

Klasifikasi Golongan Kendaraan Tol menggunakan CNN Tensorflow

* Achmad Rozy Priambodo, Abdurrahman Al Hakim, Christian, Farrel Tiuraka Vierino,
Hendra Maulana

Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur, Indonesia

Artikel Histori:

Disubmit: Januari 2025

Diterima: Mei 2025

Diterbitkan: Juni 2025

DOI

[10.33005/jifti.v7i1.151](https://doi.org/10.33005/jifti.v7i1.151)



ABSTRAK

Pengelolaan lalu lintas di jalan tol memerlukan strategi yang efektif dalam mengidentifikasi jenis kendaraan untuk meningkatkan keamanan dan efisiensi transportasi. Artikel ini membahas implementasi Convolutional Neural Network (CNN) menggunakan TensorFlow untuk klasifikasi kendaraan di jalan tol. CNN telah terbukti efektif dalam mengenali pola visual kompleks, memungkinkan identifikasi kendaraan secara akurat tanpa perlu ekstraksi fitur manual. Dengan memanfaatkan arsitektur deep learning, CNN dapat mempelajari representasi fitur dari data citra dengan tingkat akurasi yang tinggi. Penggunaan TensorFlow sebagai framework deep learning memberikan keunggulan dalam pengembangan model dengan performa tinggi. Implementasi CNN dengan TensorFlow meningkatkan efisiensi dan akurasi klasifikasi kendaraan, membantu dalam mengelola lalu lintas dengan lebih efektif. Solusi ini meminimalkan kesalahan manusia, mempercepat proses klasifikasi, dan meningkatkan pengalaman pengguna jalan tol. Integrasi TensorFlow dalam sistem pengelolaan lalu lintas dapat menciptakan solusi yang lebih efektif dalam mengatasi tantangan di jalan tol. Model klasifikasi kendaraan ini mencapai 90.6% akurasi pada data uji. Sehingga dapat disimpulkan bahwa metode ini dapat secara efektif meningkatkan akurasi dan efisiensi dalam klasifikasi jenis kendaraan di jalan tol.

Kata Kunci: Convolutional Neural Network, TensorFlow, klasifikasi kendaraan, jalan tol, efisiensi transportasi.

How to Cite:

Priambodo, A. R., Hakim, A. A., Christian, Vierino, F. T., Maulana, H. (2025). Klasifikasi Golongan Kendaraan Tol menggunakan CNN Tensorflow. *Jurnal Ilmiah Teknologi Informasi dan Robotika*, 7(1), 1-10. <https://doi.org/10.33005/jifti.v7i1.151>.

***Corresponding Author:**

Email : 21081010070@student.upnjatim.ac.id

Alamat : Jl. Rungkut Madya, Gn. Anyar, Kec. Gn. Anyar,
Surabaya, Jawa Timur 60294



This article is published under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).

PENDAHULUAN

Peningkatan jumlah kendaraan bermotor di Indonesia, sebagaimana tercatat dalam data Badan Pusat Statistik, telah memunculkan masalah kemacetan yang signifikan, terutama di jalur tol (Winardi dkk., 2023). Pada lalu lintas di jalan tol, terdapat aspek keamanan dan efisiensi transportasi yang harus dikelola dengan baik. Keamanan mencakup pencegahan kecelakaan, penegakan aturan lalu lintas, serta penyediaan fasilitas darurat. Sementara itu, efisiensi transportasi melibatkan pengelolaan arus lalu lintas agar tidak terjadi kemacetan, optimasi waktu tempuh, dan pemanfaatan teknologi untuk memantau serta mengatur volume kendaraan. Untuk menghindari penumpukan jumlah kendaraan di lokasi tertentu dibutuhkan suatu informasi tentang pertumbuhan kendaraan di daerah tersebut setiap tahunnya (Suradi dkk., 2022).

Salah satu tantangan utama dalam mengelola lalu lintas di jalan tol adalah mengidentifikasi jenis kendaraan yang berbeda-beda yang dapat memasuki jalan tol. Identifikasi yang dilakukan secara manual atau menggunakan fitur yang kurang modern sering menghasilkan hasil yang kurang efektif dalam mengenali variasi kendaraan yang kompleks. Untuk itu dibutuhkan sebuah sistem klasifikasi jenis kendaraan secara otomatis sehingga tidak perlu adanya pengelompokan jenis kendaraan di setiap gerbang tol dan juga dapat digunakan untuk menghitung volume kendaraan berdasarkan jenisnya (Nurolan, 2020). Untuk mengatasi tantangan ini, penulis memanfaatkan teknologi *Artificial Intelligence* (AI) untuk klasifikasi jenis kendaraan pada jalan tol menggunakan algoritma *Convolutional Neural Network* (CNN) (Haqiqi dkk., 2024).

Convolutional Neural Network (CNN) merupakan salah satu metode klasifikasi yang dapat digunakan untuk mengidentifikasi jenis kendaraan yang dapat memasuki jalan tol. CNN dapat digunakan untuk mendeteksi dan mengenali objek gambar (Pramana dkk., 2020). Metode deteksi objek, khususnya menggunakan teknik *Convolutional Neural Network* (CNN), telah menjadi solusi yang efektif untuk menangani tugas-tugas semacam ini (Zahra dkk., 2023). CNN telah terbukti menjadi metode yang sangat efektif dalam bidang pengolahan citra dan pengenalan pola, terutama dalam konteks klasifikasi objek. Warna, tekstur, dan bentuk adalah semua indikator kualitas relatif suatu objek (Muhammad dkk., 2022). Metode Proses CNN memungkinkan untuk mengenali pola visual yang kompleks dengan akurasi tinggi, menghasilkan hasil dalam aplikasi seperti deteksi objek yang dalam studi kasus ini sebagai klasifikasi jenis kendaraan. Perkembangan teknologi komputasi sekarang ini yang sedang banyak diteliti salah satunya adalah mengenai penggunaan kecerdasan buatan dalam melakukan pekerjaan yang dapat dilakukan oleh manusia (Yoga dkk., 2021).

Dengan memanfaatkan arsitektur *deep learning*, CNN dapat secara otomatis mempelajari representasi fitur dari data citra yang kompleks tanpa perlu melakukan ekstraksi fitur secara manual yang biasanya lebih rumit dan memakan cukup banyak waktu. Ini memberikan keunggulan signifikan dibandingkan metode manual, di mana perlu merancang dan memilih fitur yang relevan secara manual. Ada beberapa tahapan dalam pengujian ini seperti pengumpulan data, *pre-process* dataset, pembuatan data test, pembangunan model CNN, pelatihan model, dan mengevaluasi kinerja model (Prakosa dkk., 2023). Kemampuan CNN untuk belajar secara langsung dan meningkatkan performa seiring dengan penambahan data latih membuat metode ini cocok digunakan untuk sistem pengenalan kendaraan di jalan tol. Dengan demikian, implementasi CNN pada sistem ini

dapat meningkatkan efisiensi operasional dan mengurangi kesalahan identifikasi kendaraan.

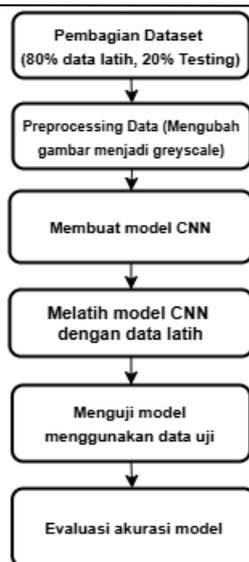
Dalam konteks klasifikasi kendaraan di jalan tol, penggunaan *Convolutional Neural Network* (CNN) dapat memberikan keunggulan yang signifikan dalam memvisualisasikan berbagai jenis kendaraan yang dapat masuk ke jalan tol, seperti mobil, truk, dan bus. CNN mampu menangkap dan menganalisis berbagai karakteristik visual yang kompleks, seperti bentuk dan ukuran kendaraan dengan tingkat akurasi yang tinggi. Hal inilah yang mendasari penelitian ini menggunakan metode CNN karena mampu membaca pengolahan citra (*image processing*) dengan tingkat akurasi yang tinggi dalam mendeteksi objek maupun *image classification* (Haqiqi dkk., 2024). Teknologi ini memungkinkan sistem untuk secara otomatis dan cepat mengidentifikasi jenis kendaraan, yang dapat mengurangi kesalahan manusia dan mempercepat proses klasifikasi.

Studi kasus ini menerapkan *Convolutional Neural Networks* (CNN) dengan menggunakan *TensorFlow*, sebuah *framework* populer dalam *deep learning* yang secara luas digunakan untuk klasifikasi citra. *TensorFlow* adalah *framework machine learning* yang bekerja dalam skala besar dan dalam *environment* yang *heterogenous* (Yunius, 2021). *TensorFlow* digunakan sebagai *framework* utama dalam proses pengembangan dan evaluasi model, memanfaatkan kekuatan algoritma-algoritma yang telah tersedia dan kemampuan komputasi yang terdapat pada GPU (Maulana dkk., 2024). *TensorFlow* memiliki berbagai fitur untuk pengembangan model *machine learning* dengan performa tinggi. Dalam konteks klasifikasi kendaraan di jalan tol, penggunaan CNN melalui *TensorFlow* dapat meningkatkan akurasi dan efisiensi proses klasifikasi dibandingkan dengan metode manual tradisional. Hal ini dikarenakan kemampuan CNN untuk mengenali pola visual kompleks dalam citra, yang sangat penting dalam mendeteksi dan mengkategorikan berbagai jenis kendaraan dengan akurasi tinggi.

Dengan memanfaatkan *TensorFlow*, pengelolaan lalu lintas di jalan tol dapat menjadi lebih canggih dan efektif. Ini membuka peluang besar untuk pengembangan sistem otomatis yang mampu mengurangi kesalahan manusia, meningkatkan efisiensi operasional, dan menyediakan data analitik yang lebih mendalam untuk pengambilan keputusan yang lebih baik dalam klasifikasi kendaraan di jalan tol. Oleh karena itu, integrasi *TensorFlow* dalam sistem pengelolaan lalu lintas dapat menghasilkan solusi yang lebih efektif dalam mengatasi tantangan di jalan tol. Data yang disajikan dalam artikel ini berguna untuk mengklasifikasikan keperluan kendaraan sesuai tarif jalan tol Indonesia (Sasongko dkk., 2020).

METODE PENELITIAN

Alur metode penelitian ditunjukkan pada Gambar 1. Langkah pertama dalam alur metode penelitian adalah membagi dataset gambar klasifikasi kendaraan jalan tol dengan persentase 20% data *testing* dan 80% data latih. Selanjutnya melakukan *preprocessing* data dengan mengubah gambar data menjadi *grayscale*. Selanjutnya langsung membuat model CNN menggunakan *Tensorflow*. Setelah membuat model, dataset gambar data latih dilatih dengan menggunakan model yang telah dibuat. lalu data uji gambar diuji menggunakan model sebelumnya. dan terakhir melakukan evaluasi terhadap akurasi model.



Gambar 1. Alur Metode Penelitian

Sumber: Data Diolah

A. Pembagian Dataset

Tahap pertama adalah membagi dataset gambar kendaraan menjadi dua *subset*, yakni data uji dan data latih. Dataset yang digunakan berasal dari *platform* Mendeley Data dan terdiri dari gambar kendaraan yang dapat memasuki jalan tol seperti mobil, truk, dan bus. Dataset dikelompokkan menjadi lima grup, dengan Grup 1 berisi 400 gambar kendaraan, dan Grup 2, 3, 4, serta 5 masing-masing berisi 200 gambar kendaraan, total 1200 gambar kendaraan. Pembagian dataset dilakukan dengan proporsi 20% untuk data uji dan 80% untuk data latih. Pembagian ini memastikan bahwa model CNN dapat dilatih dan diuji secara efektif.

B. Preprocessing Data

Preprocessing adalah tahap yang dilakukan sebelum training atau testing model dengan melakukan proses *resize* dan konversi citra RGB (Radikto dkk., 2022). Dalam hal ini menggunakan konversi citra RGB dengan data gambar diubah menjadi *grayscale* untuk menyederhanakan representasi warna dan mengurangi kompleksitas. Mengubah gambar menjadi *grayscale* membantu meningkatkan efisiensi pelatihan dan mengurangi kebutuhan akan sumber daya komputasi yang besar. Dengan demikian, model dapat lebih fokus pada pola visual yang penting tanpa terganggu oleh variasi warna.

C. Pembuatan model CNN

Perancangan CNN merupakan tahapan dalam menyusun sebuah model yang digunakan untuk melatih data dalam mengenali objek yang diinginkan (Prasetyo dkk., 2023). Arsitektur CNN dirancang khusus untuk mengenali kendaraan di jalan tol. Proses ini melibatkan penentuan jumlah dan jenis lapisan, serta parameter seperti ukuran kernel, jumlah filter, dan fungsi aktivasi. Model CNN yang diterapkan terdiri dari beberapa lapisan utama, termasuk lapisan konvolusi untuk mengekstrak fitur, lapisan *pooling* untuk mengurangi dimensi data, dan lapisan *fully connected* untuk klasifikasi akhir. Fungsi aktivasi seperti ReLU (*Rectified Linear Unit*) digunakan untuk memperkenalkan *non-linearitas* ke dalam model (Mulyo dan Widiantoro, 2018).

D. Pelatihan Model

Model CNN dilatih menggunakan data latih. Proses pelatihan melibatkan beberapa iterasi atau epoch di mana model mempelajari dan menyesuaikan bobot neuron berdasarkan kesalahan yang ditemukan selama proses pelatihan.

E. Pengujian

Setelah pelatihan selesai, model CNN diuji menggunakan data uji yang terpisah. Data uji digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan jenis kendaraan yang tidak ada dalam data latih. Evaluasi ini melibatkan visualisasi *confusion matrix* terhadap hasil pengujian model pada dataset uji coba untuk menentukan sejauh mana model dapat melakukan klasifikasi dengan benar.

F. Evaluasi Akurasi Data Uji

Langkah terakhir adalah mengevaluasi akurasi model menggunakan data uji. Model dianggap baik jika mencapai akurasi yang tinggi dalam mengklasifikasikan jenis kendaraan pada data uji. Jika akurasi model memenuhi atau melebihi kriteria yang telah ditetapkan, maka proses pelatihan dan pengujian dianggap selesai. Jika tidak, dilakukan *tuning* atau penyesuaian pada model dan proses pelatihan diulang hingga diperoleh hasil yang memuaskan.

HASIL DAN PEMBAHASAN

Pada studi kasus ini menggunakan dataset yang berasal dari mendeley data yang berisikan gambar kendaraan yang dapat masuk ke jalan tol seperti mobil, bus, dan truk. Dataset terdiri dari 5 grup dengan total data gambar kendaraan sebanyak 1200 gambar yang selanjutnya akan dibagi menjadi 3 bagian untuk memastikan bahwa model CNN efektif digunakan.

A. Mengubah Gambar Menjadi *Grayscale*

Dilakukan proses untuk menyederhanakan warna gambar kendaraan pada dataset. *Grayscale* merupakan representasi gambar yang menggunakan skala warna keabuan untuk mengurangi kompleksitas data, sehingga memudahkan model CNN untuk fokus pada pola visual yang penting tanpa terganggu oleh variasi warna yang tidak relevan.



Gambar 2. Visualisasi contoh gambar yang telah dirubah dari RGB ke *Grayscale*

Sumber: Data Diolah

Perubahan gambar RGB menjadi *grayscale* ditunjukkan pada Gambar 2. Dengan mengubah gambar menjadi *grayscale*, efisiensi pelatihan model dapat ditingkatkan dibandingkan dengan penggunaan citra berwarna. Selain itu, grayscale juga membantu memperjelas kontras antara objek dan latar belakang dalam citra, sehingga memudahkan proses ekstraksi fitur oleh model CNN. Dengan demikian, tahapan ini sangat penting untuk proses persiapan data sebelum dilakukan pelatihan model CNN untuk klasifikasi jenis kendaraan di jalan tol.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 298, 298, 32)	896
max_pooling2d (MaxPooling2D)	(None, 149, 149, 32)	0
conv2d_1 (Conv2D)	(None, 147, 147, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 73, 73, 64)	0
flatten (Flatten)	(None, 341056)	0
dense (Dense)	(None, 256)	87310592
dense_1 (Dense)	(None, 512)	131584
dense_2 (Dense)	(None, 5)	2565

Gambar 3. Struktur Model CNN yang digunakan untuk proses klasifikasi jenis kendaraan

Sumber: Data Diolah

B. Membangun Model CNN

Model CNN yang dibangun terdiri dari 8 *layer*. Model ini menerima input gambar berdimensi (300,300,3), Dan mengeluarkan output prediksi klasifikasi jenis kendaraan tol berdasarkan gambar yang diproses.

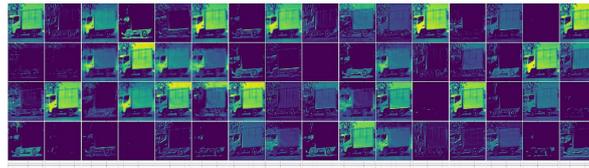
Struktur model ditunjukkan pada Gambar 3. Gambar yang diproses oleh model ini akan melalui *layer conv2d* dan *max_pooling2d* untuk mengurangi ukuran gambar agar lebih mudah dilakukan pengenalan fitur. Lalu, hasil dari empat *layer* pertama akan melalui *layer flatten*. Setelah itu hasil *layer flatten* akan melewati dua *layer dense* yang memiliki *neuron* sebanyak 256 dan 512. Akhirnya hasil dari *layer* tersebut akan melewati *layer dense* terakhir untuk menentukan kategori kendaraan tol dari gambar yang telah diproses.



Gambar 4. Visualisasi hotmap gambar pada layer conv2d pada kendaraan golongan dua

Sumber: Data Diolah

Layer konvolusi pertama ditunjukkan pada Gambar 4, ukuran gambar masih tidak jauh berbeda dibandingkan saat input. Hotmap fitur juga menunjukkan deteksi pada bagian boks truk dan bagian roda truk.



Gambar 5. Visualisasi *hotmap* gambar pada *layer conv2d_1* pada kendaraan golongan dua
Sumber: Data Diolah

Layer konvolusi kedua seperti pada Gambar 5 menunjukkan ukuran gambar menjadi lebih kecil dan menunjukkan lebih banyak deteksi fitur pada bagian roda truk.

C. Pelatihan Model

Model dilakukan training sebanyak 50 *epoch* dan didapatkan *loss* akhir sebesar 0,1023, Dan *accuracy* akhir sebesar 0,9611.

Tabel 1
Loss Dan Accuracy Pada Training

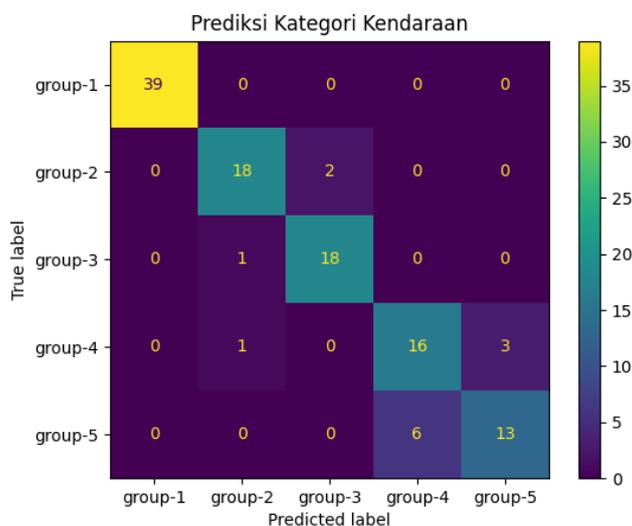
<i>Epoch</i>	<i>Loss</i>	<i>Accuracy</i>
1	1.5174	0.3247
2	1.2695	0.4824
3	1.2237	0.5037
4	1.0707	0.5751
....
28	0.2906	0.8652
29	0.3172	0.8803
30	0.2939	0.9017
....
49	0.1175	0.9583
50	0.1363	0.9518

Sumber: Data Diolah

Empat *epoch* pertama model masih memiliki tingkat akurasi yang masih rendah sesuai dengan tampilan tabel 1, yakni dibawah 60%. Tingkat akurasi mulai mencapai nilai sekitar 90% pada *epoch* ke-30. Namun, tidak menunjukkan peningkatan yang signifikan pada *epoch-epoch* selanjutnya. Sehingga, pada *epoch* ke-50 model mencapai akurasi latih akhir 95.18% dan *loss* 13.63%.

D. Pengujian Model

Model pengujian terhadap dataset uji dan mendapatkan akurasi pengujian sebesar 0.9060.



Gambar 6. Confusion matrix hasil uji model terhadap dataset uji

Sumber: Data Diolah

Dengan melihat *confusion matrix* hasil pengujian pada gambar 6, dapat disimpulkan bahwa model CNN cukup akurat dalam mengklasifikasi kendaraan golongan 1, 2, 3, Dan 4. Namun membuat lebih banyak kesalahan prediksi pada kendaraan golongan 5.

SIMPULAN

Studi kasus ini menunjukkan bahwa penerapan *Convolutional Neural Networks* (CNN) dengan menggunakan *TensorFlow* dapat secara efektif meningkatkan akurasi dan efisiensi dalam klasifikasi jenis kendaraan di jalan tol. Dengan membagi dataset menjadi data uji dan data latih, serta melakukan preprocessing seperti mengubah gambar menjadi *grayscale*, model CNN berhasil dibangun dan dilatih hingga mencapai akurasi yang tinggi. Evaluasi terhadap model menunjukkan hasil yang memuaskan dengan akurasi pengujian sebesar 90.60%. Implementasi teknologi ini mampu mengurangi kesalahan, mempercepat proses klasifikasi, dan meningkatkan efisiensi operasional di jalan tol, membuka peluang besar untuk pengelolaan lalu lintas pada jalan tol yang lebih efektif.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih yang sebesar-besarnya kepada Dosen Pembimbing mata kuliah Analisis Citra, Bapak Hendra Maulana, S.Kom., M.Kom., atas saran dan masukan yang telah diberikan dalam penyusunan artikel ini.

DAFTAR PUSTAKA

- Haqiqi, K. U., Hana, F. M., dan Aulida, H. (2024). Klasifikasi Jenis Golongan Kendaraan Di Gerbang Tol Menggunakan Arsitektur Convolutional Neural Network VGG16. *JURNAL Ilmu Komputer Dan Matematika*, 5(1), 10-15.
- Maulana, M. S., Nugroho, B. I., dan Surejo, I., "Sistem Klasifikasi Jenis Kendaraan Melalui Teknik Olah Citra Digital," *Jurnal Minfo Polgan*, vol. 11, no. 02, hal. 89-96, September 2022.
- Mulyo, B. M., Widyantoro, D. H., "Aspect-Based Sentiment Analysis Approach with CNN," *2018 5th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*, Malang, Indonesia, 2018, pp. 142-147, doi: <https://doi.org/10.1109/EECSI.2018.8752857>.
- Nurolan, A. T. (2020). Deteksi Dan Klasifikasi Jenis Kendaraan Berbasis Pengolahan Citra Dengan Metode Convolutional Neural Network (CNN).
- Prakosa, A. B., Hendry, dan Tanone, R. (2023). Implementasi Model Deep Learning Convolutional Neural Network (CNN) pada Citra Penyakit Daun Jagung untuk Klasifikasi Penyakit Tanaman. *Jurnal Pendidikan Teknologi Informasi (JUKANTI)*, 6(1). eISSN: 2621-1467.
- Pramana, A. L., Setyati, E., dan Kristian, Y. (2020). Model CNN Lenet Dalam Pengenalan Jenis Golongan Kendaraan Pada Jalan Tol. *Jurnal Teknika*, 12(2), 65-69.
- Prasetyo, M. E., Faza, M. R., Pratama, R., Alhabsy, S. N. H., Purwanti, H., dan Masa, A. P. A. (2023). Klasifikasi Ragam Kendaraan Menggunakan Metode Convolutional Neural Network (Cnn). *Adopsi Teknologi Dan Sistem Informasi (ATASI)*, 2(2), 142-148. <https://doi.org/10.30872/atasi.v2i2.1156>.
- Radikto, R., Mulyana, D. I., Rofik, M. A., dan Zoharuddin Zakaria, M. O. (2022). Klasifikasi Kendaraan pada Jalan Raya menggunakan Algoritma Convolutional Neural Network (CNN). *Jurnal Pendidikan Tambusai*, 6(1), 1668-1679. <https://doi.org/10.31004/jptam.v6i1.3179>.
- Sasongko, A. T., Jati, G., Fanany, M. I., dan Jatmiko. W., "Dataset of vehicle images for Indonesia toll road tariff classification," *Data in Brief*, vol. 32, hal. 106061, Okt. 2020.
- Suradi, A. A. M., Rasyid M. F., dan Nasaruddin, "Sistem Perhitungan Jumlah Kendaraan Berbasis Computer Vision," *Prosiding Seminar Ilmiah Sistem Informasi dan Teknologi Informasi*, vol. XI, no. 1, hal. 89-97, Juli 2022.
- Surya, M. A., Susanto. M., Setyawan, A., Fitriawan, H., dan Mardiana, "Sistem Keamanan Ruang dengan Human Detection Menggunakan Sensor Kamera Berbasis Deep Learning," *Jurnal Teknoinfo*, vol. 18, no. 1, hal. 182-192, Januari 2024. ISSN: 1693-0010 (Print), ISSN: 2615-224X (Online).

- Triardhana, Y., Sasmito, B., dan Hadi, F., "Road Damage Identification Using Deep Learning Method Convolutional Neural Networks Model," *Jurnal Geodesi Undip*, vol. 10, no. 3, hal. 33-40, Juli 2021.
- Winardi, W., Karyono, Y., Nugroho, A., Sofian, A., Budiati, I., Hastuti, A., Lestari, T. H., Mardiana, Aritonang, T. M., Lasma, Sorayan, P. H., Utami, L. P., Kristanti, H. D., Muslianti, D., Anisa, M., Riawati, E., Wulandari, M. D., Logaritma, S., Prihantoro, A. M., ... Kurniawan, A. Y. (2023). *Statistik Indonesia 2023 Statistical Yearbook of Indonesia 2023*.
- Yunius, T. R., "Implementasi Algoritma Convolutional Neural Network dengan Framework TensorFlow pada Aplikasi Mobile Pendeteksi Penyakit Melanoma dengan Memanfaatkan Webservice Framework Flask," *Jurnal Sains dan Komputer*, vol. 1, no. 2, 2021.
- Zahra, S. A., Sarifah, W. N., Elfaris, F., Rustamto, D. F., dan Rosyani, P., "Kendaraan Deteksi Pengenalan Kendaraan Menggunakan Metode Fast R-CNN," *AI dan SPK: Jurnal Artificial Intelligent dan Sistem Penunjang Keputusan*, vol. 1, no. 2, hal. 166-171, 2023.