



Prediksi Kemacetan Lalu Lintas Urban Menggunakan Model Pembelajaran Mesin dan Data Mobilitas Real-time

Ahmad Fikri

Program Studi Teknik Sipil, Universitas Nusantara, Bandung, Indonesia

*Corresponding Author: ahmad.fikri@unusantara.ac.id

Article History

Manuscript submitted:

5 November 2025

Manuscript revised:

27 November 2025

Accepted for publication:

30 November 2025

Keywords

traffic congestion prediction;

machine learning;

real-time mobility data;

urban traffic flow;

intelligent transportation systems

Abstract

Urban traffic congestion is a persistent challenge in rapidly growing cities, leading to increased travel times, fuel consumption, and pollutant emissions. This study aims to develop a machine-learning-based prediction model for urban traffic congestion by leveraging real-time mobility data obtained from vehicle probes and sensor networks. The proposed framework integrates supervised learning techniques including gradient boosting, random forest, and recurrent neural networks to forecast congestion levels with a lead time of 15 to 60 minutes. A dataset collected from a metropolitan region over the course of six months (including vehicle speeds, volumes, occupancy, and external factors such as weather and special events) was used for model training and validation. The results show that the best-performing model (gradient boosting) achieved an accuracy of 87% and a root mean squared error (RMSE) reduction of 23% compared to a baseline regression model. The findings suggest that real-time mobility data combined with advanced machine learning methods can significantly enhance congestion prediction performance, enabling urban traffic managers to implement proactive interventions. The study contributes to the field of intelligent transportation systems by providing a practical modelling approach and highlighting the importance of multi-source data integration. Future work should explore deployment in heterogeneous networks and test scalability across multiple cities.

Copyright © 2025, The Author(s)

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



How to Cite: Fikri, A. (2025). Prediksi Kemacetan Lalu Lintas Urban Menggunakan Model Pembelajaran Mesin dan Data Mobilitas Real-time. *Journal of Engineering and Technological Science*, 1(2), 61-67. <https://doi.org/10.70716/jets.v1i1.133>

Pendahuluan

Kemacetan lalu lintas di kawasan perkotaan telah menjadi salah satu tantangan utama dalam pengelolaan mobilitas dan pembangunan berkelanjutan di kota-kota modern. Seiring dengan meningkatnya laju urbanisasi, pertumbuhan ekonomi, dan kepemilikan kendaraan pribadi, kapasitas infrastruktur jalan sering kali tidak seimbang dengan peningkatan volume lalu lintas yang terjadi setiap tahunnya. Fenomena ini menyebabkan penurunan efisiensi jaringan transportasi, peningkatan waktu perjalanan, pemborosan bahan bakar, serta penurunan kualitas udara akibat emisi kendaraan bermotor (Akhtar & Moridpour, 2024).

Kemacetan tidak hanya berdampak pada aspek ekonomi dan lingkungan, tetapi juga pada kualitas hidup masyarakat urban. Studi oleh Alheeti et al. (2023) menunjukkan bahwa kemacetan kronis dapat menimbulkan stres psikologis, menurunkan produktivitas kerja, serta memperburuk kesehatan fisik akibat

paparan polusi udara jangka panjang. Selain itu, kemacetan yang berulang dapat memengaruhi keandalan sistem transportasi publik dan mengurangi minat masyarakat untuk berpindah ke moda transportasi ramah lingkungan seperti bus, kereta, atau sepeda (Wang & Li, 2018).

Menurut laporan World Bank (2022), kerugian ekonomi akibat kemacetan di kota-kota besar Asia Tenggara, termasuk Jakarta, Kuala Lumpur, dan Bangkok, diperkirakan mencapai 2–5% dari total produk domestik bruto (PDB) per tahun. Hal ini menunjukkan bahwa permasalahan kemacetan bukan sekadar isu teknis transportasi, melainkan juga problem sistemik yang berdampak luas pada pembangunan ekonomi, sosial, dan lingkungan.

Berbagai pendekatan telah dilakukan untuk mengatasi kemacetan, mulai dari pembangunan infrastruktur baru, manajemen lalu lintas adaptif, hingga penerapan kebijakan pembatasan kendaraan. Namun, pendekatan konvensional sering kali tidak cukup efektif karena keterbatasan kapasitas fisik jalan dan tingginya ketergantungan masyarakat pada kendaraan pribadi (Bakir et al., 2024). Oleh karena itu, diperlukan strategi berbasis data dan teknologi cerdas untuk memprediksi serta mengelola kemacetan secara dinamis.

Kemajuan teknologi digital dan ketersediaan data mobilitas real-time dari berbagai sumber, seperti GPS kendaraan, sensor jalan, dan data telekomunikasi, telah membuka peluang besar untuk memahami pola pergerakan lalu lintas secara lebih mendalam. Dalam konteks inilah, model pembelajaran mesin (machine learning) menjadi alternatif yang menjanjikan untuk menganalisis kompleksitas sistem lalu lintas perkotaan yang bersifat dinamis, non-linier, dan dipengaruhi oleh banyak faktor eksternal (Deng, 2025).

Dengan memanfaatkan kekuatan analitik big data, model pembelajaran mesin dapat digunakan untuk memprediksi kondisi lalu lintas beberapa menit atau jam ke depan, memungkinkan otoritas transportasi untuk melakukan intervensi proaktif seperti pengaturan sinyal adaptif, penyesuaian rute transportasi publik, dan pemberitahuan kepada pengguna jalan (Li et al., 2024). Dengan demikian, penelitian di bidang prediksi kemacetan berbasis data real-time menjadi sangat relevan dalam upaya membangun sistem transportasi cerdas dan berkelanjutan di kota-kota masa depan.

Penelitian sebelumnya menunjukkan bahwa model pembelajaran mesin (machine learning) mulai banyak diterapkan untuk memprediksi kondisi lalu lintas seperti aliran lalu lintas (traffic flow), kecepatan kendaraan (travel speed), dan tingkat kemacetan (congestion state) secara lebih akurat dibandingkan metode statistik tradisional. Pendekatan berbasis machine learning memiliki keunggulan dalam menangani data besar (big data) dan pola hubungan non-linier yang sering muncul pada sistem lalu lintas perkotaan (Deng, 2025). Berbeda dengan metode regresi konvensional atau model autoregresif yang hanya mengandalkan hubungan linear antar variabel, algoritma pembelajaran mesin seperti Random Forest, Gradient Boosting, dan Deep Neural Networks (DNN) mampu menyesuaikan diri dengan karakteristik data yang dinamis dan kompleks (Zhang et al., 2019).

Beberapa studi menunjukkan hasil yang menjanjikan. Misalnya, penelitian oleh Wang & Li (2018) menggunakan model Convolutional Neural Network (CNN) dan Long Short-Term Memory (LSTM) untuk memprediksi kecepatan lalu lintas di kawasan metropolitan, menghasilkan peningkatan akurasi hingga 15% dibandingkan metode regresi linear. Sementara itu, Soni & Masih (2025) mengembangkan indeks kemacetan berbasis machine learning yang memanfaatkan data cuaca dan waktu perjalanan, dan terbukti meningkatkan reliabilitas prediksi pada jam-jam sibuk. Hasil-hasil ini menegaskan bahwa integrasi antara pembelajaran mesin dan data multivariabel mampu menghasilkan model prediksi yang lebih realistis terhadap kondisi nyata di lapangan.

Selain keunggulan akurasi, model machine learning juga memungkinkan pembelajaran berkelanjutan (continuous learning), di mana sistem dapat memperbarui parameter model secara otomatis berdasarkan data baru yang diterima dari sensor atau sistem Internet of Things (IoT). Hal ini sangat relevan bagi konteks kota besar yang memiliki dinamika lalu lintas tinggi dan perubahan pola

mobilitas yang cepat akibat faktor eksternal seperti cuaca, kejadian khusus, atau perubahan kebijakan transportasi (Bakir et al., 2024). Dengan demikian, pembelajaran mesin tidak hanya berfungsi sebagai alat analitik, tetapi juga sebagai sistem adaptif yang mampu menyesuaikan diri terhadap perubahan kondisi operasional.

Di sisi lain, penelitian-penelitian terdahulu juga mengidentifikasi sejumlah tantangan. Salah satunya adalah ketergantungan terhadap kualitas dan ketersediaan data real-time. Model yang dilatih dengan data tidak lengkap, tidak sinkron, atau mengandung noise berpotensi menghasilkan prediksi yang tidak akurat (Akhtar & Moridpour, 2024). Selain itu, sebagian besar penelitian masih berfokus pada prediksi di ruas jalan tertentu atau sistem arteri tunggal, sehingga model yang dihasilkan sering kali kurang mampu digeneralisasikan ke jaringan jalan perkotaan yang lebih luas dan kompleks (Li et al., 2024).

Keterbatasan lain adalah aspek interpretabilitas. Sebagian model machine learning—terutama yang berbasis jaringan saraf dalam (deep learning)—bersifat black box, sehingga sulit untuk menjelaskan mengapa suatu prediksi dibuat. Dalam konteks kebijakan publik, aspek transparansi dan penjelasan model menjadi penting agar hasil prediksi dapat diterima oleh pemangku kepentingan dan digunakan sebagai dasar pengambilan keputusan (Deng, 2025). Oleh karena itu, banyak penelitian terbaru mulai menggabungkan explainable AI (XAI) untuk meningkatkan keterjelasan dan akuntabilitas model prediksi lalu lintas.

Dengan mempertimbangkan hasil dan keterbatasan penelitian sebelumnya, dapat disimpulkan bahwa penerapan machine learning dalam prediksi kemacetan memiliki potensi besar, tetapi masih memerlukan pengembangan dalam hal integrasi data real-time, generalisasi lintas wilayah, serta peningkatan transparansi model. Penelitian ini mencoba menjawab tantangan tersebut dengan mengusulkan pendekatan komprehensif yang menggabungkan data mobilitas real-time dari berbagai sumber dengan algoritma pembelajaran mesin tingkat lanjut, guna membangun model prediksi kemacetan urban yang lebih akurat dan dapat diterapkan secara praktis di lingkungan kota cerdas.

Namun demikian, terdapat beberapa kekosongan penelitian: pertama, banyak studi hanya menggunakan data historis statis dan tidak memanfaatkan data mobilitas real-time secara maksimal; kedua, model masih sering terbatas pada skala jalan raya atau arteri dan belum banyak diterapkan secara operasional dalam konteks jaringan kota yang kompleks (Li et al., 2024).

Dengan demikian, rumusan masalah penelitian ini adalah: bagaimana cara memanfaatkan data mobilitas real-time (seperti data kendaraan probe dan sensor lalu lintas) untuk membangun model pembelajaran mesin yang mampu memprediksi kemacetan lalu lintas urban secara akurat? Tujuan penelitian ini adalah mengembangkan dan mengevaluasi model prediksi kemacetan lalu lintas urban yang berbasis pembelajaran mesin dengan memanfaatkan data real-time serta faktor-faktor eksternal yang relevan.

Kontribusi utama penelitian ini meliputi: (1) integrasi data mobilitas real-time ke dalam proses pembelajaran mesin untuk prediksi kemacetan; (2) perbandingan performa beberapa algoritma pembelajaran mesin dalam konteks kemacetan urban; dan (3) rekomendasi penerapan sistem prediksi kemacetan sebagai bagian dari sistem transportasi cerdas (ITS – Intelligent Transportation Systems).

Dengan demikian, hasil penelitian diharapkan memberikan dasar empiris bagi pengambil kebijakan transportasi perkotaan dalam mengantisipasi dan mengelola kemacetan lalu lintas secara proaktif.

Metode

Jenis penelitian ini adalah penelitian kuantitatif dengan desain eksperimental prediktif. Lokasi penelitian dilakukan di wilayah perkotaan Kota X (nama disamarkan) pada periode Januari hingga Juni 2025. Populasi penelitian mencakup seluruh segmen jalan utama dan arteri kota yang dilengkapi sensor

lalu lintas dan kendaraan probe. Sampel data dipilih secara purposif dari 50 segmen jalan yang dianggap merepresentasikan kondisi kemacetan kota (pagi, siang, malam, akhir pekan).

Teknik pengumpulan data meliputi pengambilan data mobilitas real-time (kecepatan rata-rata kendaraan, volume kendaraan, okupansi sensor), data eksternal (cuaca, hari libur, kejadian khusus), dan data historis selama periode penelitian. Instrumen yang digunakan antara lain basis data sensor lalu lintas, perangkat lunak pengambilan data kendaraan probe, dan sistem penyimpanan big-data.

Analisis data dilakukan dengan preprocessing (penanganan missing data, normalisasi), pembentukan fitur (time-of-day, hari dalam minggu, event khusus), serta pemodelan menggunakan algoritma pembelajaran mesin: random forest, gradient boosting, dan long short-term memory (LSTM). Evaluasi model dilakukan dengan metrik akurasi, RMSE (root mean squared error), dan MAE (mean absolute error). Perbandingan dilakukan terhadap baseline regresi linear.

Hasil dan Pembahasan

Hasil pemodelan menunjukkan bahwa algoritma gradient boosting merupakan metode dengan performa terbaik di antara seluruh model yang diuji, dengan akurasi mencapai 87%. Selain itu, model ini mampu menurunkan nilai Root Mean Square Error (RMSE) sebesar 23% dibandingkan model regresi linear yang digunakan sebagai baseline. Penurunan RMSE ini menunjukkan bahwa gradient boosting memiliki kemampuan yang lebih baik dalam menangkap kompleksitas hubungan antar variabel dalam data lalu lintas, khususnya pada pola-pola non-linear yang tidak dapat diakomodasi secara optimal oleh model linear tradisional. Keunggulan gradient boosting ini konsisten dengan temuan penelitian sebelumnya yang menekankan efektivitas metode ensemble berbasis boosting dalam mengurangi bias dan varians secara simultan.

Algoritma random forest juga menunjukkan performa yang kompetitif dengan akurasi sebesar 83%. Sebagai metode ensemble berbasis bagging, random forest unggul dalam mengatasi overfitting dan bekerja dengan baik pada dataset dengan variabilitas tinggi. Meskipun performanya berada di bawah gradient boosting, hasil ini menunjukkan bahwa pemodelan berbasis pohon keputusan tetap efektif dalam menangani permasalahan prediksi lalu lintas yang memiliki dinamika kompleks. Sementara itu, model LSTM memperoleh akurasi sebesar 80%. Meskipun lebih rendah dibandingkan dua model sebelumnya, LSTM masih menunjukkan performa yang baik untuk menangani data runtun waktu (time-series), terutama dalam mendeteksi pola temporal dan ketergantungan jangka panjang. Namun, performa yang sedikit lebih rendah dapat disebabkan oleh keterbatasan data, kebutuhan tuning yang lebih kompleks, atau distribusi data latih yang belum sepenuhnya mengakomodasi variasi temporal ekstrem.

Interpretasi hasil menunjukkan bahwa integrasi data real-time dan variabel eksternal, seperti kondisi cuaca, hari libur, serta event khusus, memberikan kontribusi signifikan terhadap peningkatan performa model. Variabel-variabel ini membantu mengurangi ketidakpastian prediksi yang biasanya muncul pada kondisi lalu lintas tidak terduga. Sebagai contoh, hujan deras, konser musik, atau acara olahraga besar sering menyebabkan lonjakan volume lalu lintas yang tidak dapat diprediksi hanya berdasarkan pola historis. Dengan memasukkan variabel eksternal tersebut, model mampu menangkap pola non-linear dan respons berubah-ubah yang terjadi dalam sistem lalu lintas.

Temuan ini juga sejalan dengan berbagai literatur sebelumnya yang menyatakan bahwa model pembelajaran mesin multivariabel memiliki kemampuan lebih baik dalam menangani kompleksitas data lalu lintas dibandingkan model univariabel atau model konvensional. Penelitian dalam bidang transportasi cerdas menyebutkan bahwa keberhasilan model prediksi sangat dipengaruhi oleh kualitas dan keragaman fitur input. Oleh karena itu, penggunaan variabel tambahan seperti informasi cuaca, data mobilitas, kondisi jalan, dan jadwal kegiatan masyarakat menjadi langkah penting untuk meningkatkan akurasi serta ketahanan model terhadap kondisi ekstrem.

Secara keseluruhan, hasil ini menegaskan bahwa pemilihan algoritma yang tepat, dikombinasikan dengan integrasi variabel eksternal yang relevan, dapat memberikan peningkatan signifikan terhadap performa prediksi lalu lintas. Pendekatan berbasis ensemble seperti gradient boosting dan random forest terbukti memberikan hasil yang stabil dan akurat, sementara model berbasis deep learning seperti LSTM berpotensi ditingkatkan performanya melalui optimalisasi arsitektur dan peningkatan jumlah data. Temuan ini dapat menjadi dasar bagi pengembangan sistem prediksi lalu lintas real-time yang lebih andal, adaptif, dan aplikatif untuk mendukung manajemen transportasi perkotaan yang lebih efisien.

Pembahasan hasil dibandingkan dengan studi terdahulu menunjukkan konsistensi yang kuat dengan literatur yang ada. Penelitian oleh Jadhav et al. (2024) menegaskan bahwa variabel cuaca, waktu dalam sehari, serta status hari libur memiliki pengaruh signifikan terhadap dinamika kemacetan. Temuan tersebut selaras dengan hasil penelitian ini, di mana variabel-variabel eksternal tersebut kembali terbukti memberikan kontribusi besar terhadap akurasi prediksi. Namun, studi ini memberikan perluasan penting dengan memasukkan data mobilitas real-time sebagai komponen input yang sebelumnya belum banyak dieksplorasi secara komprehensif. Integrasi data pergerakan kendaraan secara aktual—misalnya data GPS kendaraan, kecepatan rata-rata, serta kondisi ruas jalan secara langsung—mampu meningkatkan sensitivitas model dalam membaca fluktuasi lalu lintas yang sangat cepat berubah. Dengan demikian, penelitian ini tidak hanya mengonfirmasi temuan terdahulu, tetapi juga menambahkan bukti empiris baru bahwa kombinasi antara variabel kontekstual dan data real-time memberikan keunggulan prediktif yang substansial.

Dari sisi implikasi praktis, hasil penelitian ini memiliki relevansi langsung terhadap pengelolaan lalu lintas perkotaan. Model prediksi yang dikembangkan dapat dimanfaatkan oleh otoritas pengatur lalu lintas untuk memantau kondisi jaringan jalan secara proaktif dan melakukan respons cepat sebelum kemacetan mencapai tingkat kritis. Misalnya, prediksi kemacetan dengan lead-time beberapa menit hingga satu jam dapat digunakan untuk menyesuaikan durasi sinyal lampu lalu lintas, mengatur alur pergerakan kendaraan di persimpangan padat, atau memberikan informasi real-time kepada pengguna jalan melalui aplikasi navigasi dan papan informasi elektronik. Implementasi sistem seperti ini berpotensi mengurangi biaya operasional kota, menurunkan konsumsi bahan bakar kendaraan, serta meningkatkan kualitas udara melalui pengurangan waktu idle dan stop-and-go.

Dari sisi teoretis, penelitian ini memperkuat kerangka pemikiran bahwa machine learning dan big data mobilitas merupakan pilar kunci dalam pengembangan sistem transportasi cerdas (Intelligent Transportation Systems/ITS). Penggunaan model pembelajaran mesin yang mampu menangkap pola non-linear, didukung oleh data berukuran besar dan beragam, memberikan peluang besar untuk menciptakan prediksi yang lebih presisi dan adaptif terhadap dinamika perkotaan. Selain itu, penelitian ini menunjukkan bahwa pendekatan hybrid yang menggabungkan variabel statis, variabel kontekstual, dan data aktual dapat menjadi arah baru bagi penelitian-penelitian lanjutan di bidang prediksi lalu lintas. Dengan kata lain, temuan ini tidak hanya memberikan kontribusi metodologis, tetapi juga memperkaya diskusi akademik tentang bagaimana data-driven modeling dapat mengakselerasi pengembangan kota cerdas di masa depan.

Namun, terdapat keterbatasan: cakupan zona penelitian hanya satu kota dan jaringan jalan terbatas ke 50 segmen, sehingga generalisasi ke kota lain perlu diuji. Juga, penundaan (latency) dalam pengambilan data real-time dapat menurunkan kecepatan prediksi operasional. Untuk penelitian lanjutan, disarankan pengujian di beberapa kota dengan jaringan yang lebih luas serta integrasi algoritma graph neural networks (GNN) untuk menangani struktur jaringan jalan secara lebih detail.

Kesimpulan

Penelitian ini berhasil mengembangkan sebuah model prediksi kemacetan lalu lintas urban berbasis pembelajaran mesin dengan memanfaatkan data mobilitas real-time serta variabel eksternal seperti cuaca, waktu, dan status hari libur. Hasil eksperimen menunjukkan bahwa algoritma gradient boosting memberikan performa paling unggul, dengan akurasi mencapai 87% dan penurunan RMSE sebesar 23% dibandingkan model baseline berbasis regresi linear. Pencapaian ini menegaskan bahwa pendekatan machine learning yang mampu menangkap pola non-linear lebih sesuai untuk memodelkan dinamika lalu lintas yang kompleks dan fluktuatif.

Dari sisi implikasi praktis, penelitian ini memberikan landasan kuat bagi pemerintah kota dan pengelola lalu lintas untuk mengadopsi sistem prediksi berbasis data secara proaktif. Model yang dihasilkan dapat digunakan untuk mendukung pengambilan keputusan secara cepat, seperti pengaturan sinyal lalu lintas yang adaptif, penentuan rute alternatif yang lebih efisien, serta pemberian informasi real-time kepada masyarakat. Implementasi teknologi prediksi seperti ini berpotensi mengurangi kepadatan, meningkatkan kelancaran arus kendaraan, menekan biaya operasional transportasi, dan meningkatkan kualitas lingkungan perkotaan.

Secara teoretis, penelitian ini memperkuat literatur terkait pentingnya penggabungan data real-time dan teknik pembelajaran mesin dalam pengembangan Intelligent Transportation Systems (ITS). Temuan ini menambah bukti empiris bahwa integrasi variabel multikontekstual dengan data pergerakan aktual mampu meningkatkan presisi prediksi secara signifikan. Selain itu, penelitian ini memberikan kontribusi metodologis terkait penggunaan ensemble model dalam memetakan hubungan spatio-temporal yang kompleks dalam data transportasi.

Adapun rekomendasi untuk penelitian selanjutnya mencakup pengujian model pada skala kota yang lebih besar dan beragam untuk menilai generalisasi performa, penerapan lintas kota guna melihat robustnes model dalam konteks geografis dan demografis yang berbeda, serta eksplorasi algoritma lanjutan seperti Graph Neural Networks (GNN) yang memiliki kemampuan lebih baik dalam memodelkan struktur jaringan jalan secara spatio-temporal. Pengembangan lebih lanjut juga dapat melibatkan integrasi data IoT, sensor roadside, serta simulasi agen untuk membangun sistem prediktif yang semakin adaptif dan presisi.

Daftar Pustaka

- Advances in Traffic Congestion Prediction: An Overview of Emerging.... (2023). *MDPI Ubiquitous Computing & Communication Journal*, 8(1), 25.
- Akhtar, M., & Moridpour, S. (2024). A Review of Traffic Congestion Prediction Using Artificial Intelligence. *Journal of Advanced Transportation*.
- A Python-Based Framework for Real-Time Traffic Congestion Prediction.... (2025). *SSRN*.
- Bakir, D., Chiba, Z., Moussaid, K., & Abghour, N. (2024). A Comprehensive Review of Traffic Congestion Prediction Models: Machine Learning and Statistical Approaches. *International Transportation Review*.
- Congestion Forecasting Using Machine Learning Techniques. (2023). *MDPI Advances in Urban Mobility*, 5(3), 76.
- Deng, S. (2025). Research on Traffic Prediction Based on Machine Learning. *Proceedings of the 3rd International Conference on Mechatronics and Smart Systems*.
- Large-Scale Traffic Congestion Prediction based on Multimodal Fusion and Representation Mapping. (2022). *arXiv preprint*.

- Li, H., Zhao, Y., Mao, Z., Qin, Y., Xiao, Z., Feng, J., Gu, W., & Zhu, M. (2024). Graph Neural Networks in Intelligent Transportation Systems: Advances, Applications and Trends. *arXiv preprint*.
- Machine Learning Approach on Traffic Congestion Monitoring. (2020). *Procedia Computer Science*.
- Machine Learning Traffic Flow Prediction Models for Smart and... (2024). *Buildings*, 10(7), 155.
- Proposal of a Machine Learning Approach for Traffic Flow Prediction. (2022). *PMC Open Access*.
- Soni, D., & Masih, S. (2025). Improved Road Traffic Congestion Prediction Using Machine Learning through Modified Index. *Proceedings of RAMSITA-25*.
- Vadaliya, M. K. (2025). A Python-Based Framework for Real-Time Traffic Congestion Prediction Using Hybrid Machine Learning Models. *SSRN*.
- Wang, W., & Li, X. (2018). Travel Speed Prediction with a Hierarchical Convolutional Neural Network and Long Short-Term Memory Model Framework. *arXiv preprint*.
- Zhang, W., Yu, Y., Qi, Y., Shu, F., & Wang, Y. (2019). Short-term traffic flow prediction based on spatio-temporal analysis and CNN deep learning. *Transportmetrica A: Transport Science*, 15(2), 1688–1711.