

Analisis Pola Temporal Volume Kendaraan di Kota Kediri Menggunakan LSTM

^{1*}Diky Kristian Erlangga, ²Daniel Swanjaya, ³Resty Wulanningrum

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

¹dikykrastian.e@gmail.com, ²daniel@unpkediri.ac.id, ³restyw@unpkdr.ac.id

Penulis Korespondensi : Diky Kristian Erlangga

Abstrak—Pertumbuhan jumlah kendaraan di perkotaan memerlukan pemahaman yang baik terhadap pola temporal lalu lintas untuk mendukung pengelolaan transportasi. Penelitian ini bertujuan menganalisis pola temporal volume kendaraan di Kota Kediri menggunakan algoritma Long Short-Term Memory (LSTM). Data diperoleh dari enam titik CCTV Dinas Perhubungan Kota Kediri pada bulan Mei 2026 dengan deteksi kendaraan menggunakan algoritma YOLOv11. Tahapan meliputi preprocessing data, ekstraksi fitur temporal, pemodelan CNN-BiLSTM, dan evaluasi menggunakan MAE dan RMSE. Hasil evaluasi menunjukkan MAE sebesar 1,69 dan RMSE sebesar 2,30. Analisis pola menunjukkan puncak volume pada pukul 09.00 dengan rata-rata 5,76 kendaraan per frame dan lonjakan pada pukul 16.00. Terdapat perbedaan pola antara hari kerja dan akhir pekan. LSTM mampu mengidentifikasi pola temporal lalu lintas perkotaan secara efektif.

Kata Kunci—jam sibuk, lalu lintas, LSTM, pola temporal, time-series

Abstract— The growth in the number of vehicles in urban areas requires a good understanding of temporal traffic patterns to support transportation management. This study aims to analyze temporal patterns of vehicle volume in Kediri City using the Long Short-Term Memory (LSTM) algorithm. Data were obtained from six CCTV points of the Kediri City Transportation Department in May 2026 with vehicle detection using the YOLOv11 algorithm. The stages included data preprocessing, temporal feature extraction, CNN-BiLSTM modeling, and evaluation using MAE and RMSE. The evaluation results show MAE of 1.69 and RMSE of 2.30. Pattern analysis shows a peak volume at 09.00 with an average of 5.76 vehicles per frame and a spike at 16.00. There are pattern differences between weekdays and weekends. LSTM can effectively identify urban traffic temporal patterns.

Keywords— LSTM, rush hour, temporal pattern, time-series, traffic

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Peningkatan jumlah kendaraan bermotor di perkotaan berkontribusi terhadap permasalahan kemacetan lalu lintas, khususnya di kota-kota berkembang seperti Kota Kediri. Volume kendaraan yang terus meningkat memerlukan pemahaman yang lebih baik terhadap pola pergerakan kendaraan agar pengelolaan lalu lintas dapat dilakukan secara efektif dan berbasis data. Pemahaman terhadap pola temporal lalu lintas, seperti identifikasi jam sibuk dan pola harian, menjadi aspek penting dalam perencanaan transportasi perkotaan[1]. Kota Kediri sebagai salah satu kota berkembang di Jawa Timur mengalami pertumbuhan kendaraan yang signifikan setiap tahunnya, sehingga diperlukan pemantauan dan analisis lalu lintas yang lebih sistematis dan berkelanjutan.

Analisis pola temporal lalu lintas merupakan pendekatan untuk memahami dinamika volume kendaraan berdasarkan faktor waktu. Pola ini mencakup identifikasi jam sibuk (peak hours), jam sepi (off-peak hours), serta perbedaan pola antara hari kerja dan akhir pekan. Parkavi dan Parthiban [2] menekankan pentingnya analisis pola temporal dalam manajemen lalu lintas perkotaan. Informasi ini sangat penting dalam mendukung pengambilan keputusan di bidang transportasi, seperti penentuan waktu rekayasa lalu lintas dan perencanaan infrastruktur jalan[3].

Penelitian sebelumnya oleh Pranolo dkk.[4], Afandizadeh dkk.[5], dan Elassy dkk.[6] telah menunjukkan bahwa pendekatan berbasis deep learning, khususnya Long Short-Term Memory (LSTM), unggul dalam menganalisis data runtut waktu dibandingkan metode statistik tradisional. Afandizadeh dkk. [7] menyimpulkan bahwa LSTM memberikan performa terbaik pada data lalu lintas dengan volatilitas tinggi. Elassy dkk. [8] menyatakan bahwa intelligent transportation systems memerlukan pendekatan analisis data yang adaptif. Wang [9] menemukan bahwa Bi-LSTM memiliki akurasi tinggi pada dataset lalu lintas kompleks. Molina dkk.[10] mengembangkan sistem monitoring lalu lintas dengan visualisasi data, namun metode analisisnya masih bersifat statistik sederhana. Ramadhani dan Hendrawan [11] membandingkan LSTM dengan TSFormer dan menunjukkan bahwa LSTM memberikan performa lebih stabil pada prediksi lalu lintas jangka pendek.

Berdasarkan kajian tersebut, diketahui bahwa penerapan LSTM untuk analisis pola temporal lalu lintas di Kota Kediri belum pernah dilakukan. Kebanyakan penelitian masih berfokus pada prediksi numerik tanpa mengidentifikasi secara spesifik karakteristik pola temporal. Oleh karena itu, penelitian ini bertujuan menganalisis pola temporal volume kendaraan menggunakan LSTM, dengan fokus pada identifikasi jam sibuk dan pola harian. Dengan memahami pola temporal secara lebih mendalam, hasil penelitian ini diharapkan dapat memberikan kontribusi bagi pengelola lalu lintas di Kota Kediri dalam merancang kebijakan transportasi yang lebih responsif terhadap dinamika volume kendaraan yang terus berubah.

II. METODE

2.1. Data Lalu Lintas

Data volume kendaraan diperoleh melalui pencatatan enam titik CCTV milik Dinas Perhubungan Kota Kediri, yaitu Semampir, Water Torn, A Yani Utara, Jetis, Dandangan, dan Nabatiasta. Deteksi kendaraan dilakukan menggunakan algoritma YOLOv11 yang mendeteksi kendaraan pada setiap frame CCTV. Data dicatat setiap interval 60 detik selama bulan Mei 2026, dengan total 121.199 baris data. Setiap data terdiri dari waktu (timestamp), lokasi, dan jumlah kendaraan yang terdeteksi per frame. Keenam titik CCTV tersebut berlokasi di persimpangan dan ruas jalan utama Kota Kediri yang memiliki tingkat aktivitas lalu lintas tinggi, sehingga merepresentasikan kondisi lalu lintas kota secara umum. Algoritma YOLOv11 mendeteksi empat kelas kendaraan yaitu mobil, motor, bus, dan truk pada setiap frame CCTV.

2.2. Preprocessing

Tahap preprocessing meliputi pembersihan data dari missing values, normalisasi menggunakan MinMax Scaling ke rentang 0–1 agar model belajar secara stabil, dan ekstraksi fitur temporal berupa transformasi sinusoidal jam dan hari (hour_sin, hour_cos, day_sin, day_cos) serta fitur biner is_rush_hour dan is_night. Data dibentuk menjadi sekuens dengan panjang jendela 20 langkah waktu. Data dibagi menjadi data pelatihan (90%) dan data pengujian (10%). Missing values yang ditemukan kurang dari 1% dari total data dan diatasi dengan interpolasi linier antar titik waktu terdekat untuk menjaga kontinuitas sekuens. Outlier diidentifikasi

menggunakan metode IQR dan dipertahankan karena merepresentasikan lonjakan lalu lintas yang valid. Data pelatihan dan pengujian diambil secara kronologis untuk menghindari data leakage.

2.3. Train LSTM

Model yang digunakan adalah CNN-BiLSTM yang terdiri dari lapisan konvolusi 1D untuk ekstraksi fitur lokal, dua lapisan Bidirectional LSTM untuk menangkap ketergantungan jangka panjang, dan lapisan Dense untuk output. Model dilatih dengan optimizer Adam (learning rate 0,001), loss MSE, 200 epoch, batch size 16, serta EarlyStopping dan ReduceLROnPlateau untuk mencegah overfitting. Arsitektur CNN-BiLSTM dipilih karena lapisan konvolusi 1D mampu mengekstraksi pola lokal dalam jendela waktu secara efisien, sedangkan lapisan Bidirectional LSTM menangkap ketergantungan temporal dari arah maju dan mundur. Dropout sebesar 20% diterapkan pada setiap lapisan untuk mengurangi overfitting, dan batch normalization digunakan untuk mempercepat konvergensi.

2.4. Evaluasi

Kinerja model dievaluasi menggunakan Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan Mean Absolute Percentage Error (MAPE). MAE mengukur rata-rata selisih absolut prediksi dan aktual. RMSE memberikan penalti lebih besar pada kesalahan besar. MAPE menyatakan kesalahan dalam persentase relatif terhadap nilai aktual. MAE dan RMSE dipilih karena memberikan interpretasi langsung dalam satuan jumlah kendaraan per frame. MAPE disertakan sebagai metrik pelengkap, meskipun kurang representatif untuk data dengan banyak nilai nol karena dapat menghasilkan nilai error yang tidak terhingga.

III. HASIL DAN PEMBAHASAN

3.1. Gambaran Data Lalu Lintas

Dataset yang terkumpul menunjukkan variasi volume kendaraan sepanjang hari. Volume kendaraan berkisar antara 0 hingga 36 kendaraan per frame dengan rata-rata 2,90. Data menunjukkan fluktuasi yang tinggi, yang merupakan karakteristik lalu lintas perkotaan. Contoh data hasil pengamatan disajikan pada Tabel 1. Variasi volume antar lokasi cukup signifikan, di mana titik Semampir dan Jetis cenderung memiliki volume lebih tinggi dibandingkan titik lainnya, sementara Nabatiassa dan A Yani Utara menunjukkan volume yang lebih rendah. Hal ini mengindikasikan bahwa distribusi lalu lintas di Kota Kediri tidak merata dan terkonsentrasi pada koridor-koridor tertentu.

Tabel 1. Data Volume Kendaraan

Waktu	Lokasi	Jumlah Kendaraan
2026-05-23 07:04:40	Jetis	12
2026-05-10 09:19:26	Semampir	9
2026-05-11 10:23:36	Semampir	11
2026-05-25 12:07:13	Water Torn	7
2026-05-26 11:36:20	Nabatiassa	3
2026-05-08 22:49:51	A Yani Utara	0

3.2. Hasil Preprocessing

Sebelum preprocessing, data volume kendaraan memiliki rentang nilai 0 hingga 36 kendaraan per frame dengan distribusi yang condong ke nilai rendah (skewed distribution). Terdapat missing values pada beberapa interval waktu akibat gangguan koneksi CCTV yang kemudian diisi menggunakan metode interpolasi linier. Setelah preprocessing, data dinormalisasi menggunakan

MinMax Scaling ke rentang [0, 1] sehingga seluruh fitur memiliki skala yang seragam dan model dapat belajar secara lebih stabil. Ekstraksi fitur temporal menghasilkan empat fitur siklik yaitu *hour_sin*, *hour_cos*, *day_sin*, dan *day_cos* yang merepresentasikan pola sirkadian dan mingguan. Fitur biner *is_rush_hour* (pukul 07.00–09.00 dan 16.00–19.00) dan *is_night* (pukul 22.00–05.00) juga ditambahkan untuk memperkuat sinyal pola jam sibuk. Data kemudian dibentuk menjadi sekuens dengan panjang jendela 20 langkah waktu, menghasilkan total 121.079 sampel sekuens yang siap digunakan untuk pelatihan model CNN-BiLSTM. Data pelatihan sebanyak 108.971 sekuens digunakan untuk melatih model, sedangkan 12.108 sekuens sisanya digunakan untuk pengujian. Pembagian ini memastikan model diuji pada data yang tidak pernah dilihat sebelumnya sehingga evaluasi yang dihasilkan lebih objektif.

3.3. Identifikasi Pola Temporal

Analisis pola temporal dilakukan dengan menghitung rata-rata volume kendaraan per jam. Hasil menunjukkan puncak volume terjadi pada pukul 09.00 dengan rata-rata 5,76 kendaraan per frame. Peningkatan volume mulai terlihat sejak pukul 06.00 dan mencapai puncak pada pukul 08.00–10.00 yang bertepatan dengan jam aktivitas masyarakat menuju tempat kerja atau sekolah. Pada pukul 16.00 terjadi lonjakan maksimum mencapai 36 kendaraan per frame, menandakan adanya peningkatan kepadatan lalu lintas pada sore hari. Pola ini konsisten dengan pola lalu lintas pada umumnya di kota-kota berkembang di Indonesia, di mana aktivitas masyarakat masih terpusat pada jam kerja kantor dan sekolah. Pola bimodal dengan dua puncak pada pagi dan sore hari merupakan ciri khas lalu lintas di kota berkembang, di mana pergerakan masyarakat masih mengikuti pola kerja tradisional yang terpusat di satu wilayah.

Volume kendaraan terendah terjadi pada pukul 19.00–21.00 dengan rata-rata kurang dari 0,5 kendaraan per frame. Pola ini menunjukkan bahwa aktivitas lalu lintas menurun signifikan pada malam hari. Menariknya, terdapat peningkatan volume pada dini hari pukul 02.00–05.00 dengan rata-rata 4–5 kendaraan per frame, yang kemungkinan berkaitan dengan aktivitas pengiriman barang atau perjalanan jarak jauh serta aktivitas distribusi logistik yang beroperasi pada dini hari untuk menghindari kemacetan di siang hari.


3.4. Perbedaan Hari Kerja dan Akhir Pekan

Perbandingan antara hari kerja dan akhir pekan menunjukkan variasi pola. Rata-rata volume pada hari kerja (2,90) hampir sama dengan akhir pekan (2,91). Namun demikian, nilai maksimum pada hari kerja mencapai 36, lebih tinggi dibandingkan akhir pekan yang mencapai 22. Hal ini menunjukkan bahwa lonjakan volume lalu lintas lebih sering terjadi pada hari kerja, terutama pada jam sibuk pagi dan sore. Temuan ini mengindikasikan bahwa karakteristik lalu lintas di Kota Kediri pada akhir pekan cenderung lebih merata tanpa lonjakan signifikan, berbeda dengan hari kerja yang memiliki pola bimodal dengan dua puncak kepadatan pada pagi dan sore hari. Informasi ini penting bagi Dinas Perhubungan Kota Kediri untuk menentukan kebijakan rekayasa lalu lintas yang berbeda antara hari kerja dan akhir pekan, seperti pengaturan waktu lampu lalu lintas dan penempatan petugas di lapangan.

3.5. Hasil Pelatihan dan Evaluasi Model

Model LSTM dilatih menggunakan 108.971 data pelatihan dan diuji pada 12.108 data pengujian. Proses training menunjukkan penurunan loss yang stabil. Hasil evaluasi pada data pengujian menunjukkan MAE sebesar 1,69 dan RMSE sebesar 2,30. Nilai MAE yang relatif kecil menunjukkan bahwa model memiliki deviasi yang rendah dalam memprediksi volume kendaraan. MAPE tercatat sebesar 70,31%, yang disebabkan oleh banyaknya nilai nol dalam dataset. Gambar 1 menyajikan perbandingan data aktual dan prediksi pada sampel pengujian. Kurva loss menunjukkan penurunan yang signifikan pada 20 epoch pertama dan kemudian stabil di sekitar

epoch ke-60, mengindikasikan bahwa model tidak mengalami overfitting berkat mekanisme EarlyStopping dan ReduceLROnPlateau. Nilai MAPE yang tinggi (70,31%) perlu diinterpretasikan dengan hati-hati karena banyaknya nilai nol dalam dataset menyebabkan pembagian dengan nilai aktual nol yang menghasilkan error tak terhingga. Meskipun demikian, MAE yang rendah (1,69) mengonfirmasi bahwa secara absolut deviasi prediksi model terhadap nilai aktual tergolong kecil.



Gambar 1. Perbandingan Volume Kendaraan Aktual dan Prediksi LSTM

Perbandingan menunjukkan bahwa model LSTM mampu mengikuti pola fluktuasi data aktual, khususnya pada saat terjadi lonjakan volume kendaraan. Model dapat menangkap pola temporal non-linear seperti peningkatan volume pada pagi hari. Hasil ini menunjukkan bahwa LSTM efektif dalam mengekstraksi pola temporal dari data time-series lalu lintas skala kecil. Meskipun demikian, terdapat beberapa titik di mana prediksi meleset cukup jauh, terutama pada saat terjadi lonjakan mendadak yang tidak didahului oleh pola serupa dalam jendela 20 langkah waktu sebelumnya. Hal ini menunjukkan bahwa penambahan fitur kontekstual seperti data cuaca atau jadwal kegiatan kota dapat meningkatkan akurasi prediksi pada kondisi anomali.

3.6. Pembahasan

Pola temporal lalu lintas di Kota Kediri menunjukkan karakteristik yang berbeda dengan pola lalu lintas kota besar pada umumnya. Puncak volume terjadi pada pukul 09.00 dengan nilai rata-rata yang relatif rendah karena data merupakan hasil deteksi per frame CCTV. LSTM mampu mengidentifikasi pola ini dengan baik, sebagaimana didukung oleh penelitian Wang [12] dan Shepelev dkk. [13] yang menyatakan LSTM efektif untuk data time-series lalu lintas. De la Cruz-Nicolas dkk. [14] juga mendukung temuan ini dengan menunjukkan bahwa LSTM adaptif mampu menangani pola kemacetan yang dinamis. Keterbatasan penelitian ini adalah penggunaan data agregat dari enam titik CCTV, sehingga analisis per lokasi secara spesifik dapat menjadi arah penelitian selanjutnya. Dibandingkan dengan penelitian Pranolo dkk. [15] yang dilakukan di kota besar dengan volume kendaraan mencapai ratusan per menit, hasil di Kota Kediri menunjukkan skala yang jauh lebih kecil, yaitu rata-rata 2,90 kendaraan per frame. Hal ini mencerminkan perbedaan karakteristik lalu lintas antara kota besar dan kota berkembang. Meskipun demikian, pola temporal yang teridentifikasi tetap menunjukkan konsistensi dengan teori lalu lintas perkotaan, di mana terdapat dua puncak kepadatan yang berkorelasi dengan jam aktivitas

masyarakat. Penelitian selanjutnya dapat mempertimbangkan penggunaan data dengan rentang waktu yang lebih panjang untuk menangkap variasi musiman.

Secara umum, penelitian ini membuktikan bahwa pemanfaatan metode deep learning berbasis LSTM dapat digunakan sebagai alat analisis untuk memahami karakteristik lalu lintas perkotaan. Kemampuan model dalam mengenali pola temporal memberikan peluang untuk penerapan lebih lanjut pada sistem transportasi cerdas yang membutuhkan pengambilan keputusan secara otomatis dan berbasis data. Hasil ini sejalan dengan temuan Afandizadeh dkk.[16] yang menyatakan bahwa LSTM unggul dalam menangkap ketergantungan jangka panjang pada data time-series lalu lintas. Penerapan metode ini di Kota Kediri membuktikan bahwa pendekatan deep learning tetap efektif meskipun dengan volume data yang relatif terbatas dibandingkan studi di kota-kota besar.

Hasil penelitian ini juga memberikan gambaran awal mengenai pola mobilitas kendaraan di Kota Kediri yang dapat menjadi dasar bagi penelitian lanjutan. Dengan ketersediaan data yang lebih panjang dan cakupan lokasi yang lebih luas, analisis di masa mendatang diharapkan mampu menghasilkan pemahaman yang lebih komprehensif mengenai dinamika lalu lintas perkotaan serta mendukung pengembangan kebijakan transportasi yang lebih efektif. Penambahan variabel eksternal seperti jadwal libur nasional, event kota, dan kondisi cuaca juga direkomendasikan untuk meningkatkan kemampuan model dalam memprediksi pola lalu lintas yang lebih akurat dan adaptif terhadap kondisi yang berubah-ubah secara dinamis.

IV. KESIMPULAN

Berdasarkan hasil analisis, algoritma LSTM mampu mengidentifikasi pola temporal volume kendaraan di Kota Kediri dengan nilai MAE 1,69 dan RMSE 2,30. Puncak volume teridentifikasi pada pukul 09.00 dengan rata-rata 5,76 kendaraan per frame serta lonjakan maksimum pada pukul 16.00. Terdapat perbedaan pola antara hari kerja dan akhir pekan, di mana lonjakan volume lebih tinggi pada hari kerja. Hasil ini menunjukkan bahwa LSTM dapat menjadi solusi efektif dalam analisis pola lalu lintas untuk mendukung pengelolaan transportasi perkotaan berbasis data. Penelitian selanjutnya dapat dikembangkan dengan analisis multi-lokasi secara spesifik serta penambahan fitur eksternal seperti data cuaca. Model CNN-BiLSTM yang digunakan menunjukkan performa yang memadai dengan MAE 1,69 dan RMSE 2,30, serta mampu menangkap pola temporal non-linear seperti peningkatan volume pada jam sibuk pagi dan sore. Temuan ini memperkuat bukti bahwa LSTM dapat diandalkan untuk analisis pola lalu lintas di kota berkembang dengan karakteristik data yang fluktuatif dan tidak stabil. Hasil penelitian ini dapat dijadikan dasar bagi Pemerintah Kota Kediri dalam mengoptimalkan pengaturan lalu lintas, seperti penjadwalan rekayasa lalu lintas pada jam sibuk dan penempatan petugas pada titik-titik rawan kemacetan. Pengembangan sistem prediksi real-time berbasis LSTM juga berpotensi diintegrasikan dengan sistem transportasi cerdas (intelligent transportation system) untuk mendukung pengambilan keputusan yang lebih responsif dan berbasis data.

DAFTAR PUSTAKA

- [1] A. Pranolo, S. Saifullah, A. B. U. Putra, R. Dreżewski, and A. P. Wibawa, "Urban Traffic Volume Prediction using LSTM and Bi-LSTM: Performance Evaluation on the Metro Interstate Dataset," *ILKOM Jurnal Ilmiah*, vol. 17, no. 3, pp. 227–240, Oct. 2025, doi: 10.33096/ilkom.v17i3.3001.227-240.

- [2] S. Parkavi and A. Parthiban, "Evaluating urban traffic dynamics: a study of mobility in Vellore city," *Frontiers in Sustainable Cities*, vol. 7, 2025, doi: 10.3389/frsc.2025.1631748.
- [3] S. S. Nurashila, F. Hamami, and T. F. Kusumasari, "PERBANDINGAN KINERJA ALGORITMA RECURRENT NEURAL NETWORK (RNN) DAN LONG SHORT-TERM MEMORY (LSTM): STUDI KASUS PREDIKSI KEMACETAN LALU LINTAS JARINGAN PT XYZ," *JIPi (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 8, no. 3, pp. 864–877, Aug. 2023, doi: 10.29100/jipi.v8i3.3961.
- [4] A. Pranolo, S. Saifullah, A. B. U. Putra, R. Dreżewski, and A. P. Wibawa, "Urban Traffic Volume Prediction using LSTM and Bi-LSTM: Performance Evaluation on the Metro Interstate Dataset," *ILKOM Jurnal Ilmiah*, vol. 17, no. 3, pp. 227–240, Oct. 2025, doi: 10.33096/ilkom.v17i3.3001.227-240.
- [5] S. Afandizadeh, S. Abdolahi, and H. Mirzahosseini, "Deep Learning Algorithms for Traffic Forecasting: A Comprehensive Review and Comparison with Classical Ones," 2024, *Hindawi Limited*. doi: 10.1155/2024/9981657.
- [6] M. Elassy, M. Al-Hattab, M. Takruri, and S. Badawi, "Intelligent transportation systems for sustainable smart cities," Jun. 01, 2024, *Elsevier Ltd*. doi: 10.1016/j.treng.2024.100252.
- [7] S. Afandizadeh, S. Abdolahi, and H. Mirzahosseini, "Deep Learning Algorithms for Traffic Forecasting: A Comprehensive Review and Comparison with Classical Ones," 2024, *Hindawi Limited*. doi: 10.1155/2024/9981657.
- [8] M. Elassy, M. Al-Hattab, M. Takruri, and S. Badawi, "Intelligent transportation systems for sustainable smart cities," Jun. 01, 2024, *Elsevier Ltd*. doi: 10.1016/j.treng.2024.100252.
- [9] Y. Wang, "Advanced Network Traffic Prediction Using Deep Learning Techniques: A Comparative Study of SVR, LSTM, GRU, and Bidirectional LSTM Models," *ITM Web of Conferences*, vol. 70, p. 03021, 2025, doi: 10.1051/itmconf/20257003021.
- [10] J. M. G. Molina, A. S. Sotis, R. C. Pascual, J. E. D. Cubillas, and J. B. Matias, "Development of Real-Time Traffic Monitoring and Visualization System Using Stationary Roadside Sensor," in *ACM International Conference Proceeding Series*, Association for Computing Machinery, Dec. 2022, pp. 154–160. doi: 10.1145/3579895.3579919.
- [11] J. W. Ramadhani and A. Hendrawan, "PEMODELAN URUTAN JANGKA PENDEK VS JANGKA PANJANG: LSTM VS TSFORMER DALAM PREDIKSI LALU LINTAS PERKOTAAN," *Jurnal Informatika Teknologi dan Sains (Jinteks)*, vol. 8, no. 1, pp. 338–345, Feb. 2026, doi: 10.51401/jinteks.v8i1.6996.
- [12] Y. Wang, "Advanced Network Traffic Prediction Using Deep Learning Techniques: A Comparative Study of SVR, LSTM, GRU, and Bidirectional LSTM Models," *ITM Web of Conferences*, vol. 70, p. 03021, 2025, doi: 10.1051/itmconf/20257003021.
- [13] V. Shepelev, A. Glushkov, A. Vorobyev, O. Ivanova, and I. Alferova, "Predicting Urban Traffic Congestion Through Deterministic and Stochastic Modeling Using LSTM Neural Networks," *Sustainability (Switzerland)*, vol. 17, no. 23, Dec. 2025, doi: 10.3390/su172310655.
- [14] E. De la Cruz-Nicolás, H. Estrada-Esquivel, A. Martínez-Rebollar, O. Pliego-Martínez, and E. Clemente Torres, "Adaptive Traffic Congestion Prediction Using LSTM Networks and Physics-Based Models," *International Journal of Combinatorial Optimization Problems and Informatics*, vol. 16, no. 4, pp. 212–232, Oct. 2025, doi: 10.61467/2007.1558.2025.v16i4.1021.
- [15] A. Pranolo, S. Saifullah, A. B. U. Putra, R. Dreżewski, and A. P. Wibawa, "Urban Traffic Volume Prediction using LSTM and Bi-LSTM: Performance Evaluation on the Metro Interstate Dataset," *ILKOM Jurnal Ilmiah*, vol. 17, no. 3, pp. 227–240, Oct. 2025, doi: 10.33096/ilkom.v17i3.3001.227-240.

- [16] S. Afandizadeh, S. Abdolahi, and H. Mirzahosseini, "Deep Learning Algorithms for Traffic Forecasting: A Comprehensive Review and Comparison with Classical Ones," 2024, *Hindawi Limited*. doi: 10.1155/2024/9981657.