



## **Klasifikasi kendaraan bermotor berdasarkan jumlah gandar menggunakan adaptive minimal ensemble**

**Abdurrahman Al Hakim<sup>1</sup>, Faisal Muttaqin<sup>\*2</sup>, Hendra Maulana<sup>3</sup>**

Email: <sup>1</sup>abdurrahmanalhakim03@gmail.com, <sup>2</sup>faisalmuttaqin.if@upnjatim.ac.id, <sup>3</sup>hendra.maulana.if@upnjatim.ac.id

<sup>1,2,3</sup>Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional Veteran Jawa Timur

Diterima: 24 Maret 2026 | Direvisi: - | Disetujui: 26 April 2026  
©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,  
Universitas Muhammadiyah Riau, Indonesia

### **Abstrak**

Peningkatan volume kendaraan bermotor membutuhkan pemantauan otomatis klasifikasi golongan kendaraan berat (Golongan I-V) berdasarkan gandar menggunakan kamera bersudut pandang menyamping (*side-view*). Proses ini merupakan tantangan *fine-grained visual classification* yang kompleks karena bentuk bodi truk yang identik. Untuk mengatasi dilema antara kebutuhan akurasi tinggi dan efisiensi komputasi, penelitian ini mengimplementasikan arsitektur *Adaptive Minimal Ensemble* (AME) yang menggabungkan model berskala kecil secara adaptif. Model dievaluasi menggunakan confusion matrix serta metrik *accuracy*, *presisi*, *recall*, dan *F1-score*. Hasil pengujian membuktikan bahwa model tunggal *EfficientNetV2-S* hanya mampu mencapai akurasi tertinggi sebesar 83% dan memiliki kelemahan signifikan dalam mengekstraksi fitur pembeda krusial, yang memicu misklasifikasi pada kendaraan Golongan 4 dan 5. Sebaliknya, arsitektur AME yang menggunakan dua model dasar *EfficientNetV2-S* terbaik berhasil mendongkrak performa secara mutlak dengan capaian *accuracy* 95%, *precision* 95.21%, *recall* 95%, dan *F1-Score* 94.99%. Kesimpulannya, mekanisme lapisan adaptif pada AME terbukti sangat efektif menutupi kelemahan prediksi individu dari model dasarnya, sehingga menghasilkan sistem pengawasan klasifikasi kendaraan yang jauh lebih presisi.

**Kata kunci:** klasifikasi kendaraan, jumlah gandar, deep learning, CNN, adaptive minimal ensemble

### ***Motor vehicle classification based on the number of axles using an adaptive minimal ensemble***

#### **Abstract**

*The increasing volume of motor vehicles requires automated monitoring for the classification of heavy vehicle categories (Category I–V) based on the number of axles using side-view cameras. This process represents a complex fine-grained visual classification challenge due to the similar body shapes of trucks. To address the dilemma between the need for high accuracy and computational efficiency, this study implements an Adaptive Minimal Ensemble (AME) architecture that adaptively combines small-scale models. The model is evaluated using a confusion matrix along with accuracy, precision, recall, and F1-score metrics. The testing results demonstrate that a single EfficientNetV2-S model is only able to achieve a maximum accuracy of 83% and exhibits significant limitations in extracting crucial distinguishing features, leading to misclassification of Category 4 and 5 vehicles. In contrast, the AME architecture, which utilizes the two best-performing EfficientNetV2-S base models, successfully achieves a substantial performance improvement with 95% accuracy, 95.21% precision, 95% recall, and a 94.99% F1-score. In conclusion, the adaptive layer mechanism in AME is proven to be highly effective in compensating for the individual prediction weaknesses of its base models, resulting in a significantly more precise vehicle classification monitoring system.*

**Keywords:** vehicle classification, axle count, deep learning, CNN, adaptive minimal ensemble

## 1. PENDAHULUAN

Kendaraan bermotor merupakan salah satu aspek penting dalam kehidupan manusia [1]. Peningkatan jumlah kendaraan bermotor di Indonesia, yang melonjak dari 142 juta menjadi 157 juta pada rentang tahun 2021 hingga 2023 [2], berdampak langsung pada manajemen lalu lintas dan tingkat keausan infrastruktur jalan raya. Dalam perencanaan dan pemeliharaan infrastruktur jalan, daya rusak jalan ditentukan secara eksponensial oleh beban dan jumlah gandar kendaraan yang melintas [3]. Oleh karena itu, penerapan standar penggolongan kendaraan berat berbasis gandar (golongan I hingga V) pada sistem pengawasan jalan arteri menjadi sangat mendesak untuk memfasilitasi pemantauan metrik tersebut secara otomatis [4].

Pemantauan klasifikasi kendaraan secara manual di lapangan sangat tidak efisien dan rentan terhadap kesalahan. Sebagai solusinya, pemantauan modern memanfaatkan kamera *Closed-Circuit Television (CCTV)* bersudut pandang menyamping (*side-view*) yang terintegrasi dalam *Intelligent Transportation System (ITS)* [5] [6]. Sudut pandang menyamping ini sangat esensial karena penentuan golongan kendaraan berat bertumpu murni pada perhitungan jumlah as roda, yang fiturnya akan tertutup oleh bodi kendaraan jika diamati dari sudut atas atau depan [7]. Meskipun fiturnya terlihat jelas dari samping, otomatisasi sistem ini tetap menantang karena tergolong dalam *fine-grained visual classification*. Objek truk sering kali memiliki bentuk bodi yang sangat identik dan murni hanya dapat dibedakan dari letak serta jumlah as rodanya [8]. Kompleksitas identifikasi ini menjadikan klasifikasi berbasis citra samping sebagai tantangan yang tepat untuk menguji model *Deep Learning*, khususnya *Convolutional Neural Network* [9]. Hal ini dikarenakan CNN dapat secara otomatis belajar mengenali fitur-fitur yang unik pada citra [10].

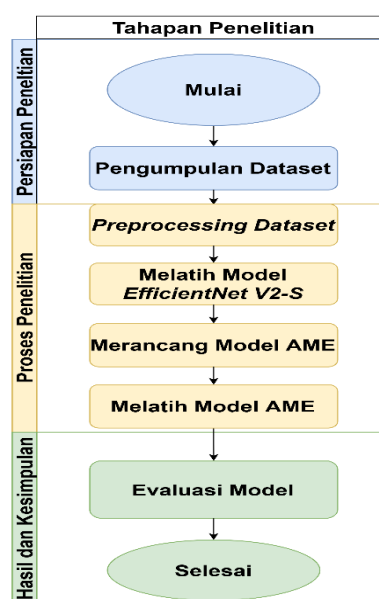
Penerapan CNN untuk klasifikasi golongan kendaraan telah dibuktikan keberhasilannya oleh berbagai penelitian sebelumnya. Sebagai contoh, Haqiqi et al. berhasil mencapai akurasi validasi 90% menggunakan arsitektur *VGG-16* dengan *transfer learning* [11]. Penelitian lain oleh Sasongko et al. yang menggunakan arsitektur *ResNet* dengan *fine-tuning* bahkan mampu mencapai akurasi 99% pada klasifikasi golongan kendaraan tertentu [12]. Hendra Maulana menggunakan *CNN* custom dan meraih akurasi 95% [13]. Namun, meskipun akurat, model-model tersebut umumnya memiliki jumlah parameter besar yang meningkatkan kebutuhan sumber daya komputasi, biaya, dan energi, sehingga menimbulkan tantangan dalam penerapan skala besar antara akurasi dan efisiensi sistem [14].

Untuk mengatasi dilema tersebut, strategi yang dapat digunakan adalah merancang arsitektur *CNN* tunggal yang lebih efisien seperti *EfficientNetV2* [15], atau menggunakan metode *Adaptive Minimal Ensemble (AME)* yang menggabungkan model berskala kecil secara adaptif untuk meningkatkan akurasi tanpa mengorbankan efisiensi komputasi [16].

Berdasarkan penjelasan di atas, penelitian ini bertujuan untuk mengimplementasikan *CNN Adaptive Minimal Ensemble* dalam klasifikasi kendaraan bermotor berdasarkan jumlah gandar. Model akan dilatih, divalidasi, dan dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Penelitian ini diharapkan memberikan kontribusi sebagai referensi atau bahan evaluasi untuk penelitian selanjutnya, khususnya penelitian yang berkaitan dengan klasifikasi kendaraan atau model *Adaptive Minimal Ensemble*.

## 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. Tahapan Penelitian

Pada Gambar 1. menggambarkan tahapan-tahapan penelitian. Berikut adalah penjelasan mengenai tahapan penelitian.

### 2.1. Pengumpulan Dataset

Tahap pengumpulan data dalam penelitian ini bertujuan untuk mengumpulkan dataset citra kendaraan yang telah diklasifikasikan berdasarkan standar golongan jumlah gandar (Golongan I - V). Dataset yang digunakan dalam penelitian ini terdiri atas dua jenis, yaitu dataset primer dan dataset sekunder. Dataset primer diperoleh dari potongan-potongan citra yang dihasilkan melalui rekaman video yang direkam oleh peneliti. Sementara itu, dataset sekunder merupakan dataset publik yang diperoleh dari *Mendeley Data*, yang juga berbentuk potongan citra dari video.

Tabel 1. Tabel Dataset

Golongan Kendaraan	Jumlah Gambar Dataset Primer	Jumlah Gambar Dataset Sekunder	Contoh Gambar
Golongan 1	20	397	
Golongan 2	20	200	
Golongan 3	20	199	
Golongan 4	20	200	
Golongan 5	20	199	

Pada Tabel 1 digambarkan dataset yang digunakan dalam penelitian ini. Baik dataset primer maupun dataset sekunder berisi citra kendaraan yang direkam dari sisi kanan maupun sisi kiri kendaraan, sehingga karakteristik jumlah roda maupun jumlah gandar dapat terlihat dengan jelas. Seluruh citra dalam kedua dataset disimpan dalam format gambar berwarna 24-bit RGB. Rincian lebih lanjut terkait dataset akan dijelaskan di subbab dataset.

### 2.2. Preprocessing Dataset

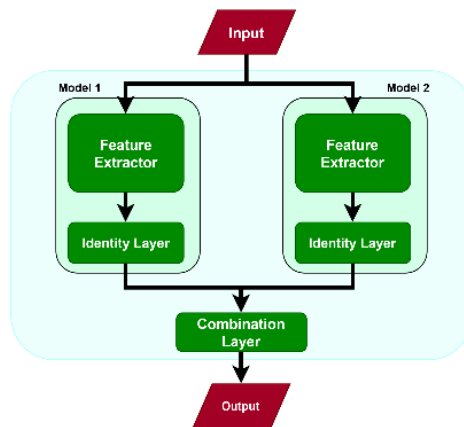
Augmentasi data merupakan teknik dalam pengolahan citra untuk meningkatkan variasi data pelatihan tanpa menambah dataset baru, sehingga dapat mencegah *overfitting*, meningkatkan akurasi, dan membantu generalisasi model. Pada penelitian ini, augmentasi yang diterapkan meliputi *resize* dan *random horizontal flip*. *Resize* dilakukan pada seluruh dataset untuk mengubah ukuran citra menjadi  $256 \times 256$  piksel dengan rasio aspek 1:1, sedangkan *random horizontal flip* diterapkan pada dataset latih dan validasi dengan membalik citra terhadap sumbu y guna menambah variasi pola. Augmentasi tidak diterapkan pada dataset uji agar data tetap merepresentasikan kondisi nyata.

### 2.3. Melatih Model EfficientNet V2-S

Dalam penelitian ini, peneliti menggunakan data sekunder untuk dataset latih dan validasi, Serta data primer untuk dataset testing. Peneliti membagi secara acak dataset sekunder keseluruhan menjadi 80% dataset latih dan 20% dataset validasi. Dengan adanya pembagian ini maka akan menghasilkan *subset* data latih dan validasi yang berbeda-beda pada tiap model. Seluruh pelatihan menggunakan *AdaBelief optimizer*. Pada tahap awal, dilakukan pelatihan secara *end-to-end* terhadap arsitektur *EfficientNetV2-S* sebanyak lima kali sehingga diperoleh lima model terlatih.

### 2.4. Merancang Model Adaptive Minimal Ensemble (AME)

Tahap selanjutnya adalah perancangan arsitektur model *Adaptive Minimal Ensemble* yang akan digunakan dalam penelitian ini. Pada penelitian ini, model lemah (*weak model*) yang digunakan berasal dari arsitektur *EfficientNetV2*. Dari keseluruhan model *EfficientNetV2-S* yang telah dilatih, dua model dengan akurasi pengujian terbaik kemudian dipilih untuk dijadikan *weak learners* pada kerangka *Adaptive Minimal Ensemble (AME)*.



Gambar 2. Arsitektur Adaptive Minimal Ensemble

Pada Gambar 2 digambarkan arsitektur AME yang digunakan dalam penelitian ini, model AME pada penelitian ini akan meneruskan terlebih dahulu data dari *feature extractor* dari model lemah ke *layer identity*. Hal ini dikarenakan kendala teknis dimana layer dari sebuah model yang telah dilatih tidak bisa dihilangkan begitu saja namun bisa diganti dengan layer lain. Pada kasus ini layer *identity* yang mengganti layer *classifier* tidak akan merubah data yang diterima dari *feature extractor*.

### 2.5. Melatih Model Adaptive Minimal Ensemble (AME)

Model Adaptive Minimal Ensemble dilatih secara *fine-tune* dengan hyperparameter dan pembagian dataset yang sama dengan pelatihan model *EfficientNet V2-S*. Model akan dilatih sebanyak lima kali dan akan dipilih model dengan akurasi testing tertinggi untuk proses evaluasi.

### 2.6. Evaluasi Model

Hasil prediksi pada 100 citra data uji akan dikonversi menjadi *Confusion Matrix*. Dari matriks tersebut, dihitung nilai *Accuracy*, *Precision*, *Recall*, dan *F1-Score*.

## 3. HASIL DAN PEMBAHASAN

Pada bagian ini akan dipaparkan hasil eksperimen meliputi pelatihan model *EfficientNet V2-S*, Adaptive Minimal Ensemble serta hasil evaluasi model.

### 3.1. Pelatihan Model EfficientNet V2-S

Pelatihan model *EfficientNet V2-S* dilakukan secara end-to-end, yaitu model dilatih dari awal menggunakan bobot dan bias yang diinisialisasi secara acak tanpa menerapkan teknik *freezing* atau pembekuan layer. Dengan demikian, seluruh layer pada model berpartisipasi dalam proses pembelajaran dan mengalami pembaruan bobot serta bias selama proses pelatihan.

Tabel 2. Tabel Hasil Pelatihan *EfficientNet V2-S*

Epoch	Model 0	Model 1	Model 2	Model 3	Model 4
1	0.3614	0.3427	0.3645	0.3729	0.3885
5	0.6135	0.5979	0.6343	0.6135	0.6093
10	0.7250	0.7020	0.6854	0.6614	0.7010
15	0.8020	0.7749	0.7562	0.6989	0.7854
20	0.8156	0.8177	0.8000	0.7677	0.8697
25	0.8666	0.8999	0.8437	0.7875	0.8687
30	0.8791	0.9125	0.8593	0.8104	0.9322

Berdasarkan data pada Tabel 4.12, kelima model menunjukkan tren peningkatan akurasi yang signifikan pada lima epoch pertama yakni sekitar 0,2. Memasuki epoch 10 hingga 25, pertumbuhan akurasi mulai ,empat dari lima model memiliki akurasi lebih dari 0.8 . Pada epoch 30, model mencapai titik *convergence* dengan capaian performa di atas 0.84 untuk seluruh model.

Tabel 3. Tabel Hasil Validasi *EfficientNet V2-S*

Epoch	Model 0	Model 1	Model 2	Model 3	Model 4
1	0.4649	0.369	0.3565	0.469	0.3592
5	0.6732	0.622	0.4476	0.6155	0.5774
10	0.5899	0.6976	0.7405	0.7071	0.6196
15	0.8042	0.8113	0.7494	0.753	0.8202

Epoch	Model 0	Model 1	Model 2	Model 3	Model 4
20	0.6524	0.8357	0.7952	0.7696	0.8786
25	0.8655	0.9107	0.8417	0.7685	0.8792
30	0.8821	0.9327	0.8494	0.8565	0.8577

Berdasarkan data hasil pengujian performa klasifikasi pada Tabel 4.13, Model 1 dan Model 4 menunjukkan performa lebih baik dibandingkan tiga model lainnya. Model 1 meraih performa terbaik dengan *accuracy* 0.83, *precision* 0.865, *recall* 0.7, dan *F1-Score* sebesar 0.8248. Disusul dengan model 4 dengan *accuracy* 0.79, *precision* 0.8335, *recall* 0.79, dan *F1-Score* sebesar 0.7853.

Tabel 4. Tabel Hasil Pengujian *EfficientNet V2-S*

Model	Accuracy	Precision	Recall	F1-Score
Model 0	0.7	0.7627	0.7	0.6906
Model 1	0.83	0.8657	0.83	0.8248
Model 2	0.62	0.5199	0.6200	0.5507
Model 3	0.67	0.7153	0.67	0.6492
Model 4	0.79	0.8335	0.79	0.7854

Berdasarkan data hasil pengujian performa klasifikasi pada Tabel 4.13, Model 1 dan Model 4 menunjukkan performa lebih baik dibandingkan tiga model lainnya. Model 1 meraih performa terbaik dengan *accuracy* 0.83, *precision* 0.865, *recall* 0.7, dan *F1-Score* sebesar 0.8248. Disusul dengan model 4 dengan *accuracy* 0.79, *precision* 0.8335, *recall* 0.79, dan *F1-Score* sebesar 0.7853. Dari data pengujian yang telah dijelaskan, Model 1 dan Model 4 dipilih sebagai *weak learner* pada Model *adaptive minimal ensemble*. Kedua model ini dipilih karena berhasil mencapai nilai akurasi tertinggi dibandingkan model *EfficientNet V2-S* lainnya.

### 3.2. Pelatihan Model Adaptive Minimal Ensemble

Tabel 5. Tabel Hasil Pelatihan *Adaptive Minimal Ensemble*

Epoch	Model 0	Model 1	Model 2	Model 3	Model 4
1	0.8677	0.8719	0.8604	0.8208	0.8469
5	0.9729	0.9646	0.9563	0.9656	0.9615
10	0.9708	0.9625	0.9594	0.9552	0.9615
15	0.975	0.9656	0.9604	0.9656	0.9677
20	0.9698	0.9656	0.9635	0.9646	0.9521
25	0.9656	0.9563	0.9646	0.9688	0.9604
30	0.9625	0.9625	0.9656	0.9635	0.9677

Secara keseluruhan, hasil pelatihan pada Tabel 4.27 membuktikan bahwa pendekatan *Adaptive Minimal Ensemble* mampu menghasilkan stabilitas dan akurasi pelatihan yang luar biasa. Dengan memanfaatkan pengetahuan dari model dasar yang telah konvergen, *AME* mampu memulai pelatihan dengan akurasi awal >82% dan dengan cepat mencapai saturasi performa di angka 96% hanya dalam 5 *epoch*. Hal ini mengindikasikan bahwa mekanisme pembobotan *adaptive* bekerja efektif dalam meminimalisir kesalahan yang mungkin masih dimiliki oleh masing-masing model tunggal.

Tabel 6. Tabel Hasil Validasi *Adaptive Minimal Ensemble*

Epoch	Model 0	Model 1	Model 2	Model 3	Model 4
1	0.9833	0.9917	0.9875	0.9875	0.9876
5	0.9875	1	0.9917	0.9875	0.9875
10	0.9875	0.9917	1	0.9917	0.9702
15	0.9958	0.9827	0.9958	0.9917	0.9958
20	0.9917	0.9958	0.9917	0.9917	0.9827
25	0.9875	0.9917	0.9792	0.9917	0.9958
30	0.9833	0.9792	0.9917	0.9958	0.9917


Hasil validasi pada Tabel 4.28 menegaskan superioritas arsitektur *Adaptive Minimal Ensemble*. Jika dibandingkan dengan model tunggal *EfficientNet V2-S* dengan akurasi sekitar 0,83 atau *V2-L* dengan akurasi sekitar 0,56 - 0,71, model *AME* mampu mendongkrak performa secara drastis hingga menyentuh titik kesempurnaan. Tercatat Model 1 dan Model 2 sempat menyentuh akurasi validasi 100% pada epoch 5 dan 10. Konsistensi nilai akurasi yang terjaga di atas 0,98 sepanjang 30 epoch membuktikan bahwa mekanisme ensemble berhasil menutupi kelemahan prediksi individu dari model *weak learner*-nya, menghasilkan sistem klasifikasi yang sangat presisi.

Tabel 7. Tabel Hasil Pengujian *Adaptive Minimal Ensemble*

Model	Accuracy	Precision	Recall	F1-Score
Model 0	0.93	0.9287	0.93	0.9287
Model 1	0.9	0.9154	0.9	0.8971
Model 2	0.93	0.9302	0.93	0.9294
Model 3	0.95	0.9521	0.95	0.9499
Model 4	0.91	0.9127	0.91	0.9078

Berdasarkan tabel hasil pengujian performa klasifikasi pada Tabel 4.29, implementasi metode *Adaptive Minimal Ensemble* menunjukkan kinerja yang sangat superior dan konsisten di seluruh model uji. Model 3 tercatat sebagai model dengan performa terbaik, mencapai Akurasi 0,95 dan *F1-Score* 0,9499, yang mengindikasikan keseimbangan sempurna antara *precision* dan *recall*. Bahkan model dengan performa terendah dalam eksperimen ini, yaitu Model 1, masih mampu mencatatkan akurasi sebesar 0,9. Tingginya nilai metrik evaluasi ini membuktikan bahwa strategi penggabungan dua model *weak learner* melalui lapisan adaptif berhasil meminimalisir kesalahan prediksi model tunggal, menghasilkan sistem yang jauh lebih *robust*.

### 3.3. Evaluasi Model



Gambar 3. Confusion Matrix Model *Adaptive Minimal Ensemble*

Gambar 3 menyajikan confusion matrix dari model *EfficientNet V2-S* dan *Adaptive Minimal Ensemble (AME)*, di mana intensitas warna pada diagonal utama merepresentasikan tingkat akurasi prediksi model. Meskipun model *EfficientNet V2-S* mengindikasikan performa yang optimal pada klasifikasi kendaraan Golongan 1 dan 2, model ini menunjukkan kelemahan signifikan dalam mengekstraksi fitur pembeda krusial, seperti jumlah as roda yang mengakibatkan terjadinya misklasifikasi pada kendaraan Golongan 4 dan 5 yang diprediksi sebagai Golongan 1. Model AME menunjukkan akurasi klasifikasi yang lebih bagus dibandingkan model sebelumnya. Model ini terbukti mampu mengklasifikasikan kendaraan Golongan 4 dan 5 ke dalam kategori kendaraan berat secara konsisten dan tepat sasaran.

Tabel 8. Tabel Hasil Evaluasi Model

Arsitektur	Accuracy	Precision	Recall	F1-Score
<i>EfficientNet V2-S</i>	0.83	0.8657	0.83	0.8248
<i>Adaptive Minimal Ensemble (AME)</i>	0.95	0.9521	0.95	0.9499

Berdasarkan Tabel 7, Model *Adaptive Minimal Ensemble* menunjukkan dominasi mutlak dengan mencapai akurasi 0.95, *precision* 0.9521, *recall* 0.95, dan *F1-Score* 0.9499. Hasil ini membuktikan hipotesis bahwa penggabungan dua *weak learners* yakni *EfficientNet V2-S* melalui lapisan adaptif mampu menutupi kelemahan prediksi individu dan menghasilkan keputusan klasifikasi yang jauh lebih presisi dibandingkan model tunggal *EfficientNet V2-S* yang hanya mampu mencapai akurasi tertinggi 0.83, *precision* 0.8657, *recall* 0.83, dan *F1-Score* 0.8248.

## 4. KESIMPULAN

Berdasarkan hasil eksperimen dan pengujian klasifikasi kendaraan bermotor berdasarkan jumlah gandar, penerapan metode *Adaptive Minimal Ensemble (AME)* terbukti sangat efektif dalam menyelesaikan tantangan *fine-grained visual classification* pada citra kendaraan dari sudut pandang menyamping (*side-view*). Penggabungan dua model dasar *EfficientNetV2-S* melalui lapisan adaptif berhasil menutupi kelemahan prediksi individu dari model tunggal. Secara spesifik, model AME terbukti mampu mengklasifikasikan kendaraan berat pada Golongan 4 dan 5 secara konsisten dan tepat sasaran, yang mana fitur krusial ini sebelumnya sering gagal diekstraksi dan rentan diprediksi sebagai Golongan 1 oleh model dasar *EfficientNetV2-S*. Dari segi evaluasi kinerja kuantitatif, model AME menunjukkan dominasi mutlak dengan mencapai tingkat akurasi 95%, *precision* 95,21%, *recall* 95%, dan *F1-Score* 94,99%. Capaian ini menegaskan adanya lonjakan performa yang signifikan dibandingkan kinerja model tunggal *EfficientNetV2-S* yang hanya mampu mencapai batas akurasi tertinggi di angka 83%. Secara keseluruhan, strategi penggabungan melalui mekanisme pembobotan adaptif ini menghasilkan keputusan klasifikasi yang jauh lebih presisi.

**DAFTAR PUSTAKA**

- [1] Faris Humami, "Analisis Emisi Gas Buang Kendaraan Komersial Berdasarkan Karakteristik Kendaraan Bermotor," Jan. 2024.
- [2] B. P. S. Indonesia, "Jumlah Kendaraan Bermotor Menurut Provinsi dan Jenis Kendaraan (unit), 2023 - Tabel Statistik," 2023, *Badan Pusat Statistik Indonesia*. [Online]. Available: <https://www.bps.go.id/id/statistics-table/3/Vj3NGRGa3dkRk5MTIU1bVNFOTVVbmQyVURSTVFUMDkjMw==/jumlah-kendaraan-bermotor-menurut-provinsi-dan-jenis-kendaraan-unit-2023.html>
- [3] Kementerian Pekerjaan Umum, "Keputusan Menteri Pekerjaan Umum Nomor 370/KPTS/M/2007 tentang Penetapan Gol Jenis Kendaraan Bermotor pada Ruas Jalan Tol yang sudah Beroperasi dan Besarnya Tarif Tol pada Beberapa Ruas Jalan Tol," Oct. 2021.
- [4] Vinsensius Budiman Pantas, Niakku Imanuel Maggang, and Anie Adrianti Tuati, "Analisis Pengaruh Kendaraan Over Dimension Overload (ODOL) Terhadap Perkerasan Pada Ruas Jalan Timor Raya," *Jurnal Teknologi dan Manajemen Industri Terapan*, vol. 4, no. 1, pp. 181–189, Mar. 2025, doi: 10.55826/jtmit.v4i1.1028.
- [5] A. S. Alghamdi, T. Imran, K. T. Mursi, A. Ejaz, M. Kamran, and A. Alamri, "A Vehicle Classification System for Intelligent Transport System using Machine Learning in Constrained Environment," *International Journal of Advanced Computer Science and Applications*, vol. 14, no. 7, 2023, doi: 10.14569/IJACSA.2023.0140746.
- [6] Ade Irma, Nasron, and Martinus Mujur Rose, "Implementasi Aplikasi Berbasis Teknologi IoT pada Perangkat Tracking dan Kendali Kendaraan Bermotor," *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 1, no. 2, pp. 57–64, Oct. 2020, doi: 10.37859/coscitech.v1i2.2191.
- [7] J. Barreyro, L. R. Yoshioka, C. L. Marte, C. G. Piccirillo, M. M. D. Santos, and J. F. Justo, "Assessment of Vehicle Category Classification Method Based on Optical Curtains and Convolutional Neural Networks," *IEEE Access*, vol. 12, pp. 133532–133544, 2024, doi: 10.1109/ACCESS.2024.3410160.
- [8] L. A. Marcomini and A. L. Cunha, "Truck Axle Detection with Convolutional Neural Networks," Mar. 2023, [Online]. Available: <http://arxiv.org/abs/2204.01868>
- [9] M. E. Prasetyo, M. R. Faza, R. Pratama, S. N. H. Alhabsy, H. Purwanti, and A. P. A. Masa, "Klasifikasi Ragam Kendaraan Menggunakan Metode Convolutional Neural Network (Cnn)," *Adopsi Teknologi dan Sistem Informasi (ATASI)*, vol. 2, no. 2, pp. 142–148, Dec. 2023, doi: 10.30872/atai.v2i2.1156.
- [10] R. A. Syahputra, W. Firmantara, S. F. Rosyad, and F. Muttaqin, "Klasifikasi Citra Diabetic Foot Ulcer Menggunakan ResNet50 dengan Evaluasi Confusion Matrix pada Dataset Validasi," vol. 4, no. 1, doi: 10.31284/p.semtik.2025-1.8481.
- [11] K. U. Haqiqi, F. M. Hana, and H. Aulida, "KLASIFIKASI JENIS GOLONGAN KENDARAAN DI GERBANG TOL MENGGUNAKAN ARSITEKTUR CNN VGG16," 2024.
- [12] A. T. Sasongko and M. Ivan Fanany, "Indonesia Toll Road Vehicle Classification Using Transfer Learning with Pre-trained Resnet Models," in *2019 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, IEEE, Dec. 2019, pp. 373–378. doi: 10.1109/ISRITI48646.2019.9034590.
- [13] A. R. Priambodo, A. A. Hakim, Christian, F. T. Vierino, and H. Maulana, "Klasifikasi Golongan Kendaraan Tol menggunakan CNN Tensorflow," *Jurnal Ilmiah Teknologi Informasi dan Robotika*, doi: 10.33005/jifri.v7i1.151.
- [14] E. Strubell, A. Ganesh, and A. McCallum, "Energy and Policy Considerations for Deep Learning in NLP," Jun. 2019.
- [15] M. Tan and Q. V. Le, "EfficientNetV2: Smaller Models and Faster Training," 2021. [Online]. Available: <https://github.com/google/>
- [16] A. Bruno *et al.*, "Improving plant disease classification by adaptive minimal ensembling," *Front. Artif. Intell.*, vol. 5, Sep. 2022, doi: 10.3389/frai.2022.868926.