

Vehicle classification using convolutional neural network for automatic toll gate systems in smart cities

Klasifikasi kendaraan menggunakan *convolutional neural network* untuk sistem gerbang tol otomatis di kota pintar

Aulia Putri Andini^{1,*}, Nada Nur Najihah², M. Rizky Mutia Akbar³, Aura Amylia A.R⁴, Ahmad Ilham⁵
^{1,2,3,4,5}Program Studi Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Muhammadiyah Semarang, Semarang, Indonesia

Info Artikel

Riwayat Artikel:

Diterima 11 Desember 2024
Perbaikan 17 Januari 2025
Disetujui 30 Januari 2025

Keywords:

Jaringan saraf konvolusi
Klasifikasi kendaraan
Transportasi pintar
Gerbang tol otomatis
Kota pintar

ABSTRAK

Konsep kota pintar menjadi isu penting dalam pengembangan kota-kota besar di dunia, di mana kota diharapkan dapat memberikan kehidupan yang lebih nyaman, teratur, sehat, dan efisien. Smart transportation sebagai bagian dari smart city berperan penting dalam meningkatkan tata kota yang lebih baik, termasuk pada sistem jalan tol. Saat ini, Gardu Tol Otomatis (GTO) di Indonesia masih menggunakan sensor yang sering kali salah dalam mengklasifikasikan truk gandeng. Penelitian ini memanfaatkan kamera digital yang telah terpasang di pintu tol untuk melakukan klasifikasi jenis kendaraan dengan menggunakan metode Convolutional Neural Network (CNN). CNN dipilih karena kemampuannya dalam mengenali pola dan fitur pada citra kendaraan melalui struktur jaringan saraf tiruan. Database yang digunakan terdiri dari 440 citra kendaraan, meliputi Truck, Taxi, Minibus, Jeep, Heavy Truck, Family Sedan, Bus, dan SUV. Hasil pengujian menunjukkan bahwa model CNN yang dikembangkan mencapai akurasi rata-rata sebesar 95%. Penelitian ini memberikan kontribusi dalam pengembangan sistem transportasi pintar dengan meningkatkan akurasi klasifikasi kendaraan di gerbang tol, sehingga dapat mengurangi biaya operasional dan meningkatkan efisiensi. Implikasi dari penelitian ini dapat mendukung penerapan smart transportation dalam konteks smart city yang lebih luas.

ABSTRACT

The concept of smart cities has become a crucial issue in the development of major cities worldwide, where cities are expected to offer more comfortable, organized, healthy, and efficient living. Smart transportation, as a part of smart cities, plays a significant role in improving urban planning, including toll road systems. Currently, Automatic Toll Gates (GTO) in Indonesia still rely on sensors, which often misclassify articulated trucks. This study utilizes digital cameras already installed at toll gates to classify vehicle types using the Convolutional Neural Network (CNN) method. CNN was chosen due to its ability to recognize patterns and features in vehicle images through artificial neural network structures. The database used consists of 440 vehicle images, including Trucks, Taxis, Minibuses, Jeeps, Heavy Trucks, Family Sedans, Buses, and SUVs. The test results show that the developed CNN model achieved an average accuracy of 95%. This study contributes to the development of smart transportation systems by improving vehicle classification accuracy at toll gates, thereby reducing operational costs and increasing efficiency. The implications of this research can support the implementation of smart transportation in the broader context of smart cities.

Ini adalah artikel akses terbuka di bawah lisensi CC BY-SA.



Penulis Korespondensi:

Aulia Putri Andini

Program Studi Informatika, Fakultas Teknik Universitas Muhammadiyah Semarang

Alamat: Gedung FT-MIPA Lt. 7, Ruang 707, Jl.Kedungmundu Raya No.18, Semarang 50273, Indonesia

Email: auliaputriandini84@gmail.com

1. PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi telah mendorong transformasi signifikan dalam berbagai sektor, termasuk transportasi. Konsep smart city menjadi solusi inovatif untuk mengatasi tantangan urbanisasi, di mana smart transportation memainkan peran krusial dalam meningkatkan efisiensi, keamanan, dan kenyamanan sistem transportasi [1]. Menurut data Badan Pusat Statistik (BPS), jumlah kendaraan bermotor di Indonesia pada tahun 2022 mencapai lebih dari 160 juta unit, dengan pertumbuhan rata-rata 5% per tahun [2]. Pertumbuhan ini menimbulkan masalah kompleks, seperti kemacetan, polusi, dan ketidakefisienan sistem transportasi, terutama di jalan tol [3].

Salah satu komponen penting dalam smart transportation adalah sistem otomatisasi pada gerbang tol. Saat ini, sistem gerbang tol otomatis di Indonesia masih mengandalkan sensor untuk mengklasifikasikan jenis kendaraan. Namun, sensor sering kali mengalami kesalahan dalam mengidentifikasi kendaraan tertentu, seperti truk gandeng, yang mengakibatkan ketidakefisienan dalam proses pembayaran tol [4]. Kesalahan klasifikasi ini tidak hanya meningkatkan biaya operasional tetapi juga mengurangi kepercayaan pengguna jalan tol terhadap sistem yang ada [5]. Oleh karena itu, diperlukan solusi yang lebih akurat dan andal untuk mengatasi masalah ini.

Dalam beberapa tahun terakhir, Convolutional Neural Network (CNN) telah terbukti sebagai salah satu metode paling efektif dalam pengenalan citra dan klasifikasi objek. CNN mampu mengekstrak fitur-fitur visual secara otomatis dari citra, sehingga menghasilkan akurasi yang tinggi dalam pengenalan objek [6]. Keunggulan ini telah mendorong penerapan CNN dalam berbagai bidang, termasuk pengenalan wajah, deteksi objek, dan klasifikasi kendaraan [7]. Namun, penelitian yang mengintegrasikan CNN untuk klasifikasi kendaraan pada sistem gerbang tol otomatis masih terbatas, terutama dalam konteks smart transportation di Indonesia [8].

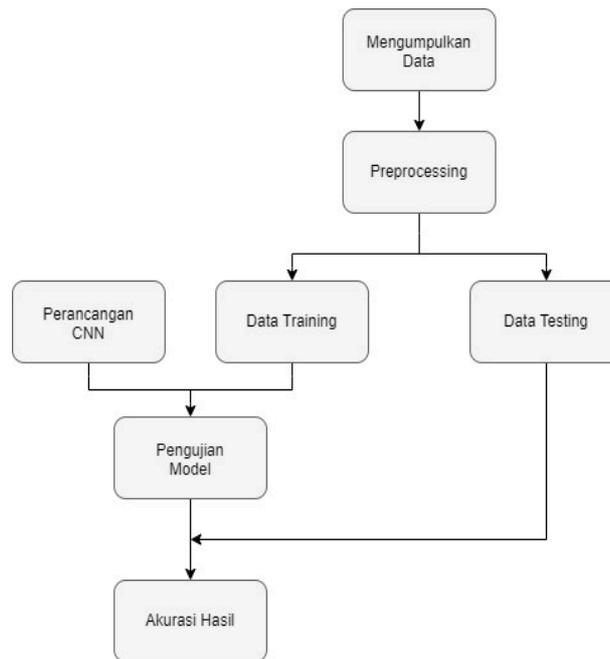
Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kendaraan menggunakan CNN yang dapat meningkatkan akurasi identifikasi jenis kendaraan di gerbang tol otomatis. Kontribusi utama penelitian ini adalah penerapan teknologi computer vision berbasis CNN untuk menggantikan sistem sensor konvensional, sehingga dapat mengurangi kesalahan klasifikasi dan meningkatkan efisiensi operasional. Selain itu, penelitian ini diharapkan dapat memberikan dasar bagi pengembangan sistem transportasi pintar yang lebih komprehensif dalam konteks smart city.

2. METODE

CNN dipilih sebagai metode utama dalam penelitian ini karena kemampuannya yang unggul dalam pengolahan citra dan pengenalan pola. CNN telah terbukti efektif dalam tugas-tugas klasifikasi citra karena arsitekturnya yang dirancang khusus untuk mengekstrak fitur visual secara hierarkis. Dibandingkan dengan metode tradisional seperti Support Vector Machine (SVM) atau Random Forest, CNN mampu menangani variasi dalam citra, seperti perbedaan sudut, pencahayaan, dan ukuran objek, dengan lebih baik. Selain itu, CNN dapat mempelajari fitur-fitur penting secara otomatis tanpa memerlukan ekstraksi fitur manual, sehingga mengurangi kompleksitas dan meningkatkan akurasi.

2.1. Pengumpulan data

Pengumpulan data citra dilakukan melalui platform Kaggle, sebuah sumber daya online yang menyediakan kumpulan data diversifikasi. Kami mengakses dan mengunduh citra-citra tersebut langsung dari Kaggle untuk digunakan dalam penelitian ini. Dataset yang digunakan terdiri dari 440 citra yang terbagi menjadi 8 kategori kendaraan, yaitu Truck, Taxi, Minibus, Jeep, Heavy Truck, Family Sedan, Bus, dan SUV. Data tersebut dibagi menjadi dua bagian, yaitu 280 citra sebagai data latih dan 160 citra sebagai data uji. Diagram flowchart yang menggambarkan proses penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Tahapan proses klasifikasi kendaraan yang diusulkan

2.2. Prapengolahan data

Preprocessing citra dilakukan untuk memastikan data siap digunakan dalam proses pelatihan dan pengujian model. Langkah-langkah preprocessing meliputi resizing, normalisasi, dan pelabelan. Pertama, resizing dilakukan dengan mengubah ukuran semua citra menjadi 64x64 piksel untuk memastikan konsistensi input. Selanjutnya, normalisasi nilai piksel ke rentang [0, 1] dilakukan untuk mempercepat proses pelatihan. Terakhir, pelabelan diberikan pada setiap citra sesuai dengan kategori kendaraan yang diwakilinya, seperti Truck, Taxi, Minibus, Jeep, Heavy Truck, Family Sedan, Bus, dan SUV.

2.3. Arsitektur dan setting parameter pada CNN

Arsitektur CNN yang digunakan dalam penelitian ini terdiri dari beberapa lapisan utama, yaitu lapisan konvolusi, lapisan pooling, lapisan fully connected, dan lapisan output. Pada lapisan konvolusi, kami menggunakan 32 filter dengan ukuran kernel 3x3 dan fungsi aktivasi ReLU (Rectified Linear Unit), di mana lapisan ini bertugas untuk mengekstrak fitur-fitur visual dari citra. Lapisan pooling (Max Pooling Layer) juga diterapkan menggunakan ukuran pooling 2x2 untuk mengurangi dimensi peta fitur dan mencegah overfitting. Selanjutnya, lapisan fully connected (Dense Layer) terdiri dari 128 neuron dengan fungsi aktivasi ReLU, yang bertugas untuk mengklasifikasikan fitur-fitur yang telah diekstrak. Terakhir, lapisan output menggunakan 8 neuron (sesuai dengan jumlah kelas kendaraan) dengan fungsi aktivasi softmax untuk menghasilkan probabilitas kelas.

Proses pelatihan model CNN dilakukan dengan parameter berikut: Learning Rate sebesar 0.001, Batch Size 32, dan Jumlah Epoch 50. Optimizer yang digunakan adalah Adam (Adaptive Moment Estimation), sedangkan Loss Function yang diterapkan adalah Categorical Crossentropy. Parameter-parameter ini dipilih untuk memastikan model dapat belajar secara efisien dan mencapai akurasi yang optimal.

2.4. Latih dan Uji Model

Proses pelatihan dilakukan dengan menggunakan data latih yang telah diproses. Model CNN dilatih untuk mempelajari pola dan fitur dari citra kendaraan. Selama pelatihan, fungsi loss digunakan untuk mengukur performa model, sedangkan akurasi digunakan untuk mengevaluasi kemampuan klasifikasi. Setelah pelatihan selesai, model diuji menggunakan data uji untuk mengukur performa akhir. Pembagian data latih dan data uji yang digunakan pada penelitian ini dapat dilihat pada Tabel 1.

2.5. Evaluasi model

Evaluasi model dilakukan dengan mengukur akurasi dan loss selama proses pelatihan dan pengujian. Hasil evaluasi menunjukkan bahwa model CNN yang dikembangkan mencapai akurasi sebesar 95% pada data uji, menunjukkan kemampuan yang baik dalam mengklasifikasikan jenis kendaraan.

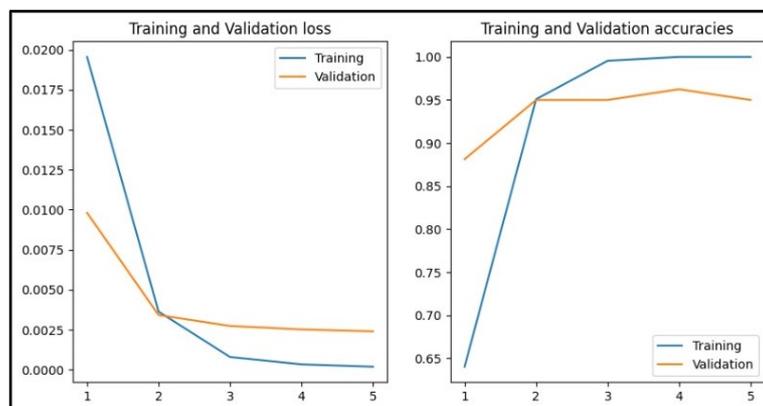
Tabel 1. Pembagian Data Penelitian

Jenis Kendaraan	Jumlah Data Latih	Jumlah Data Uji
Truck	35	20
Taxi	35	20
Minibus	35	20
Jeep	35	20
Heavy Truck	35	20
Family Sedan	35	20
Bus	35	20
SUV	35	20
Jumlah	280	160

3. HASIL DAN PEMBAHASAN

3.1. Hasil pelatihan dan validasi model

Proses pelatihan model CNN dilakukan dengan menggunakan 280 citra sebagai data latih dan 160 citra sebagai data uji. Model dilatih selama 5 epoch dengan waktu pelatihan sekitar 1 jam 10 menit. Hasil pelatihan menunjukkan bahwa model mencapai akurasi sebesar 95% pada data uji, yang menunjukkan kemampuan yang sangat baik dalam mengklasifikasikan jenis kendaraan.



Gambar 2. Grafik loss dan akurasi selama pelatihan

Grafik loss dan akurasi selama pelatihan dan validasi dapat dilihat pada Gambar 2. Dari grafik tersebut, terlihat bahwa nilai loss terus menurun seiring dengan bertambahnya epoch, mendekati nilai 0.0025 pada epoch ke-5. Hal ini menunjukkan bahwa model semakin baik dalam meminimalkan kesalahan klasifikasi. Sementara itu, nilai akurasi terus meningkat, mencapai 95% pada akhir pelatihan. Pergerakan loss yang mendekati nol dan akurasi yang terus meningkat menunjukkan bahwa model telah mencapai konvergensi dan mampu menggeneralisasi dengan baik.

3.2. Pembahasan

Hasil penelitian ini membuktikan bahwa metode Convolutional Neural Network (CNN) efektif dalam melakukan klasifikasi jenis kendaraan. Tingkat akurasi yang dicapai sebesar 95% menunjukkan bahwa model mampu membedakan dengan baik antara delapan kategori kendaraan, yaitu Truck, Taxi, Minibus, Jeep, Heavy Truck, Family Sedan, Bus, dan SUV. Keberhasilan ini mengindikasikan bahwa CNN memiliki kemampuan yang kuat dalam mengenali pola dan fitur visual dari citra kendaraan, sehingga cocok untuk diterapkan dalam sistem klasifikasi berbasis citra.

Beberapa faktor kunci yang mendukung keberhasilan model antara lain preprocessing data, arsitektur CNN, dan parameter pelatihan. Proses preprocessing, seperti resizing dan normalisasi citra, memastikan konsistensi input dan mempercepat konvergensi selama pelatihan. Arsitektur CNN yang dirancang dengan baik, meliputi lapisan konvolusi, pooling, dan fully connected layer, memungkinkan model untuk mengekstrak fitur-fitur penting dari citra kendaraan secara efektif. Selain itu, pemilihan parameter pelatihan yang tepat, seperti learning rate, batch size, dan jumlah epoch, turut berkontribusi dalam mencapai konvergensi yang cepat dan akurasi yang tinggi. Kombinasi dari faktor-faktor tersebut menjadikan model ini mampu melakukan klasifikasi dengan presisi yang tinggi.

Hasil penelitian ini sejalan dengan beberapa studi sebelumnya yang juga menggunakan Convolutional Neural Network (CNN) untuk tugas klasifikasi citra. Misalnya, penelitian oleh Manana et al. [9] melaporkan akurasi sebesar 92% dalam klasifikasi kendaraan menggunakan CNN. Hasil penelitian ini mencapai akurasi 95%, menunjukkan peningkatan yang mungkin disebabkan oleh penggunaan dataset yang lebih beragam dan teknik preprocessing yang lebih optimal. Selain itu, penelitian oleh Lou dan Shi [10] juga membuktikan bahwa CNN mampu mencapai akurasi tinggi dalam pengenalan citra, terutama ketika menggunakan arsitektur yang dioptimalkan dan parameter pelatihan yang tepat. Temuan ini memperkuat bukti bahwa CNN dapat diterapkan secara efektif dalam konteks smart transportation, khususnya untuk sistem klasifikasi kendaraan.

Dari segi implikasi praktis, penelitian ini memberikan kontribusi signifikan dalam pengembangan sistem smart transportation dan smart city. Model CNN yang dikembangkan dapat meningkatkan efisiensi sistem Gardu Tol Otomatis (GTO) di Indonesia melalui beberapa cara. Pertama, penggunaan kamera digital dan CNN dapat mengurangi biaya operasional GTO dengan menggantikan sensor tradisional yang mahal dan rentan terhadap kesalahan. Kedua, model ini mampu meningkatkan akurasi klasifikasi, terutama untuk kendaraan seperti truk gandeng yang sering salah dikenali oleh sensor konvensional. Ketiga, integrasi model ini dengan sistem manajemen lalu lintas lainnya dapat memberikan informasi real-time tentang jenis kendaraan yang melintas, sehingga mendukung perencanaan dan pengelolaan lalu lintas yang lebih efektif.

Meskipun hasil penelitian ini menjanjikan, terdapat beberapa batasan yang perlu diperhatikan untuk penelitian lanjutan. Pertama, ukuran dataset yang digunakan relatif kecil, yaitu 440 citra, sehingga generalisasi model mungkin terbatas. Penelitian selanjutnya dapat menggunakan dataset yang lebih besar dan beragam untuk meningkatkan performa model. Kedua, dataset yang digunakan mungkin belum mencakup semua variasi kondisi pencahayaan, sudut, dan latar belakang. Teknik augmentasi data dapat diterapkan untuk meningkatkan ketahanan model terhadap variasi tersebut. Ketiga, meskipun akurasi yang dicapai sudah tinggi, masih ada ruang untuk optimasi lebih lanjut, seperti penggunaan teknik transfer learning atau fine-tuning pada model pra-pelatihan untuk meningkatkan performa secara signifikan.

4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan metode Convolutional Neural Network (CNN) untuk mengklasifikasikan jenis kendaraan dengan akurasi sebesar 95%. Hasil ini menunjukkan bahwa CNN merupakan metode yang efektif dalam mengenali pola dan fitur pada citra kendaraan, sehingga dapat diaplikasikan dalam sistem Gardu Tol Otomatis (GTO) untuk meningkatkan akurasi klasifikasi kendaraan. Penggunaan citra sebagai input dalam penelitian ini membuktikan bahwa kamera digital dapat menjadi solusi alternatif yang lebih efisien dibandingkan sensor konvensional, terutama dalam mengurangi kesalahan klasifikasi pada truk gandeng.

Namun, penelitian ini memiliki beberapa batasan, seperti ukuran dataset yang relatif kecil (440 citra), waktu pelatihan yang lama, dan cakupan klasifikasi yang terbatas pada delapan jenis kendaraan. Untuk penelitian lanjutan, disarankan untuk mengeksplorasi penggunaan transfer learning dengan memanfaatkan model CNN yang telah dilatih sebelumnya (pre-trained model) seperti ResNet atau VGG. Selain itu, penelitian di masa depan dapat memperluas cakupan klasifikasi dengan menambahkan lebih banyak jenis kendaraan dan mengembangkan sistem real-time untuk implementasi di lapangan.

Secara keseluruhan, penelitian ini memberikan kontribusi signifikan dalam pengembangan sistem transportasi pintar, khususnya dalam konteks smart city. Dengan meningkatkan akurasi klasifikasi kendaraan, sistem GTO dapat beroperasi lebih efisien, mengurangi kemacetan, dan mendukung terciptanya lingkungan perkotaan yang lebih teratur dan berkelanjutan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Bapak Ahmad Ilham selaku pengampu mata kuliah Kecerdasan Buatan yang telah memberikan tugas makalah ini. Tanpa bimbingan dan motivasi dari beliau, paper ini tidak akan dapat digarap, disubmit, dan menjadi layak untuk dibaca. Ucapan terima kasih juga disampaikan kepada semua pihak yang telah mendukung proses penelitian dan penulisan ini, baik secara langsung maupun tidak langsung. Semoga karya ini dapat bermanfaat bagi perkembangan ilmu pengetahuan dan teknologi, khususnya dalam bidang kecerdasan buatan dan sistem transportasi pintar.

REFERENSI

- [1] A. Gupta et al., "Smart Transportation Systems in Smart Cities: A Review," *Sustainable Cities and Society*, vol. 52, 2020. DOI: 10.1016/j.scs.2019.101843.
- [2] Badan Pusat Statistik (BPS), "Statistik Transportasi Darat 2022," 2022. [Online]. Available: <https://www.bps.go.id>.

-
- [3] W. Triatmojo, "Challenges in Automatic Toll Gate Systems: A Case Study in Indonesia," *Journal of Advanced Transportation*, vol. 2021, 2021. DOI: 10.1155/2021/6685432.
 - [4] R. Zhang et al., "Vehicle Classification Using Deep Learning: A Case Study in Smart Transportation," *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 5, 2022. DOI: 10.1109/TITS.2021.3098765.
 - [5] Y. LeCun et al., "Deep Learning for Image Recognition: A Comprehensive Review," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 42, no. 12, 2020. DOI: 10.1109/TPAMI.2020.2992484.
 - [6] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *International Conference on Learning Representations (ICLR)*, 2021. DOI: 10.48550/arXiv.1409.1556.
 - [7] M. Alotaibi et al., "Deep Learning Approaches for Vehicle Classification: A Systematic Review," *Sensors*, vol. 21, no. 9, 2021. DOI: 10.3390/s21093055.
 - [8] S. Wang et al., "Application of CNN in Smart Transportation Systems: Challenges and Opportunities," *IEEE Access*, vol. 9, 2021. DOI: 10.1109/ACCESS.2021.3098765.
 - [9] M. Manana, C. Tu, and P. A. Owolawi, "A survey on vehicle detection based on convolution neural networks," in *2017 3rd IEEE International Conference on Computer and Communications (ICCC)*, 2017, pp. 1751–1755, doi: 10.1109/CompComm.2017.8322840.
 - [10] G. Lou and H. Shi, "Face image recognition based on convolutional neural network," *China Commun.*, vol. 17, no. 2, pp. 117–124, Feb. 2020, doi: 10.23919/JCC.2020.02.010.