan pendekatan yang efektif untuk meningkatkan efisiensi transportasi dan memprediksi tingkat kepadatan lalu lintas secara akurat [8]. Untuk mengembangkan model yang dapat memprediksi volume lalu lintas yang lebih akurat, penelitian ini akan mempelajari penggunaan pembelajaran mesin, khususnya algoritma Random Forest [9]. Random forest adalah metode ensemble dari decision tree yang menggabungkan kemudahan decision tree dengan fleksibilitas, yang menghasilkan peningkatan besar pada akurasi dan prediksi [10]. Random forest menggunakan metode aggregating bootstrapped, yang menggabungkan set data bootstrapped untuk mengurangi variasi dalam kumpulan data bising, dan kemudian menggabungkannya dengan melakukan voting pada hasil terbanyak. Random Forest digunakan sebagai alternatif model prediksi yang dapat mengatasi data dengan banyak variabel dan menghasilkan hasil yang stabil. Beberapa penelitian lain juga telah mengkaji prediksi kemacetan lalu lintas, seperti prediksi di persimpangan jalan menggunakan model BML, prediksi arus lalu lintas berdasarkan kesamaan pola kemacetan, serta prediksi perambatan arus lalu lintas. Namun, metode linier dan nonlinier dalam penelitian-penelitian tersebut tidak memberikan hasil yang memuaskan [11].

Dalam penelitian sebelumnya juga memprediksi harga rumah menggunakan model Multiple Linear Regression dan Random Forest Regression menunjukkan bahwa model terbaik adalah random forest regression dengan 10 variabel bebas yang didasarkan pada *RMSE (root mean squared error)* terendah yaitu sebesar 561272163. Prediksi harga rumah menggunakan model random forest regression dengan 10 variabel bebas menghasilkan *MSE (mean squared error)* sebesar 315026440571417216, *MAE (mean absolute error)* sebesar 329673439, *MAPE (Mean Absolute Percentage Error)* sebesar 0.23848362397897027 dan  $R^2$  (*R-squared*) sebesar 0.8465141937802718 [12]. Studi terbaru menunjukkan bahwa penggunaan AI dalam pengelolaan gerbang tol dapat mempercepat proses, mengurangi kemacetan, dan mungkin mengurangi efek negatif dari lonjakan jumlah kendaraan bermotor di Indonesia [13]. Metode Random Forest digunakan untuk memprediksi kepadatan lalu lintas dengan menggabungkan beberapa pohon keputusan. Metode ini lebih tahan terhadap overfitting dan menghasilkan nilai evaluasi yang baik, seperti *RMSE*, *MAE*, dan ( $R^2$ ), yang menunjukkan akurasi model yang tinggi [14]. Dalam beberapa tahun terakhir, kemajuan dalam teknologi informasi, telah menunjukkan hasil prediksi yang baik [15]. Random forest adalah model pembelajaran mesin yang mampu mengenali pola-pola kompleks dalam data dan dapat diterapkan di berbagai bidang, termasuk dalam konteks prediksi lalu lintas [16].

Penelitian ini bertujuan untuk mengembangkan model prediksi yang dapat memproyeksikan kepadatan lalu lintas di masa depan, dengan fokus pada prediksi untuk taun yang akan datang. Hasil dari penelitian ini diharapkan tidak hanya memberikan wawasan tentang tren kepadatan lalu lintas di berbagai wilayah di Indonesia tetapi juga menjadi dasar bagi kebijakan dan strategi peningkatan manajemen lalu lintas yang lebih efektif.

## 2. Metode Penelitian

Penelitian ini dilakukan melalui beberapa tahapan yang disajikan dalam bentuk diagram alur metode penelitian seperti ditampilkan pada gambar 1.



Gambar 1. Diagram Alur Pengolahan Data

Pada Gambar 1 Diagram di atas menunjukkan alur proses yang digunakan untuk membuat model prediksi menggunakan data algoritma machine learning. Setelah data dikumpulkan, tahap prapemrosesan dilakukan, di mana data dibersihkan dari nilai yang hilang atau tidak ada, dihapus dari *outliers*, dan dilakukan transformasi yang diperlukan untuk mempersiapkan data. Random Forest dalam memprediksi atau menganalisis data. Pada tahap berikutnya, pelatihan data dilakukan menggunakan yang telah dipilih, dan algoritma akan mempelajari pola dari data tersebut. Setelah pelatihan selesai, model diuji pada data uji atau data baru untuk mengetahui seberapa baik prediksinya dilakukan.

### 2.1 Pengumpulan Data

Dalam Studi ini, set data yang digunakan peneliti adalah Data *Traffic Count* diperoleh dari sensor gardu tol Semarang Demak. Set data ini terdiri dari 120 baris dan 8 kolom dimana data ini berisi informasi volume lalu lintas pada Januari–April 2024.

### 2.2 Pemrosesan Data

Pada pemrosesan data diperlukan sebelum proses prediksi untuk mempersiapkan data sehingga data yang akan diolah lebih teratur. Studi ini melakukan beberapa tahap pemrosesan data, termasuk normalisasi data dan mengisi nilai yang hilang dengan menggunakan nilai modus pembagian data pelatihan dan pengujian. Nilai hilang adalah ketika data memiliki nilai yang tidak lengkap atau kosong pada salah satu kriteria.

### 2.3 Random Forest

Metode Random Forest digunakan untuk memprediksi kepadatan lalu lintas dengan menggabungkan beberapa pohon keputusan. Hasil akhir ditentukan oleh mayoritas prediksi dari pohon-pohon tersebut. Metode ini tahan terhadap overfitting dan memberikan estimasi yang lebih akurat.

$$\text{Entropy} = - \sum p(x) \log_2 p(x)$$

Keterangan:

- S = Kumpulan data dalam node
- $p_i$  = Proporsi data kelas ke-i di node tersebut
- n = Jumlah total kelas

## 2.4 Evaluasi

Untuk melakukan evaluasi terhadap model, terdapat tiga parameter kunci yang akan dibandingkan. koefisien determinasi ( $R^2$ ) mengukur kelayakan model dengan rentang nilai antara 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan kemampuan model dalam menjelaskan proporsi variabilitas dalam data. *Root mean square error* (RMSE) mengukur selisih antara nilai prediksi dan nilai aktual, dihitung dengan mengambil akar dari *mean square error* (MSE), yang memberikan gambaran tentang seberapa besar kesalahan model dalam unit yang sama dengan data asli. *Mean absolute error* (MAE) adalah rata-rata kesalahan mutlak antara nilai prediksi dan nilai aktual, memberikan pemahaman yang jelas mengenai rata-rata kesalahan prediksi dalam bentuk absolut.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \tag{1}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \tag{2}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \tag{3}$$

## 3. Hasil dan Evaluasi

### 3.1 Pengumpulan Data

Dalam Studi ini, set data yang digunakan peneliti adalah Data *Traffic Count* diperoleh dari sensor gardu tol Semarang Demak. Set data terdiri dari 120 baris dan 8 kolom dimana data ini berisi informasi volume lalu lintas pada Januari – April 2024. Peneliti ingin memprediksi kepadatan lalu lintas berdasarkan beberapa kondisi informasi sebagai berikut:

**Tabel 1.** Dataset

No.	Hari	Tanggal	Total
1	Senin	1/1/2024	13.931
2	Selasa	2/1/2024	9.206
3	Rabu	3/1/2024	8.760
...	...	...	...
...	...	...	...
119	Senin	29/4/2024	9.417
120	Selasa	30/4/2024	10.385

Tabel 1 memberikan gambaran set data yang akan di olah berfungsi untuk mengamati volume kendaraan harian, yang memungkinkan analisis jumlah lalu lintas berdasarkan hari dan kategori yang relevan di arah Semarang dan Demak.

### 3.2 Pemrosesan Data

Setelah pengumpulan data Langkah selanjutnya, Penelitian ini menggunakan data kepadatan lalu lintas yang diawali dengan pemilihan atribut penting, yaitu Hari, Tanggal, Total Knedaraan yang melintas. Data yang tersedia hanya mencakup periode empat bulan (Januari hingga April 2024), sehingga tidak dapat menggambarkan pola lalu lintas sepanjang tahun. Ini dapat menyebabkan bias musiman, di mana data tidak menggambarkan variasi lalu lintas selama periode lain, seperti liburan atau musim puncak. Untuk mengatasi keterbatasan ini, metode normalisasi Min-Max digunakan agar setiap variabel berada dalam rentang yang seragam. Ini membantu model tetap stabil meskipun cakupan datanya terbatas. Selain itu, meskipun data tambahan dari bulan lain dapat meningkatkan akurasi dan generalisasi model, kombinasi hyperparameter yang dipilih dioptimalkan untuk memastikan performa terbaik pada data yang tersedia. Pengolahan data menggunakan metode min-max normalization untuk menangani perbedaan skala data yang signifikan. Setelah normalisasi, data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian agar model dapat dilatih serta diuji akurasi secara efektif.

### 3.3 Pemodelan Prediksi

**Tabel 2.** Hasil Pengujian Kombinasi HyperParameter Random Forest

Nilai n_estimators	Nilai Max_depth	Nilai Random_State	Nilai MSE	Nilai RMSE
500	10	100	4.025	2.006
500	10	1	3.998	2.000
100	1	1	4.770	2.184
100	1	1	4.744	2.178

Pada Tabel 2, dilakukan pengujian kombinasi hyperparameter untuk model Random Forest dengan variasi nilai n\_estimators, max\_depth, dan random\_state. Hasilnya menunjukkan bahwa kombinasi terbaik dicapai dengan n\_estimators sebesar 500 dan random\_state sebesar 1 tanpa mengatur max\_depth. Kombinasi ini menghasilkan nilai MSE sebesar 3,998 dan RMSE sebesar 2,000.

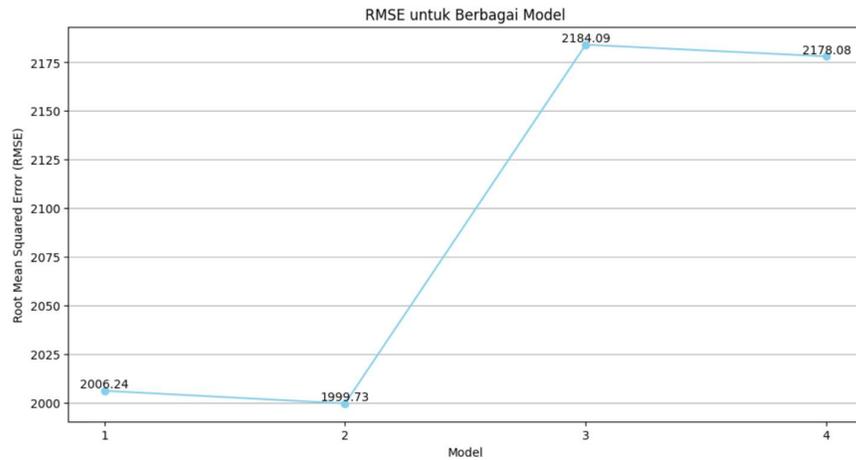
### 3.4 Evaluasi Model

Tabel 3 merupakan hasil nilai akurasi prediksi menggunakan metode Random Forest.

**Tabel 3.** Hasil metode Random Forest

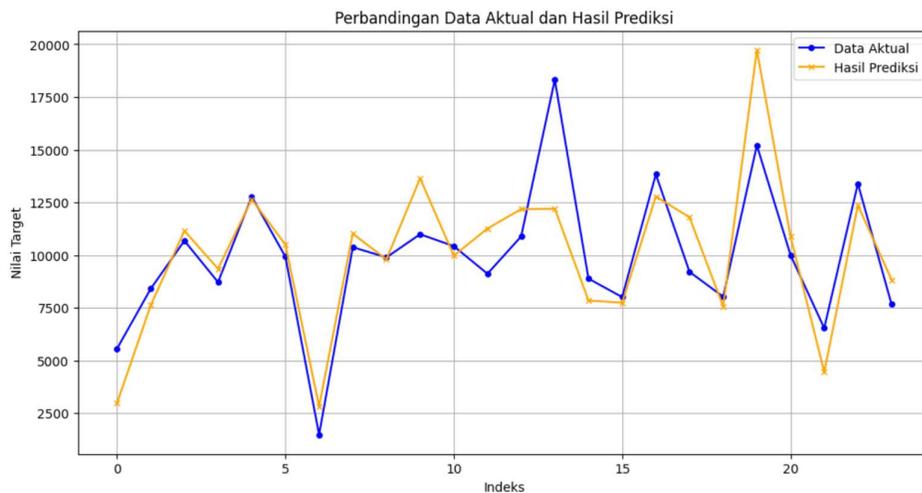
Algoritma	Random Forest	
MSE	Train	486235
	Test	4104797
RMSE	Train	697
	Test	2026
MAE	Train	495
	Test	1457
R <sup>2</sup>	Train	0.9639
	Test	0.6167

Model terbaik merupakan model dengan nilai MSE dan RMSE terkecil. Berdasarkan Tabel 3, maka model terbaik dalam prediksi jumlah Total kendaraan yang melewati tol adalah menggunakan Random Forest Regressor dengan akurasi nilai MSE-train sebesar 486235, MSE-test sebesar 4104797, dan nilai RMSE-train sebesar 697, RMSE-test sebesar 2026. Model Random Forest ini menunjukkan performa yang baik pada data train (dengan R<sup>2</sup> = 0.9639), namun performa menurun pada data test (dengan R<sup>2</sup> = 0.6167). Hal ini menunjukkan potensi overfitting yang di sebabkan data bersekala kecil, di mana model sangat baik pada data train namun kurang optimal pada data test.



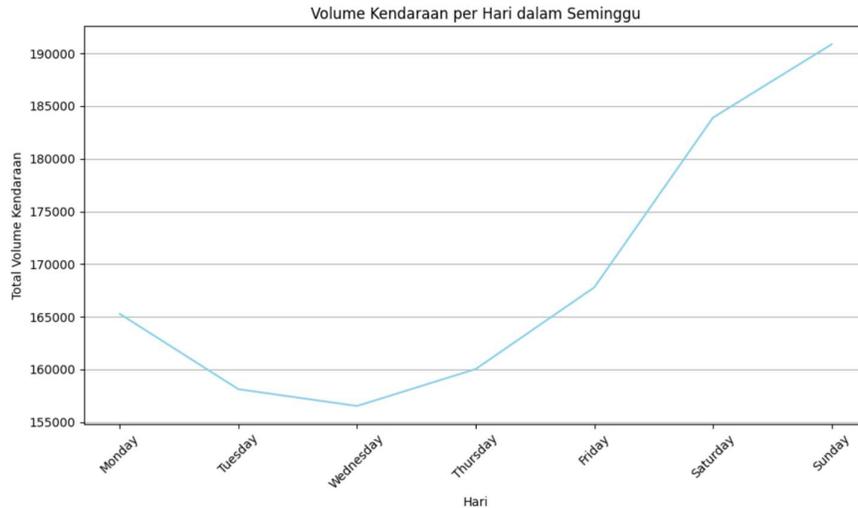
**Gambar 2.** Perbandingan Root Mean Squared Error (RMSE)

Grafik di atas menunjukkan perbandingan Root Mean squared error (RMSE) untuk berbagai model prediksi. RMSE adalah metrik yang mengukur seberapa besar kesalahan prediksi model, dengan nilai yang lebih rendah menunjukkan akurasi prediksi yang lebih baik. Model 1 memiliki RMSE sebesar 2006.24, menunjukkan akurasi yang cukup baik. Model 2 adalah model dengan kinerja terbaik, memiliki nilai RMSE terendah yaitu 1999.73, yang menunjukkan bahwa model ini menghasilkan prediksi paling akurat. Model 3 memiliki nilai RMSE tertinggi, yaitu 2184.09, menunjukkan kesalahan prediksi terbesar dan kinerja yang kurang baik dibandingkan model lain. Model 4 memiliki RMSE sebesar 2178.08, sedikit lebih rendah dari Model 3, namun masih lebih tinggi dari Model 1 dan Model 2. Secara keseluruhan, Model 2 adalah pilihan terbaik untuk digunakan dalam kasus ini karena memiliki tingkat akurasi tertinggi dengan RMSE terendah.



**Gambar 3.** Plot Grafik Data Actual Dan Hasil Prediksi

Pada Gambar 3 menunjukkan grafik perbandingan antara data aktual dan hasil prediksi untuk suatu model prediksi lalu lintas. Berikut penjelasan detail dari grafik tersebut Y mewakili "Nilai Target," yaitu nilai dari variabel target yang diprediksi dan diukur dalam data aktual. X mewakili indeks atau pengamatan dalam dataset. Garis biru dengan titik-titik melambangkan Data Aktual, yaitu data asli yang diamati. Garis oranye dengan tanda silang melambangkan hasil prediksi menunjukkan akurasi tertinggi.



**Gambar 4.** Hasil Prediksi Total Kendaraan perhari

Pada Gambar 4 menunjukkan total volume kendaraan per hari dalam seminggu. Berikut adalah analisis dari grafik:

- Volume kendaraan cenderung rendah di awal minggu, dimulai dari hari Senin dengan sedikit penurunan hingga Rabu. Puncak penurunan terjadi pada hari Rabu, menunjukkan bahwa di pertengahan minggu lalu lintas relatif lebih sepi.
- Mulai Kamis, volume kendaraan mulai meningkat, dengan kenaikan yang berlanjut hingga akhir pekan.
- Volume kendaraan tertinggi tercatat pada hari Minggu, menunjukkan peningkatan signifikan dibandingkan hari-hari sebelumnya.

Secara keseluruhan, pola ini menunjukkan bahwa lalu lintas cenderung lebih padat pada akhir pekan (Sabtu dan Minggu), kemungkinan disebabkan oleh aktivitas rekreasi atau perjalanan liburan. Sementara itu, lalu lintas relatif lebih tenang di pertengahan minggu, terutama pada hari Selasa dan Rabu.

#### 4. Kesimpulan

Random Forest terbukti sebagai model terbaik untuk memprediksi jumlah kendaraan yang melewati tol, menunjukkan performa yang baik pada data train dengan MSE sebesar 486235, RMSE sebesar 697, dan ( $R^2$ ) sebesar 0.9639, namun mengalami penurunan akurasi pada data test dengan MSE sebesar 4104797, RMSE sebesar 2026, dan ( $R^2$ ) sebesar 0.6167, yang mengindikasikan potensi overfitting karena keterbatasan data. Model 2, yang memiliki RMSE terendah sebesar 1999.73, menjadi model paling akurat berdasarkan perbandingan antar model. Analisis mingguan menunjukkan adanya peningkatan volume kendaraan signifikan menjelang akhir pekan, dengan puncak pada hari Minggu. Untuk meningkatkan akurasi prediksi dan mengatasi overfitting, disarankan agar penelitian lanjutan menggunakan set data yang lebih besar atau lebih bervariasi, menerapkan teknik regularisasi, atau mengeksplorasi model lain seperti XGBoost, guna menghasilkan prediksi yang lebih stabil dan akurat dalam membantu pengelolaan lalu lintas tol.

#### References

- [1] S. Samasal, S. E. Manakane, F. S. Leuwol, and K. L. Lintas, "Dampak Kemacetan Lalu Lintas Terhadap Jam Masuk Kuliah Mahasiswa Program Studi Pendidikan Geografi Fakultas Keguruan Dan Ilmu Pendidikan The Impact of Traffic Congestion on Lecture Entrance Hours for Students in the Geography Education Study Program , Fac," vol. 2, no. 1, pp. 54–63, 2024.
- [2] F. Novita Meysabed Sianturi and P. Negeri Medan, "Analysis of Time Mean Speed and Space Mean Speed on Arterial Roads," *Jcebt*, vol. 8, no. 1, 2024, [Online]. Available: <http://ojs.uma.ac.id/index.php/jcebt>
- [3] G. P. Ramadhani, M. Syai, L. Subiyanto, Z. Maulana, A. Putra, and I. Munadhif, "Skema

- Koordinasi Persampingan untuk Kelancaran Arus Lalu Lintas dengan Metode Neural Network,” vol. 11, pp. 396–408, 2024.
- [4] R. Mudiyo and G. D. Asfari, “Kajian Pengaruh Pembangunan Jalan Tol Semarang - Demak Terhadap Kinerja Jalan Raya Kaligawe,” *J. Planol.*, vol. 18, no. 1, p. 132, 2021, doi: 10.30659/jpsa.v18i1.13316.
- [5] A. K. N. Classifier, M. F. Febrianto, A. Priyatno, H. Adisty, and A. F. Saputri, “Prediksi Situasi Lalu Lintas Menggunakan Machine Learning Dengan,” vol. 4221, no. April, pp. 28–34, 2024.
- [6] F. Febriana, Y. Salim, and H. Darwis, “Implementasi Analisis Volume Capacity Ratio Untuk Memprediksi Kepadatan Lalu Lintas Di Kota Makassar,” *Bul. Sist. Inf. dan Teknol. Islam*, vol. 3, no. 3, pp. 219–224, 2022, doi: 10.33096/busiti.v3i3.864.
- [7] R. Ridha, Syarwan, and Supardin, “Jurnal sipil sains terapan 1.,” *J. Sipil Sains Terap.*, vol. 03, no. 2, pp. 1–14, 2020.
- [8] L. Ardian Nugroho, “Dampak Jumlah Kendaraan Besar Terhadap Kemacetan Lalu Lintas Di Jalan Tol,” *Repository.Pnj.Ac.Id*, vol. 5, no. 01, pp. 915–928, 2023, [Online]. Available: [https://repository.pnj.ac.id/12414/1/Leonard Ardian Nugroho\\_1901413025\\_01\\_Dampak Jumlah Kendaraan Besar Terhadap Kemacetan Lalu Lintas di Jalan Tol\\_Halaman Identitas.pdf](https://repository.pnj.ac.id/12414/1/Leonard%20Ardian%20Nugroho_1901413025_01_Dampak%20Jumlah%20Kendaraan%20Besar%20Terhadap%20Kemacetan%20Lalu%20Lintas%20di%20Jalan%20Tol_Halaman%20Identitas.pdf)
- [9] M. Putri, “Prediksi Penyakit Stroke Menggunakan Machine Learning Dengan Algoritma Random Forest,” *J. Infomedia Tek. Inform.*, vol. 9, no. 2, pp. 16–21, 2024.
- [10] A. Rozy, “Penerapan Random Forest Untuk Prediksi Virus Hepatitis C,” vol. 1, no. 1, pp. 19–23, 2024.
- [11] B. Priambodo, Y. Jumaryadi, and U. Salamah, “Prediksi Perambatan Arus Lalu Lintas Berdasarkan Korelasi Tertinggi Antar Jalan,” *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 3, p. 667, 2022, doi: 10.30865/jurikom.v9i3.4203.
- [12] N. A. Cahyani Putri and D. B. Arianto, “Komparasi Penggunaan Information Gain Pada Machine Learning untuk Memprediksi Harga Rumah di Jabodetabek,” *J. Sains dan Teknol.*, vol. 5, no. 3, pp. 756–762, 2024, doi: 10.55338/saintek.v5i3.2052.
- [13] Q. Amelia, “Penerapan Algoritma Neural Network Untuk Klasifika,” vol. 1, no. 5, pp. 1–16, 2024.
- [14] A. Kurniawan and R. Z. A. Aziz, “Prediksi Kabut Bandar Udara di Indonesia Menggunakan Neural Network dan Radom Forest,” vol. 6, no. 2, pp. 746–757, 2024, doi: 10.47065/bits.v6i2.5544.
- [15] R. Pratama, R. Herdiana, R. Hamonangan, and S. Anwar, “Analisis Prediksi Kelulusan Mahasiswa Menggunakan Metode Artificial Neural Network,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 687–693, 2024, doi: 10.36040/jati.v8i1.8762.
- [16] J. Ahsana, “Prediksi Pelanggaran Lalu Lintas Di Kabupaten Karangasem Menggunakan Algoritma Neural Network,” vol. 2, no. 1, pp. 21–26, 2024.