

Klasifikasi Golongan Kendaraan Menggunakan EfficientNetV2-S Dan EfficientNetV2-L

Abdurrahman Al Hakim^{*1}, Faisal Muttaqin², Hendra Maulana³

^{1,2,3} Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur, Surabaya, Indonesia

¹ abdurrahmanalhakim03@gmail.com*, ² faisalmuttaqin.if@upnjatim.ac.id, ³ hendra.maulana.if@upnjatim.ac.id

INFO ARTIKEL

Article history:
Received Juni 2026
Published Juli 2026

ABSTRAK

Peningkatan volume kendaraan berat di Indonesia menuntut adanya sistem klasifikasi otomatis di jalan arteri. Penggolongan kendaraan berat yang sangat bergantung pada letak dan jumlah susunan as roda memunculkan tantangan fine-grained visual classification, sehingga membutuhkan pengambilan citra dari sudut menyamping. Arsitektur Convolutional Neural Network (CNN) terbukti andal dalam pengenalan citra, namun model berskala besar umumnya sangat membebani beban komputasi. Penelitian ini bertujuan menganalisis komparasi performa arsitektur yang efisien, yakni keluarga EfficientNetV2, untuk menemukan keseimbangan optimal antara akurasi dan parameter komputasi. Pengujian membandingkan performa varian ringan EfficientNetV2-S yang dilatih secara end-to-end dengan varian berskala masif EfficientNetV2-L yang dievaluasi menggunakan skema end-to-end dan fine-tuning. Eksperimen menggunakan 2.500 dataset citra berimbang yang dioptimasi dengan augmentasi dan diolah menggunakan optimizer AdaBelief. Hasil pengujian menunjukkan bahwa EfficientNetV2-S mencatatkan performa superior dengan akurasi 89% dan F1-Score 88,67%. Sebaliknya, peningkatan kapasitas parameter pada EfficientNetV2-L justru memicu overfitting akibat keterbatasan variasi data lokal, sehingga menghasilkan akurasi yang lebih rendah, yakni 76% (end-to-end) dan 71% (fine-tuning). Kesimpulannya, arsitektur berparameter kecil terbukti lebih tangguh, efisien, dan jauh lebih direkomendasikan untuk implementasi fine-grained classification pada sistem jalan tol dibandingkan mengandalkan model masif maupun skema transfer learning.

Kata Kunci: klasifikasi kendaraan, jumlah gandar, deep learning, CNN, EfficientNet V2

ABSTRACT

The increasing volume of heavy vehicles in Indonesia necessitates the implementation of automatic classification systems on arterial roads. Since the classification of heavy vehicles relies heavily on the arrangement and number of axle configurations, it presents a fine-grained visual classification challenge that requires image acquisition from a side-view perspective. Convolutional Neural Network (CNN) architectures have proven effective for image recognition tasks; however, large-scale models generally impose substantial computational costs. This study aims to analyze and compare the performance of efficient architectures from the EfficientNetV2 family to identify the optimal balance between accuracy and computational requirements. The evaluation compares the lightweight EfficientNetV2-S variant trained end-to-end with the large-scale EfficientNetV2-L variant evaluated using both end-to-end and fine-tuning approaches. Experiments were conducted using a balanced dataset of 2,500 images, enhanced through data augmentation and optimized using the AdaBelief

optimizer. The results show that EfficientNetV2-S achieved superior performance, attaining 89% accuracy and an F1-score of 88.67%. In contrast, the increased parameter capacity of EfficientNetV2-L led to overfitting due to the limited diversity of local data, resulting in lower accuracies of 76% (end-to-end) and 71% (fine-tuning). In conclusion, architectures with fewer parameters proved to be more robust, computationally efficient, and significantly more suitable for fine-grained classification in toll road systems than relying on large-scale models or transfer learning approaches.

Keywords: Vehicle Classification, Axle Count, Deep Learning, Convolutional Neural Network (CNN), EfficientNetV2.

©2026 Authors. Licensed Under [CC-BY-NC-SA 4.0](#)

1. Pendahuluan

Jumlah kendaraan bermotor di Indonesia terus menunjukkan eskalasi yang signifikan setiap tahunnya (Indonesia, 2023). Berdasarkan data Badan Pusat Statistik, tercatat lonjakan jumlah kendaraan dari 159 juta unit pada tahun 2023 menjadi 172 juta pada tahun 2025. Kendaraan berat truk mengalami peningkatan sebanyak 386 ribu unit dan bus sebanyak 35 ribu unit pada dua tahun tersebut (Badan Pusat Statistik Indonesia, 2025). Peningkatan masif ini berimplikasi langsung terhadap tantangan manajemen lalu lintas dan penurunan kualitas infrastruktur jalan (Sianipar, 2020). Tingginya intensitas serta keberagaman jenis dan tonase kendaraan yang melintas berpotensi mempercepat tingkat keausan konstruksi jalan raya (Satria et al., n.d.), sekaligus meningkatkan risiko terjadinya kongesti atau kemacetan lalu lintas.

Proses identifikasi jenis kendaraan yang dilakukan secara manual terbukti kurang efisien dan memiliki risiko kesalahan yang tinggi (A. R. Priambodo et al., n.d.). Untuk mengatasi hal tersebut, sistem pengawasan lalu lintas masa kini mengadopsi kamera Closed-Circuit Television dengan sudut pengambilan gambar dari samping yang terhubung langsung pada Intelligent Transportation System (Dwiyanto et al., n.d.). Penggunaan sudut pandang lateral ini sangat krusial, mengingat penggolongan kendaraan berat sangat bergantung pada jumlah sumbu roda (Sasongko & Ivan Fanany, 2019). Fitur pembeda ini umumnya tidak terlihat jika diamati melalui kamera yang menyorot dari arah depan maupun atas karena terhalang oleh badan kendaraan (Amiruddin et al., 2024).

Walaupun sudut samping memberikan visibilitas yang lebih baik, upaya mengotomatisasi pengenalan ini masih dihadapkan pada kesulitan tingkat tinggi yang dikenal sebagai fine-grained visual classification (Khoba et al., 2022). Berbagai jenis truk sering memiliki desain eksterior yang nyaris serupa, dan murni hanya dapat dibedakan melalui letak serta jumlah as rodanya. Tingkat kerumitan visual inilah yang menjadikan klasifikasi citra samping sebagai studi kasus yang sangat relevan untuk dievaluasi menggunakan algoritma Deep Learning, seperti Convolutional Neural Network (ul Khairi et al., 2023). Keunggulan metode ini terletak pada kemampuannya dalam mengekstraksi dan mempelajari karakteristik visual yang spesifik secara otomatis dari suatu citra (Anggay Luri Pramana, 2024).

Keandalan arsitektur CNN dalam penggolongan kendaraan telah banyak dibuktikan melalui berbagai studi terdahulu. Meskipun mampu menawarkan tingkat presisi yang sangat tinggi, arsitektur CNN konvensional umumnya memuat parameter komputasi dalam jumlah masif (Andrianto et al., 2024). Hal ini berdampak langsung pada lonjakan beban komputasi, konsumsi energi, serta tingginya biaya operasional, yang memunculkan dilema serius antara mempertahankan akurasi dan menjaga efisiensi sistem saat diterapkan dalam skala luas. Menyikapi ketimpangan tersebut, pendekatan strategis yang dapat diambil adalah mengadopsi rancangan arsitektur CNN yang secara fundamental jauh lebih ringan namun tetap mempertahankan performa unggul, seperti EfficientNetV2 (Kurniawan & Hermanto, n.d.).

EfficientNetV2 adalah arsitektur CNN yang dirancang khusus untuk mengoptimalkan efisiensi komputasi tanpa mengorbankan tingkat akurasi. Dalam keluarga arsitektur ini, terdapat rentang skala model mulai dari varian ringan, yakni EfficientNetV2-S (Tan & Le, 2021), hingga varian berkapasitas masif, yakni EfficientNetV2-L. Meskipun efisiensi model dasar ini telah teruji, tantangan krusial selanjutnya terletak pada penentuan strategi pelatihan yang paling optimal.


Terdapat dua paradigma utama yang umum digunakan dalam pelatihan model deep learning, yakni pelatihan menyeluruh dari awal atau end-to-end training dan penyesuaian bobot menggunakan model

yang telah dilatih sebelumnya atau fine-tuning(Eka et al., n.d.). Skema end-to-end memungkinkan model mempelajari fitur spesifik kendaraan lokal secara utuh dari awal, namun rentan terhadap waktu konvergensi yang lama. Di sisi lain, skema fine-tuning menawarkan percepatan konvergensi dengan memanfaatkan representasi visual umum dari pre-trained weights (Deva et al., n.d.).

Oleh karena itu, penelitian ini difokuskan pada analisis komparatif untuk mengevaluasi kinerja arsitektur dengan kompleksitas berbeda di bawah skema pelatihan yang berlainan. Secara spesifik, penelitian ini membandingkan performa model ringan EfficientNetV2-S yang dilatih secara end-to-end, melawan model berskala besar EfficientNetV2-L yang dilatih menggunakan dua skema berbedan end-to-end dan fine-tuning. Komparasi ini bertujuan untuk menginvestigasi apakah lonjakan parameter pada model bervolume besar sepadan dengan peningkatan akurasi, serta untuk mengidentifikasi skema pelatihan mana yang menawarkan keseimbangan terbaik antara akurasi klasifikasi fine-grained dan efisiensi komputasi pada sistem jalan.

2. Metode Penelitian

Pada bab ini akan dijelaskan langkah-langkah yang dilakukan oleh peneliti untuk menyelesaikan permasalahan yang diangkat. Alur sistematis yang dilakukan dalam penelitian ini diilustrasikan secara rinci pada Gambar 1.



Gambar 1. Alur Tahapan Penelitian

Sumber: Penulis, 2026

Pada Gambar 1 ditunjukkan alur tahapan penelitian yang dimulai dari pengumpulan dataset hingga evaluasi model.

A. Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari dataset primer dan dataset sekunder. Kedua dataset merupakan citra kendaraan golongan I hingga V yang diambil dari sisi kanan ataupun kiri kendaraan sehingga menghasilkan citra *side view*.

Tabel 1. Jumlah Gambar Pada Dataset.

Golongan Kendaraan	Dataset Primer	Dataset Sekunder
Golongan 1	20	397
Golongan 2	20	200
Golongan 3	20	199
Golongan 4	20	200
Golongan 5	20	199
Total Gambar	100	1195

Pada Tabel 1 ditampilkan jumlah gambar pada dataset yang digunakan. Dataset primer merupakan potongan gambar dari video yang diambil langsung oleh peneliti di jalan sekitar pintu masuk tol tanjung perak di kota Surabaya. Jumlah gambar tiap kelas pada dataset ini berjumlah 20 sehingga total gambar pada dataset primer adalah 100 gambar.

Dataset sekunder adalah dataset public dari jurnal Indonesia Toll Road Vehicle Classification Using Transfer Learning with Pre-trained Resnet Models [7]. Jumlah gambar tiap kelas pada dataset bervariasi dari 197 hingga 200.

B. Pembagian Dataset

Pada penelitian ini dataset primer akan digunakan untuk pengujian. Sedangkan dataset sekunder digunakan pada proses pelatihan model. Dataset sekunder akan dibagi menjadi dua subset dataset latihan dan dataset validasi dengan pembagian 80% dataset latihan dan 20% dataset validasi.

C. Preprocessing Dataset

Preprocessing merupakan tahapan awal yang krusial sebelum proses pelatihan dan pengujian model. Tahap ini bertujuan untuk meningkatkan kuantitas serta variasi dataset melalui teknik augmentasi citra, sehingga jumlah gambar pada setiap golongan dataset menjadi seimbang dan tidak terjadi ketidakseimbangan data. Dalam penelitian ini, teknik augmentasi yang digunakan meliputi Resize, Random Horizontal Flip, Random Rotation, Random Affine, dan Color Jitter.

Tabel 2. Jumlah Gambar Pada Dataset.

Golongan Kendaraan	Dataset Primer	Dataset Sekunder
Golongan 1	20	500
Golongan 2	20	500
Golongan 3	20	500
Golongan 4	20	500
Golongan 5	20	500
Total Gambar	100	2500

Pada Tabel 2 dirincikan jumlah gambar tiap kelas setelah dilakukan augmentasi.

D. Membuat Model

Arsitektur Deep Learning yang diimplementasikan dalam penelitian ini adalah EfficientNetV2-S, yang merupakan varian dengan beban komputasi ringan dari keluarga model EfficientNetV2. Untuk menyesuaikan dengan ruang lingkup studi kasus, modifikasi secara spesifik dilakukan pada lapisan klasifikasi dari model dasar tersebut. Penyesuaian arsitektur ini dirancang agar keluaran output jaringan dapat memprediksi dan mengkategorikan citra masukan secara presisi ke dalam lima kelas golongan kendaraan.

E. Melatih Model

Pelatihan model dilakukan melalui tiga skema pengujian: EfficientNetV2-S dengan pelatihan end-to-end, serta EfficientNetV2-L yang dilatih secara end-to-end maupun fine-tuning. Seluruh skema eksperimen ini dieksekusi menggunakan hyperparameter yang seragam guna memastikan validitas

perbandingan performa antar model. Konfigurasi standar yang diimplementasikan meliputi penetapan ukuran batch sebesar 8 dan penggunaan optimizer AdaBelief.

F. Menguji Model

Untuk memvalidasi konsistensi performa, setiap skema dilatih sebanyak lima kali menggunakan inisialisasi dataset latih dan validasi yang diacak

G. Evaluasi Model

Pada tahap ini, representasi model terbaik dari masing-masing skema pelatihan yakni end-to-end dan fine-tuning akan dikomparasi dan dievaluasi kinerjanya secara komprehensif. Evaluasi performa tidak hanya bertumpu pada tingkat akurasi keseluruhan, tetapi juga memperhitungkan metrik Precision, Recall, dan F1-Score.

3. Hasil dan Pembahasan

Pada studi kasus ini menggunakan dataset yang berasal dari Indonesia Toll Road Vehicle Classification Using Transfer Learning with Pre-trained Resnet Models [7], dan yang diambil sendiri oleh peneliti yang berisikan gambar kendaraan seperti mobil, bus, dan truk. Augmentasi diterapkan sesuai dengan yang dibahas pada bab sebelumnya.



Gambar 2. Contoh Gambar setelah Augmentasi
Sumber: Penulis, 2026

Pada Gambar 2 ditampilkan contoh gambar sebelum dan sesudah augmentasi. Penyeragaman ukuran atau Resize ke resolusi 256×256 piksel lalu Random Horizontal Flip dengan probabilitas 50% untuk mensimulasikan kendaraan dari arah berlawanan. Selanjutnya Random Rotation memutar citra secara acak antara -15° hingga 15° guna mengakomodasi variasi kemiringan jalan atau posisi kamera. Random Affine digunakan untuk menggeser posisi objek secara acak pada sumbu horizontal dan vertikal hingga 10% dari ukuran citra agar model tidak bergantung pada objek di tengah bingkai. Terakhir, Color Jitter memodifikasi brightness, contrast, dan saturation masing-masing sebesar 20% untuk mensimulasikan variasi kondisi pencahayaan seperti mendung, terik, atau sore hari.

Tabel 3. Hasil pengujian Model.

Skema Pelatihan	Varian Model	Akurasi
<i>EfficientNetV2-S</i>	Inisialisasi 1	89 %
	Inisialisasi 2	87 %
	Inisialisasi 3	80 %
	Inisialisasi 4	81 %
	Inisialisasi 5	80 %
<i>EfficientNetV2-L End-to-End</i>	Inisialisasi 1	45 %
	Inisialisasi 2	58 %
	Inisialisasi 3	62 %
	Inisialisasi 4	76 %
	Inisialisasi 5	54 %
<i>EfficientNetV2-L Fine Tune</i>	Inisialisasi 1	67 %
	Inisialisasi 2	67 %
	Inisialisasi 3	70 %
	Inisialisasi 4	71 %
	Inisialisasi 5	60 %


Berdasarkan hasil pengujian pada Tabel , EfficientNetV2-S menunjukkan performa terbaik dengan tingkat akurasi puncak sebesar 89%, meskipun kelima inisialisasi modelnya masih memperlihatkan sedikit perbedaan stabilitas. Sebaliknya, pengujian pada EfficientNetV2-L dengan skema end-to-end menghasilkan akurasi yang sangat fluktuatif pada setiap inisialisasi, dengan nilai tertinggi hanya mencapai 76%. Tingginya volatilitas ini menunjukkan ketidakmampuan model berukuran besar dalam

mempertahankan stabilitas konvergensi selama proses pelatihan, yang sering kali dipicu oleh ketidakseimbangan antara masifnya parameter model dengan ketersediaan jumlah data latih. Lebih lanjut, implementasi skema fine-tuning pada EfficientNetV2-L justru menempatkan model ini pada posisi terendah dengan akurasi maksimal sebesar 71%. Penurunan performa ini membuktikan bahwa metode transfer learning tidak selalu efektif, terutama ketika diterapkan pada klasifikasi citra fine-grained yang membutuhkan ekstraksi fitur visual beresolusi tinggi dan sangat spesifik.

Tabel 3. Tabel Evaluasi Model


Model	Accuracy	Precision	Recall	F1-Score
Model terbaik dari <i>EfficientNetV2-S</i>	89	90.79	89	88.67
Model terbaik dari <i>EfficientNetV2-L</i> <i>End-to-End</i>	76	75.95	76	75.75
Model terbaik dari <i>EfficientNetV2-L</i> <i>Fine Tune</i>	71	71.74	71	69.98

Berdasarkan evaluasi pada Tabel 6, representasi model terbaik EfficientNetV2-S unggul secara absolut pada seluruh metrik evaluasi dibandingkan dengan EfficientNetV2-L. Model ini mencatatkan Accuracy 89%, Precision 90.79%, Recall 89%, dan F1-Score 88.67%. EfficientNetV2-L sebagai model yang memiliki parameter jauh lebih besar hanya mampu mencapai F1-Score 75.75% dengan skema End-to-End dan 69.98% secara Fine-Tune mengindikasikan terjadinya gejala overfitting. Jumlah parameter komputasi yang masif pada arsitektur varian L terbukti tidak berbanding lurus dengan kemampuannya melakukan generalisasi pada studi kasus ini.




Gambar 3. Confusion Matrix EfficientNetV2-S
Sumber: Penulis, 2026

Pada Gambar 3 ditampilkan confusion matrix untuk model terbaik EfficientNet V2-S, Terlihat model ini cukup baik memprediksi kendaraan golongan 1, 3, 4, dan 5. Namun masih memiliki kelemahan dalam sering salah memprediksi golongan 2 ke golongan 3.



Gambar 4. Confusion Matrix EfficientNetV2-L End-to-End
Sumber: Penulis, 2026

Pada Gambar 4 ditampilkan confusion matrix untuk model terbaik EfficientNet V2-L End-to-End. Berdasarkan distribusi prediksinya, model ini masih menunjukkan kapabilitas yang memadai dalam mengklasifikasikan kendaraan Golongan 1, 2, dan 3. Akan tetapi, degradasi akurasi yang drastis terjadi ketika model dihadapkan pada Golongan 4 dan 5. Model tampak kehilangan kemampuannya dalam membedakan kedua golongan truk berat tersebut secara presisi. Penurunan performa ini sangat mungkin dipicu oleh fenomena overfitting, di mana kapasitas parameter model yang masif gagal melakukan generalisasi terhadap fitur fine-grained yang kompleks seperti konfigurasi multi-sumbu roda yang rapat pada truk berdimensi panjang.



Gambar 5. Confusion Matrix EfficientNetV2-L Fine Tune
Sumber: Penulis, 2026

Pada Gambar 5 ditampilkan confusion matrix untuk model terbaik EfficientNet V2-L Fine Tune, model cukup berhasil mengenali kelas kendaraan Golongan 1, 2, dan 3. Namun, tingkat kesalahan prediksi melonjak tajam pada pengenalan Golongan 4 dan 5. Kegagalan membuktikan bahwa representasi visual bawaan dari pre-trained weights kurang relevan untuk diadaptasi pada studi kasus ini. Pengetahuan awal model gagal mengekstraksi fitur letak dan jumlah gandar roda yang berdekatan secara optimal, sehingga batas yang dihasilkan menjadi bias dan memicu tingginya angka kesalahan klasifikasi antar kelas kendaraan berat.

Secara keseluruhan, komparasi hasil eksperimen ini menegaskan bahwa penggunaan arsitektur model Deep Learning yang lebih masif dan kompleks tidak selalu berbanding lurus dengan peningkatan performa, terutama pada kasus fine-grained visual classification dengan dataset spesifik yang terbatas. Model EfficientNetV2-S terbukti jauh lebih superior, stabil, dan efisien dalam mengenali fitur susunan as roda kendaraan dibandingkan arsitektur raksasa EfficientNetV2-L. Kegagalan varian berskala besar dalam mencapai konvergensi optimal, baik melalui skema end-to-end maupun fine-tuning, membuktikan bahwa efisiensi parameter dan kesesuaian kapasitas jaringan dengan jumlah data latih adalah kunci utama dalam membangun sistem klasifikasi kendaraan jalan yang andal.

4. Kesimpulan

Berdasarkan serangkaian eksperimen, evaluasi, dan analisis yang telah dilakukan terhadap sistem klasifikasi golongan kendaraan menggunakan citra side-view, dapat ditarik beberapa kesimpulan utama sebagai berikut.

A. Superioritas Model Ringan

Arsitektur EfficientNetV2-S yang dilatih dengan skema end-to-end terbukti menjadi model yang paling optimal dan adaptif untuk tugas klasifikasi ini. Model ini berhasil mencatatkan performa terbaik dengan tingkat akurasi mencapai 89%, serta metrik Precision, Recall, dan F1-Score yang mengungguli seluruh skenario pengujian lainnya

B. Dampak Negatif Overparameterization

Peningkatan skala arsitektur pada model EfficientNetV2-L justru berdampak pada penurunan performa secara signifikan. Besarnya jumlah parameter komputasi memicu terjadinya overfitting akibat keterbatasan variasi dataset lokal, yang ditandai dengan tingginya volatilitas akurasi dan ketidakmampuan model dalam membedakan kendaraan berat Golongan 4 dan 5.

C. Inefektivitas Transfer Learning pada Fitur Spesifik

Pendekatan fine-tuning pada EfficientNetV2-L menghasilkan tingkat akurasi terendah, yakni 71%. Hal ini membuktikan bahwa representasi fitur visual umum yang dibawa oleh pre-trained weights kurang efektif ketika dihadapkan pada kerumitan fine-grained classification, di mana sistem dituntut membedakan detail ekstrem seperti jarak dan jumlah susunan as roda truk.

5. Ucapan Terima Kasih

Penulis menyampaikan terima kasih yang sebesar-besarnya kepada Dosen Pembimbing Bapak Faisal Muttaqin dan Bapak Hendra Maulana atas saran dan masukan yang telah diberikan dalam penyusunan artikel ini.

Daftar Pustaka

- A. R. Priambodo, A. A. Hakim, Christian, F. T. Vierino, & H. Maulana. (n.d.). Klasifikasi Golongan Kendaraan Tol menggunakan CNN Tensorflow. *Jurnal Ilmiah Teknologi Informasi Dan Robotika*. <https://doi.org/10.33005/jifti.v7i1.151>
- Amiruddin, Muh. N. F., Navastara, D. A., & Yuniarti, A. (2024). Klasifikasi Jenis Kendaraan Darat di Indonesia Menggunakan Pendekatan Deep Learning. *Jurnal Teknik ITS*, 13(3). <https://doi.org/10.12962/j23373539.v13i3.146954>
- Andrianto, A., Tahyudin, I., & Karyono, G. (2024). Perbandingan Efficientnet, Visual Geometry Group 16, dan Residual Network 50 Untuk Klasifikasi Kendaraan Bermotor. *Building of Informatics, Technology and Science (BITS)*, 6(3), 1995–2004. <https://doi.org/10.47065/bits.v6i3.6450>

- Anggay Luri Pramana. (2024). Analisis Perbandingan Evaluasi Metode Deep Learning pada Klasifikasi Jenis Kendaraan. *Journal of Computer Science and Visual Communication Design*, 9(1), 451–465. <https://doi.org/10.55732/jikdiskomvis.v9i1.1252>
- Badan Pusat Statistik Indonesia. (2025). *Jumlah Kendaraan Bermotor Menurut Provinsi dan Jenis Kendaraan (unit), 2025 - Tabel Statistik*.
- Deva, J., Oktavian, N., Arishandy, Z. I., Pradana, A., Zakita, P., & Muttaqin, F. (n.d.). PERBANDINGAN MODEL TRANSFER LEARNING INCEPTIONV3 DAN RESNET50 UNTUK KLASIFIKASI PENYAKIT MATA PADA CITRA RETINA. In *Jurnal Pendidikan Teknologi Informasi dan Komunikasi* (Vol. 5).
- Dwiyanto, R., Widodo, D. W., & Kasih, P. (n.d.). *Implementasi Metode You Only Look Once (YOLOv5) Untuk Klasifikasi Kendaraan Pada CCTV Kabupaten Tulungagung*. Retrieved <https://arxiv.org/abs/1506.02640>.
- Eka, A., Wulyono, P., Muttaqin, F., & Mulyo, B. M. (n.d.). *Perbandingan efficientnet-B0 Pretrained dan Prototypical Network from Scratch untuk Klasifikasi Diabetic Retinopathy* (Vol. 4).
- Indonesia, B. P. S. (2023). *Jumlah Kendaraan Bermotor Menurut Provinsi dan Jenis Kendaraan (unit), 2023 - Tabel Statistik*. Badan Pusat Statistik Indonesia. <https://www.bps.go.id/id/statistics-table/3/VjJ3NGRGa3dkRk5MTIU1bVNFOTVVbmQyVURSTVFUMDkjMw==/jumlah-kendaraan-bermotor-menurut-provinsi-dan-jenis-kendaraan-unit—2023.html>
- Khoba, P. K., Parikh, C., Jawahar, C. V., Sarvadevabhatla, R. K., & Saluja, R. (2022). A Fine-Grained Vehicle Detection (FGVD) Dataset for Unconstrained Roads*. *Proceedings of the Thirteenth Indian Conference on Computer Vision, Graphics and Image Processing*, 1–9. <https://doi.org/10.1145/3571600.3571626>
- Kurniawan, R., & Hermanto, D. (n.d.). *Klasifikasi Jenis Penyakit Tanaman Jagung Berdasarkan Citra Daun dengan Algoritma EfficientNetV2-S*.
- Sasongko, A. T., & Ivan Fanany, M. (2019). Indonesia Toll Road Vehicle Classification Using Transfer Learning with Pre-trained Resnet Models. *2019 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, 373–378. <https://doi.org/10.1109/ISRITI48646.2019.9034590>
- Satria, A., Wicaksana, T., Yuniarta, A., Didik, D., & Mabui, S. S. (n.d.). “*Technological Innovation for Infrastructure and building Development on Soft Soil to Achieve Sustainable Development Goals (SDG)*.”
- Sianipar, A. (2020). Analisis Distribusi Beban pada Kendaraan Angkutan Barang Sesuai dengan Konfigurasi Axle. *Warta Penelitian Perhubungan*, 32(1), 11–20. <https://doi.org/10.25104/warlit.v32i1.1270>
- Tan, M., & Le, Q. V. (2021). *EfficientNetV2: Smaller Models and Faster Training*. <https://github.com/google/>
- ul Khairi, D., Ayaz, F., Saeed, N., Ahsan, K., & Ali, S. Z. (2023). Analysis of Deep Convolutional Neural Network Models for the Fine-Grained Classification of Vehicles. *Future Transportation*, 3(1), 133–149. <https://doi.org/10.3390/futuretransp3010009>