

Optimalisasi Rekayasa Lalu Lintas Melalui Teknologi Deteksi Objek

Roy Rudolf Huizen

Institut Teknologi dan Bisnis STIKOM Bali

e-mail: roy@stikom-bali.ac.id

Diajukan: 20 Desember 2023; Direvisi: 9 Januari 2024; Diterima: 11 Januari 2024

Abstrak

Pertumbuhan populasi dan urbanisasi yang pesat telah menyebabkan peningkatan signifikan dalam jumlah kendaraan, terutama di daerah perkotaan. Kondisi ini memicu berbagai masalah lalu lintas, seperti kemacetan dan polusi udara, yang berdampak negatif pada kehidupan sosial dan ekonomi masyarakat. Untuk mengatasi tantangan ini, diperlukan pendekatan rekayasa lalu lintas berbasis teknologi yang cerdas dan efisien. Penelitian ini membandingkan tiga metode utama—Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF), Decision Tree, dan Random Forest—dalam memprediksi kemungkinan terjadinya kemacetan pada suatu jalan. Menggunakan dataset lalu lintas yang mencakup faktor-faktor seperti volume kendaraan, kecepatan rata-rata, dan kondisi cuaca, setiap metode dilatih dan diuji untuk mengklasifikasikan data lalu lintas menjadi kategori kemacetan atau tidak. Hasil penelitian menunjukkan bahwa Random Forest memiliki performa terbaik, dengan akurasi mencapai 91,06%, precision hingga 83,04%, recall sebesar 91,06%, dan F1-score tertinggi di antara metode yang diuji. Untuk SVM menunjukkan akurasi antara 89,52% hingga 90,04%, dan Decision Tree menunjukkan akurasi antara 87,03% hingga 87,39%. Random Forest menunjukkan keunggulan dalam memprediksi kemacetan lalu lintas dan dapat menjadi solusi andal untuk diterapkan dalam sistem rekayasa lalu lintas berbasis teknologi.

Kata kunci: Kemacetan lalu lintas, Rekayasa lalu lintas, Support vector machine, Random forest, Decision tree.

Abstract

Rapid population growth and urbanization have led to a significant increase in the number of vehicles, especially in urban areas. This condition has triggered various traffic problems, such as congestion and air pollution, which negatively impact the social and economic life of the community. To address these challenges, an intelligent and efficient technology-based traffic engineering approach is needed. This study compares three main methods—Support Vector Machine (SVM) with Radial Basis Function (RBF) kernel, Decision Tree, and Random Forest—in predicting the likelihood of traffic congestion on a road. Using a traffic dataset that includes factors such as vehicle volume, average speed, and weather conditions, each method was trained and tested to classify traffic data into congestion or non-congestion categories. The results showed that Random Forest performed the best, with accuracy reaching 91.06%, precision up to 83.04%, recall at 91.06%, and the highest F1-score among the methods tested. SVM showed accuracy between 89.52% and 90.04%, and Decision Tree showed accuracy between 87.03% and 87.39%. Random Forest demonstrated superiority in predicting traffic congestion and can be a reliable solution for implementation in technology-based traffic engineering systems.

Keywords: Max traffic congestion, Traffic engineering, Support vector machine, Random forest, Decision tree.

1. Pendahuluan

Pertumbuhan populasi dan urbanisasi yang pesat telah menyebabkan peningkatan signifikan jumlah kendaraan terutama di kota-kota besar[1]. Kondisi ini memicu berbagai masalah lalu lintas, seperti kemacetan, polusi udara, dan lainnya. Persoalan tersebut tidak hanya mengganggu aktivitas sehari-hari masyarakat tetapi juga berdampak terhadap beberapa hal terkait masalah sosial[2][3]. Untuk menghadapi tantangan ini, perlu pengaturan dan melakukan terobosan salah satunya rekayasa lalu lintas berbasis

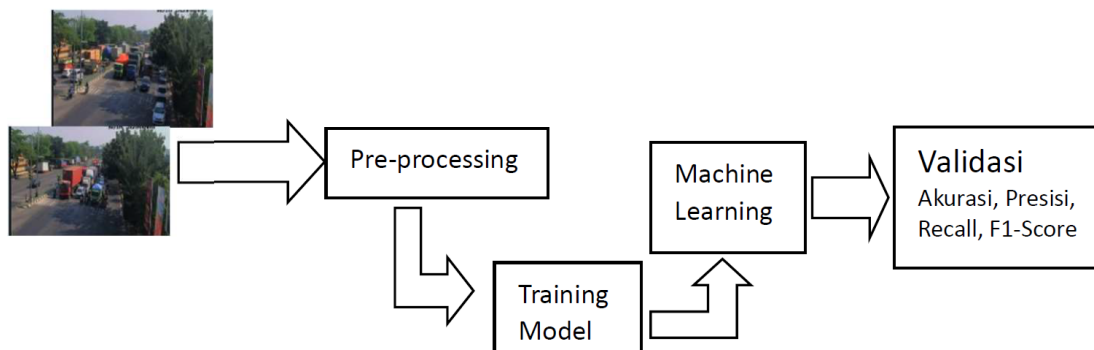
teknologi[4]. Proses tersebut bertujuan untuk merancang, mengatur, dan mengelola aliran lalu lintas secara efisien untuk mengurangi kemacetan dan meningkatkan keselamatan[5].

Penggunaan teknologi berbasis kecerdasan untuk mengoptimalkan rekayasa lalu lintas menjadi salah satu pendekatan dikarenakan kompleksitas dari sistem transportasi yang dinamis dan berubah-ubah[4]. Pendekatan yang dilakukan dengan memadukan metode konvensional dalam rekayasa lalu lintas dengan teknologi deteksi objek untuk pengenalan dan pemantauan melalui kamera. Identifikasi dan deteksi objek serta pola lalu lintas serta pejalan kaki dapat terdeteksi lebih akurat dan rinci untuk mendukung pengambilan keputusan dalam rekayasa lalu lintas[6].

Penelitian ini membandingkan tiga pendekatan utama yaitu menggunakan Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF), Decision Tree, dan Random Forest yang digunakan untuk memprediksi kemungkinan terjadinya kemacetan pada suatu jalan[7]. SVM dengan kernel RBF untuk data yang tidak terstruktur dan non-linear. Prediksi kemacetan dengan SVM dapat mengklasifikasikan data lalu lintas menjadi kategori kemacetan atau tidak[8]. Metode berikutnya menggunakan Decision Tree, dengan struktur pohon Decision Tree membuat keputusan berdasarkan berbagai fitur *input*, yaitu volume lalu lintas, kecepatan kendaraan, dan kondisi cuaca. Metode berikutnya yaitu Random Forest yang menggabungkan banyak pohon keputusan untuk meningkatkan akurasi dan stabilitas prediksi. Random Forest mengurangi masalah overfitting yang dapat terjadi pada Decision Tree tunggal[9].

2. Metode Penelitian

Penelitian ini mengembangkan dan menerapkan metode deteksi objek untuk prediksi kemacetan lalu lintas menggunakan Support Vector Machine (SVM), Decision Tree dan Random Forest. Adapun tahapan proses penelitian ditunjukkan pada Gambar 1, dimulai dari pengumpulan data, pre-processing, training model. Pengolahan menggunakan machine learning dan proses validasi.



Gambar 1. Tahapan penelitian deteksi objek.

a. Pengumpulan Data

Pada penelitian ini dataset lalu lintas sebanyak 8.936. dataset ini mencakup data dari berbagai area dan persimpangan utama, mencakup informasi seperti volume lalu lintas, kecepatan rata-rata, tingkat kemacetan, dan penggunaan kapasitas jalan. Sebagai ilustrasi gambar dari rekaman kamera CCTV menunjukkan kondisi jalan seperti ditunjukkan pada Gambar 1.



Gambar 2. Rekaman CCTV dari berbagai titik.

b. Pre-processing Data

Pre-processing digunakan untuk mengatasi permasalahan pada data dengan pembersihan dan peningkatan kualitas gambar, proses ini untuk memastikan data gambar yang mengandung noise dibersihkan menggunakan teknik filterisasi sedangkan untuk peningkatan kualitas gambar menggunakan kontras, sharpening, dan peningkatan tepi, diterapkan untuk memastikan fitur objek dalam gambar dapat diidentifikasi dengan lebih baik.

c. Training Model

Data diproses dengan melatih model menggunakan Support Vector Machine (SVM), Decision Tree dan Random Forest. Pada tahap ini, model dilatih untuk mengenali dan mengklasifikasikan objek-objek seperti kendaraan dan pejalan kaki dalam berbagai kondisi kualitas gambar. Model Support Vector Machine (SVM), Decision Tree dan Random Forest dengan kernel RBF dikomparasikan untuk mendeteksi suatu jalan mengalami kemacetan atau tidak.

d. Pengujian Model (Machine Learning)

Model dilatih kemudian diuji pada dataset baru yang tidak termasuk dalam data pelatihan. Pengujian ini dilakukan untuk mengevaluasi kemampuan model Support Vector Machine (SVM), Decision Tree dan Random Forest dalam mengenali dan mengklasifikasikan objek sehingga penggunaan metode tersebut dapat untuk mengetahui kemacetan lalu lintas.

e. Validasi Model

Validasi model bertujuan untuk mengukur efektivitas dan akurasi model Support Vector Machine (SVM), Decision Tree dan Random Forest dalam mendeteksi suatu jalan terjadi kemacetan atau tidak. Validasi dilakukan dengan menggunakan beberapa metrik evaluasi, yaitu Akurasi digunakan untuk mengukur seberapa sering model membuat prediksi yang benar. Presisi untuk mengetahui ketepatan model dalam mendeteksi objek yang sesuai. Recall untuk mengukur kemampuan model dalam menemukan semua instance dari kelas tertentu. Sedangkan F1-Score untuk mengetahui kombinasi presisi dan recall yang memberikan gambaran keseimbangan antara keduanya. Persamaan 1 sampai 4 berturut-turut untuk menghitung akurasi, presisi, recall dan F1-score[10].

$$Accuracy = \frac{(TP+TN)}{(TP+FP+FN+TN)} \times 100\% \tag{1}$$

$$Precision = \frac{TP}{(TP + FP)} \times 100\% \tag{2}$$

$$Recall = \frac{TP}{(TP + FN)} \times 100\% \tag{3}$$

$$F1 - Score = \frac{(2 \times Precision \times Recall)}{(Precision + Recall)} \tag{4}$$

Untuk TP merupakan jumlah data aktual yang sebenarnya benar dan diprediksi benar. TN merupakan jumlah data aktual yang sebenarnya salah dan diprediksi salah. FP merupakan jumlah data aktual yang sebenarnya benar dan diprediksi salah. Sedangkan FN merupakan jumlah data aktual yang sebenarnya salah dan diprediksi benar[11].

3. Hasil dan Pembahasan

Pre-processing merupakan tahap awal pemrosesan citra untuk meningkatkan kualitas gambar salah satunya dengan penajaman gambar (*image sharpening*). Penajaman gambar dilakukan dengan menerapkan filter tertentu, seperti kernel penajaman, menggunakan kernel konvolusi, matriks yang diterapkan pada setiap piksel dalam gambar untuk meningkatkan kontras dan menonjolkan tepi atau detail. Kernel yang digunakan dalam penajaman memiliki nilai negatif di sekeliling dan nilai positif yang lebih tinggi di tengahnya, hasil penajaman ditunjukkan pada Gambar 3.



a. Sebelum Pra pemrosesan data



b. Sesudah Pra pemrosesan data


Gambar 3. Salah satu proses pre-processing pada data.

Model dari Support Vector Machine (SVM), Decision Tree dan Random Forest diuji menggunakan pembagian dataset training dan test ditunjukkan pada Tabel 1.

Tabel 1. Pembagian Training dan Testing.

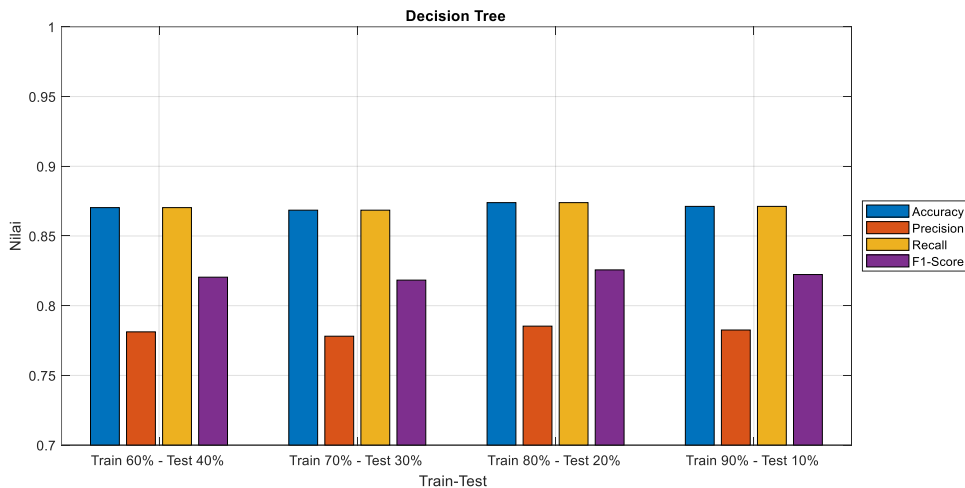
No	Training	Testing
1	60 %	40 %
2	70 %	30 %
3	80 %	20 %
4	90 %	10 %

Hasil pengujian menggunakan Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF) ditunjukkan pada Gambar 4, Pengujian tersebut menunjukkan kinerja yang konsisten pada berbagai pembagian data latih dan uji. Akurasi SVM berkisar antara 89,52% hingga 90,04%, yang menunjukkan bahwa model ini cukup handal dalam mengklasifikasikan data lalu lintas yang mengalami kemacetan atau tidak. Precision SVM sedikit lebih rendah, berkisar antara 80,14% hingga 81,08%. Recall pada SVM juga cukup tinggi, menunjukkan kemampuan model dalam mendeteksi. Sedangkan untuk nilai F1-score berkisar antara 84,57% hingga 85,33%, mengindikasikan keseimbangan yang baik antara precision dan recall.



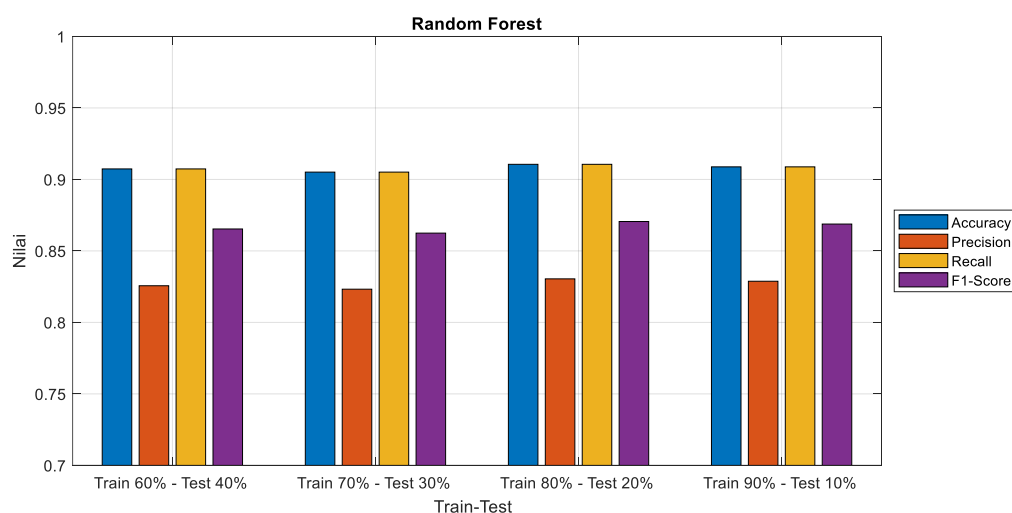
Gambar 4. Pengujian menggunakan Support Vector Machine (SVM)

Dari dua kelas label yang ada pada dataset yaitu macet dan tidak macet maka hasil pengujian dari model Decision Tree ditunjukkan pada Gambar 5, hasilnya menunjukkan model ini berada di kisaran 87,03% hingga 87,39%. Precision Decision Tree berkisar antara 77,81% hingga 78,53%. Recall dengan nilai di kisaran 86,85% hingga 87,39%. Sedangkan untuk nilai F1-score berkisar antara 81,83% hingga 82,57%.



Gambar 5. Pengujian menggunakan Decision Tree.

Pengujian menggunakan Random Forest ditunjukkan pada Gambar 5, akurasi model ini berada di kisaran 90,51% hingga 91,06%, yang mengindikasikan keunggulan dalam memprediksi dengan benar mayoritas data lalu lintas. Precision Random Forest berkisar antara 82,32% hingga 83,04%, menunjukkan kemampuan model ini dalam menghindari prediksi positif palsu dan memberikan prediksi yang lebih tepat. Recall Random Forest juga sangat baik, dengan nilai di kisaran 90,51% hingga 91,06%, menunjukkan kemampuan model dalam mendeteksi hampir semua contoh positif yang ada. Nilai F1-score berkisar antara 86,25% hingga 87,06%, menunjukkan bahwa Random Forest memiliki keseimbangan terbaik antara precision dan recall.



Gambar 6. Pengujian menggunakan Random Forest.

Dari ketiga metode yang diuji, Random Forest merupakan metode yang paling efektif dalam memprediksi kemacetan lalu lintas. Random Forest tidak hanya menawarkan akurasi yang lebih tinggi tetapi juga precision dan recall yang lebih baik dibandingkan dengan SVM dan Decision Tree.

4. Kesimpulan

Pada penelitian ini melakukan optimalisasi rekayasa lalu lintas melalui penggunaan teknologi deteksi objek yang cerdas, khususnya dengan memanfaatkan algoritma machine learning untuk memprediksi kemacetan lalu lintas. Penelitian ini membandingkan tiga metode utama, yaitu Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF), Decision Tree, dan Random Forest. Dataset lalu lintas yang digunakan mencakup berbagai faktor seperti volume kendaraan, kecepatan rata-rata, dan kondisi cuaca. Hasil penelitian menunjukkan bahwa metode Random Forest memiliki kinerja terbaik dalam memprediksi kemacetan lalu lintas, dengan akurasi mencapai 91,06%, precision hingga 83,04%, recall sebesar 91,06%, dan F1-score tertinggi dibandingkan dengan metode lainnya. Sementara itu, SVM menunjukkan akurasi antara 89,52% hingga 90,04%, dan Decision Tree menunjukkan akurasi antara 87,03% hingga 87,39%. Keunggulan Random Forest dalam memprediksi kemacetan menjadikannya solusi yang andal untuk diterapkan dalam sistem rekayasa lalu lintas berbasis teknologi.

Daftar Pustaka

- [1] X. Zhao, H. Yang, Y. Yao, H. Qi, M. Guo, and Y. Su, "Factors affecting traffic risks on bridge sections of freeways based on partial dependence plots," *Phys. A Stat. Mech. its Appl.*, vol. 598, Jul. 2022, doi: 10.1016/j.physa.2022.127343.
- [2] P. Rani and R. Sharma, "Intelligent transportation system for internet of vehicles based vehicular networks for smart cities," *Comput. Electr. Eng.*, vol. 105, no. December 2022, p. 108543, 2023, doi: 10.1016/j.compeleceng.2022.108543.
- [3] L. Liu, A. Guevara, and J. E. Sanchez-Galan, "Identification and classification of road traffic incidents in Panama City through the analysis of a social media stream and machine learning," *Intell. Syst. with Appl.*, vol. 16, Nov. 2022, doi: 10.1016/j.iswa.2022.200158.
- [4] S. El Hamdani, N. Benamar, and M. Younis, "Pedestrian Support in Intelligent Transportation Systems: Challenges, Solutions and Open issues," *Transp. Res. Part C Emerg. Technol.*, vol. 121, Dec. 2020, doi: 10.1016/j.trc.2020.102856.
- [5] S. Mohammadian, M. M. Haque, Z. Zheng, and A. Bhaskar, "Integrating safety into the fundamental relations of freeway traffic flows: A conflict-based safety assessment framework," *Anal. Methods Accid. Res.*, vol. 32, Dec. 2021, doi: 10.1016/j.amar.2021.100187.
- [6] A. Ait Ouallane, A. Bakali, A. Bahnasse, S. Broumi, and M. Talea, "Fusion of engineering insights and emerging trends: Intelligent urban traffic management system," *Inf. Fusion*, vol. 88, pp. 218–248, Dec. 2022, doi: 10.1016/j.inffus.2022.07.020.
- [7] V. Divya, R. Deepika, C. Yamini, and P. Sobiyaa, "An Efficient K-Means Clustering Initialization Using Optimization Algorithm," *Proc. 2019 Int. Conf. Adv. Comput. Commun. Eng. ICACCE 2019*, 2019, doi: 10.1109/ICACCE46606.2019.9079998.

-
- [8] A. H. Alomari, T. S. Khedaywi, A. R. O. Marian, and A. A. Jadah, "Traffic speed prediction techniques in urban environments," *Heliyon*, vol. 8, no. 12, Dec. 2022, doi: 10.1016/j.heliyon.2022.e11847.
- [9] S. Shakil, D. Arora, and T. Zaidi, "Feature based classification of voice based biometric data through Machine learning algorithm," *Mater. Today Proc.*, vol. 51, pp. 240–247, 2021, doi: 10.1016/j.matpr.2021.05.261.
- [10] K. Balachandar and R. Jegadeeshwaran, "Friction stir welding tool condition monitoring using vibration signals and Random forest algorithm - A Machine learning approach," in *Materials Today: Proceedings*, 2021, vol. 46, pp. 1174–1180, doi: 10.1016/j.matpr.2021.02.061.
- [11] S. Khan and M. Narvekar, "Novel fusion of color balancing and superpixel based approach for detection of tomato plant diseases in natural complex environment," *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 34, no. 6, pp. 3506–3516, 2022, doi: 10.1016/j.jksuci.2020.09.006.