

Perbandingan Kinerja Metode Convolutional Neural Network (CNN) dan VGG-16 dalam Klasifikasi Rambu Lalu Lintas

Achmad Yusuf Yulestiono¹, MOH. MARIO SUBAGIO², Mulyani Satya Bhakti³, Anggraini Puspita Sari⁴

^{1,2,3,4} Universitas Pembangunan Nasional “Veteran” Jawa Timur

¹22081010180@student.upnjatim.ac.id ²22081010138@student.upnjatim.ac.id

³22081010331@student.upnjatim.ac.id ⁴anggraini.puspita.if@upnjatim.ac.id

Email : 22081010331@student.upnjatim.ac.id

Abstract

This study compares the performance of Convolutional Neural Network (CNN) and VGG-16 methods in traffic sign classification using a preprocessed image dataset. The CNN used involves several convolutional layers, pooling, dropout, dense layers, and the application of data augmentation to enhance model performance. The study results show that a simple CNN can achieve better accuracy in traffic sign classification compared to VGG-16. The CNN model consists of simpler yet effective layers for feature extraction and data dimension reduction, thereby reducing computational complexity and preventing overfitting. VGG-16, one of the more complex and deep CNN architectures, requires more computational resources and longer training time. Although VGG-16 was fine-tuned on the last few layers to adapt the model to the traffic sign dataset, the experimental results indicate that VGG-16 still requires more time and resources compared to a simple CNN. This study concludes that a simple CNN is not only efficient and effective for applications with resource limitations but also capable of providing higher accuracy than VGG-16. The advantage of a simple CNN lies in its computational efficiency and its ability to be further optimized, including the application of transfer learning techniques to improve model performance without the need for retraining from scratch. Therefore, a simple CNN becomes a more ideal choice for traffic sign classification applications, especially in contexts requiring time and computational resource efficiency. This study opens opportunities for further exploration in the use of optimization and transfer learning techniques to enhance model performance in various image classification applications.

Keywords: traffic signs, VGG16, Convolutional Neural Network (CNN)

Abstrak

Penelitian ini membandingkan kinerja metode Convolutional Neural Network (CNN) dan VGG-16 dalam klasifikasi rambu lalu lintas menggunakan dataset gambar yang telah diproses sebelumnya. CNN yang digunakan melibatkan beberapa lapisan konvolusi, pooling, dropout, dense, serta penerapan data augmentasi untuk meningkatkan performa model. Hasil penelitian menunjukkan bahwa CNN sederhana mampu menghasilkan akurasi yang lebih baik dalam klasifikasi rambu lalu lintas dibandingkan dengan VGG-16. Model CNN terdiri dari lapisan-lapisan yang lebih sederhana namun efektif dalam mengekstraksi fitur dan mengurangi dimensi data, sehingga mengurangi kompleksitas komputasi dan mencegah overfitting. VGG-16, yang merupakan salah satu arsitektur CNN yang lebih kompleks dan mendalam, memerlukan sumber daya komputasi yang lebih besar serta waktu pelatihan yang lebih lama. Meskipun VGG-16 dilatih dengan fine-tuning pada beberapa lapisan terakhir untuk menyesuaikan model dengan dataset rambu lalu lintas, hasil eksperimen menunjukkan bahwa VGG-16 masih memerlukan lebih banyak waktu dan sumber daya dibandingkan dengan CNN sederhana. Hasil penelitian ini menyimpulkan bahwa CNN sederhana tidak hanya efisien dan efektif untuk aplikasi dengan keterbatasan sumber daya tetapi juga mampu memberikan akurasi yang lebih

tinggi dibandingkan VGG-16. Keunggulan CNN sederhana terletak pada efisiensi komputasi dan kemampuannya untuk dioptimalkan lebih lanjut, termasuk penerapan teknik transfer learning untuk meningkatkan performa model tanpa perlu pelatihan ulang dari awal. Dengan demikian, CNN sederhana menjadi pilihan yang lebih ideal untuk aplikasi klasifikasi rambu lalu lintas, terutama dalam konteks yang memerlukan efisiensi waktu dan sumber komputasi. Penelitian ini membuka peluang untuk eksplorasi lebih lanjut dalam penggunaan teknik optimisasi dan transfer learning guna meningkatkan kinerja model dalam berbagai aplikasi klasifikasi gambar.

Kata Kunci: rambu lalu lintas, VGG16, convolutional neural network (CNN)

PENDAHULUAN

Masalah terbesar di kota besar Indonesia ialah kemacetan lalu lintas dimana-mana (Sembiring, 2017). Kemacetan lalu lintas adalah situasi di mana ada lebih banyak kendaraan di jalan daripada kapasitasnya (Kawulur, Naukoko, & Maramis, 2020). Pada umumnya jalan raya dilengkapi dengan banyak rambu peringatan tergantung pada fungsi dan kelasnya, yaitu jalan utama untuk perjalanan jarak jauh, kecepatan rata-rata tinggi, dan jumlah jalan dibatasi secara efektif, dan jalan kolektor untuk pengumpulan/distribusi kendaraan (Rahayu, 2007). Dengan karakteristik berkendaraan yang dapat diterima, kecepatan rata-rata sedang dan jumlah jalan akses terbatas. Namun hingga saat ini masih banyak kendaraan yang mengabaikan lalu lintas karena tidak mengikuti jalur yang telah ditentukan (Silaban & Pase, 2021).

Berjalannya waktu ke waktu kecelakaan lalu lintas menjadi masalah yang cukup serius yaitu dengan dibarengi timbulnya berbagai dampak negatif yang lain seperti kemacetan, pemborosan bahan bakar (Hafifah, Rahman, & Asih, 2021). Kegagalan sistem transportasi di Indonesia adalah penyebab besar kematian di kalangan anak muda di seluruh tempat (Nirmala & Patria, 2016) Apalagi sebagian besar jalan macet, korban jiwa dan luka di antara pengemudi muda berusia sekitar 15-29 tahun sering terjadi di negara yang berpenghasilan rendah dan menengah (WHO, 2015).

Kami disini bertujuan untuk membantu masyarakat dalam mengetahui

rambu lalu lintas yang ada berbagai macam bentuk. Rambu lalu lintas dapat dibagi menjadi beberapa kategori berdasarkan fungsinya, dan dalam kategori tersebut dibagi lebih lanjut berdasarkan bentuk dan warnanya. Kami mengambil dataset rambu lalu lintas untuk mengetahui rambu lalu lintas tersebut. Metode klasifikasi berbasis Convolutional Neural Network (CNN) telah terbukti efektif dalam berbagai tugas pengenalan gambar dan klasifikasi visual. CNN mampu mengekstraksi fitur-fitur penting dari gambar secara otomatis, membuatnya sangat cocok untuk aplikasi klasifikasi rambu lalu lintas. Selain CNN, arsitektur VGG-16 yang merupakan jaringan saraf dalam (deep neural network) juga banyak digunakan karena kemampuannya yang luar biasa dalam tugas-tugas klasifikasi gambar yang kompleks. Meskipun banyak penelitian telah dilakukan dalam bidang klasifikasi rambu lalu lintas, perbandingan kinerja antara CNN sederhana dan arsitektur VGG-16 masih perlu dieksplorasi lebih lanjut.

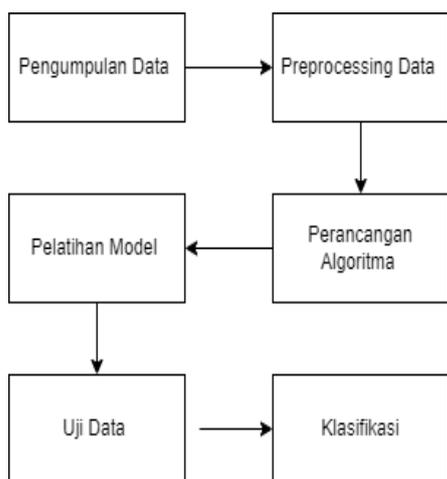
Dalam penelitian ini, kami menggunakan metode VGG16 dan CNN, sebuah metode yang telah terbukti efektif untuk tugas-tugas klasifikasi gambar. Untuk penelitian ini kami menggunakan dataset gambar yang terdiri dari beberapa kelas yang berbeda, kemudian dibagi menjadi set pelatihan, validasi, dan pengujian. Dataset yang kami gunakan telah disediakan oleh Kaggle untuk melakukan training dan testing. Untuk penelitian ini, peneliti melakukan perbandingan hasil pada model yang

menggunakan VGG16 dan CNN yang memiliki metode dan hasil yang berbeda.

Hasil dari penelitian ini diharapkan dapat memberikan kontribusi penting dalam bidang klasifikasi gambar, khususnya dalam aplikasi pengenalan rambu lalu lintas. Temuan penelitian ini dapat digunakan sebagai acuan bagi pengembang sistem kendaraan otonom dan aplikasi asisten pengemudi dalam memilih metode klasifikasi yang paling sesuai dengan kebutuhan mereka. Selain itu, penelitian ini juga dapat membuka peluang untuk pengembangan lebih lanjut dalam optimisasi model CNN dan teknik transfer learning.

METODE

Dalam metode penelitian, terdapat beberapa tahapan yang harus dilalui dengan seksama dan teliti guna memastikan kelancaran dan keberhasilan penelitian yang dilakukan. Tahapan-tahapan tersebut diantaranya mencakup pengumpulan data, Pre - processing data, perancangan algoritma metode CNN dan model VGG 16, training data, uji data, analisis performa model Adapun tahapan dari setiap metode dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

Pengumpulan Data

Tahap pertama dalam melakukan pengumpulan data adalah peneliti mengumpulkan data yang diperlukan

untuk penelitian dari sumber website kaggle. Dataset ini berjumlah 34.801 citra rambu lalu lintas yang terbagi menjadi beberapa kelas dengan jumlah 43. Setiap kelas memiliki jumlah sekitar 809 citra. Untuk memberikan gambaran visual terhadap citra rambu lalu lintas yang ada. Peneliti telah menyajikan Tabel 1 untuk memberikan gambaran contoh dari beberapa rambu lalu lintas sebagai dataset yang digunakan dalam penelitian ini.

Tabel 1. Dataset Citra Rambu Lalu Lintas

Dataset Rambu Lalu Lintas	Contoh 1	Contoh 2	Contoh 3
Speed limit (20 km/h)			
Speed limit (30 km/h)			
No passing			
Stop			
Turn Right Ahead			

Pre - Processing Data

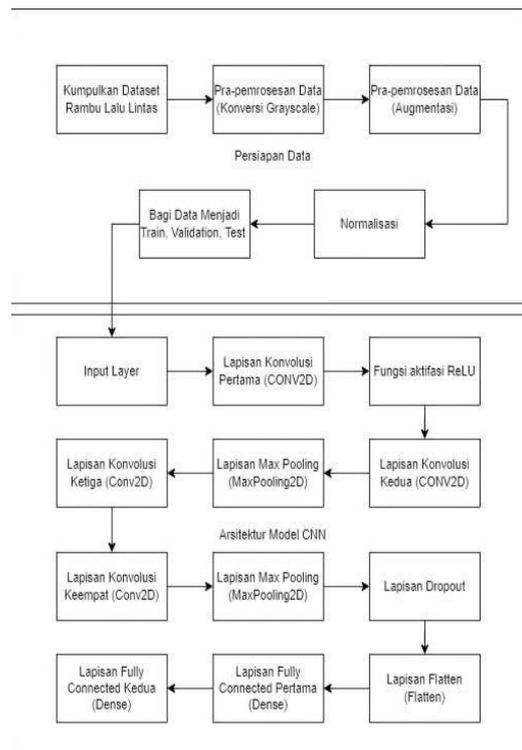
Preprocessing data adalah tahap kritis dalam pengolahan citra sebelum memasukkan gambar ke dalam model jaringan saraf. Terdapat beberapa tahap dalam metode ini, diantaranya :

Pertama, setelah memuat dataset gambar dari 43 direktori, setiap gambar diubah ke dalam citra grayscale menggunakan fungsi grayscale. Langkah

ini memungkinkan reduksi dimensi warna dari tiga (RGB) menjadi satu (grayscale), yang membantu mengurangi beban komputasi tanpa kehilangan informasi struktural penting dari gambar. Selanjutnya, gambar diperlakukan dengan equalize untuk menyeimbangkan distribusi intensitas piksel dalam citra. Proses equalisasi histogram ini membantu meningkatkan kontras gambar, membuat fitur-fitur yang penting lebih terlihat dan mempermudah pemahaman oleh model. Setelah itu, gambar dinormalisasi dengan membagi nilai pikselnya dengan 255, mengubah rentang nilai piksel dari [0, 255] menjadi [0, 1]. Normalisasi ini diterapkan untuk mempercepat konvergensi selama pelatihan model dan untuk menghindari masalah numerik yang mungkin timbul karena skala nilai yang berbeda. Selain itu, untuk memenuhi persyaratan model VGG16, gambar-gambar tersebut dipreproses dengan menggunakan fungsi `preprocess_input`. Fungsi ini secara khusus mengatur format input gambar agar sesuai dengan yang diharapkan oleh model VGG16 yang telah dilatih pada dataset ImageNet. Proses ini termasuk pengurangan mean dari setiap saluran warna (R, G, B) dan penyesuaian lainnya untuk memastikan konsistensi dan performa model yang optimal. Langkah terakhir adalah mengonversi label kelas ke dalam bentuk kategori. Pada penelitian ini terdapat 43 kelas dengan jumlah 34.801 citra yang akan terbagi menjadi tiga bagian berbeda, diantaranya data training sejumlah 22.272, data validation sejumlah 5.568 dan data testing sejumlah 6.961 citra rambu lalu lintas. Langkah ini penting agar model dapat memprediksi dengan tepat kelas-kelas yang diinginkan, dengan mengubah label numerik menjadi representasi one-hot encoding yang dikenal oleh model.

Training Data dengan Metode CNN

Berikut ini adalah visualisasi pelatihan model CNN yang dapat dilihat pada Gambar 2.

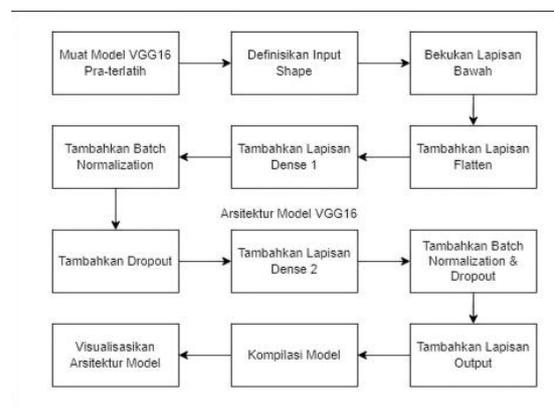


Gambar 2. Visualisasi Pelatihan Metode CNN

Arsitektur CNN kami menggunakan beberapa lapisan konvolusi dan pooling untuk mengekstrak fitur-fitur dari gambar rambu lalu lintas. Kemudian, lapisan fully connected digunakan untuk mengklasifikasikan gambar berdasarkan fitur-fitur tersebut. Lapisan dropout ditambahkan untuk mencegah overfitting.

Model VGG-16

Berikut ini adalah visualisasi pelatihan model VGG 16 yang dapat dilihat pada Gambar 3.



Gambar 3. Visualisasi Pelatihan Model VGG 16

Model klasifikasi rambu lalu lintas dibangun dengan memanfaatkan arsitektur VGG16 yang sudah terlatih pada dataset ImageNet. Beberapa lapisan awal VGG16 dibekukan untuk mempertahankan fitur-fitur umum, sementara lapisan fully connected ditambahkan dan disesuaikan untuk tugas klasifikasi rambu lalu lintas. Lapisan-lapisan tambahan ini meliputi Flatten, Dense (512 neuron), Batch Normalization, Dropout, Dense (512 neuron), Batch Normalization, Dropout, dan lapisan output Dense (dengan jumlah neuron sesuai jumlah kelas rambu) menggunakan aktivasi softmax. Model ini kemudian dikompilasi dengan optimizer Adam, fungsi loss categorical crossentropy, dan metrik akurasi

Pengujian Data

Kedua model yang dikembangkan, yaitu model CNN kustom dan model berbasis VGG16, dievaluasi menggunakan dataset pengujian yang belum pernah dilihat sebelumnya. Evaluasi meliputi perhitungan akurasi untuk setiap kelas rambu lalu lintas. Selain itu, confusion matrix dibangun untuk menganalisis kesalahan klasifikasi, dan contoh prediksi yang salah ditampilkan untuk investigasi lebih lanjut.

Model CNN kustom dilatih dari awal dengan arsitektur yang dirancang khusus untuk tugas klasifikasi rambu, sementara model berbasis VGG16 memanfaatkan bobot pra-latih dari ImageNet dengan penyesuaian pada lapisan fully connected. Kedua model menggunakan augmentasi data untuk meningkatkan variasi data pelatihan dan mencegah overfitting.

HASIL DAN PEMBAHASAN

Hasil penelitian ini menunjukkan bahwa CNN standar mampu untuk lebih unggul dibandingkan dengan VGG-16 dalam klasifikasi rambu lalu lintas pada dataset yang digunakan. Meskipun VGG-16 merupakan model yang lebih dalam dengan 16 lapisan, yang biasanya diharapkan memiliki kemampuan lebih baik dalam ekstraksi fitur kompleks. Akan tetapi terdapat beberapa faktor yang menyebabkan kinerja dari VGG-16 lebih rendah dalam kasus ini, diantaranya yaitu Untuk membuktikan hal tersebut, kami melakukan perbandingan terhadap nilai hasil data training dengan jumlah epoch 3, 6, 9, 12, 15. Sehingga akan didapatkan performa terbaik dari kedua metode tersebut dalam melakukan klasifikasi terhadap rambu lalu lintas yang ada.

Hasil

```
Epoch 1/15
2000/2000 [.....] - 1121s 559s/step - loss: 1.3886 - accuracy: 0.5917 - val_loss: 0.1482 - val_accuracy: 0.9983
Epoch 2/15
2000/2000 [.....] - 1135s 558s/step - loss: 0.4566 - accuracy: 0.8552 - val_loss: 0.0548 - val_accuracy: 0.9837
Epoch 3/15
2000/2000 [.....] - 1138s 570ms/step - loss: 0.3110 - accuracy: 0.9019 - val_loss: 0.0405 - val_accuracy: 0.9783
Epoch 4/15
2000/2000 [.....] - 1139s 570ms/step - loss: 0.2452 - accuracy: 0.9229 - val_loss: 0.0283 - val_accuracy: 0.9923
Epoch 5/15
2000/2000 [.....] - 1131s 565ms/step - loss: 0.2025 - accuracy: 0.9370 - val_loss: 0.0271 - val_accuracy: 0.9923
Epoch 6/15
2000/2000 [.....] - 1137s 568ms/step - loss: 0.1862 - accuracy: 0.9418 - val_loss: 0.0191 - val_accuracy: 0.9941
Epoch 7/15
2000/2000 [.....] - 1123s 551ms/step - loss: 0.1694 - accuracy: 0.9482 - val_loss: 0.0245 - val_accuracy: 0.9934
Epoch 8/15
2000/2000 [.....] - 1128s 563ms/step - loss: 0.1570 - accuracy: 0.9516 - val_loss: 0.0231 - val_accuracy: 0.9923
Epoch 9/15
2000/2000 [.....] - 1119s 559ms/step - loss: 0.1464 - accuracy: 0.9553 - val_loss: 0.0204 - val_accuracy: 0.9921
Epoch 10/15
2000/2000 [.....] - 1112s 556ms/step - loss: 0.1409 - accuracy: 0.9577 - val_loss: 0.0228 - val_accuracy: 0.9928
Epoch 11/15
2000/2000 [.....] - 1125s 562ms/step - loss: 0.1340 - accuracy: 0.9589 - val_loss: 0.0317 - val_accuracy: 0.9907
Epoch 12/15
2000/2000 [.....] - 1131s 566ms/step - loss: 0.1275 - accuracy: 0.9613 - val_loss: 0.0139 - val_accuracy: 0.9968
Epoch 13/15
2000/2000 [.....] - 1135s 567ms/step - loss: 0.1235 - accuracy: 0.9630 - val_loss: 0.0148 - val_accuracy: 0.9960
Epoch 14/15
2000/2000 [.....] - 1134s 567ms/step - loss: 0.1208 - accuracy: 0.9630 - val_loss: 0.0206 - val_accuracy: 0.9928
Epoch 15/15
2000/2000 [.....] - 1135s 568ms/step - loss: 0.1171 - accuracy: 0.9647 - val_loss: 0.0197 - val_accuracy: 0.9948
```

Gambar 4. Hasil Proses Pelatihan Model CNN Standar

```
Epoch 1/15
45/45 [.....] - 1982s 4s/step - loss: 1.8078 - accuracy: 0.1801 - val_loss: 2.4115 - val_accuracy: 0.1668 - lr: 1.0000e-04
45/45 [.....] - 1982s 4s/step - loss: 2.0000 - accuracy: 0.4271 - val_loss: 1.9480 - val_accuracy: 0.3133 - lr: 1.0000e-04
Epoch 2/15
45/45 [.....] - 1979s 4s/step - loss: 1.5327 - accuracy: 0.5305 - val_loss: 1.7591 - val_accuracy: 0.4879 - lr: 1.0000e-04
45/45 [.....] - 1981s 4s/step - loss: 1.0805 - accuracy: 0.6569 - val_loss: 0.7020 - val_accuracy: 0.7000 - lr: 1.0000e-04
Epoch 3/15
45/45 [.....] - 1984s 4s/step - loss: 0.7275 - accuracy: 0.7673 - val_loss: 0.6569 - val_accuracy: 0.7983 - lr: 1.0000e-04
45/45 [.....] - 2013s 5s/step - loss: 0.6557 - accuracy: 0.8029 - val_loss: 0.5840 - val_accuracy: 0.8026 - lr: 1.0000e-04
Epoch 4/15
45/45 [.....] - 1992s 4s/step - loss: 0.4589 - accuracy: 0.8515 - val_loss: 0.2693 - val_accuracy: 0.9111 - lr: 1.0000e-04
45/45 [.....] - 1984s 4s/step - loss: 0.3095 - accuracy: 0.8825 - val_loss: 0.2014 - val_accuracy: 0.9181 - lr: 1.0000e-04
Epoch 5/15
45/45 [.....] - 1947s 4s/step - loss: 0.2911 - accuracy: 0.9076 - val_loss: 0.1891 - val_accuracy: 0.9384 - lr: 1.0000e-04
45/45 [.....] - 1976s 4s/step - loss: 0.2374 - accuracy: 0.9235 - val_loss: 0.1187 - val_accuracy: 0.9584 - lr: 1.0000e-04
Epoch 6/15
45/45 [.....] - 1976s 4s/step - loss: 0.2095 - accuracy: 0.9338 - val_loss: 0.1136 - val_accuracy: 0.9547 - lr: 1.0000e-04
45/45 [.....] - 1956s 4s/step - loss: 0.1754 - accuracy: 0.9464 - val_loss: 0.0911 - val_accuracy: 0.9695 - lr: 1.0000e-04
Epoch 7/15
45/45 [.....] - 1969s 4s/step - loss: 0.1658 - accuracy: 0.9504 - val_loss: 0.0615 - val_accuracy: 0.9519 - lr: 1.0000e-04
45/45 [.....] - 1969s 4s/step - loss: 0.1435 - accuracy: 0.9545 - val_loss: 0.1011 - val_accuracy: 0.9675 - lr: 1.0000e-04
Epoch 15/15
45/45 [.....] - ETA: 0s - loss: 0.1392 - accuracy: 0.9568
Epoch 15: ReduceLROnPlateau reducing learning rate to 0.0000010000000000e+00
45/45 [.....] - 1969s 4s/step - loss: 0.1392 - accuracy: 0.9560 - val_loss: 0.1078 - val_accuracy: 0.9679 - lr: 1.0000e-04
```

Gambar 5. Hasil Proses Pelatihan Model VGG 16

Hasil proses *training* dari tiap model, baik dari CNN Standard maupun VGG16 pada epoch 3,6,9,12, dan 15 bisa dilihat pada gambar 2 dan 3. Epoch sendiri adalah periode waktu tertentu yang menandai awal dari suatu era atau peristiwa penting dalam berbagai konteks, seperti geologi, pembelajaran mesin, dan komputasi. Dalam pelatihan biasanya akan

menggunakan beberapa epoch untuk model mempelajari pola dari data dengan baik. Sedangkan loss mengacu seberapa buruk prediksi model dibandingkan dengan nilai sebenarnya, digunakan untuk mengarahkan optimisasi model selama pelatihan.

Pembahasan

Berdasarkan Gambar 4 di atas, proses *training per-epoch* memiliki waktu rata-rata sekitar 1.051 detik. Tingkat akurasi *train* dan *validation* tiap *epoch* tidak memiliki perbedaan yang signifikan tetapi perlu diperhatikan ketika *epoch* pertama mempunyai perbedaan yang cukup jauh. Secara keseluruhan model CNN Standar memberikan performa yang tinggi pada data yang dilatih. Tingkat akurasi yang tinggi yaitu 99% dan validasi serta *loss* yang minim menunjukkan bahwa model ini memiliki potensi yang kuat untuk digunakan dalam pengklasifikasian rambu lalu lintas.

Berdasarkan Gambar 5 di atas, proses *training per-epoch* memiliki waktu rata-rata sekitar 1.975 detik, lebih lama dibandingkan dengan metode CNN Standar namun dalam segi akurasi tidak kalah dengan CNN Standar. Tingkat akurasi metode VGG16 juga tinggi yaitu 96% tidak dapat mengalahkan akurasi dari metode CNN Standar.

Penelitian ini menunjukkan bahwa model CNN standar lebih unggul dibandingkan dengan VGG-16 dalam klasifikasi rambu lalu lintas pada dataset yang digunakan. Meskipun VGG-16 memiliki 16 lapisan yang lebih dalam dan umumnya diharapkan lebih baik dalam ekstraksi fitur kompleks, dalam kasus ini, CNN standar menunjukkan performa yang lebih baik dengan akurasi mencapai 99% dan waktu pelatihan per epoch yang lebih cepat (rata-rata 1.051 detik) dibandingkan dengan VGG-16 yang memiliki akurasi 96% dan waktu pelatihan per epoch yang lebih lama (rata-rata 1.975 detik). Oleh karena itu, CNN standar terbukti lebih efisien dan efektif untuk klasifikasi rambu

lalu lintas pada dataset yang digunakan.

Setelah melakukan dan mendapat hasil yang memuaskan *training*, langkah berikutnya adalah melakukan proses pengujian. Kami menggunakan contoh 5 kelas rambu yang sering dijumpai di Indonesia. Setiap kelas berisi 5 sampel data. Rambu-rambu yang dipilih untuk pengujian meliputi rambu "Petunjuk-lokasi-putar-balik", "Petunjuk-penyeberangan-pejalan-kaki", "berhenti-sesaat", "larangan-putar-balik", dan "lampu-merah".



Gambar 6. Uji sampel data putar balik
Predicted class: petunjuk-penyeberangan-pejalan-kaki



1/1 [=====] - 1s 522ms/step

Gambar 7. Uji sampel penyeberangan pejalan kaki

Pada gambar 6 dan 7 proses pengujian dilakukan untuk mengevaluasi kinerja model CNN standar dalam mengenali dan mengklasifikasikan rambu-

rambu ini dengan akurasi tinggi. Hasil pengujian menunjukkan bahwa model CNN standar berhasil mengklasifikasikan semua sampel dengan benar, mempertahankan tingkat akurasi yang tinggi pada set pengujian ini. Selain itu, model ini juga mampu memberikan prediksi dengan waktu yang sangat cepat, menunjukkan efisiensi dalam aplikasi dunia nyata.

Tabel 1. Hasil Uji Data Tes

Dataset Rambu	Class Terdeteksi	Benar/Salah
Putar Balik (1).jpg	1	Benar
Putar Balik (2).jpg	1	Benar
Putar Balik (3).jpg	1	Benar
Penyebrangan (1).jpg	2	Benar
Penyebrangan (1).jpg	2	Benar
Penyebrangan (1).jpg	2	Benar
Berhenti Sesaat (1).jpg	3	Benar
Berhenti Sesaat (2).jpg	3	Benar
Berhenti Sesaat (3).jpg	3	Benar
Dilarang Putar Balik(1).jpg	4	Benar
Dilarang Putar Balik(2).jpg	5	Salah
Dilarang Putar Balik(3).jpg	4	Benar
Lampu Merah (1).jpg	5	Benar
Lampu Merah (2).jpg	5	Benar
Lampu Merah (3).jpg	5	Benar

Pada tabel 1 kami menggunakan 15 citra rambu acak sebagai data uji, terbagi dalam 3 data pada 5 *class* sampel. Penomoran *class* berdasarkan urutan kelas data yang kami input berurutan "Petunjuk-lokasi-putar-balik", "Petunjuk-penyeberangan-pejalan-kaki", "berhenti-sesaat", "larangan-putar-balik", dan "lampu-merah".

Terlihat ada satu kesalahan dalam prediksi gambar program tersebut, yakni pada Dilarang Putar Balik (2).jpg yang terdeteksi memiliki kelas 5 yaitu lampu merah. Dapat dilihat pada gambar berikut



Gambar 8. Kesalahan deteksi larangan putar balik

Dapat dilihat pada gambar 8 citra rambu larangan putar balik mendapat *class* lampu-merah.

SIMPULAN (PENUTUP)

Penelitian ini membandingkan kinerja dua arsitektur jaringan saraf, yaitu Convolutional Neural Network (CNN) standar dan VGG-16, dalam tugas klasifikasi rambu lalu lintas. Hasil penelitian menunjukkan bahwa metode CNN standar memperoleh tingkat akurasi yang lebih tinggi, yaitu 99%, dibandingkan dengan metode VGG-16 yang mencapai akurasi 96%. Meskipun VGG-16 merupakan model yang lebih dalam dan kompleks, yang biasanya unggul dalam banyak tugas pengenalan gambar, beberapa faktor menjelaskan penyebab bahwa CNN standar tampil lebih baik dalam konteks ini. Faktor-faktor tersebut meliputi potensi overfitting yang lebih besar pada VGG-16 karena arsitekturnya yang lebih kompleks, efektivitas penyesuaian hyperparameter yang lebih optimal pada CNN standar, serta kecocokan yang lebih baik dari struktur

CNN standar dengan karakteristik dataset rambu lalu lintas yang digunakan. Temuan ini menyoroti pentingnya pemilihan arsitektur model yang tepat sesuai dengan spesifikasi tugas dan karakteristik dataset yang digunakan, serta menunjukkan bahwa meskipun VGG-16 memiliki reputasi sebagai model yang kuat untuk banyak aplikasi pengenalan gambar, dalam kasus klasifikasi rambu lalu lintas ini, CNN standar terbukti lebih efektif dan efisien. Dengan demikian, hasil penelitian ini memberikan wawasan berharga mengenai strategi terbaik untuk klasifikasi rambu lalu lintas, yaitu dengan mempertimbangkan kesesuaian antara model dan dataset yang digunakan.

Untuk penelitian di masa depan, disarankan untuk mengeksplorasi kombinasi arsitektur CNN dengan teknik augmentasi data yang lebih canggih atau pendekatan transfer learning yang diadaptasi khusus untuk dataset rambu lalu lintas. Selain itu, studi lebih lanjut dapat mempertimbangkan penggunaan model-model baru dan teknik regularisasi yang lebih efektif untuk mengurangi risiko overfitting pada model yang lebih kompleks seperti VGG-16. Hal ini dapat memberikan wawasan lebih mendalam tentang bagaimana model yang berbeda dapat dioptimalkan untuk berbagai jenis tugas klasifikasi gambar.

UCAPAN TERIMA KASIH

Penulis mengucapkan rasa terima kasih yang tulus kepada Dr. Eng. Ir. Anggarini Puspita Sari, MT sebagai dosen pengampu mata kuliah Kecerdasan Buatan yang telah memberikan bimbingan, dukungan, dan dorongan yang tak ternilai selama penelitian ini. Keahlian dan wawasan beliau sangat berperan penting dalam penyelesaian studi ini.

Selain itu, penulis juga mengucapkan penghargaan yang sebesar-besarnya kepada anggota tim peneliti yang telah bekerja keras, berdedikasi, dan teliti dalam menyelesaikan jurnal ini. Komitmen mereka terhadap keunggulan dan kerjasama

sangat penting bagi keberhasilan proyek ini.

DAFTAR PUSTAKA

- Adiningsi, S., & Saputra, R. A. (t.t.). *JIP (Jurnal Informatika Polinema) IDENTIFIKASI JENIS DAUN TANAMAN OBAT MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) DENGAN MODEL VGG16*.
- AGUSTINA, R., MAGDALENA, R., & PRATIWI, N. K. C. (2022). Klasifikasi Kanker Kulit menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(2), 446. <https://doi.org/10.26760/elkomika.v10i2.446>
- Akbar, M. (2022). *Pengenalan Rambu Lalu-lintas menggunakan Convolutional Neural Network (Studi Kasus: Rambu Lalu-lintas Indonesia)*. 6(2). <https://doi.org/10.30743/infotekjar.v6i2.4564>
- Akbar, M., Purnomo, A. S., & Supatman, S. (2022). Multi-Scale Convolutional Networks untuk Pengenalan Rambu Lalu Lintas di Indonesia. *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, 11(3), 310–315. <https://doi.org/10.32736/sisfokom.v11i3.1452>
- Balai, E. S., Daerah, B., & Yogyakarta, I. (t.t.). *HUMOR DALAM RAMBU LALU LINTAS *) HUMOR IN TRAFFIC SIGNS*. [https://ejurnal.seminar-id.com/index.php/tin](https://id.Wi-Hafifah, F., Rahman, S., & Asih, S. (2021). Klasifikasi Jenis Kendaraan Pada Jalan Raya Menggunakan Metode Convolutional Neural Networks (CNN)</i>. 2(5), 292–301. <a href=)

- Haris Munandar, M., & Bangun, B. (t.t.-a). Perancangan Sistem Pengenalan Rambu-Rambu Lalu Lintas Pada MTS Islamiyah Menggunakan Adobe Flash Profesional CS6. Dalam *Journal of Student Development Information System (JoSDIS) e-ISSN* (Vol. 1, Nomor 1).
- Haris Munandar, M., & Bangun, B. (t.t.-b). Perancangan Sistem Pengenalan Rambu-Rambu Lalu Lintas Pada MTS Islamiyah Menggunakan Adobe Flash Profesional CS6. Dalam *Journal of Student Development Information System (JoSDIS) e-ISSN* (Vol. 1, Nomor 1).
- Hartono, I., Noertjahyana, A., & Santoso, L. W. (t.t.). *Deteksi Masker Wajah dengan Metode Convolutional Neural Network*.
- Jinan, A., & Ikorasaki, F. (2020). RANCANG BANGUN APLIKASI RAMBU-RAMBU LALU LINTAS DALAM BENTUK POP QUIZ BERBASIS ANDROID DESIGN AND BUILD TRAFFIC SIGNS APPLICATIONS IN THE FORM OF POP QUIZ BASED ON ANDROID. Dalam *184. IT Journal* (Vol. 8, Nomor 2).
- Kholik, A. (2021). KLASIFIKASI MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA TANGKAPAN LAYAR HALAMAN INSTAGRAM. *JDMSI*, 2(2), 10–20.
- Nicola, M., Virgono, A., & Saputra, R. E. (t.t.-a). 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.
- 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>
- Putri, A., Negara, B. S., & Sanjaya, S. (2022). Penerapan Deep Learning Menggunakan VGG-16 untuk Klasifikasi Citra Glioma. *Jurnal Sistem Komputer dan Informatika (JSON)*, 3(4), 379. <https://doi.org/10.30865/json.v3i4.4122>
- Rizky, D., Fortuna, F., Rahmadi, I. F., Ardyananda, D. A., Sari, A. P., Informatika, P. S., Pembangunan, U., Veteran, N. ", & Timur, J. (2023). Analisis Prediksi Intensitas Cahaya Lampu Menggunakan Metode Fuzzy Mamdani dan Sugeno. Dalam *Seminar Nasional Informatika Bela Negara (SANTIKA)* (Vol. 3).
- Sinha, Y., Hadassa, B., Krishna, G., & Ravi Kumar, C. V. (2020b). Traffic sign recognition using convolutional neural networks. *International Journal of Electrical Engineering and Technology*, 11(3), 210–217. <https://doi.org/10.14710/jtsiskom.2021.13959>