

Klasifikasi Pengemudi yang Terdistraksi Menggunakan Densenet 169

Muhammad Reza Syahfahlevi^{*1}, Yufis Azhar¹

Univeristas Muhammadiyah Malang

rzasyalevi22@gmail.com^{*1}, yufis@umm.ac.id¹

Abstrak

Penelitian ini bertujuan untuk mendeteksi pengemudi yang terdistraksi menggunakan arsitektur DenseNet-169, di mana salah satu penyebab utama kecelakaan lalu lintas adalah gangguan pada pengemudi. Hal ini dapat menyebabkan kerugian materi maupun kehilangan nyawa. Dataset yang digunakan adalah State Farm Distracted Driver Detection, yang terdiri dari 19.000 gambar dalam 10 kelas berbeda. DenseNet-169 dipilih karena kemampuannya yang unggul dalam menangani dataset yang besar dan kompleks dengan efisiensi parameter yang tinggi. Model dilatih menggunakan pre-trained weights dari ImageNet dan dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa DenseNet-169 memberikan performa yang baik dalam mengklasifikasikan kondisi pengemudi yang terdistraksi dengan akurasi 97,50% pada data uji. Diharapkan teknologi ini dapat berkontribusi pada keselamatan jalan raya dengan mendeteksi pengemudi yang terdistraksi.

Kata Kunci: DenseNet-169, Distraksi Pengemudi, Klasifikasi Gambar, Keselamatan Lalu Lintas, Pembelajaran Mesin

Abstract

The study aimed to detect distracted drivers using the DenseNet-169 architecture, one of the causes being driver distractions due to road accidents. This can lead to both material losses and loss of lives. The used dataset is the State Farm Distracted Driver Detection, which consists of 19,000 images across 10 different classes. DenseNet-169 was selected for its superior capabilities in dealing with large and complex datasets with high parameter efficiency. The model was trained with pre-trained weights from ImageNet and evaluated with the metrics of accuracy, precision, recall, and F1-score. The findings of the study reveal that DenseNet-169 performs quite well in the classification of the state of distracted drivers with an accuracy of 97.50% on the test data. It is hoped that this technology could contribute to road safety by detecting distracted drivers.

Keywords: DenseNet-169, Driver Distraction, Image Classification, Traffic Safety, Machine Learning

1. Pendahuluan

Kecelakaan lalu lintas adalah suatu peristiwa yang tidak diinginkan dan tidak terduga yang melibatkan kendaraan dan menyebabkan kerugian materi atau korban manusia. Menurut KBBI, kecelakaan disebutkan sebagai kejadian yang menyebabkan orang celaka atau mendapat kesulitan. Menurut Undang-undang Lalu Lintas dan Angkutan Jalan (UU No. 22

Tahun 2009), kecelakaan lalu lintas adalah suatu peristiwa di jalan yang tidak diduga dan tidak disengaja, melibatkan kendaraan dengan atau tanpa pengguna jalan lain yang mengakibatkan korban manusia atau kerugian harta benda.

Indonesia, sebagai negara dengan populasi kendaraan bermotor yang tinggi, terutama mobil, mengalami peningkatan jumlah kecelakaan lalu lintas. Data Korps Lalu Lintas (Korlantas) melalui Sub-Direktorat Kecelakaan (Subditlaka) menunjukkan peningkatan jumlah kasus kecelakaan lalu lintas dari 140.248 pada 2022 menjadi 148.307 pada 2023, meningkat 0,06%. Kecelakaan ini tidak hanya menyebabkan kerugian materi, tetapi juga mengakibatkan hilangnya nyawa dan cacat permanen.

Salah satu faktor utama penyebab kecelakaan adalah kesalahan manusia (human error). Dari 148.307 kasus kecelakaan, sekitar 45.000 di antaranya disebabkan oleh tabrakan depan, sering kali akibat kurangnya kesadaran dan ketidakfokusan pengemudi. Penelitian ini bertujuan

untuk mengembangkan sistem pendeteksi pengemudi yang terdistraksi menggunakan metode DenseNet-169.

DenseNet adalah jenis jaringan saraf konvolusi yang menggunakan koneksi padat antar lapisan. Model DenseNet-169, salah satu varian dari DenseNet, dirancang untuk klasifikasi gambar dan memiliki keunggulan dalam ukuran dan akurasi dibandingkan dengan model lain seperti DenseNet-121. DenseNet-169 menggunakan berbagai lapisan termasuk lapisan konvolusi, max pool, dense, dan transisi, serta dua fungsi aktivasi yaitu ReLU dan SoftMax.

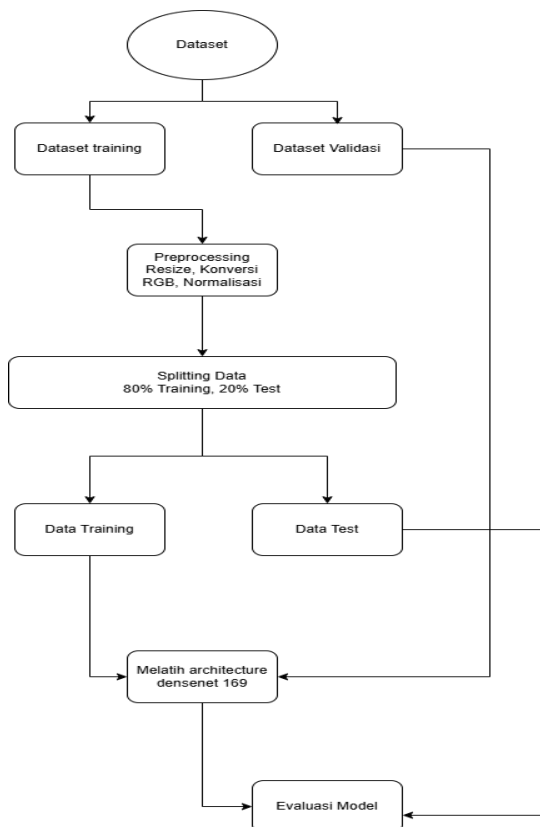
Model DenseNet-169, salah satu varian DenseNet, menawarkan keseimbangan antara ukuran model dan akurasi yang dihasilkan, sehingga ideal untuk diterapkan dalam klasifikasi gambar. DenseNet-169 menggunakan lapisan-lapisan konvolusi, *max pooling*, *dense*, dan transisi, dengan fungsi aktivasi ReLU dan SoftMax. Kombinasi ini membuat DenseNet-169 unggul dalam menangkap fitur penting pada gambar dengan kompleksitas tinggi.

Keunggulan DenseNet-169 ini telah dibuktikan melalui berbagai penelitian. Misalnya, penelitian oleh Kartik Nair menunjukkan bahwa model ini memiliki keandalan tinggi dalam aplikasi waktu nyata untuk mendeteksi penyakit paru-paru seperti Covid-19, Tuberkulosis, dan Pneumonia (1). Selain di bidang medis, DenseNet-169 juga menunjukkan performa yang baik dalam aplikasi lain, seperti face recognition (2).

Penelitian sebelumnya menunjukkan bahwa pendekatan untuk mengklasifikasikan pengemudi terdistraksi banyak dilakukan menggunakan arsitektur model seperti VGG dan ResNet, Densenet 121 dan Densenet 201 [(3,4,5)]. Namun, pada dataset State Farm Distracted Driver Detection, belum ada penelitian yang menggunakan arsitektur DenseNet-169. Penelitian ini menerapkan arsitektur DenseNet-169 pada dataset tersebut dan membandingkan performanya dengan ResNet untuk memahami bagaimana kedua arsitektur menangani klasifikasi pada data besar dan beragam.

2. Metode Penelitian

Gambar 1 ini akan menjelaskan bagaimana alur metode penelitian ini, dengan berbagai tahapan, yaitu koleksi data, *preprocessing* data, *splitting* data, pelatihan model serta evaluasi model



Gambar 1. Rancangan Penelitian

Awalnya, dataset terdapat 2 folder yaitu set pelatihan dan validasi. Selanjutnya, prosedur preprocessing diterapkan pada data, termasuk mengubah ukuran, konversi ke RGB, dan normalisasi, untuk memastikan konsistensi di semua sampel. Setelah preprocessing selesai, data latih dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Setelah itu, arsitektur DenseNet-169 digunakan untuk melatih model menggunakan data validasi. Langkah terakhir melibatkan evaluasi model menggunakan data pengujian, di mana prediksi model dibandingkan dengan label aktual untuk menilai kinerjanya.

2.1 Dataset

Keterangan Pada penelitian ini, dataset yang akan digunakan ialah dataset deteksi pengemudi terdistraksi dari State Farm yang tersedia di Kaggle. Dataset ini khusus dirancang untuk mengidentifikasi berbagai tingkat distraksi pada pengemudi yang sedang mengemudi. Ketika di download terdapat dua folder yaitu folder data training dan data validasi. Untuk data training terdapat 10 klasifikasi tingkah laku yang menjadi fokus dalam penelitian ini, yang masing-masing merepresentasikan tingkat distraksi berbeda. *Normal Driving, Texting – Right, Talking on the Phone – Right, Texting – left, Talking on the Phone – left, Operating the Radio, Drinking, Reaching Behind, Touching Face dan Talking to Passenger.*

Tabel 1. Total Citra di Setiap Kelas

Kelas	Total
<i>Normal Driving</i>	1900
<i>Texting – Right</i>	1900
<i>Talking on the Phone – Right</i>	1900
<i>Texting – left</i>	1900
<i>Talking on the Phone – left</i>	1900
<i>Operating the Radio</i>	1900
<i>Drinking</i>	1900
<i>Reaching Behind</i>	1900
<i>Touching Face</i>	1900
<i>Talking to Passenger</i>	1900

Setiap kelas dalam dataset ini memiliki jumlah citra yang sama, yaitu 1.900 citra per kelas, sehingga total keseluruhan adalah 19.000 citra. Dataset dibagi menjadi dua set: latih dan uji. Dengan proporsi 80% untuk latih, 20% test. Pembagian ini penting untuk mengevaluasi performa model secara objektif. Set latih digunakan untuk melatih model. Sedangkan test untuk menguji model yang sudah di latih

Distribusi yang seragam ini membantu dalam mengurangi bias selama proses pelatihan model pembelajaran mesin. Berikut merupakan beberapa citra di Gambar 2 ini.



Gambar 2. Contoh Citra

2.2 Preprocessing

Dalam penelitian ini, preprocessing adalah langkah penting yang dilakukan untuk mempersiapkan data citra sebelum digunakan oleh model pembelajaran mesin. Preprocessing data yang dilakukan meliputi beberapa tahap berikut ini:

2.2.1 Resize

Langkah pertama dalam preprocessing adalah mengubah ukuran gambar. Proses ini melibatkan penyesuaian resolusi atau dimensi horizontal dan vertikal suatu gambar, yang dapat dilakukan untuk memperbesar atau memperkecil sesuai kebutuhan. Dalam penelitian ini, ukuran gambar diubah menjadi 224 x 224 piksel, yang merupakan standar umum untuk penggunaan dalam model pembelajaran mesin. Konversi RGB

Tahap selanjutnya adalah konversi format warna gambar ke model warna RGB (Red, Green, Blue). Model RGB adalah standar dalam pengolahan gambar digital, yang memungkinkan representasi warna dengan kombinasi tiga kanal warna utama.

2.2.2 Normalisasi


Normalisasi adalah langkah penting dalam preprocessing untuk meningkatkan performa model pembelajaran mesin. Gambar dalam dataset umumnya memiliki nilai intensitas piksel dalam rentang 0 hingga 255 untuk setiap kanal warna (RGB). Untuk memudahkan pelatihan model dan mempercepat proses konvergensi, nilai-nilai piksel ini dinormalisasi ke dalam rentang 0 hingga 1. Normalisasi membantu memastikan bahwa model dapat memproses data secara lebih efisien dan konsisten.

2.3 Densenet 169

DenseNet (Densely Connected Convolutional Networks) adalah arsitektur jaringan saraf konvolusional (CNN) yang dirancang untuk mengoptimalkan aliran informasi dan gradien melalui jaringan (6). Arsitektur ini dikembangkan untuk meningkatkan efisiensi pembelajaran dengan memanfaatkan konektivitas yang sangat padat antar lapisan. DenseNet mencapai efisiensi ini melalui konsep blok Dense, di mana setiap lapisan terhubung langsung dengan setiap lapisan lain dalam blok yang sama. Keterhubungan ini memungkinkan setiap lapisan menerima input tambahan dari semua lapisan sebelumnya, menghasilkan koneksi yang dikenal sebagai "concatenate" (bukan penjumlahan), yang mendukung 'feature reuse'—penggunaan ulang fitur secara efektif untuk mengurangi jumlah parameter dan memastikan aliran gradien yang efisien saat pelatihan (7).

DenseNet-169 adalah jaringan saraf konvolusional yang padat, di mana setiap lapisan terhubung dengan semua lapisan berikutnya, menghasilkan $N(N + 1) / 2$ koneksi untuk N lapisan [9]. Arsitektur ini terdiri dari lapisan konvolusional awal, empat blok padat (dense block) dengan lapisan transisi di antara setiap blok, dan diakhiri dengan lapisan klasifikasi yang menggunakan fungsi aktivasi softmax.

Setiap blok padat terdiri dari konvolusi 1×1 yang diikuti oleh konvolusi 3×3 . Terdapat 6, 12, 32, dan 32 set konvolusi, menghasilkan total 82 set konvolusi. Dengan 164 lapisan konvolusional, tiga lapisan transisi, satu lapisan konvolusional, dan satu lapisan klasifikasi, total keseluruhan adalah 169 lapisan. Model ini memiliki laju pertumbuhan sebesar 32, yang menentukan jumlah fitur baru yang ditambahkan pada setiap blok padat (7).



Gambar 3. Arsitektur Densenet 169

Dalam pengembangannya, arsitektur DenseNet-169 dirancang untuk meningkatkan efisiensi parameter dengan konektivitas padat antar lapisan, memungkinkan transfer informasi dan gradien yang lebih baik. Salah satu keunggulan utama dari DenseNet-169 adalah

kemampuannya untuk meminimalkan jumlah parameter sekaligus mencapai akurasi yang tinggi, bahkan pada dataset besar dengan kompleksitas tinggi.

Penelitian ini menggunakan metode transfer learning dengan arsitektur DenseNet-169 yang telah dilatih sebelumnya pada dataset ImageNet. Arsitektur ini memanfaatkan lapisan dasar DenseNet-169 sebagai feature extractor, dengan bagian klasifikasinya (top layer) dimodifikasi untuk menyesuaikan jumlah kelas pada dataset. Ukuran input gambar adalah 224×224 piksel dengan tiga saluran warna (RGB), yang sesuai dengan standar input untuk model pralatih.

Model yang digunakan dalam penelitian ini memiliki beberapa komponen penting sebagai berikut:

1. *Input Layer: Mengambil citra dengan dimensi $224 \times 224 \times 3$, di mana setiap piksel direpresentasikan dalam format warna RGB.*
2. *Base Model: DenseNet-169 dengan parameter `include_top=False`, sehingga hanya bagian ekstraksi fitur yang digunakan. Output dari base model berupa representasi fitur dengan dimensi spasial yang telah direduksi.*
3. *Global Average Pooling: Lapisan ini mengubah fitur dua dimensi menjadi vektor satu dimensi dengan menghitung rata-rata dari setiap saluran fitur. Ini memastikan setiap saluran memberikan kontribusi yang seimbang dalam klasifikasi.*
4. *Dense Layers: Dua lapisan fully connected digunakan setelah pooling. Lapisan pertama memiliki 512 unit dengan fungsi aktivasi ReLU, dan lapisan kedua memiliki 256 unit dengan fungsi aktivasi ReLU. Lapisan ini bertujuan untuk mempelajari hubungan non-linear yang kompleks dalam data.*
5. *Dropout: Untuk mencegah overfitting, lapisan dropout digunakan setelah masing-masing lapisan Dense, dengan rasio dropout sebesar 0.5 dan 0.3 secara berurutan.*
6. *Output Layer: Lapisan Dense terakhir memiliki 10 neuron (sesuai jumlah kelas pada dataset), menggunakan fungsi aktivasi softmax untuk menghasilkan probabilitas klasifikasi untuk setiap kelas.*

Selama pelatihan, lapisan-lapisan pada model dasar DenseNet-169 dibekukan agar parameter pralatih dari ImageNet tidak berubah. Hal ini dilakukan untuk memanfaatkan fitur-fitur yang telah dipelajari model tersebut, sehingga model dapat fokus pada adaptasi terhadap dataset baru. Setelah itu, model dikompilasi menggunakan optimizer Adam dengan learning rate 0.0001, dan loss function categorical crossentropy, yang cocok untuk klasifikasi multikelas. Berikut *table model training parametersnya*.

2.4 Pelatihan dan Parameter Model

Pelatihan model dilakukan dengan menggunakan beberapa parameter penting untuk mengoptimalkan hasil klasifikasi. Berikut penjelasan masing-masing parameter:

1. BatchSize

Dalam penelitian ini, digunakan ukuran batch sebesar 50. Batch size adalah jumlah sampel data yang diproses sebelum model memperbarui bobot selama pelatihan. Ukuran batch yang lebih besar dapat menggantikan penurunan laju pembelajaran dan memberikan hasil yang sebanding pada kurva pembelajaran, baik pada data pelatihan maupun pengujian. Selain itu, ukuran batch yang besar dapat mengurangi jumlah pembaruan parameter yang diperlukan, sehingga meningkatkan paralelisme dan mengurangi waktu pelatihan (8).

2. Epoch

Pelatihan model dilakukan dengan 50 epoch. Epoch merujuk pada satu siklus penuh di mana algoritma machine learning memproses seluruh data pelatihan. Proses ini dilakukan secara iteratif untuk memastikan konvergensi nilai bobot. Pemilihan jumlah epoch yang tepat tidak bisa ditentukan secara langsung, sehingga dilakukan pengujian beberapa nilai epoch untuk mencapai akurasi optimal [(9)].

3. LearningRate

Learning rate yang digunakan dalam penelitian ini sebesar 0.0001. Learning rate merupakan konstanta proporsionalitas yang menentukan ukuran langkah pembaruan parameter model berdasarkan estimasi gradien. Parameter ini sangat penting dalam proses optimisasi karena memengaruhi kecepatan dan stabilitas konvergensi fungsi kerugian (10).

Tabel 2. Paramater Latih Model

Parameter	Settings
Batch Size	40
Optimizer	Adam
Epoch	50
Learning Rate	0.0001
Loss Function	Categorical Crossentropy

2.5 Evaluasi

Evaluasi model dilakukan menggunakan beberapa metrik, yaitu confusion matrix, F1 score, precision, recall, dan support. Confusion matrix adalah alat penting untuk analisis prediktif dalam pembelajaran mesin, khususnya dalam mengevaluasi kinerja model klasifikasi (11). Dalam konteks klasifikasi multiclass, confusion matrix berfungsi sebagai tabel yang menggambarkan kinerja model dengan menunjukkan jumlah prediksi yang benar dan salah untuk setiap kelas. Pada klasifikasi multiclass, confusion matrix memiliki dimensi $Q \times Q$, di mana Q adalah jumlah kelas yang ada (12).

Selain itu, evaluasi model juga dilakukan dengan menggunakan data uji. Model yang telah selesai dibuat dievaluasi menggunakan data uji untuk menilai kinerja dan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

3. Hasil Penelitian dan Pembahasan

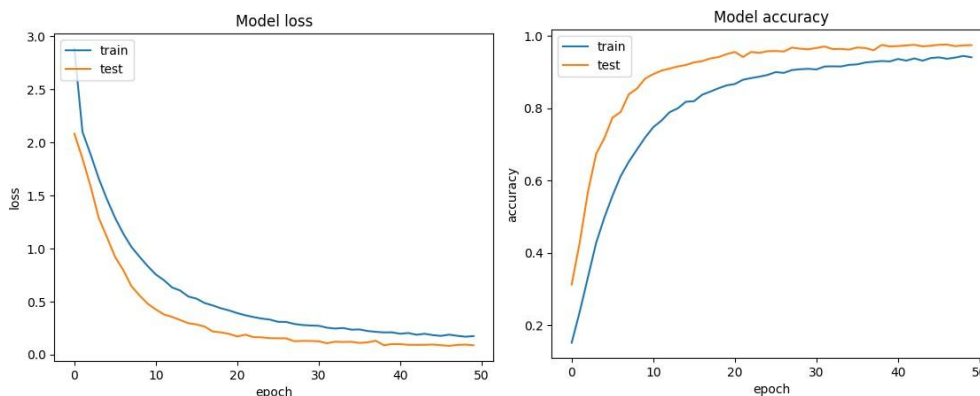
Pada bagian ini, kami memaparkan hasil dari eksperimen yang dilakukan menggunakan model DenseNet-169 untuk klasifikasi pengemudi yang terdistraksi. Model ini dilatih dan diuji menggunakan dataset State Farm Distracted Driver Detection yang terdiri dari 19.000 gambar dalam 10 kelas yang berbeda.

3.1 Akurasi Model

Model DenseNet-169 yang digunakan dalam penelitian ini menunjukkan performa yang sangat baik dalam klasifikasi pengemudi yang terdistraksi. Akurasi yang dicapai pada data uji adalah 97.50%, menunjukkan kemampuan model untuk mengenali pola dengan akurasi tinggi.

3.2 Grafik Akurasi dan Loss

Grafik akurasi dan loss selama pelatihan menunjukkan bahwa model mengalami peningkatan akurasi yang stabil dan penurunan loss yang konsisten. Akurasi pada data latih dan test mendekati 1, sementara loss menunjukkan penurunan yang signifikan, menandakan bahwa model tidak mengalami overfitting dan memiliki kemampuan generalisasi yang baik.

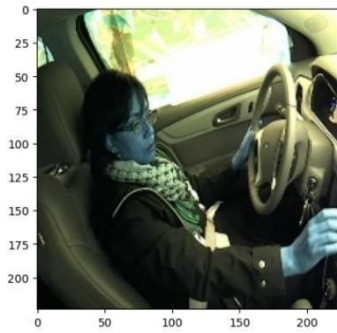


Gambar 4. Loss dan Akurasi


3.3 Evaluasi dengan Data Uji

Pengujian model dengan data uji menunjukkan bahwa model dapat mempertahankan performa yang tinggi. Dengan melakukan komparasi dengan model dengan data uji. Dengan 10 gambar, mendapatkan perbandingan 7:3, model tersebut mampu mendeteksi pengemudi yang terdistraksi, tetapi kesulitan untuk mendeteksi pengemudi terdistraksi class *talking passanger*. Berikut gambar evaluasi dengan data uji


Predicted: Operating the radio




Predicted: Operating the radio




Predicted: Talking to passenger



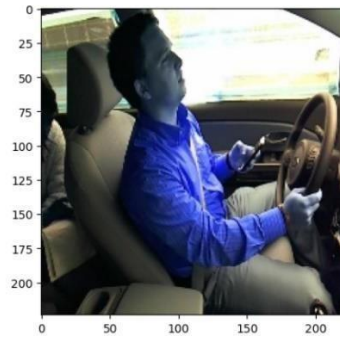
Predicted: Talking to passenger



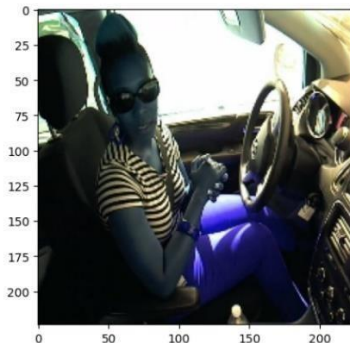
Predicted: Texting - left




Predicted: Texting - left

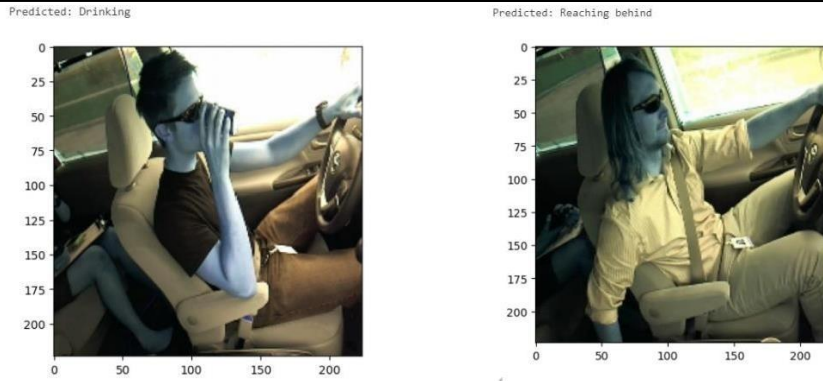


Predicted: Talking to passenger



Predicted: Reaching behind






Gambar 5. Hasil Uji Dari Test

3.4 Confusion Matrix Serta Clasification Report

Confusion matrix yang dihasilkan menunjukkan distribusi prediksi model dibandingkan dengan label sebenarnya.



Gambar 6. Confusion Matrix

Sebagian besar prediksi berada pada diagonal utama, yang menunjukkan bahwa model memiliki akurasi yang baik dalam mengklasifikasikan setiap kelas. Ini memberikan informasi yang lebih mendetail tentang kinerja model dibandingkan dengan hanya menggunakan tingkat kesalahan klasifikasi. Untuk *Classification Report* berikut Tabel 3.

Tabel 3. Classification Report

	Precision	Recall	F1-score	Support
Class 0	0.93	0.99	0.96	360
Class 1	0.98	0.99	0.99	379
Class 2	0.98	0.97	0.97	379
Class 3	0.99	0.92	0.95	390
Class 4	0.94	0.98	0.96	405
Class 5	0.99	0.99	0.99	386
Class 6	0.98	0.99	0.98	386
Class 7	1.00	0.98	0.99	392

Class 8	0.97	0.98	0.98	363
Class 9	0.99	0.96	0.97	360
Accuracy			0.97	3800
Macro avg	0.98	0.98	0.98	3800
Weighted avg	0.98	0.97	0.97	3800

Akurasi yang dicapai pada data uji mendukung hasil dari evaluasi sebelumnya, dengan metrik evaluasi seperti precision, recall, dan F1-score yang menunjukkan nilai rata-rata yang tinggi.

3.5 Perbandingan

Dalam penelitian ini, dilakukan perbandingan performa antara model DenseNet-169 dan ResNet-50 untuk tugas klasifikasi pengemudi terdistraksi. Hasil perbandingan menunjukkan bahwa dalam hal akurasi, ResNet-50 sedikit lebih unggul dengan akurasi sebesar 98%, dibandingkan DenseNet-169 yang memiliki akurasi 97,5% pada data uji. Saat diuji menggunakan data latih, kedua model menghasilkan prediksi yang sama, yaitu 7 prediksi benar dan 3 prediksi salah dari 10 sampel uji. Namun, jenis kesalahan prediksi yang dilakukan oleh kedua model berbeda. DenseNet-169 mengalami kesalahan pada kelas "berbicara dengan penumpang," sementara ResNet-50 menunjukkan kesalahan pada kelas "merias wajah" dan "meminum".

Dari segi efisiensi waktu pelatihan, ResNet-50 membutuhkan waktu yang lebih singkat per epoch dibandingkan DenseNet-169, dengan selisih waktu rata-rata 20 detik lebih cepat pada penggunaan GPU yang sama. Hal ini menunjukkan bahwa ResNet-50 lebih ringan secara komputasi, meskipun memiliki performa yang hampir setara dengan DenseNet-169.

3.6 Diskusi

DenseNet-169 berhasil menunjukkan performa yang baik dalam klasifikasi kondisi pengemudi terdistraksi. Koneksi padat antar layer dan mekanisme *feature reuse* dalam arsitektur DenseNet-169 memungkinkan model menangkap pola kompleks dengan efisien. Namun, waktu pelatihan DenseNet-169 lebih lama dibandingkan ResNet-50. Beberapa faktor yang mempengaruhi performa model antara lain:

- 1) Preprocessing Data: Resize gambar ke ukuran 224x224 dan normalisasi piksel berperan dalam meningkatkan akurasi model.
- 2) Parameter Pelatihan: Penggunaan learning rate yang kecil dan optimizer Adam membantu model mencapai konvergensi yang stabil.
- 3) Dataset: Distribusi data yang seimbang di setiap kelas meminimalkan bias dan mendukung generalisasi model.

4. Kesimpulan

Penelitian ini membuktikan bahwa model DenseNet-169 mampu mencapai akurasi 97.50% pada dataset *State Farm Distracted Driver Detection*. Meskipun ResNet-50 menunjukkan akurasi lebih tinggi, DenseNet-169 memiliki keunggulan dalam stabilitas performa pada dataset besar. Penelitian ini dapat dilanjutkan dengan:

- 1) Menggunakan teknik augmentasi data untuk meningkatkan generalisasi model.
- 2) Menggunakan arsitektur model lain seperti EfficientNet atau Inception untuk evaluasi komparatif lebih dalam.
- 3) Menguji model dalam kondisi real-time untuk implementasi praktis.

Referensi

- [1] Nair K, Deshpande A, Guntuka R, Patil A. Analysing X-Ray Images to Detect Lung Diseases Using DenseNet-169 technique. SSRN Electron J. 2022.
- [2] Nandy A. A densenet based robust face detection framework. Proc - 2019 Int Conf Comput Vis Work ICCVW 2019. 2019;1840–7.
- [3] Satardekar S. Distracted Driver Detection and Classification Distracted Driver Detection and Classification Prof . Pramila M . Chawan *, Shreyas Satardekar **, Dharmin Shah **, Rohit. 2018;(July):2–7.

-
- [4] Vaegae NK, Pulluri KK, Bagadi K, Oyerinde OO. Design of an Efficient Distracted Driver Detection System: Deep Learning Approaches. IEEE Access. 2022;10(November):116087–97.
- [5] Arafin I, Tazwar SI, Das NS, Anika ST. Application Of CNN Based Architectures in Detection of Distracted Drivers. 2022;(August).
- [6] Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. Densely connected convolutional networks. Proc - 30th IEEE Conf Comput Vis Pattern Recognition, CVPR 2017. 2017;2017-January:2261–9.
- [7] Dalvi PP, Edla DR, Purushothama BR. Diagnosis of Coronavirus Disease From Chest X- Ray Images Using DenseNet-169 Architecture. SN Comput Sci [Internet]. 2023;4(3):1–6. Available from: <https://doi.org/10.1007/s42979-022-01627-7>
- [8] Smith SL, Kindermans PJ, Ying C, Le Q V. Don't decay the learning rate, increase the batch size. 6th Int Conf Learn Represent ICLR 2018 - Conf Track Proc. 2018;(2017):1–11.
- [9] Wibawa SM. Jurnal Sistem dan Informatika Pengaruh Fungsi Aktivasi, Optimisasi dan Jumlah Epoch Terhadap Performa Jaringan Saraf Tiruan. J Sist Dan Inform [Internet]. 2017;11(December):1–7. Available from: <http://archive.ics.uci.edu/ml/datasets/Wine>
- [10] Andrew Senior, Georg Heigold, Marc'Aurelio Ranzato KY. An Empirical Study of Learning Rates In Deep Neural Networks For Speech Recognition Andrew Senior , Georg Heigold , Marc ' Aurelio Ranzato , Ke Yang New York. New York. 2013;6724–8.
- [11] Murphy A, Moore C. Confusion matrix. Radiopaedia.org. 2019;(October).
- [12] Machart P, Ralaivola L. Confusion Matrix Stability Bounds for Multiclass Classification. 2012; Available from: <http://arxiv.org/abs/1202.6221>