Journal of Computer Science and Technology
JCS-TECH Vol.6, No.2, November 2026, PP. 60-67
e-ISSN 2808-9677, p-ISSN 2809-1140

ANALISIS PERBANDINGAN MODEL *MOBILENETV2* DAN *RESNET50* PADA KLASIFIKASI CITRA KENDARAAN RINGAN

Syahira Nasywa Andina Humaedi[1], Adinda Rahmawati[2], Elsha Nurdwi Baharsyah[3], Hanif Zaidan Sinaga[4*]
[1,2,3,4]Program Studi Bisnis Digital,Fakultas Ekonomi dan Bisnis, Universitas Ibn Khaldun Bogor,
[1]hirasya244@gmail.com, [2]adindarahmawati0066@gmail.com, [3]elshanurdwibaharsyah@gmail.com,
[4*]hanif.zaidan@gmail.com

Abstrak

Perkembangan teknologi transportasi mendorong kebutuhan akan sistem identifikasi kendaraan yang mampu bekerja secara otomatis, cepat, dan akurat, khususnya untuk mendukung implementasi sistem parkir otomatis dan sistem transportasi cerdas. Penelitian ini bertujuan membandingkan performa arsitektur *Convolutional Neural Network (CNN)* berbasis *Transfer Learning*, yaitu *MobileNetV2* dan *ResNet50*, dalam mengklasifikasikan citra kendaraan mobil dan motor. Dataset yang digunakan berasal dari Kaggle dengan total 1.590 citra yang terdiri atas 790 citra mobil dan 800 citra motor. Dataset dibagi menjadi data latih (80%), data validasi (10%), dan data uji (10%). Tahap *preprocessing* meliputi *resizing* citra menjadi 224 × 224 piksel, normalisasi, dan augmentasi data. Kedua model dilatih selama 20 *epoch* menggunakan *optimizer Adam* dengan pendekatan *Transfer Learning*. Evaluasi model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Hasil pengujian menunjukkan bahwa model *MobileNetV2* memperoleh *accuracy* sebesar 98,74%, *precision* sebesar 0,99, *recall* sebesar 0,99, dan *F1-score* sebesar 0,99. Sementara itu, model *ResNet50* memperoleh *accuracy* sebesar 79,87%, *precision* sebesar 0,80, *recall* sebesar 0,80, dan *F1-score* sebesar 0,80. Hasil tersebut menunjukkan bahwa *MobileNetV2* memiliki performa yang lebih unggul dibandingkan *ResNet50* dalam mengklasifikasikan citra kendaraan. Dengan demikian, *MobileNetV2* terbukti memberikan performa yang lebih baik dan berpotensi diterapkan sebagai model klasifikasi kendaraan pada sistem parkir otomatis maupun berbagai aplikasi transportasi cerdas berbasis kecerdasan buatan.

Kata kunci: CNN, MobileNetV2, ResNet50, Klasifikasi Citra, Kendaraan.

Abstract

Abstract: *Advances in transportation technology have driven the need for vehicle identification systems capable of operating automatically, quickly, and accurately, particularly to support the implementation of automated parking systems and smart transportation systems. This study aims to compare the performance of Transfer Learning-based Convolutional Neural Network (CNN) architectures namely MobileNetV2 and ResNet50 in classifying images of cars and motorcycles. The dataset used was sourced from Kaggle and consists of a total of 1,590 images, comprising 790 car images and 800 motorcycle images. The dataset was divided into training data (80%), validation data (10%), and test data (10%). The preprocessing stage included resizing the images to 224 × 224 pixels, normalization, and data augmentation. Both models were trained for 20 epochs using the Adam optimizer with a Transfer Learning approach. Model evaluation was performed using the metrics accuracy, precision, recall, F1-score, and confusion matrix. The test results showed that the MobileNetV2 model achieved an accuracy of 98.74%, a precision of 0.99, a recall of 0.99, and an F1-score of 0.99. Meanwhile, the ResNet50 model achieved an accuracy of 79.87%, a precision of 0.80, a recall of 0.80, and an F1-score of 0.80. These results indicate that MobileNetV2 outperforms ResNet50 in classifying vehicle images. Thus, MobileNetV2 has been shown to deliver better performance and has the potential to be applied as a vehicle classification model in automated parking systems and various AI-based smart transportation applications.*

Keywords: CNN, MobileNetV2, ResNet50, Image Classification, Vehicle

1. Pendahuluan

Peningkatan jumlah kendaraan bermotor mendorong kebutuhan sistem identifikasi kendaraan otomatis dalam mendukung pengawasan lalu lintas, parkir otomatis, dan transportasi cerdas. (Prasetyo et al., 2023). Pengenalan jenis kendaraan menjadi semakin penting terutama ketika jumlah kendaraan yang diamati sangat banyak dan berlangsung secara *real-time*. Oleh karena itu, diperlukan suatu sistem yang mampu melakukan identifikasi dan klasifikasi kendaraan secara digital. Salah satu teknologi yang berkembang pesat untuk menyelesaikan permasalahan tersebut adalah *Computer Vision* yang dipadukan dengan metode *Deep Learning*. Teknologi ini memungkinkan komputer untuk mengenali objek pada gambar dan mengelompokkannya ke dalam kategori tertentu berdasarkan karakteristik visual yang dimiliki (Wibowo et al., 2024).

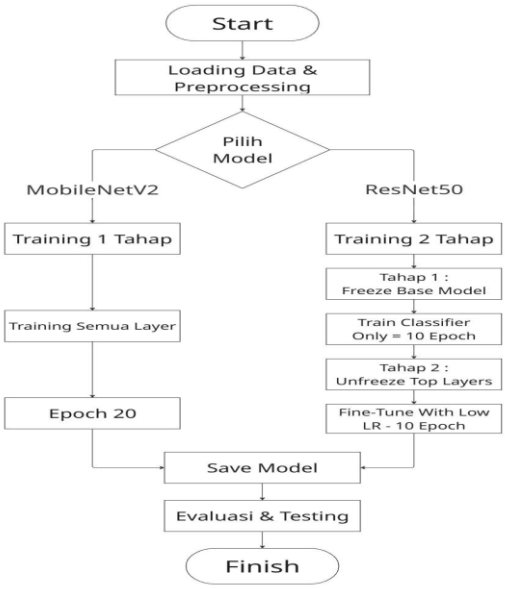
Salah satu metode *Deep Learning* yang banyak digunakan dalam pengolahan citra adalah *Convolutional Neural Network* (*CNN*). *Convolutional Neural Network (CNN)* merupakan arsitektur jaringan saraf tiruan yang memiliki lapisan tersembunyi dan menggunakan bobot (*weight*) dalam proses pembelajarannya yang dirancang khusus untuk mengolah dan memberikan keluaran berdasarkan karakteristik fitur-fitur penting secara otomatis, seperti bentuk, warna, tekstur, dan pola objek (Radikto et al., 2022). Keunggulan *Convolutional Neural Network (CNN)* terletak pada kemampuannya dalam mengekstraksi fitur secara otomatis tanpa memerlukan proses ekstraksi fitur manual sehingga banyak digunakan dalam berbagai aplikasi *Computer Vision* seperti klasifikasi citra, deteksi objek, dan pengenalan wajah (Nur Ridho et al., 2024).

Berbagai penelitian terdahulu menunjukkan bahwa *Convolutional Neural Network (CNN)* memiliki performa yang baik dalam klasifikasi kendaraan. Penelitian sebelumnya melaporkan bahwa model *Convolutional Neural Network (CNN)*, *VGG16* , dan *ResNet50* mampu mencapai akurasi yang cukup tinggi pada klasifikasi kendaraan (Anggay Luri Pramana, 2024). Selain itu, *Convolutional Neural Network (CNN)* juga terbukti efektif dalam mengklasifikasikan mobil dan motor dengan hasil yang sangat baik (Armando & Sutresna Wati, 2024), serta mampu mengenali kendaraan roda dua dan roda empat secara akurat (Gupta et al., 2022). Hasil tersebut menunjukkan bahwa *Convolutional Neural Network (CNN)* memiliki potensi besar untuk diterapkan pada sistem klasifikasi kendaraan sebagai bagian dari transportasi cerdas.

Seiring perkembangan *Deep Learning*, berbagai arsitektur *CNN* terus dikembangkan untuk meningkatkan performa klasifikasi citra. Salah satu arsitektur yang banyak digunakan adalah *MobileNetV2*, yaitu model ringan yang dirancang untuk menghasilkan performa tinggi dengan kebutuhan komputasi yang efisien. Penelitian sebelumnya menunjukkan bahwa *MobileNetV2* mampu mencapai akurasi sebesar 96% pada klasifikasi citra furnitur (Epiphany Shavna Gracia & Nurul Anisa Sri Winarsih, 2025). Selain itu, *ResNet50* juga banyak digunakan karena memiliki kemampuan ekstraksi fitur yang lebih kompleks melalui konsep *residual learning*. Beberapa penelitian menunjukkan bahwa *ResNet50* memperoleh akurasi validasi sebesar 85% pada klasifikasi kepadatan lalu lintas (Fauzi & Haqdu D, 2025), serta akurasi hingga 95,00% pada klasifikasi tanaman herbal dan 89,3% pada klasifikasi *undertone* kulit wajah (Herlawati et al., 2026).

Meskipun *MobileNetV2* dan *ResNet50* telah terbukti memiliki performa yang baik dalam klasifikasi citra, penelitian yang secara khusus membandingkan kedua arsitektur tersebut pada klasifikasi kendaraan roda dua dan roda empat untuk sistem parkir otomatis masih terbatas. *MobileNetV2* unggul dalam efisiensi komputasi, sedangkan *ResNet50* memiliki kemampuan ekstraksi fitur yang lebih kompleks. Perbedaan ini perlu dikaji untuk menentukan model yang paling optimal dalam klasifikasi kendaraan. Berdasarkan hal tersebut, penelitian ini membandingkan kinerja *MobileNetV2* dan *ResNet50* pada klasifikasi citra mobil dan motor untuk mengetahui model terbaik dari sisi akurasi dan efisiensi sebagai dasar pengembangan sistem parkir otomatis yang lebih cepat, akurat, dan efektif.

2. Metode Penelitian



Gambar 1. Metode Pembelajaran yang Diusulkan

Gambar 1 menunjukkan metode penelitian yang diawali dengan pengumpulan data gambar kendaraan, yaitu mobil dan motor. Selanjutnya dilakukan preprocessing untuk mempersiapkan data sebelum proses pelatihan. Model kemudian dirancang menggunakan metode Transfer Learning dengan dua arsitektur, yaitu *MobileNetV2* dan *ResNet50*, untuk membandingkan performa model ringan dan model yang lebih dalam. Pelatihan dilakukan menggunakan *optimizer Adam*, sedangkan evaluasi model menggunakan metrik *accuracy*, *precision*, *recall*, dan F1-score.

2.1. Pengumpulan Data

Penelitian ini menggunakan data dari https://www.kaggle.com/datasets/mohamedmaher5/vehicle-classification, data yang diambil sebanyak 1590 citra, dengan 2 jenis kendaraan (mobil dan motor) dengan masing-masing jenis sebanyak 790 citra mobil dan 800 citra motor.

2.2. Preprocessing

Tahap preprocessing dilakukan untuk menyiapkan data sebelum pelatihan model. Proses ini meliputi resizing citra menjadi 224×224 piksel, normalisasi, serta augmentasi data seperti rotasi dan pembalikan gambar untuk meningkatkan variasi data latih dan mencegah overfitting (Husnurrizqi et al., 2026). Dataset kemudian dibagi menjadi data latih (80%), validasi (10%), dan pengujian (10%).

2.3. Data Training

Proses pelatihan model dilakukan menggunakan *optimizer Adam* dengan fungsi kerugian *(loss function) Sparse Categorical Crossentropy.* Untuk memastikan konsistensi dan kemampuan generalisasi model, konfigurasi hyperparameter diatur sebagai berikut: ukuran batch (*batch size*) ditetapkan sebesar 32, dan model dilatih selama 20 epoch. Data augmentasi seperti pembalikan horizontal (*random flip*), rotasi acak (*random rotation* 0.1), dan zoom acak (*random zoom* 0.1) diterapkan secara *on-the-fly* selama proses pelatihan untuk meningkatkan variasi data latih. Detail lengkap parameter pelatihan disajikan pada Tabel 1.

Tabel 1. Parameter Training

Parameter	*MobileNetV2*	*ResNet50*
Optimizer	Adam	Adam
Initial *Learning Rate*	*Default Adam* (0.001)	Tahap 1: Default (0.001) Tahap 2 (Fine-tuning): 1e-5
Batch Size	32	32
Epochs	20	*20 (10 Feature Extraction + 10 Fine-tuning)*
Loss Function	Sparse_categorical_crossentropy	Sparse_categorical_crossentropy
Activation Output	Softmax	Softmax
Dense Layer Akhir	*Dense(2, activation='softmax')*	*Dense(2, activation='softmax')*
Dropout Rate	0.2	0.3
Data Augmentation	*RandomFlip, RandomRotation(0.1), RandomZoom(0.1)*	*RandomFlip, RandomRotation(0.1), RandomZoom(0.1)*
Freeze/ Unfreeze Strategy	*MobileNetV2* dioptimalkan menggunakan algoritma *Adam* selama 20 *epoch* dengan *batch size* 32. Model ini dilengkapi lapisan *dropout* 0,2 dan fungsi aktivasi *Softmax* untuk membedakan dua jenis kendaraan.	Tahap 1: Base model dibekukan (trainable=False). Tahap 2: 20 layer teratas dibuka (layer.trainable=True) untuk (layers[:-20]).

2.4. Data Validation

Data validasi digunakan selama proses pelatihan untuk mengevaluasi performa model pada setiap epoch. Sebanyak 10% dari total dataset digunakan sebagai data validasi. Hasil evaluasi data validasi digunakan untuk memantau kemampuan generalisasi model dan mendeteksi kemungkinan terjadinya overfitting selama proses pelatihan.

2.5. Perancangan Model

Perancangan model bertujuan untuk mempelajari pola fitur pada citra kendaraan sehingga mampu melakukan klasifikasi dengan akurat. Dalam penelitian ini, digunakan dua arsitektur Transfer Learning, yaitu *MobileNetV2*

dan *ResNet50*, dengan penyesuaian lapisan akhir (head model) yang terdiri dari Global Average Pooling, lapisan Dropout, dan lapisan Dense dengan aktivasi Softmax.

a. *MobileNetV2*

Proses pelatihan model *MobileNetV2* dilaksanakan selama 20 epoch menggunakan *optimizer Adam*. Konfigurasi arsitektur meliputi penggunaan dropout sebesar 0,2 untuk regularisasi dan lapisan aktivasi Softmax pada output akhir untuk mengklasifikasikan dua kategori kendaraan.

b. *ResNet50*

ResNet50 digunakan sebagai pembanding dengan arsitektur yang lebih dalam. Model ini menerapkan strategi pelatihan dua tahap (two-stage training) untuk memaksimalkan ekstraksi fitur:

- Tahap 1 (*Feature Extraction*): Selama 10 epoch pertama, seluruh lapisan dasar *ResNet50* dibekukan (frozen), sehingga hanya lapisan klasifikasi baru yang diperbarui.
- Tahap 2 (*Fine-tuning*): Pada 10 epoch berikutnya, 20 lapisan teratas dari model dasar dibuka (unfrozen) agar model dapat mempelajari fitur yang lebih spesifik. Pada tahap ini, learning rate diturunkan menjadi 1e-5 agar pembaruan bobot terjadi secara halus dan stabil. Lapisan Dropout diatur sebesar 0.3 mengingat kompleksitas model yang lebih tinggi.

2.6. Data Testing

Data testing atau data pengujian adalah data yang digunakan untuk menguji kinerja model yang telah dilatih. Sebanyak 10% dari total dataset digunakan untuk mengevaluasi sejauh mana model dapat memprediksi atau mengambil keputusan yang akurat terhadap data yang belum pernah dilihat sebelumnya (*unseen* data).

2.7. Pengujian Model

Pada tahap pengujian, kedua model dievaluasi menggunakan data uji untuk mengukur kemampuan klasifikasi citra kendaraan. Evaluasi dilakukan dengan metrik *accuracy*, *precision*, *recall*, dan confusion matrix guna mengetahui performa model secara keseluruhan serta tingkat ketepatan klasifikasi pada setiap kelas kendaraan (Husnurrizqi et al., 2026). Hasil evaluasi kemudian dibandingkan untuk menentukan model yang paling optimal.

3. Hasil Penelitian dan Pembahasan

3.1. Hasil *Preprocessing*

Setelah proses pengumpulan data selesai dilakukan, tahap berikutnya adalah *preprocessing* data citra kendaraan. Dataset yang digunakan berasal dari Kaggle dengan jumlah total 1.590 citra yang terdiri dari 790 gambar mobil dan 800 gambar motor. Tahap *preprocessing* bertujuan untuk mempersiapkan data agar dapat digunakan secara optimal dalam proses pelatihan model *Convolutional Neural Network (CNN)* berbasis *Transfer Learning ResNet50* dan *MobileNetV2.*

Data kemudian dibagi menjadi tiga kelompok menggunakan metode *stratified split*, yaitu data latih (*training*) sebanyak 1.272 gambar, data validasi (*validation*) sebanyak 159 gambar, dan data uji (*test*) sebanyak 159 gambar. Rincian pembagian data dapat dilihat pada Tabel 2 berikut:

Tabel 2. Pembagian Data Penelitian

Jenis Kendaraan	Jumlah Data Latih	Jumlah Data Validasi	Jumlah Data Uji
Mobil	632	79	79
Motor	640	80	80
Total	1.272	159	159

Pada tahap ini juga dilakukan normalisasi citra dengan membagi nilai piksel oleh 255 agar berada pada rentang [0,1], serta *resizing* ke ukuran 224×224 piksel sesuai standar input *ResNet50* dan *MobileNetV2* melalui pipeline *tf.data*. Seluruh data berhasil diproses tanpa ditemukan file yang rusak atau korup, sehingga keseluruhan dataset dapat dimanfaatkan secara penuh pada tahap pelatihan maupun pengujian model.

3.2. Hasil Pelatihan Model

Proses pelatihan model dilakukan menggunakan dua arsitektur berbeda dengan strategi yang disesuaikan untuk memaksimalkan kemampuan *Transfer Learning*.

a. Pelatihan Model *ResNet50* (Two-Stage *Training*)

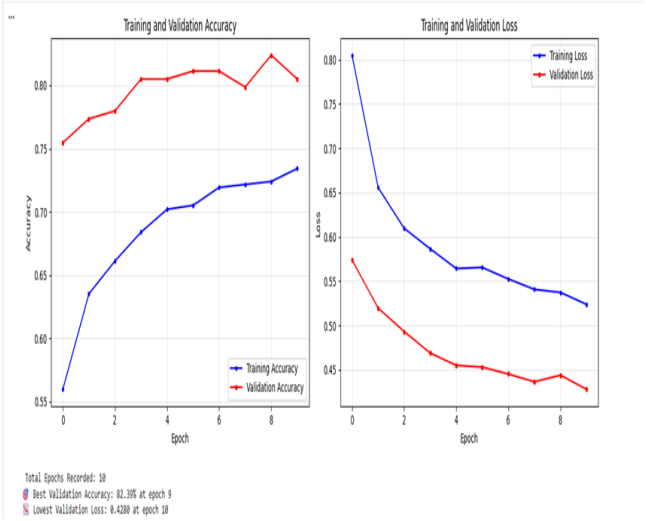
Pelatihan model *ResNet50* dilakukan dengan strategi *two-stage training* selama 20 *epoch* menggunakan *optimizer Adam* untuk menjaga bobot *pretrained* sekaligus menyesuaikan model dengan dataset kendaraan.

Tahap 1: *Feature Extraction* (*Epoch* 1-10)

Pada 10 *epoch* pertama, lapisan dasar (base layers) *ResNet50* dibekukan (*frozen*), sehingga hanya lapisan klasifikasi atas yang dilatih untuk menyesuaikan fitur umum. Berdasarkan log pelatihan (Gambar 2), akurasi meningkat stabil dari 55,97% pada *epoch* 1 hingga 79,87% pada *epoch* 10, dengan val_loss turun konsisten hingga 0,4280, yang menunjukkan proses ekstraksi fitur berjalan efektif.

Tahap 2: *Fine Tuning* (*Epoch* 11-20)

Pada 10 *epoch* berikutnya, sebagian lapisan atas model dibuka (*unfrozen*) dan dilatih ulang dengan learning rate lebih kecil untuk memperhalus representasi fitur agar lebih spesifik membedakan mobil dan motor. Hasilnya, akurasi validasi terbaik (Best *Validation Accuracy*) mencapai 82,39% pada *epoch* ke-19 sebelum sedikit berfluktuasi di *epoch* terakhir.



Gambar 2. *Grafik Loss* dan Akurasi Pelatihan Model *ResNet50* (*20 Epoch*)

b. Pelatihan Model *MobileNetV2*

Sebagai pembanding, *MobileNetV2* dilatih langsung selama 20 *epoch* tanpa pembekuan lapisan yang ketat karena arsitekturnya yang lebih ringan dan efisien. Hasilnya menunjukkan performa yang sangat tinggi, dengan *training accuracy* berada pada rentang 0,990–0,998 dan *validation accuracy* stabil hingga 98,74% pada akhir pelatihan (Gambar 3). Hal ini didukung oleh nilai loss yang rendah, yaitu *training* loss mendekati 0,015 dan *validation* loss sekitar 0,024. Selisih kecil antara *training* dan *validation accuracy* (kurang dari 1%) menunjukkan kemampuan generalisasi yang sangat baik tanpa indikasi overfitting.



Gambar 3. *Grafik Loss* dan Akurasi Pelatihan Model *MobileNetV2*

3.3. Hasil Pengujian Model

Setelah proses pelatihan selesai, dilakukan pengujian model menggunakan citra kendaraan yang tidak digunakan selama proses pelatihan. Pengujian bertujuan untuk mengetahui kemampuan model dalam mengklasifikasikan jenis kendaraan berdasarkan citra yang diberikan.

a. Hasil Evaluasi Model

Tabel 3. Hasil Evaluasi Model

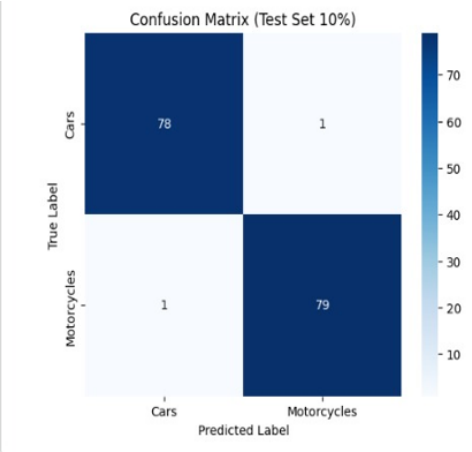
Model	***Test Accuracy***	***Test Loss***	***Precision (Avg)***	***Recall (Avg)***	***F1-score (Avg)***
MobileNetV2	98,74%	0,0384	0,99	0,99	0,99
ResNet50	79,87%	0,4489	0,80	0,80	0,80

Berdasarkan Tabel 3, *MobileNetV2* menunjukkan performa yang lebih baik dibandingkan *ResNet50*. *MobileNetV2* mencapai test *accuracy* 98,74% dengan test loss 0,0384, sedangkan *ResNet50* hanya 79,87% dengan test loss 0,4489. Selain itu, rata-rata *precision*, *recall*, dan *F1-score* *MobileNetV2* sebesar 0,99, menunjukkan tingkat ketepatan dan konsistensi yang sangat tinggi dalam mengenali objek kendaraan.

Sebaliknya, *ResNet50* hanya memperoleh rata-rata *precision*, *recall*, dan *F1-score* sebesar 0,80, yang masih cukup baik namun di bawah *MobileNetV2*. Perbedaan ini menunjukkan bahwa *MobileNetV2* memberikan performa klasifikasi yang lebih baik dibandingkan *ResNet50* pada dataset kendaraan ringan yang digunakan dalam penelitian ini. Berdasarkan karakteristik arsitekturnya yang lebih ringan,

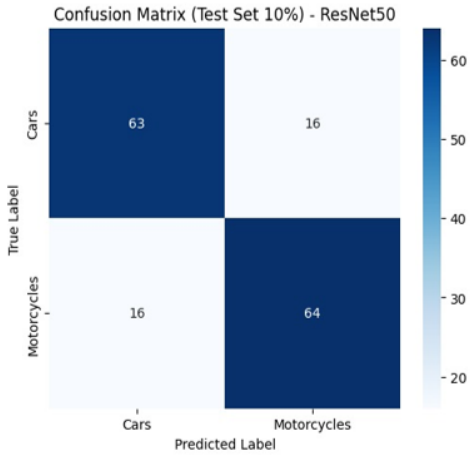
MobileNetV2 juga berpotensi lebih sesuai untuk implementasi sistem berbasis perangkat dengan keterbatasan komputasi.

b. Confusion Matrix



Gambar 4. *Confusion matrix MobileNetV2*

Gambar 4 menunjukkan confusion matrix hasil pengujian *MobileNetV2* dengan data uji 10% dari total dataset. Model berhasil mengklasifikasikan 78 citra mobil dan 79 citra motor dengan benar, serta hanya melakukan dua kesalahan klasifikasi. Hasil ini menunjukkan bahwa *MobileNetV2* memiliki kemampuan klasifikasi yang sangat baik dengan tingkat kesalahan yang rendah.



Gambar 5. *Confusion matrix ResNet50*

Gambar 5 menunjukkan *confusion matrix* hasil pengujian *ResNet50*. Model berhasil mengklasifikasikan 63 citra mobil dan 64 citra motor dengan benar, namun masih terdapat 32 kesalahan klasifikasi. Hasil ini menunjukkan bahwa performa *ResNet50* lebih rendah dibandingkan *MobileNetV2* pada dataset yang digunakan.

Berdasarkan hasil confusion matrix, *MobileNetV2* lebih unggul dibandingkan *ResNet50* karena hanya menghasilkan dua kesalahan klasifikasi, sedangkan *ResNet50* menghasilkan 32 kesalahan. Ini menunjukkan bahwa *MobileNetV2* lebih efektif dalam mengenali karakteristik visual kendaraan dan memiliki kemampuan generalisasi yang lebih baik.

c. Classification Report

Tabel 4. *Classification Report MobileNetV2*

Jenis Kendaraan	***Precision***	***Recall***	***F1-Score***	***Support***
Mobil	0,99	0,99	0,99	79
Motor	0,99	0,99	0,99	80

Berdasarkan Tabel 4, model *MobileNetV2* menunjukkan performa yang sangat baik pada kedua kelas kendaraan, yaitu mobil dan motor. *Nilai precision, recall,* dan *F1-score* masing-masing mencapai 0,99 untuk kedua kelas. Hal ini menunjukkan bahwa model mampu mengidentifikasi kendaraan dengan tingkat akurasi yang sangat tinggi serta memiliki keseimbangan performa yang baik antar kelas. Nilai support sebanyak 79 data mobil dan 80 data motor menunjukkan bahwa evaluasi dilakukan secara seimbang sehingga hasil pengujian dapat dikatakan valid.

Tabel 5. *Classification Report ResNet50*

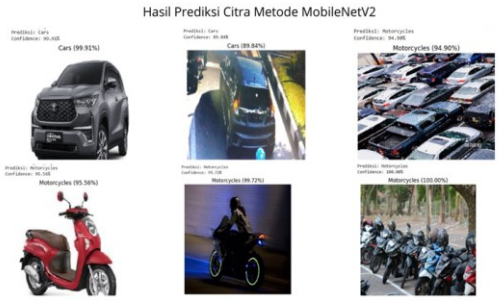
Jenis Kendaraan	***Precision***	***Recall***	***F1-Score***	***Support***
Mobil	0,80	0,80	0,80	79
Motor	0,80	0,80	0,80	80

Sedangkan berdasarkan Tabel 5, Model *ResNet50* memperoleh nilai *precision, recall,* dan *F1-score* pada rentang 0,80 hingga 0,80. Pada kelas mobil, model menghasilkan *precision* sebesar 0,80, *recall* 0,80, dan *F1-score* 0,80 dengan jumlah support sebanyak 79 data. Sementara pada kelas motor, model memperoleh *precision* sebesar 0,80, *recall* 0,80, dan *F1-score* 0,80 dengan support sebanyak 80 data. Hasil ini menunjukkan bahwa *ResNet50* masih cukup baik dalam melakukan klasifikasi, namun performanya masih lebih rendah

dibandingkan *MobileNetV2.* Hasil *classification report* model *ResNet50* ditunjukkan pada Tabel 5.

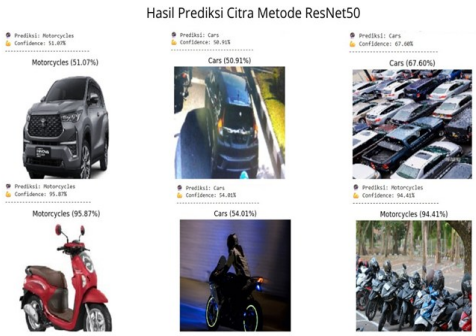
Perbandingan kedua tabel tersebut menunjukkan bahwa *MobileNetV2* lebih unggul dalam menjaga konsistensi klasifikasi pada setiap kelas kendaraan, baik dari sisi ketepatan prediksi *(precision)*, kemampuan menemukan seluruh data yang relevan (*recall*), maupun keseimbangan keduanya *(F1-score).*

d. Hasil Prediksi Citra (Gambar hasil uji coba)



Gambar 6. Hasil Prediksi Citra Menggunakan Model *MobileNetV2*

Gambar 6 menampilkan contoh hasil prediksi citra kendaraan menggunakan model *MobileNetV2* pada data uji. Hasil tersebut menunjukkan bahwa model berhasil mengklasifikasikan kedua kelas, yaitu mobil dan motor, dengan benar. Nilai *confidence* score berada pada rentang 89,84% hingga 100%, yang menandakan bahwa model memiliki kemampuan yang baik dalam mengenali karakteristik visual masing-masing kendaraan.



Gambar 7. Hasil Prediksi Citra Menggunakan Model *ResNet50*

Gambar 7 menampilkan contoh hasil prediksi citra kendaraan menggunakan model *ResNet50* pada data uji. Hasil tersebut menunjukkan bahwa model dapat mengklasifikasikan citra ke dalam dua kategori, yaitu mobil dan motor. Namun, nilai confidence yang dihasilkan lebih bervariasi dibandingkan *MobileNetV2*, dengan beberapa prediksi memiliki tingkat keyakinan yang lebih rendah. Hal ini menunjukkan bahwa *ResNet50* mampu mengenali pola visual kendaraan, tetapi masih belum seoptimal *MobileNetV2* dalam menghasilkan prediksi yang konsisten.

e. Analisis Kesalahan Prediksi



Gambar 8. Hasil Kesalahan Prediksi Citra

Kesalahan prediksi diduga disebabkan oleh sudut pengambilan gambar yang hanya menampilkan sebagian kecil kendaraan, terutama roda dan bagian bawah bodi mobil. Akibatnya, fitur khas mobil seperti bentuk kabin, lampu, atau keseluruhan bodi tidak terlihat dengan jelas. Selain itu, ukuran objek yang terpotong dan kemiripan visual roda mobil dengan roda sepeda motor menyebabkan model MobileNetV2 dan ResNet50 kesulitan mengekstraksi fitur yang membedakan kedua kelas, sehingga citra salah diklasifikasikan sebagai Motor.

Penelitian ini masih memiliki beberapa keterbatasan, antara lain hanya menggunakan dua kelas kendaraan (mobil dan motor), jumlah dataset yang relatif terbatas, serta menggunakan satu sumber dataset. Penelitian selanjutnya dapat menambahkan lebih banyak kategori kendaraan, memperbesar jumlah dataset, dan menguji model pada kondisi pencahayaan maupun sudut pengambilan gambar yang lebih beragam.

4. Kesimpulan

Penelitian ini berhasil menerapkan metode *Convolutional Neural Network (CNN)* berbasis *Transfer Learning* untuk melakukan klasifikasi citra kendaraan ringan, yaitu mobil dan motor. Penelitian menggunakan dataset sebanyak 1.590 citra, yang terdiri atas 790 citra mobil dan 800 citra motor, serta melalui tahapan *preprocessing* berupa resizing, normalisasi, augmentasi data, dan pembagian data menjadi data latih, validasi, dan pengujian. Hasil penelitian menunjukkan bahwa kedua model yang digunakan, yaitu *MobileNetV2* dan *ResNet50*, mampu melakukan klasifikasi

kendaraan berdasarkan karakteristik visual yang terdapat pada citra.

Berdasarkan hasil evaluasi, *MobileNetV2* menunjukkan performa yang lebih baik dibandingkan *ResNet50* pada dataset yang digunakan dalam penelitian ini. *MobileNetV2* memperoleh akurasi sebesar 98,74% dengan nilai *precision*, *recall*, dan *F1-score* sebesar 0,99, serta hanya menghasilkan dua kesalahan klasifikasi. Sementara itu, *ResNet50* memperoleh akurasi sebesar 79,87% dengan nilai *precision*, *recall*, dan *F1-score* sebesar 0,80, serta menghasilkan jumlah kesalahan klasifikasi yang lebih banyak. Hasil tersebut menunjukkan bahwa *MobileNetV2* memiliki kemampuan generalisasi dan konsistensi prediksi yang lebih baik pada kasus klasifikasi kendaraan ringan.

Secara keseluruhan, penelitian ini menyimpulkan bahwa *MobileNetV2* merupakan model yang paling optimal untuk klasifikasi citra kendaraan ringan pada dataset yang digunakan, terutama dari sisi akurasi dan konsistensi prediksi. Berdasarkan karakteristik arsitekturnya yang lebih ringan, *MobileNetV2* juga berpotensi untuk diimplementasikan pada berbagai aplikasi transportasi cerdas yang memiliki keterbatasan sumber daya komputasi, seperti sistem parkir otomatis, pengawasan lalu lintas, dan sistem identifikasi kendaraan berbasis kecerdasan buatan. Selain itu, penelitian ini menunjukkan bahwa pemilihan arsitektur *Convolutional Neural Network (CNN)* yang sesuai dengan karakteristik data memiliki pengaruh yang signifikan terhadap keberhasilan sistem klasifikasi citra kendaraan.

5. Daftar Pustaka

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

Armando, M., & Sutresna Wati. (2024). Klasifikasi Kendaraan Militer (Pesawat F16, Kapal Fregat, Tank Leopard) Di Indonesia Menggunakan Convolutional Neural Network (Cnn). *Jurnal Elektrosista*, *12*(1), 64–74. https://doi.org/10.63824/jtep.v12i1.245

Epiphany Shavna Gracia, & Nurul Anisa Sri Winarsih. (2025). Comparison of *VGG16* , *MobileNetV2*, InceptionV3, *ResNet50*, and Custom CNN Architectures for Furniture Image Classification. *Infotekmesin*, *16*(1), 24–30. https://doi.org/10.35970/infotekmesin.v16i1.2500

Fauzi, D. R., & Haqdu D, G. A. (2025). Comparison of CNN Models Using EfficientNetB0, *MobileNetV2*, and *ResNet50* for Traffic Density with Transfer Learning. *Journal of Intelligent Systems Technology and Informatics*, *1*(1), 22–30. https://doi.org/10.64878/jistics.v1i1.6

Gupta, J., Pathak, S., & Kumar, G. (2022). *Deep Learning* (CNN) and Transfer Learning: A Review. *Journal of Physics: Conference Series*, *2273*(1). https://doi.org/10.1088/1742-6596/2273/1/012029

Herlawati, H., Hendharsetiawan, A. A., Priatna, W., Dzulqiyana, A. P., & Rahmadant, R. A. (2026). *Komparasi Kinerja ResNet50 dan MobileNetV2 pada Klasifikasi Citra Multi-Domain*. *10*(1), 46–61.

Husnurrizqi, H. A., Kurnia, D. A., Wijaya, Y. A., Dikananda, F., Studi, P., Informatika, T., Studi, P., Informatika, M., Studi, P., & Informasi, S. (2026). *KLASIFIKASI CITRA MENGGUNAKAN ARSITEKTUR MOBILENETV2 DENGAN PENDEKATAN TRANSFER LEARNING*. *3*(03), 1–5.

Nur Ridho, A., Mellyka, G., Saputra, F., & Padmo Azam Masa, A. (2024). Implementasi Metode *Convolutional Neural Network (CNN)* Untuk Klasifikasi Gambar Mobil dan Motor Menggunakan Keras. *Jurnal Jambo Digitech*, *1*(1), 54–64. https://jurnal.lldikti13.id/index.php/jjd/article/view/24

Prasetyo, M. E., Faza, M. R., Pratama, R., Alhabsy, S. N. H., Purwanti, H., & 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, Mulyana, D. I., Rofik, M. A., & Zakaria, M. O. Z. (2022). Klasifikasi kendaraan pada jalan raya menggunakan algoritma convolutional neural network (cnn). *Jurnal Pendidikan Tambusai*, *6*(1), 1668–1679.

Wibowo, B. L., Caesarizky, O. Y., Hakim, M. I., & Munsarif, M. (2024). Penerapan algoritma *Convolutional Neural Network (CNN)* untuk mengklasifikasi jenis kendaraan. *Jurnal Komputer Dan Teknologi Informasi*, *2*(2), 94–99. https://doi.org/10.26714/jkti.v2i2.13938