

KLASIFIKASI JENIS KENDARAAN BERBASIS CITRA MENGUNAKAN *DEEP LEARNING*

Naufal Andhika Pratama¹, Petrick Kristanto², Nasarrudin Darmawan³

^{1,2,3}Program Studi SI Informatika, Fakultas Teknik Informatika
Universitas Bina Sarana Informatika, Indonesia

[1naufalandhika97@gmail.com](mailto:naufalandhika97@gmail.com), [2patrikkristanto@gmail.com](mailto:patrikkristanto@gmail.com), [3mayoudun@gmail.com](mailto:mayoudun@gmail.com)

ABSTRAK

Perkembangan sistem transportasi cerdas menuntut kemampuan identifikasi kendaraan yang akurat dan efisien. Penelitian ini bertujuan untuk mengklasifikasikan jenis kendaraan berbasis citra menggunakan pendekatan deep learning dengan teknik *transfer learning*. Model yang digunakan adalah *VGG16* pralatih *ImageNet* yang dimodifikasi dengan *Global Average Pooling* dan lapisan fully connected untuk mengklasifikasikan sepuluh kelas kendaraan, yaitu *SUV*, *bus*, *family sedan*, *fire engine*, *heavy truck*, *jeep*, *minibus*, *racing car*, *taxi*, dan *truck*. Dataset terdiri dari 1.400 citra data latih dan 200 citra data validasi dengan variasi sudut pandang dan kondisi pencahayaan. Proses pelatihan dilakukan dalam dua tahap, yaitu pelatihan awal dengan lapisan konvolusi dibekukan dan tahap fine-tuning dengan membuka sebagian lapisan akhir *VGG16*. Hasil pengujian menunjukkan model mencapai akurasi validasi terbaik sebesar 89% dengan nilai *loss* sebesar 0,32. Hasil ini menunjukkan bahwa pendekatan transfer learning efektif untuk klasifikasi kendaraan berbasis citra dan berpotensi diterapkan pada sistem transportasi cerdas.

Kata Kunci: Deep Learning, CNN, Klasifikasi Kendaraan, Pengolahan Citra

ABSTRACT

The development of intelligent transportation systems requires accurate and efficient vehicle identification. This study aims to classify vehicle types from image data using a deep learning approach with transfer learning. A pre-trained VGG16 model on ImageNet was employed and modified using Global Average Pooling and fully connected layers to classify ten vehicle categories: SUV, bus, family sedan, fire engine, heavy truck, jeep, minibus, racing car, taxi, and truck. The dataset consists of 1,400 training images and 200 validation images with diverse viewpoints and lighting conditions. The training process was conducted in two stages: initial training with frozen convolutional layers followed by fine-tuning by unfreezing the upper layers of VGG16. Experimental results show that the proposed model achieved a best validation accuracy of 89% with a loss value of 0.32. These results indicate that VGG16-based transfer learning is effective for image-based vehicle classification and has potential applications in intelligent transportation systems.

Key Word: Deep Learning, CNN, Vehicle Classification, Image Processing

PENDAHULUAN

Perkembangan teknologi *deep learning* telah membawa perubahan signifikan dalam bidang pengolahan citra dan pengenalan objek, termasuk pada sistem transportasi cerdas (*Intelligent Transportation Systems/ITS*). Salah satu kebutuhan utama dalam ITS adalah kemampuan mengidentifikasi dan mengklasifikasikan jenis kendaraan secara otomatis dan akurat guna mendukung pengawasan lalu lintas, perencanaan transportasi, serta pengambilan kebijakan berbasis data.

Pemanfaatan kamera CCTV sebagai sensor visual menawarkan keunggulan dalam

pemantauan lalu lintas secara real-time dengan biaya relatif rendah. Namun, analisis citra CCTV secara manual tidak efisien karena membutuhkan waktu, tenaga, serta rentan terhadap kesalahan manusia. Oleh karena itu, diperlukan sistem klasifikasi kendaraan otomatis yang mampu bekerja pada kondisi citra yang kompleks, seperti variasi pencahayaan, sudut pandang beragam, serta keberadaan *noise* dan *occlusion*.

Convolutional Neural Network (CNN) merupakan arsitektur *deep learning* yang terbukti efektif dalam tugas klasifikasi citra karena kemampuannya mengekstraksi fitur visual secara otomatis tanpa rekayasa fitur

manual. Berbagai penelitian sebelumnya menunjukkan bahwa CNN mampu mencapai performa tinggi dalam klasifikasi kendaraan, baik menggunakan arsitektur yang dilatih dari awal maupun melalui pendekatan *transfer learning*.

Pendekatan *transfer learning* menjadi solusi yang relevan ketika ketersediaan data terbatas, dengan memanfaatkan model pralatih pada dataset berskala besar seperti ImageNet. Salah satu arsitektur yang banyak digunakan adalah VGG16 karena struktur jaringannya yang sederhana namun mampu menangkap representasi visual tingkat tinggi secara efektif.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan model klasifikasi jenis kendaraan berbasis citra menggunakan CNN dengan pendekatan *transfer learning* VGG16. Model dirancang untuk mengklasifikasikan sepuluh jenis kendaraan pada kondisi visual yang beragam. Hasil penelitian diharapkan dapat menjadi dasar pengembangan sistem analisis lalu lintas otomatis yang lebih akurat dan efisien dalam mendukung implementasi ITS.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan *deep learning* dengan model *Convolutional Neural Network* (CNN) untuk mengklasifikasikan jenis kendaraan berdasarkan citra. Metodologi penelitian terdiri dari empat tahapan utama, yaitu pengumpulan data, pra-pemrosesan citra, perancangan dan pelatihan model, serta evaluasi performa.

Dataset yang digunakan berupa citra kendaraan yang diperoleh dari berbagai sumber daring dan citra CCTV jalan raya. Dataset mencakup sepuluh kelas kendaraan, yaitu SUV, bus, family sedan, fire engine, heavy truck, jeep, minibus, racing car, taxi, dan truck. Data yang tidak memenuhi kualitas visual, seperti citra buram atau tidak relevan, dieliminasi. Dataset kemudian dibagi menjadi data pelatihan sebesar 80% dan data validasi sebesar 20%.

Pada tahap pra-pemrosesan, seluruh citra diubah ukurannya menjadi 224×224 piksel sesuai dengan kebutuhan input VGG16. Nilai

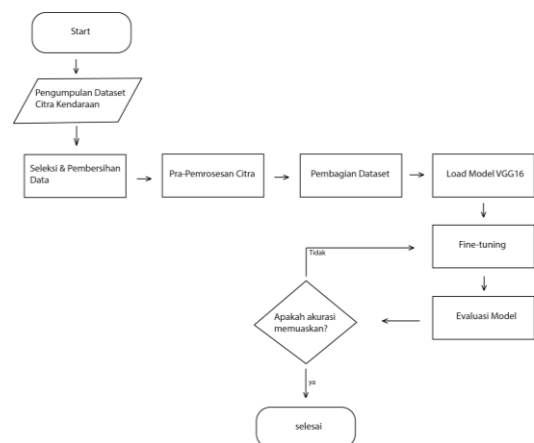
piksel dinormalisasi ke rentang 0–1 untuk meningkatkan stabilitas proses pembelajaran. Selain itu, diterapkan teknik *data augmentation* seperti rotasi, *horizontal flip*, *zoom*, dan pergeseran posisi untuk meningkatkan variasi data dan mengurangi risiko *overfitting*.

Model klasifikasi dibangun menggunakan pendekatan *transfer learning* dengan arsitektur VGG16 pralatih ImageNet. Lapisan konvolusi awal dibekukan pada tahap awal pelatihan (*head training*), kemudian ditambahkan lapisan Global Average Pooling, satu lapisan *dense* dengan fungsi aktivasi ReLU, serta lapisan *output* dengan fungsi aktivasi Softmax untuk klasifikasi sepuluh kelas kendaraan. Model dilatih menggunakan *optimizer* Adam.

Proses pelatihan dilakukan dalam dua tahap, yaitu pelatihan awal dan *fine-tuning*. Pada tahap *fine-tuning*, sebagian lapisan konvolusi akhir dibuka kembali untuk menyesuaikan fitur tingkat tinggi dengan karakteristik dataset. Evaluasi model dilakukan menggunakan data validasi dengan metrik akurasi, loss, serta analisis confusion matrix sebagai dasar pembahasan hasil.

HASIL DAN PEMBAHASAN

Metodologi penelitian ini dirancang untuk mengklasifikasikan jenis kendaraan berbasis citra menggunakan pendekatan *deep learning* dengan *transfer learning*. Alur penelitian mencakup tahapan pengumpulan data, pra-pemrosesan citra, pelatihan model, hingga evaluasi performa model.



Gambar 1. Diagram alir metodologi penelitian klasifikasi jenis kendaraan berbasis citra

Diagram alir pada Gambar 1 menunjukkan tahapan penelitian yang dimulai dari pengumpulan dataset citra kendaraan, seleksi dan pembersihan data, serta pra-pemrosesan citra. Dataset kemudian dibagi menjadi data latih dan data validasi sebelum digunakan pada model VGG16 pralatih ImageNet. Proses pelatihan dilakukan melalui tahap fine-tuning, diikuti dengan evaluasi model menggunakan metrik akurasi dan confusion matrix. Proses pelatihan diulang hingga diperoleh performa model yang memuaskan.

1. Hasil Pelatihan Model

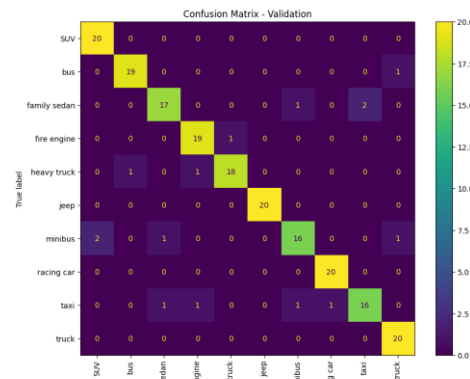


Gambar 2. Grafik akurasi dan loss selama proses pelatihan dan validasi

Proses pelatihan model dilakukan dalam dua tahap, yaitu *head training* dan *fine-tuning*. Kinerja model selama proses pelatihan dan validasi ditunjukkan melalui grafik akurasi dan *loss* sebagaimana ditampilkan pada Gambar 2. Grafik tersebut menunjukkan bahwa nilai akurasi pelatihan dan validasi mengalami peningkatan yang stabil seiring bertambahnya *epoch*, sementara nilai *loss* menurun secara konsisten.

Selisih antara akurasi pelatihan dan validasi relatif kecil, yang mengindikasikan bahwa model tidak mengalami *overfitting* yang signifikan. Hal ini menunjukkan bahwa kombinasi *transfer learning*, *data augmentation*, dan strategi *fine-tuning* yang diterapkan mampu meningkatkan kemampuan generalisasi model terhadap data validasi.

2. Evaluasi Klasifikasi Menggunakan Confusion Matrix



Gambar 3. Confusion matrix hasil klasifikasi data validasi

Evaluasi performa model pada tingkat kelas dilakukan menggunakan *confusion matrix* yang ditunjukkan pada Gambar 3. Confusion matrix tersebut menggambarkan distribusi prediksi benar dan salah pada sepuluh kelas kendaraan yang diuji menggunakan data validasi.

Hasil evaluasi menunjukkan bahwa beberapa kelas kendaraan dengan karakteristik visual yang khas, seperti SUV, jeep, racing car, dan truck, dapat diklasifikasikan dengan tingkat akurasi yang sangat tinggi. Sementara itu, kesalahan klasifikasi lebih sering terjadi pada kelas kendaraan yang memiliki kemiripan visual, seperti family sedan dengan taxi, serta minibus dengan SUV dan family sedan. Kemiripan bentuk bodi dan sudut pengambilan citra menjadi faktor utama yang mempengaruhi kesalahan prediksi pada kelas-kelas tersebut.

Secara keseluruhan, confusion matrix menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik dan konsisten pada sebagian besar kelas kendaraan, meskipun masih terdapat ruang untuk peningkatan pada kelas dengan karakteristik visual yang saling menyerupai.

3. Contoh hasil prediksi Model



Gambar 4. Contoh hasil prediksi model pada citra uji

Untuk menguji kemampuan model secara kualitatif, dilakukan pengujian terhadap satu citra uji sebagaimana ditunjukkan pada **Gambar 4**. Model berhasil mengklasifikasikan citra kendaraan sebagai kelas *jeep* dengan tingkat kepercayaan sebesar 0,79. Hasil ini menunjukkan bahwa model tidak hanya mampu memberikan prediksi kelas kendaraan, tetapi juga menghasilkan nilai probabilitas yang dapat digunakan sebagai indikator tingkat kepercayaan prediksi.

Contoh hasil prediksi ini menunjukkan potensi penerapan model dalam sistem analisis lalu lintas berbasis citra secara praktis, khususnya pada skenario pengawasan kendaraan menggunakan kamera CCTV.

SIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa penerapan *deep learning* dengan pendekatan *transfer learning* menggunakan arsitektur VGG16 mampu mengklasifikasikan jenis kendaraan berbasis citra dengan performa yang baik. Model yang dikembangkan berhasil mencapai akurasi validasi sebesar 89%, yang mengindikasikan bahwa fitur visual kendaraan dapat dipelajari secara efektif meskipun dataset yang digunakan memiliki keterbatasan jumlah dan variasi.

Strategi pelatihan dua tahap, yaitu pelatihan awal dengan pembekuan lapisan konvolusi dan dilanjutkan dengan *fine-tuning* pada lapisan akhir, terbukti meningkatkan kemampuan model dalam menyesuaikan

representasi fitur terhadap karakteristik citra kendaraan. Hasil evaluasi menggunakan *confusion matrix* menunjukkan bahwa sebagian besar kelas kendaraan dapat dikenali dengan baik, meskipun masih terdapat kesalahan klasifikasi pada kelas kendaraan dengan karakteristik visual yang saling menyerupai.

Sebagai saran untuk pengembangan selanjutnya, penelitian ini dapat ditingkatkan dengan menambah jumlah dan variasi data pelatihan, khususnya pada kelas kendaraan yang sulit dibedakan. Selain itu, penggunaan arsitektur CNN yang lebih modern dan efisien, serta pengujian pada data video CCTV secara real-time, dapat dilakukan untuk meningkatkan kemampuan generalisasi dan kesiapan sistem dalam penerapan dunia nyata.

DAFTAR PUSTAKA

- Abadi, M., et al. (2016). TensorFlow: A system for large-scale machine learning. *Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation*, 265–283.
- Chen, Z., Xu, J., & Chen, Y. (2019). Vehicle classification based on deep convolutional neural networks. *Sensors*, 19(6), 1–15. <https://doi.org/10.3390/s19061367>
- Chollet, F., et al. (2018). Keras: The Python deep learning library. *Astrophysics Source Code Library*.
- Deng, J., et al. (2009). ImageNet: A large-scale hierarchical image database. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 248–255.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Liu, S., Li, X., & Wang, J. (2020). Deep learning-based vehicle detection and classification for intelligent transportation systems. *IEEE*

Transactions on Intelligent Transportation Systems, 21(2), 749–761.

Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359.

Perez, L., & Wang, J. (2017). The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint*, arXiv:1712.04621.

Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *International Conference on Learning Representations*.

Zhang, Y., Liu, D., & Wang, Y. (2017). Vehicle type classification using deep learning. *IEEE Access*, 5, 1884–1893.

Biografi Penulis



Biografi Penulis 1

Naufal Andhika Pratama adalah mahasiswa Program Studi S1 Informatika

Universitas Bina Sarana Informatika. Minat penelitiannya meliputi deep learning, computer vision, dan pengolahan citra digital.

Biografi Penulis 2

Petrick Kristanto adalah mahasiswa Program Studi S1 Informatika Universitas Bina Sarana Informatika. Minat penelitiannya meliputi deep learning, computer vision, dan pengolahan citra digital. akademis, serta *research interest* atau fokus penelitian



Biografi Penulis 3

Nassarudin Darmawan adalah mahasiswa Program Studi S1 Informatika Universitas Bina Sarana Informatika. Minat penelitiannya meliputi deep learning, computer vision, dan pengolahan citra digital.

