

## Analisis Perbandingan CNN Model Xception Dan InceptionV3 Dalam Pengklasifikasian Rambu Lalu Lintas Di Indonesia

Bimayudha Al'Fattah  
Fakultas Informatika, Universitas  
Telkom, Bandung  
[bimayudha@students.telkomuniversity.ac.id](mailto:bimayudha@students.telkomuniversity.ac.id)

Bedy Purnama  
Fakultas Informatika, Universitas  
Telkom, Bandung  
[bedyurnama@telkomuniversity.ac.id](mailto:bedyurnama@telkomuniversity.ac.id)

Gamma Kosala  
Fakultas Informatika, Universitas  
Telkom, Bandung  
[gammakosala@telkomuniversity.ac.id](mailto:gammakosala@telkomuniversity.ac.id)

### Abstrak

Permasalahan ketidakpatuhan terhadap rambu lalu lintas di Indonesia menjadi salah satu penyebab utama kecelakaan lalu lintas. Perilaku pengemudi yang sering mengabaikan rambu, seperti mendahului kendaraan tanpa memastikan keamanan. Penelitian ini menggunakan pendekatan berbasis *Deep Learning* dengan membandingkan dua arsitektur *Convolutional Neural Networks* (CNN) populer, yaitu *InceptionV3* dan *Xception*, untuk klasifikasi rambu lalu lintas di Indonesia. Kedua model diuji untuk mengevaluasi performa dalam mengenali berbagai rambu dengan fitur visual yang berbeda. Arsitektur *Xception* menunjukkan stabilitas yang lebih baik dalam mengklasifikasikan sebagian besar kelas, dengan akurasi tertinggi mencapai 91.43% pada percobaan kedua. Namun, model ini masih memiliki tantangan dalam mengenali rambu dengan fitur yang lebih kompleks. Di sisi lain, *InceptionV3* memiliki akurasi tertinggi 91.74% pada beberapa kelas tertentu, tetapi menunjukkan variabilitas lebih besar pada kelas-kelas dengan kemiripan visual, seperti "lampu merah" dan "larangan parkir".

**Kata kunci :** *Convolutional Neural Network* (CNN), *Xception*, *InceptionV3*, Rambu Lalu Lintas

### 1. PENDAHULUAN

#### Latar Belakang

Lalu lintas merupakan aspek penting dalam aktivitas berkendara di Indonesia, dengan rambu lalu lintas berperan sebagai panduan bagi pengemudi dalam memahami aturan jalan. Rambu lalu lintas terdiri dari simbol, huruf, angka, atau kombinasi yang berfungsi sebagai peringatan, larangan, perintah, atau petunjuk, sesuai dengan peraturan Menteri Perhubungan Nomor 13 Tahun 2014[1]. Di Indonesia, terdapat lebih dari 300 jenis rambu lalu lintas yang dikelompokkan ke dalam rambu peringatan, larangan, wajib, dan informasi[2]. Namun, masih banyak pengguna jalan yang kurang memahami rambu-rambu tersebut, yang dapat berpotensi membahayakan keselamatan dan menyebabkan gangguan lalu lintas seperti kemacetan atau kecelakaan[3]. Ketidakpatuhan terhadap rambu lalu lintas merupakan salah satu penyebab utama kecelakaan di Indonesia, terutama akibat perilaku melanggar rambu dan aturan jalan[4]. Kesadaran dan kepatuhan terhadap rambu lalu lintas menjadi faktor penting dalam meningkatkan keselamatan berkendara serta menciptakan lingkungan lalu lintas yang lebih tertib. Penelitian ini bertujuan mendukung upaya tersebut dengan memanfaatkan teknologi canggih untuk mempermudah pengenalan dan klasifikasi rambu lalu lintas di Indonesia.

Penelitian sebelumnya yang dilakukan oleh Mutaqin Akbar, Agus Sidiq Purnomo, dan Supatman menunjukkan bahwa metode *Convolutional Neural Network* (CNN) mampu mencapai akurasi tinggi sebesar 99,67% dalam

### Abstract

*Non-compliance with traffic signs in Indonesia is one of the main causes of traffic accidents. Drivers often ignore traffic signs, such as overtaking without ensuring safety. This study employs a Deep Learning approach by comparing two popular Convolutional Neural Network (CNN) architectures, namely InceptionV3 and Xception, for traffic sign classification in Indonesia. Both models were tested to evaluate their performance in recognizing various traffic signs with different visual features. The Xception architecture demonstrated better stability in classifying most classes, achieving the highest accuracy of 91.43% in the second experiment. However, the model still faced challenges in recognizing traffic signs with more complex features. On the other hand, InceptionV3 achieved a slightly higher accuracy of 91.74% in certain classes but exhibited greater variability in classes with visually similar features, such as "red light" and "no parking".*

**Keywords:** *Convolutional Neural Network* (CNN), *Xception*, *InceptionV3*, *Traffic Signs*

pengenalan rambu lalu lintas[2]. Studi serupa oleh Michael Griffith juga menggunakan CNN untuk klasifikasi rambu lalu lintas, dengan tingkat akurasi 84% dan keberhasilan deteksi tanpa kesalahan[5]. Selain itu, penelitian yang dilakukan oleh Nirwana Amir dan Nur Asisa dalam skripsinya mengenai identifikasi makanan tradisional Sulawesi menggunakan arsitektur *Xception* mencapai akurasi 86% [6]. Hasil dari penelitian-penelitian ini menunjukkan efektivitas CNN dalam berbagai tugas klasifikasi, termasuk rambu lalu lintas dan objek lainnya.

Penelitian ini menggunakan 21 jenis rambu lalu lintas yang dianggap representatif dan relevan dengan kondisi di Indonesia, sehingga memungkinkan evaluasi model yang lebih komprehensif. Dalam penelitian ini, dua arsitektur CNN, yaitu *InceptionV3* dan *Xception*, dibandingkan untuk tugas klasifikasi rambu lalu lintas. *InceptionV3* dikenal efisien dengan modul "*Inception*" yang mengurangi kebutuhan komputasi, sedangkan *Xception* mengembangkan konsep tersebut dengan *Depthwise Separable Convolution* untuk pemrosesan lebih mendalam. Perbandingan ini bertujuan untuk menentukan model yang paling sesuai dengan karakteristik dataset rambu lalu lintas di Indonesia.

#### Topik dan Batasannya

Penelitian ini berfokus pada penerapan teknologi *Convolutional Neural Network* (CNN) untuk mengklasifikasi rambu lalu lintas di Indonesia, yang memiliki karakteristik khusus seperti variasi warna, bentuk, dan simbol. Dengan menggunakan dua arsitektur CNN,

yaitu *InceptionV3* dan *Xception*, penelitian bertujuan membandingkan performa kedua metode dalam mengenali dan membedakan rambu-rambu tersebut.

Adapun batasan-batasan penelitian yang terdapat dalam penelitian ini. Pertama, dataset yang digunakan terdiri dari 21 jenis rambu lalu lintas dengan jumlah data yang diambil dari platform Kaggle. Selain itu, model yang digunakan dibatasi pada dua arsitektur CNN, yaitu *Xception* dan *InceptionV3*, mengingat keterbatasan sumber daya komputasi, meskipun arsitektur lain seperti ResNet atau *EfficientNet* berpotensi dieksplorasi dalam penelitian lanjutan. Proses augmentasi data juga dibatasi pada teknik sederhana seperti rotasi, *flip horizontal*, dan *zoom*, karena keterbatasan waktu untuk menerapkan teknik augmentasi yang lebih kompleks.

**Tujuan**

Tujuan dari penelitian ini adalah untuk menjelaskan penerapan kecerdasan buatan menggunakan *Deep Learning*, khususnya dalam penggunaan model *Convolutional Neural Networks* (CNN) arsitektur *Xception* dan *InceptionV3*, dalam proses klasifikasi rambu lalu lintas. Penelitian ini bertujuan untuk memberikan pemahaman yang lebih dalam mengenai implementasi kedua model tersebut dalam pengenalan dan klasifikasi gambar rambu lalu lintas dengan tingkat akurasi yang optimal. Selain itu, penelitian ini juga bertujuan untuk melakukan identifikasi dan analisis perbandingan antara kedua model, yaitu *Xception* dan *InceptionV3*, dalam hal efektivitas dan performa masing-masing dalam tugas klasifikasi rambu lalu lintas.

**2. KAJIAN TEORI**

Berbagai penelitian telah membuktikan efektivitas *Convolutional Neural Network* (CNN) dalam klasifikasi citra. Mutaqin Akbar (2022) mengembangkan sistem *Traffic Sign Recognition* (TSR) menggunakan CNN dengan dataset 2.050 citra rambu dalam 10 kelas, mencapai akurasi 99,33%[1]. Pengembangan lebih lanjut oleh Akbar, Purnomo, dan Supatman (2022) menggunakan dataset primer dengan optimasi tambahan, meningkatkan akurasi menjadi 99,67%[2]. Sementara itu, penelitian oleh Nicola F. S., Virgono, dan Saputra (2021) menerapkan CNN pada robot *self-driving* untuk mengenali tiga jenis rambu lalu lintas, mencapai akurasi 100%[7]. Selain itu, Nirwana Amir dan Nur Asisa (2024) menggunakan CNN arsitektur *Xception* untuk mengidentifikasi makanan tradisional khas Sulawesi dengan akurasi 81%[6]. Hasil penelitian ini menunjukkan bahwa CNN, termasuk model seperti *Xception*, memiliki potensi besar dalam klasifikasi citra dan dapat dioptimalkan lebih lanjut untuk berbagai aplikasi.

**Convolutional Neural Network (CNN)**

*Convolutional Neural Network* (CNN) merupakan arsitektur jaringan saraf yang sangat efisien dalam menangani berbagai tugas pemrosesan gambar, terutama dalam klasifikasi dan deteksi objek[8]. Struktur CNN terdiri dari tiga jenis lapisan utama, yaitu lapisan konvolusi, lapisan pooling, dan lapisan *fully connected*, yang bekerja secara berurutan untuk mengekstrak fitur dari suatu gambar[9][10]. Ketika ketiga lapisan ini digabungkan, maka terbentuklah arsitektur CNN secara keseluruhan yang mampu mengenali pola dalam data visual dengan tingkat akurasi tinggi. Selain itu, CNN dirancang dengan beberapa lapisan khusus yang bertujuan untuk mengenali dan

menangkap pola spasial dalam suatu gambar, sehingga mampu mengidentifikasi berbagai fitur penting, seperti tepi, tekstur, dan bentuk[11]. Dengan kemampuannya dalam memahami karakteristik visual, CNN banyak digunakan dalam berbagai aplikasi, termasuk pengenalan wajah, kendaraan otonom, serta klasifikasi rambu lalu lintas.

**Xception**

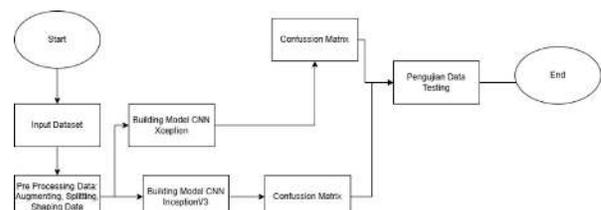
*Xception*, atau sering disebut *Extreme Inception*, adalah pengembangan dari arsitektur *Inception* tradisional[12]. Dirancang untuk memiliki akurasi tinggi, ukuran kompak, dan jumlah parameter yang lebih sedikit, *Xception* memungkinkan model untuk lebih efisien dalam tugas prediksi citra[13]. Arsitektur ini terdiri dari 36 lapisan konvolusional untuk ekstraksi fitur, dengan perbedaan utama pada penggunaan *Depthwise Separable Convolutions*[14], yang membedakannya dari *Inception* tradisional yang menggunakan filter dengan berbagai ukuran untuk menggabungkan informasi spasial dan kanal.

**InceptionV3**

Metode CNN *InceptionV3* adalah teknik *deep learning* yang digunakan untuk klasifikasi dengan arsitektur jaringan yang mendalam. Terdiri dari tiga komponen utama: input, output, dan proses klasifikasi. Model ini mengekstraksi fitur menggunakan lapisan-lapisan seperti konvolusi, pooling, aktivasi (ReLU), *softmax*, dan *fully connected layer*[15]. *InceptionV3* bekerja secara terstruktur dengan mengorganisir objek, di mana hasil konvolusi pada satu lapisan menjadi input untuk lapisan konvolusi berikutnya.

**3. METODE**

Berikut merupakan alur penelitian yang menggambarkan tahapan yang dilakukan dalam penelitian ini untuk mengembangkan sistem klasifikasi rambu lalu lintas menggunakan metode *Xception* dan *InceptionV3* pada model CNN.



**GAMBAR 1**  
Alur Penelitian

**Dataset**

Data yang digunakan dalam penelitian ini diambil dari platform Kaggle. Pemilihan data didasarkan pada kriteria yang sesuai dengan batasan masalah, yakni jenis rambu lalu lintas yang termasuk dalam 21 kategori dan kondisi pencahayaan yang optimal. Untuk mencapai akurasi terbaik dalam penerapan algoritma *Convolutional Neural Network* (CNN), diperlukan 1.470 dataset yang terbagi menjadi 1.029 data pelatihan, 441 data validasi, dan 630 data pengujian.

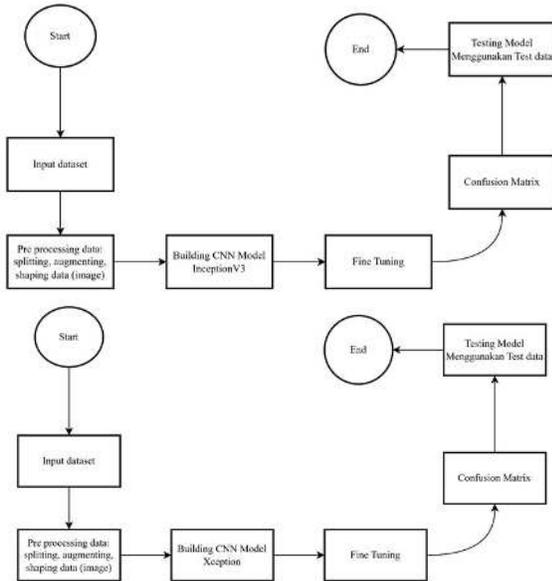
**Pre Processing Data**

*Preprocessing* adalah tahap awal untuk mempersiapkan data dalam pelatihan model, mencakup teknik seperti penyaringan, normalisasi, pelabelan, augmentasi gambar, serta penyesuaian ukuran gambar dan *batch size*. Dataset gambar yang digunakan hanya dalam format .jpg, .jpeg, dan .png, karena kompatibel dengan

berbagai pustaka pemrograman dan *framework deep learning*. Proses pelabelan mengelompokkan gambar dalam 21 kelas, dengan data dibagi menjadi tiga subset: pelatihan, validasi, dan pengujian. Pembagian data dilakukan dengan 70% untuk pelatihan dan 30% untuk validasi, guna mengukur kemampuan model pada data baru. Augmentasi gambar dilakukan dengan teknik seperti *shearing, zooming, rotasi, dan pergeseran posisi*, serta penyesuaian kecerahan untuk meningkatkan generalisasi model. Gambar yang digunakan memiliki ukuran 224x224 piksel dengan tiga saluran warna RGB, dan batch size diatur 32 untuk setiap iterasi pelatihan.

**Pelatihan Model CNN**

Berikut merupakan flowchart dari model *Xception* dan *InceptionV3*.



GAMBAR 2

Flowchart Model CNN *Xception* dan *InceptionV3*

Pada setiap percobaan, model melalui serangkaian lapisan yang dirancang untuk meningkatkan kinerja dan akurasi. Lapisan-lapisan tersebut meliputi

Berikut merupakan flowchart dari arsitektur *Xception* dan *InceptionV3* yang digunakan dalam penelitian ini. Kedua model dilatih dengan beberapa konfigurasi lapisan yang dicoba dalam tiga skenario percobaan untuk masing-masing arsitektur. Pelatihan dilakukan dengan menyesuaikan parameter guna meminimalkan nilai galat dan meningkatkan akurasi model. Dalam proses pelatihan, model CNN menggunakan beberapa lapisan tambahan untuk meningkatkan performa klasifikasi, yaitu *GlobalAveragePool, Batch Normalization, Dense Layer*.

**Confussion Matrix**

Untuk mengevaluasi performa model secara lebih mendetail, digunakan *Confussion Matrix* sebagai alat analisis. *Confussion Matrix* memberikan gambaran tentang bagaimana prediksi model dibandingkan dengan label sebenarnya.

$$Akurasi = \frac{Jumlah\ Prediksi\ Benar}{Total\ Prediksi} \times 100\% \quad (1)$$

**Pengujian Data Testing**

Setelah pelatihan selesai, model disimpan dalam format .h5 dan diuji dengan gambar individual untuk menilai kemampuannya mengenali kelas pada data baru. Proses ini mencakup pemuatan ulang model, pemrosesan gambar, serta pembuatan dan penampilan hasil prediksi.

peringatan-banyak-pejalan-kaki-menggunakan-zebra-cross (0.9991)



larangan-parkir (0.9995)



GAMBAR 3

Hasil Prediksi Model

**4. HASIL DAN PEMBAHASAN**

Pada bagian ini, hasil pelatihan model akan dijelaskan melalui dua tahap, yaitu hasil pengujian dan analisis pengujian. Cara kerja sistem adalah dengan menginput gambar/citra ke dalam sistem, lalu kemudian sistem akan memprediksi gambar/citra sesuai dengan hasil pelatihan pola yang dimilikinya. Setelah melakukan tiga kali percobaan pada masing-masing model, kedua model mendapatkan nilai akurasi tertinggi pada percobaan keduanya, dimana *Xception* mendapatkan tingkat akurasi 91,43% dan *InceptionV3* mendapatkan nilai akurasi 91,74%.

**4.1 Hasil Pelatihan Model**

Berikut ini merupakan hasil skenario pelatihan model.

TABEL 1

Hasil Pelatihan Model

Model	Percobaan 1	Percobaan 2	Percobaan 3
<i>Xception</i>	90.95%	91.43%	81.00%
<i>InceptionV3</i>	89.37%	91.74%	87.00%

Dalam eksperimen yang dilakukan, beberapa skenario pelatihan dan fine-tuning diterapkan pada model *Xception* dan *InceptionV3* untuk meningkatkan akurasi klasifikasi rambu lalu lintas. Pada skenario pertama, *Xception* mencapai akurasi 90,95% dengan konfigurasi input shape 299x299 piksel, pelatihan awal 30 *epoch*, *fine-tuning* 20 epoch, dan penambahan lapisan Dense (256, 128) serta Batch Normalization dan Dropout (0.5). Skenario kedua meningkatkan akurasi menjadi 91,43% dengan mengurangi *patience callback* menjadi 6, membekukan 50 layer awal selama *fine-tuning*, dan menggunakan Model *Checkpoint* untuk menyimpan *loss* terbaik. Namun, pada

skenario ketiga, penyederhanaan arsitektur dengan menghilangkan lapisan Dense dan *Batch Normalization* menurunkan akurasi menjadi 81%, meskipun bertujuan mengurangi *overfitting*.

Di sisi lain, *InceptionV3* menunjukkan performa yang bervariasi. Skenario keempat dengan pembagian data 70:30 dan augmentasi seperti *rescaling*, *shear range*, dan *rotation* mencapai akurasi 89,37%. Skenario kelima, dengan pembagian data 80:20 dan ukuran input 224x224 piksel, berhasil meningkatkan akurasi menjadi 91,74%, tertinggi di antara semua skenario. Namun, pada skenario keenam, pengurangan *dropout* menjadi 0.3 dan *patience* menjadi 3 menurunkan akurasi menjadi 87%. Secara keseluruhan, hasil ini menunjukkan bahwa konfigurasi dan strategi *fine-tuning* yang tepat, seperti pembagian data, augmentasi, dan penambahan lapisan, sangat memengaruhi performa model. *InceptionV3* mampu mencapai akurasi tertinggi, sementara *Xception* lebih stabil dengan akurasi yang konsisten.

4.2 Analisis Hasil Pengujian

Hasil analisis menunjukkan bahwa *Xception* memiliki performa yang lebih stabil dengan akurasi tertinggi 91,43% pada skenario ke-2. Model ini mampu mengklasifikasikan sebagian besar kelas rambu dengan baik, terutama pada kategori yang memiliki perbedaan visual yang jelas. Namun, model *Xception* masih mengalami tantangan dalam mengenali kelas dengan fitur visual yang lebih kompleks, seperti rambu dengan pola detail tinggi atau warna yang menyerupai latar belakang.

Di sisi lain, model *InceptionV3* mencapai akurasi tertinggi sebesar 91,74% pada skenario ke-5. Model ini menunjukkan kemampuan yang lebih baik dalam beberapa kelas tertentu, terutama pada rambu yang memiliki ciri khas yang jelas. Namun, kelemahan utama *InceptionV3* adalah kesulitan dalam mengenali rambu dengan kemiripan visual tinggi, seperti perbedaan antara "lampu merah" dan "larangan parkir," yang dapat menyebabkan tingkat kesalahan prediksi lebih tinggi dibandingkan *Xception*.

Dari hasil ini, pemilihan model bergantung pada kebutuhan spesifik. Jika stabilitas dan konsistensi dalam klasifikasi semua kelas rambu menjadi prioritas, maka *Xception* adalah pilihan yang lebih baik. Namun, jika akurasinya yang lebih tinggi serta kemampuannya dalam mengenali beberapa jenis rambu secara lebih optimal lebih diutamakan, maka *InceptionV3* menjadi pilihan yang lebih unggul dalam konteks tertentu.

4.3 Hasil Pengujian

Tabel di bawah ini menyajikan hasil perbandingan performa dua model deep learning, yaitu *InceptionV3* dan *Xception*, dalam mengklasifikasikan berbagai jenis rambu lalu lintas. Kolom Kelas menunjukkan jenis rambu yang diuji, sedangkan kolom *InceptionV3* dan *Xception* menampilkan hasil prediksi dari masing-masing model terunggul di ketiga percobaan yang telah di latih. Hasil prediksi dinilai sebagai Benar jika sesuai dengan label sebenarnya, dan Salah jika tidak sesuai. Kolom Output menunjukkan hasil akhir klasifikasi, yang dapat berupa Sesuai (jika prediksi benar) atau rambu lain yang diprediksi oleh model jika terjadi kesalahan.

TABEL 2  
Hasil Perbandingan Performa

Kelas	<i>Xception</i>	<i>InceptionV3</i>	Output
Lampu Hijau	Benar	Benar	Sesuai
Lampu Kuning	Salah	Salah	Salah
Lampu Kuning(2)	Benar	Benar	Sesuai
Lampu Merah	Benar	Benar	Sesuai
Larangan Belok Kanan	Salah	Benar	Salah
Larangan Belok Kanan(2)	Benar	Benar	Sesuai
Larangan Belok Kiri	Benar	Benar	Sesuai
Larangan Berhenti	Benar	Benar	Sesuai
Larangan Berjalan Terus Wajib Berhenti Sesaat	Salah	Benar	Salah
Larangan Berjalan Terus Wajib Berhenti Sesaat (2)	Salah	Salah	Salah
Larangan Berjalan Terus Wajib Berhenti Sesaat (3)	Salah	Salah	Salah
Larangan Berjalan Terus Wajib Berhenti Sesaat (4)	Benar	Benar	Sesuai
Larangan Masuk Bagi Kendaraan Bermotor Dan Tidak Bermotor	Benar	Benar	Sesuai
Larangan Parkir	Benar	Benar	Sesuai
Larangan Parkir (2)	Benar	Benar	Sesuai
Larangan Parkir (3)	Benar	Benar	Sesuai

Berdasarkan evaluasi performa model *InceptionV3* dan *Xception* dalam klasifikasi rambu lalu lintas, pemilihan model terbaik tergantung pada kebutuhan aplikasi. *Xception* lebih stabil, akurat, dan cepat dalam konvergensi, cocok untuk deteksi rambu dengan detail kecil seperti "lampu merah." Namun, model ini rentan terhadap *overfitting* tanpa regularisasi yang tepat. Di sisi lain, *InceptionV3* lebih fleksibel untuk eksperimen dan optimasi parameter, cocok untuk rambu dengan variasi bentuk besar seperti rambu peringatan, meskipun memerlukan pengaturan hati-hati untuk menghindari kesalahan klasifikasi. Jika prioritasnya adalah keandalan dan keakuratan, *Xception* lebih direkomendasikan. Namun, untuk eksplorasi dan optimasi lebih lanjut, *InceptionV3* menjadi pilihan yang lebih fleksibel.

5. KESIMPULAN

Analisis perbandingan antara model *InceptionV3* dan *Xception* dalam klasifikasi rambu

lalu lintas menunjukkan bahwa kedua model memiliki keunggulan masing-masing. *Xception* lebih konsisten dengan akurasi tertinggi 91,43% dan stabil dalam mengklasifikasikan sebagian besar kelas rambu, meskipun masih kesulitan mengenali kelas dengan fitur visual kompleks. Sementara itu, *InceptionV3* mencatat akurasi tertinggi sedikit lebih tinggi, yaitu 91,74%, dan unggul dalam beberapa kelas tertentu, tetapi mengalami kesulitan pada kelas dengan kemiripan visual tinggi.

Untuk penelitian selanjutnya, disarankan untuk mengeksplorasi arsitektur CNN lain seperti ResNet atau *EfficientNet*, mengembangkan sistem identifikasi real-time, meningkatkan variasi dataset dengan kondisi pencahayaan dan cuaca yang beragam, serta menggunakan metode *k-fold cross-validation* untuk evaluasi yang lebih akurat dan generalisabel.

#### REFERENSI

- [1] M. Akbar, "Pengenalan Rambu Lalu-lintas menggunakan Convolutional Neural Network ( Studi Kasus : Rambu Lalu-lintas Indonesia )," *J. Nas. Inform. dan Teknol. Jar.*, vol. 2, no. 2, 2022.
- [2] M. Nicola, A. Virgono, and R. E. Saputra, "RANCANG BANGUN SELF-DRIVING CAR ROBOT BERBASIS PENGENALAN RAMBU LALU LINTAS DI INDONESIA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DESIGN FOR SELF-DRIVING CAR ROBOT BASED ON INDONESIA ROAD SIGN RECOGNITION USING CONVOLUTIONAL NEURAL NETWORK."
- [3] S. Feni and E. Mubalus, "ANALISIS FAKTOR-FAKTOR PENYEBAB KECELAKAAN LALU LINTAS DI KABUPATEN SORONG DAN PENANGGULANGANNYA," vol. 6, no. 1, 2023.
- [4] M. Nalsalisa, B. Barus, C. O. Sinaga, and V. R. Hutasuht, "Analisis Dampak Pelanggaran Lalu Lintas terhadap Keselamatan Masyarakat dan Upaya Mempromosikan Nilai-Nilai Kemanusiaan dan kesadaran berkendara," vol. 2, no. 3, 2024.
- [5] M. Akbar, A. S. Purnomo, and S. Supatman, "Multi-Scale Convolutional Networks untuk Pengenalan Rambu Lalu Lintas di Indonesia," *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 11, no. 3, pp. 310–315, Dec. 2022, doi: 10.32736/sisfokom.v11i3.1452.
- [6] M. Griffith, G. Dewantoro, and I. Setyawan, "Pendeteksi Rambu Lalu Lintas Menggunakan Color Masking Filter dan Convolutional Neural Network Menggunakan OpenCV dan Tensorflow," 2022.
- [7] N. Amir and N. Asisa, "Identifikasi Makanan Tradisional Khas Daerah Sulawesi Menggunakan Metode Convolutional Neural Network (CNN)," 2024.
- [8] A. Soimun, A. Leliana, E. I. Ulmi, D. H. Ziantono, and H. Widyastuti, "Analisis Pemahaman Pelajar Pada Rambu Lalu Lintas," *J. Teknol. Transp. dan Logistik*, vol. 1, no. 2, pp. 91–100, 2020.
- [9] A. Gustiani, M. D. Apriansyah, and P. Rosyani, "Analisis LogikaFuzzy Mamdani dalam Pengenalan Rambu Lalu Lintas pada Sistem Gambar," vol. 01, no. 01, pp. 1–7, 2023.
- [10] N. Fadlia and R. Kosasih, "Klasifikasi Jenis Kendaraan Menggunakan Metode Convolutional Neural Network (Cnn)," *J. Ilm. Teknol. dan Rekayasa*, vol. 24, no. 3, pp. 207–215, 2019, doi: 10.35760/tr.2019.v24i3.2397.
- [11] A. E. Putra, M. F. Naufal, and V. R. Prasetyo, "Klasifikasi Jenis Rempah Menggunakan Convolutional Neural Network dan Transfer Learning," *J. Edukasi dan Penelit. Inform.*, vol. 9, no. 1, p. 12, 2023, doi: 10.26418/jp.v9i1.58186.
- [12] Princky and Chairisni Lubis, "Klasifikasi Buah Segar Dan Busuk Menggunakan Convolutional Neural Network Berbasis Android," pp. 1–5, 2019.
- [13] A. Arkadia, S. A. Damayanti, and D. S. Prasvita, "Klasifikasi Buah Mangga Badami Untuk Menentukan Tingkat Kematangan dengan Metode CNN," *Semin. Nas. Mhs. Ilmu Komput. dan Apl.*, no. September, pp. 158–165, 2021.
- [14] G. B. Sulistyono and P. Widodo, "KLASIFIKASI CITRA X-RAY COVID-19 DENGAN MODEL CONVOLUTIONAL NEURAL NETWORKS ALGORITHM LOGISTIC REGRESSION," *Indones. J. Netw. Secur.*, vol. 11, no. 1, 2022.
- [15] R. Kurniawan, P. B. Wintoro, Y. Mulyani, and M. Komarudin, "IMPLEMENTASI ARSITEKTUR XCEPTION PADA MODEL MACHINE LEARNING KLASIFIKASI SAMPAH ANORGANIK," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 2, Apr. 2023, doi: 10.23960/jitet.v11i2.3034.