



Analisis Performa Convolutional Neural Network untuk Klasifikasi Aktivitas Pengemudi Terganggu

Zufar Abdullah Rabbani^{1*}, Wahyu Syaifullah J. S², Alfian Rizaldy Pratama³

^{1,2,3} Universitas Pembangunan Nasional “Veteran” Jawa Timur, Fakultas Ilmu Komputer
Program Studi Sains Data, Indonesia

Alamat: Jl. Rungkut Madya, Gn. Anyar, Kec. Gn. Anyar, Surabaya, Jawa Timur 60294

Korespondensi penulis: 22083010080@student.upnjatim.ac.id *

Abstract. Private vehicles are a frequently used mode of transportation because they are considered more practical. However, using private vehicles carries several risks, such as traffic accidents due to drivers losing focus on the road due to other activities, such as making calls on smartphones, drinking, or operating the radio. Approximately 90% of accidents are caused by human error. Convolutional Neural Network (CNN) is a type of neural network commonly used on image data. CNN is often used for image classification due to its high performance and accuracy. Therefore, this study aims to analyze the performance of CNN for the classification of distracted driving activities. The results show that the CNN model is able to effectively classify images of distracted driving activities, with an accuracy of approximately 99% across all datasets and across all input image size variations. Furthermore, the results of this study also show that differences in right-hand and left-hand drive datasets do not significantly affect model accuracy. Variations in input image size also do not significantly affect model accuracy, but do affect the training duration.

Keywords: Convolutional Neural Network, Distracted Driver, Image Size, Left Hand Drive, Right Hand Drive

Abstrak. Kendaraan pribadi merupakan transportasi yang sering digunakan karena dianggap lebih praktis. Namun menggunakan kendaraan pribadi memiliki beberapa risiko seperti terjadinya kecelakaan lalu lintas akibat pengemudi kehilangan fokus pada jalan karena aktivitas lain, seperti melakukan panggilan pada *smartphone*, minum, atau mengoperasikan radio. Sekitar 90% kecelakaan disebabkan oleh faktor kelalaian manusia. Convolutional Neural Network (CNN) adalah salah satu jenis neural network yang biasa digunakan pada data gambar. CNN seringkali digunakan untuk melakukan klasifikasi gambar karena performa dan akurasi yang dihasilkan cukup tinggi. Oleh karena itu, penelitian ini bertujuan untuk menganalisis performa CNN untuk klasifikasi aktivitas pengemudi terganggu. Hasil penelitian menunjukkan bahwa model CNN mampu melakukan klasifikasi citra aktivitas pengemudi terganggu secara efektif, dengan akurasi sekitar 99% pada semua dataset dan pada semua variasi ukuran citra input. Lebih lanjut lagi, hasil penelitian ini juga menunjukkan bahwa perbedaan dataset kemudi kanan dan kiri tidak mempengaruhi akurasi model secara signifikan, variasi ukuran citra input juga tidak mempengaruhi akurasi model secara signifikan, namun mempengaruhi durasi waktu pelatihan.

Kata kunci: Convolutional Neural Network, Kemudi Kanan, Kemudi Kiri, Pengemudi terganggu, Ukuran Citra

1. LATAR BELAKANG

Transportasi merupakan salah satu hal yang sangat penting bagi kelancaran seluruh aktivitas manusia. Transportasi yang sering digunakan dan mengalami peningkatan adalah kendaraan pribadi, karena dianggap lebih praktis untuk perjalanan jauh. Namun meski dianggap lebih praktis, menggunakan kendaraan pribadi memiliki beberapa risiko seperti terjadinya kecelakaan lalu lintas akibat pengemudi kehilangan fokus pada jalan karena aktivitas lain, seperti melakukan panggilan pada *smartphone*, minum, atau mengoperasikan radio (Amalia & Utaminingrum, 2021). Kecelakaan dapat ditinjau dari tiga faktor, yaitu faktor lingkungan jalan, faktor kendaraan, dan faktor manusia. Diantara ketiga faktor tersebut, faktor

manusia seringkali ditetapkan sebagai faktor utama penyebab terjadinya kecelakaan, sekitar 90% kecelakaan disebabkan oleh faktor kelalaian manusia (Firdaus & Artika, 2021).

Beberapa upaya untuk menangani dan mencegah kecelakaan akibat fokus pengemudi yang terganggu tersebut antara lain adalah menegakkan peraturan dan edukasi untuk perilaku mengemudi, membangun infrastruktur jalan raya seperti rambu lalu lintas, area istirahat, dan elemen jalan, kemudian juga terdapat *Advanced Driver Assistance Systems* (ADAS) yaitu antarmuka perangkat sistem dalam kendaraan untuk mendukung keamanan mengemudi. Salah satu ADAS yang dapat diimplementasikan dengan baik untuk pengamatan perilaku pengemudi secara alami adalah menggunakan kamera. Kamera digunakan untuk menganalisis kegiatan dalam perilaku pengemudi seperti melakukan panggilan pada *smartphone*, minum, atau mengoperasikan radio (Hermawan, 2024).

Convolutional Neural Network (CNN) adalah salah satu jenis *neural network* yang biasa digunakan pada data gambar, seperti gambar dari hasil tangkapan kamera. CNN bisa digunakan untuk mendeteksi dan mengenali objek pada sebuah gambar (Faizal Nazili, Firmansyah, & Purbaningtyas, 2023). Teknologi CNN ini seringkali digunakan untuk melakukan klasifikasi suatu gambar, dikarenakan hasil akurasi dan performa yang dihasilkan cukup tinggi (Putra, Hutabarat, & Khaira, 2023). Sistem pemrosesan gambar dengan CNN ini kemudian dapat berfungsi pada kamera pengawas sebagai deteksi atau klasifikasi pengemudi terganggu dengan memanfaatkan gambar tangkapan kamera pengawas sebagai input sistem. Jaringan CNN yang terdiri dari banyak lapisan perceptron dapat menghasilkan klasifikasi pembacaan yang akurat dalam waktu singkat (Hidayat, Latifah Husni, & Damsi, 2022).

Beberapa penelitian telah dilakukan untuk klasifikasi aktivitas pengemudi terganggu ini, dan telah dibuktikan bahwa metode CNN ini memiliki akurasi yang tinggi dalam klasifikasi pengemudi terganggu. Penelitian yang dilakukan oleh Hossain dkk (2022) menunjukkan bahwa metode CNN sederhana dapat menghasilkan akurasi sebesar 96 – 97% untuk klasifikasi aktivitas pengemudi terganggu, metode CNN ini bahkan mengungguli akurasi dari metode ResNet50 yang akurasinya hanya mencapai 94 – 95%. Namun penelitian ini tidak melakukan analisis performa CNN lebih lanjut pada dataset dengan kemudi sebelah kanan, karena penelitian ini hanya terbatas pada dataset dengan kemudi sebelah kiri saja (Uzzol Hossain dkk., 2022). Hal ini tentunya menjadi celah/*gap* karena penelitian yang dilakukan oleh Hermawan (2024) menyatakan bahwa antara dataset dengan kemudi sebelah kanan dan kiri dapat menunjukkan perbedaan signifikan dalam akurasi karena variasi distribusi data dan visual yang

berbeda, dan juga di Indonesia kemudi sebelah kanan tentunya lebih relevan untuk aplikasi dunia nyata dibandingkan dengan kemudi sebelah kiri (Hermawan, 2024).

Oleh karena itu penelitian ini bertujuan untuk melakukan analisis performa CNN lebih lanjut pada dataset dengan kemudi kiri dan kanan. Penelitian ini juga melakukan analisis pengaruh resolusi input terhadap akurasi dan performa model yang tidak dilakukan pada penelitian sebelumnya. Dengan begitu, penelitian ini diharapkan dapat berkontribusi secara ilmiah terhadap penelitian CNN, khususnya pada klasifikasi aktivitas pengemudi terganggu yang akan datang. Kemudian penelitian ini diharapkan juga dapat menjadi acuan atau referensi untuk penelitian dan implementasi sistem klasifikasi aktivitas pengemudi terganggu yang akan datang untuk meminimalisir risiko terjadinya kecelakaan karena faktor manusia yang kehilangan fokus.

2. KAJIAN TEORITIS

A. State of The Art

Terdapat beberapa studi kasus yang melakukan klasifikasi aktivitas pengemudi terganggu menggunakan CNN, diantaranya adalah penelitian yang berjudul *Automatic Driver Distraction Detection Using Deep Convolutional Neural Networks* (2022). Penelitian tersebut menggunakan data citra aktivitas pengemudi terganggu *State Farm Distracted Driver Detection*, dan hasil akurasi dari klasifikasi tersebut sebesar 96 – 97% menggunakan CNN. Pada penelitian tersebut menggunakan metode CNN sederhana untuk klasifikasi aktivitas pengemudi terganggu dianggap baik dan dapat digunakan untuk membantu perkembangan sistem *Advanced Driver Assistance Systems* (ADAS) (Uzzol Hossain dkk., 2022).

Studi kasus berikutnya berjudul *Klasifikasi Pengemudi Terganggu Berdasarkan Citra Menggunakan ResNet50* (2024). Penelitian tersebut juga melakukan klasifikasi aktivitas pengemudi terganggu menggunakan data citra *AUC Driver Distracted*, tetapi menggunakan metode ResNet50 yang merupakan bagian dari arsitektur CNN. Penelitian tersebut menunjukkan bahwa perbedaan data citra dengan kemudi sebelah kiri dan kanan dapat mempengaruhi hasil akurasi dari sebuah model, karena disebabkan oleh variasi distribusi data dan visual antara kedua dataset (Hermawan, 2024).

Studi kasus ketiga berjudul *Lightweight Convolutional Neural Network Architecture For Facial Expression Recognition* (2024). Penelitian tersebut bertujuan untuk melakukan pengenalan ekspresi wajah secara akurat dan ringan menggunakan arsitektur CNN sederhana.

Metode yang diusulkan pada penelitian tersebut adalah CNN sederhana dan ringan yang menghasilkan nilai akurasi sebesar 97%. Penelitian tersebut membuktikan bahwa CNN sederhana dapat mencapai akurasi yang tinggi dan memiliki performa yang baik (Robot, Lolowang, & Putro, 2024).

Studi kasus keempat berjudul *Kinerja Metode CNN Untuk Klasifikasi Pneumonia Dengan Variasi Ukuran Citra Input* (2021). Penelitian ini bertujuan untuk mengembangkan proses pendeteksian pneumonia berdasarkan citra paru-paru dari hasil foto rontgen (x-ray) menggunakan *Convolutional Neural Network*. Penelitian ini menunjukkan bahwa ukuran citra input berpengaruh besar terhadap kinerja klasifikasi (Nugroho & Yulia, 2021).

Dari keempat studi kasus tersebut, metode CNN terbukti memiliki performa tinggi dalam klasifikasi citra, tetapi penerapannya pada citra aktivitas pengemudi terganggu masih belum diteliti lebih lanjut. Penelitian pertama yang berjudul *Automatic Driver Distraction Detection Using Deep Convolutional Neural Networks* (2022), menggunakan metode CNN untuk klasifikasi aktivitas pengemudi terganggu, hanya saja penelitian tersebut hanya menggunakan dataset dengan kemudi sebelah kiri dan menggunakan ukuran citra input yang sama. Penelitian kedua yang berjudul *Klasifikasi Pengemudi Terganggu Berdasarkan Citra Menggunakan ResNet50* (2024), melakukan klasifikasi aktivitas pengemudi terganggu menggunakan dataset dengan kemudi sebelah kiri dan kanan, namun penelitian tersebut tidak menggunakan metode CNN dan menggunakan ukuran citra input yang sama. Penelitian ketiga yang berjudul *Lightweight Convolutional Neural Network Architecture For Facial Expression Recognition* (2024), menggunakan metode CNN sederhana untuk pengenalan ekspresi wajah. Dan penelitian keempat yang berjudul *Kinerja Metode CNN Untuk Klasifikasi Pneumonia Dengan Variasi Ukuran Citra Input* (2021), menggunakan metode CNN dan ukuran citra input yang bervariasi, namun tidak diterapkan pada citra aktivitas pengemudi terganggu. Oleh karena itu, penelitian ini mengisi celah (*gap*) tersebut pada penelitian sebelumnya, yaitu dengan menggunakan metode CNN untuk klasifikasi aktivitas pengemudi terganggu pada dataset dengan kemudi sebelah kiri dan kanan, serta menambahkan variasi ukuran citra input.

B. Landasan Teori


1) Klasifikasi Citra Aktivitas Pengemudi Terganggu

Berbagai studi menggunakan CNN sebagai inti sistem untuk mendeteksi aktivitas pengemudi terganggu dengan mengekstraksi fitur visual dari citra pengemudi dan mengklasifikasikannya ke dalam kategori perilaku tertentu. Penelitian sebelumnya

mengusulkan CNN untuk mengidentifikasi distraksi manual, visual, dan kognitif, menunjukkan bahwa arsitektur *deep learning* mampu mempelajari pola pose tubuh, posisi tangan, dan arah pandangan secara efektif dari citra untuk membedakan aktivitas mengemudi normal dan terganggu dengan akurasi yang dilaporkan dapat melampaui 95–97% pada dataset pengemudi terganggu, sehingga membuka peluang integrasi ke dalam sistem bantuan pengemudi cerdas (ADAS) (Shevtekar & Gangurde, 2024). Studi tentang *driver distraction detection* menunjukkan bahwa model CNN dapat diintegrasikan dengan kamera kabin dan modul deteksi objek/pose untuk mengklasifikasi *frame* demi *frame* aktivitas pengemudi sambil tetap mempertahankan kecepatan pemrosesan yang memadai untuk sistem peringatan dini. Beberapa kerangka kerja bahkan menggabungkan deteksi perilaku pengemudi terganggu dengan pengenalan objek di jalan dalam satu sistem terpadu, sehingga dapat sekaligus memantau kondisi sekitar kendaraan dan aktivitas pengemudi, yang berpotensi besar meningkatkan keselamatan lalu lintas dan mengurangi kecelakaan akibat distraksi (Salakapuri dkk., 2025).

2) Convolutional Neural Network

Metode *Convolutional Neural Network* (CNN) muncul sebagai solusi revolusioner untuk menangani data citra yang memiliki dimensi tinggi dan variasi visual yang kompleks. Secara historis, CNN mulai menarik perhatian global setelah keberhasilan arsitektur AlexNet pada tahun 2012, yang memperkenalkan penggunaan *Graphics Processing Unit* (GPU) untuk komputasi paralel dan fungsi aktivasi *Rectified Linear Unit* (ReLU) untuk mempercepat konvergensi model (Mienye, Swart, Obaido, Jordan, & Ilono, 2025). Kelebihan fundamental dari CNN terletak pada kemampuannya melakukan *automatic feature extraction*. Berbeda dengan algoritma *Machine Learning* klasik seperti *Support Vector Machine* (SVM) atau *K-Nearest Neighbors* (KNN) yang membutuhkan input fitur yang telah diekstraksi sebelumnya (seperti deteksi tepi atau histogram warna), CNN mampu mempelajari hierarki fitur secara mandiri langsung dari piksel mentah (Minarno, Fadhlan, Munarko, & Chandranegara, 2024).



Gambar 1. Arsitektur CNN

Struktur CNN terdiri dari input, proses ekstraksi fitur, proses klasifikasi dan *output*. Proses ekstraksi dalam CNN terdiri dari beberapa lapisan tersembunyi atau *hidden layer*, yaitu lapisan konvolusi, fungsi aktivasi, *pooling*, dan *flattening*. CNN bekerja secara hierarki, sehingga *output* pada lapisan konvolusi pertama digunakan sebagai input pada lapisan konvolusi selanjutnya. Pada proses klasifikasi terdiri dari *fully connected* dan fungsi aktivasi *softmax* yang *output*-nya berupa hasil klasifikasi (Fauzi Jessar, Toto Wibowo, & Rachmawati, 2021). CNN memiliki input tensor sebagai berikut:

$$N \times H_{in} \times W_{in} \times C_{in} \quad (1)$$

Keterangan:

N : jumlah input (*batch size*).

H_{in} : tinggi dari input (*height*).

W_{in} : lebar dari input (*width*).

C_{in} : jumlah kanal pada input (*input channels*).

Kemudian memiliki output sebagai berikut:

$$N \times H_{out} \times W_{out} \times C_{out} \quad (2)$$

Keterangan:

H_{out} : tinggi peta fitur (*height*) setelah konvolusi.

W_{out} : lebar peta fitur (*width*) setelah konvolusi.

C_{out} : jumlah kanal peta fitur (*output channels*), yang dihasilkan oleh filter konvolusi.

3) Matriks Evaluasi

Untuk mengukur kinerja model klasifikasi citra maka digunakan *confusion matrix*. Matriks ini merangkum hasil prediksi dengan membandingkannya terhadap label aktual dengan empat komponen utama, yaitu *True Positive* (TP) sebagai jumlah data positif yang diprediksi dengan benar, *True Negative* (TN) sebagai jumlah data negatif yang diprediksi dengan benar, *False Positive* (FP) sebagai jumlah data negatif yang salah diprediksi sebagai positif, dan *False Negative* (FN) sebagai jumlah data positif yang salah diprediksi sebagai negatif. Beberapa metrik yang umum digunakan antara lain akurasi, presisi, recall, dan *F1-score* (Krisnawan, Rabbani, Trimono, & Idhom, 2025). Rumus dari masing-masing matriks dapat dijelaskan sebagai berikut:

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$


$$Presisi = \frac{TP}{TP + FP} \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

$$F1 - score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (6)$$

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan dengan metode *Convolutional Neural Network*, yang merupakan model *supervised learning* untuk klasifikasi citra. Klasifikasi citra aktivitas pengemudi terganggu menggunakan bantuan *software Google Collab* dan *Python Programming Language*. Berikut visualisasi dari langkah-langkah metode penelitian:



Gambar 2. Flowchart Klasifikasi Citra dengan CNN

Tahapan penelitian dirancang mengikuti alur sistematis sesuai flowchart penelitian, meliputi pengumpulan data hingga evaluasi model, sebagai berikut:

A. Pengumpulan Data

Pengumpulan data dilakukan dengan mengambil data *State Farm Distracted Driver Detection* dari situs *kaggle.com*. Secara total, data ini berjumlah 22.424 citra untuk masing-masing dataset dengan kemudi sebelah kiri dan kanan. Tabel 1 menunjukkan label pada dataset, contoh sampel gambarnya, dan jumlah citra untuk masing-masing label pada kedua dataset.

Tabel 1. Data Citra Aktivitas Pengemudi Terganggu

No	Nama Label/Kelas	Sampel Data Citra Kemudi Sebelah Kiri	Sampel Data Citra Kemudi Sebelah Kanan	Jumlah Citra
1	c0 (<i>Safe driving</i>)			2.489
2	c1 (<i>Texting-right</i>)			2.267
3	c2 (<i>Calling on the phone-right</i>)			2.317
4	c3 (<i>Texting-left</i>)			2.346
5	c4 (<i>Calling on the phone-left</i>)			2.326
6	c5 (<i>Operating the radio</i>)			2.312
7	c6 (<i>Drinking</i>)			2.325
8	c7 (<i>Reaching behind</i>)			2.002
9	c8 (<i>Hair and makeup</i>)			1.911
10	c9 (<i>Talking to the passenger</i>)			2.129
Total	-	-	-	22.424

B. Data Preprocessing

Seluruh data yang diperoleh kemudian dilakukan tahap *preprocessing* agar data gambar siap digunakan lebih lanjut. Tahapan ini mencakup proses pembagian dataset untuk membagi dataset menjadi dua bagian, yaitu 70% untuk data pelatihan (*training set*) dan 30% untuk data pengujian (*testing set*), rasio ini dipilih karena pada penelitian ini memberikan keseimbangan antara jumlah data yang cukup untuk melatih model dan jumlah data yang cukup untuk menguji performa model terhadap data yang belum pernah dilihat sebelumnya. Kemudian proses *image resizing* untuk menyesuaikan format dan ukuran gambar agar dapat diolah oleh komputer, proses ini juga yang akan menambahkan variasi ukuran citra input nantinya (Talebi & Milanfar, 2021). Lalu proses *standarization & normalization* untuk membuat nilai pixel menjadi skala yang relatif sama dan mempercepat proses pengolahan gambar (Fei, Gao, Lu, & Xiang, 2021).

C. Pemodelan CNN

Data citra yang telah dikumpulkan sebelumnya dan telah melalui proses preprocessing, diklasifikasikan menggunakan model CNN sederhana. Pemilihan CNN didasarkan karena merupakan salah satu model pembelajaran mendalam yang efektif dalam mengekstraksi fitur visual dari data gambar melalui lapisan konvolusional yang berurutan, sehingga sangat cocok untuk tugas pengenalan pola pada citra digital. CNN telah banyak diadopsi dalam penelitian klasifikasi citra dengan akurasi tinggi di berbagai domain aplikasi, seperti pengenalan penyakit tanaman, objek visual, maupun pengenalan wajah (Linda, kusrini, & Hartanto, 2024).

D. Evaluasi

Tahap akhir dalam penelitian ini adalah evaluasi kinerja model menggunakan beberapa metrik, yaitu akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix*. Evaluasi ini bertujuan untuk menilai kemampuan model dalam mengklasifikasikan citra secara akurat. Akurasi mengukur proporsi prediksi yang benar secara keseluruhan, presisi menunjukkan ketepatan dalam memprediksi kelas positif, *recall* mengukur seberapa baik model mendeteksi semua data positif, sedangkan *F1-score* merepresentasikan keseimbangan antara presisi dan *recall*. Sementara itu, *confusion matrix* memberikan gambaran menyeluruh terhadap pola klasifikasi dan kesalahan yang terjadi. Melalui metrik ini, dapat diketahui sejauh mana model mampu mengklasifikasi secara akurat untuk setiap kelas, pada setiap dataset kemudi sebelah kanan dan kiri, dan pada berbagai variasi ukuran citra input (Anggraini & Alita, 2024).

4. HASIL DAN PEMBAHASAN


Berikut adalah hasil dan pembahasan penelitian dengan metodologi pemodelan klasifikasi citra aktivitas pengemudi terganggu menggunakan *Convolutional Neural Network* (CNN).

A. Pengumpulan Data

Pengumpulan data citra aktivitas pengemudi terganggu dilakukan dengan mengambil data dari situs *kaggle.com* dengan kata kunci *State Farm Distracted Driver Detection*. Dataset ini juga memiliki versi kemudi sebelah kanan dan kemudi sebelah kiri, yang keduanya digunakan pada penelitian ini untuk dibandingkan. Dataset ini memiliki total jumlah citra sebanyak 22.424 dan berukuran 1-2 GB.

B. Data Preprocessing


Sebelum dilakukan proses klasifikasi citra, data terlebih dahulu melalui serangkaian tahapan *preprocessing* untuk menyiapkannya dalam bentuk yang sesuai bagi model. Tahap *preprocessing* dimulai dengan pembagian dataset menjadi dua bagian, yaitu data latih untuk melatih model klasifikasi dan data uji untuk mengevaluasi kinerjanya. Pembagian data dilakukan dengan proporsi 70% untuk pelatihan data 30% untuk pengujian. Kemudian dilakukan *image resizing* yang diperlihatkan seperti gambar dibawah ini.



Gambar 3. Sampel Variasi Ukuran Citra Input

Image resizing ini bertujuan untuk menyesuaikan ukuran citra input dengan ukuran yang konsisten, sehingga ukuran citra asli yang berukuran 480x640 diubah menjadi 96x96, 128x128, 160x160, dan 224x224. Selain dilakukan untuk menyesuaikan ukuran citra input kepada model

CNN, hal ini juga dilakukan untuk mengurangi beban komputasi, dan ukuran citra input yang konsisten dapat dilakukan perbandingan seperti yang dilakukan pada penelitian ini. Ukuran 96x96, 128x128, 160x160, dan 224x224 dipilih untuk perbandingan karena ukuran-ukuran tersebut merupakan rentang umum yang diuji dalam literatur untuk mengevaluasi trade-off antara informasi visual dengan kompleksitas komputasi, yang dapat mempengaruhi performa model untuk setiap ukuran yang berbeda (Tang dkk., 2023). Setelah itu, dilakukan *standarization & normalization* untuk membuat nilai pixel menjadi skala yang relatif sama dan mempercepat proses pengolahan gambar, seperti yang ditunjukkan pada gambar dibawah ini.



Gambar 4. Sampel Hasil *Normalization & Standarization*

Hasil visualisasi menunjukkan bahwa normalisasi [0,1] hanya mengubah rentang nilai piksel tanpa mengubah bentuk distribusinya, sedangkan standardisasi *Z-score* menghasilkan distribusi piksel yang terpusat di sekitar nol dengan standar deviasi mendekati satu. Hal ini menunjukkan bahwa standardisasi mampu menormalkan variasi intensitas antar citra, sehingga berpotensi meningkatkan stabilitas dan konsistensi proses pelatihan model CNN. Proses *preprocessing* ini tentunya juga dilakukan pada dataset citra kemudi sebelah kiri.

C. Pemodelan CNN

Pada tahap pemodelan, penelitian ini diawali dengan merancang eksperimen untuk mengkaji pengaruh variasi ukuran citra input terhadap kinerja model CNN. Empat ukuran citra digunakan, yaitu 96×96, 128×128, 160×160, dan 224×224 piksel. Setiap ukuran citra diperlakukan sebagai satu skenario eksperimen yang berdiri sendiri, sehingga memungkinkan

analisis perbandingan performa model secara objektif. Model yang digunakan merupakan CNN sederhana bertingkat (deep CNN) dengan struktur yang sama untuk seluruh eksperimen ukuran citra. Arsitektur ini terdiri dari beberapa komponen utama, yaitu lapisan konvolusi, *batch normalization*, *max pooling*, *dropout*, *global average pooling*, dan lapisan *fully connected (dense layer)*. Struktur ini dirancang agar cukup representatif untuk analisis dampak ukuran citra, namun tetap efisien secara komputasi.

Setiap model CNN dilakukan proses pelatihan dengan parameter utama sebagai berikut:

- *Optimizer*: Adam
- *Learning rate* awal: 0,001
- Fungsi *loss*: *Sparse Categorical Crossentropy*
- Jumlah *epoch* maksimum: 30

Kemudian untuk meningkatkan kualitas pelatihan, diterapkan beberapa mekanisme kontrol, yaitu:

- *Early Stopping* untuk menghentikan pelatihan ketika performa validasi tidak lagi meningkat.
- *Reduce Learning Rate on Plateau* untuk menyesuaikan laju pembelajaran saat model mengalami stagnasi.
- *Model Checkpoint* untuk menyimpan bobot model terbaik berdasarkan akurasi validasi.

Selain itu, waktu pelatihan dan jumlah parameter model dicatat untuk setiap ukuran citra guna mendukung analisis efisiensi.

D. Evaluasi

Setelah pemodelan CNN selesai, model terbaik untuk setiap ukuran citra dievaluasi menggunakan data uji yang tidak pernah dilihat sebelumnya oleh model. Evaluasi dilakukan menggunakan beberapa metrik, yaitu akurasi, *precision*, *recall*, dan *f1-score*. Hasil pelatihan dan evaluasi dari seluruh ukuran citra kemudian dibandingkan untuk menganalisis perubahan akurasi model seiring peningkatan resolusi citra, dampak ukuran citra terhadap waktu pelatihan, dan *trade-off* antara performa dan kompleksitas model. Kemudian juga dilakukan perbandingan hasil evaluasi terhadap kedua dataset kemudi sebelah kanan dan kiri. Berikut ini adalah tabel komparasi perbandingan hasil evaluasi:


Tabel 2. Hasil Evaluasi Dataset Kemudi Sebelah Kanan

<i>Image Size</i>	<i>Training Time (s)</i>	<i>Training Time (m)</i>	<i>Val Accuracy</i>	<i>Test Accuracy</i>	<i>Test F1-score</i>	<i>Total Parameters</i>	<i>Params per Pixel</i>
96	1097.9529	18.2992	0.9938	0.9938	0.9938	166890	18.1087
128	1160.4373	19.3406	0.9923	0.9911	0.9911	166890	10.1862
160	1489.9220	24.8320	0.9952	0.9938	0.9938	166890	6.5191
224	2185.2435	36.4207	0.9964	0.9944	0.9944	166890	3.3261


Tabel 3. Hasil Evaluasi Dataset Kemudi Sebelah Kiri

<i>Image Size</i>	<i>Training Time (s)</i>	<i>Training Time (m)</i>	<i>Val Accuracy</i>	<i>Test Accuracy</i>	<i>Test F1-score</i>	<i>Total Parameters</i>	<i>Params per Pixel</i>
96	1109.9313	18.4989	0.9949	0.9955	.9955	166890	18.1087
128	1061.3056	17.6884	0.9926	0.9923	0.9923	166890	10.1862
160	1255.0983	20.9183	0.9941	0.9926	0.9925	166890	6.5191
224	2166.6283	36.1105	0.9911	0.9908	0.9908	166890	3.3261


Tabel evaluasi menunjukkan bahwa secara keseluruhan model CNN menghasilkan nilai akurasi yang tinggi untuk semua variasi citra input dan kedua dataset. Tetapi jika dilihat secara spesifik, perbedaan antara penggunaan dataset kemudi sebelah kanan dan kiri tidak mempengaruhi kinerja model CNN secara signifikan. Hal tersebut dibuktikan oleh nilai akurasi yang relatif sama untuk kedua dataset, dan waktu pelatihan (training time) yang relatif sama juga. Kemudian hal tersebut juga sama dengan perbedaan variasi citra terhadap nilai akurasi model, yang menunjukkan bahwa nilai akurasi model tidak berbeda jauh antar variasi ukuran citra input, baik pada dataset kemudi sebelah kanan maupun kiri. Walaupun variasi ukuran citra input yang digunakan tidak secara signifikan mempengaruhi nilai akurasi model, tetapi hal tersebut mempengaruhi durasi waktu pelatihan yang lebih terlihat. Hal tersebut dibuktikan dengan tren semakin besar ukuran citra input semakin lama juga durasi waktu pelatihannya. Dengan mempertimbangkan hal tersebut, ukuran citra input 96 dan 128 merupakan ukuran citra input yang paling ideal dibandingkan ukuran citra input yang lainnya. Hal tersebut dikarenakan nilai akurasi yang tidak berbeda secara signifikan, tetapi memakan waktu pelatihan yang lebih lama, semakin tingginya nilai ukuran citra input pada konteks data citra aktivitas pengemudi terganggu ini. Secara spesifik ukuran citra input 96 lebih ideal untuk dataset kemudi sebelah kiri, dan ukuran citra input 128 lebih ideal untuk dataset kemudi sebelah kanan, dan hal tersebut didukung oleh *plot loss* pelatihan dan akurasi dibawah ini:




Gambar 5. Plot Loss Pelatihan dan Akurasi Kemudi Kanan Ukuran 96



Gambar 6. Plot Loss Pelatihan dan Akurasi Kemudi Kanan Ukuran 128



Gambar 7. Plot Loss Pelatihan dan Akurasi Kemudi Kiri Ukuran 96



Gambar 8. Plot Loss Pelatihan dan Akurasi Kemudi Kiri Ukuran 128

Dari Gambar 5, 6, 7, dan 8 terlihat bahwa ukuran citra input 128 lebih stabil dan lebih konsisten pada saat pelatihan menggunakan dataset kemudi sebelah kanan dibandingkan dengan ukuran citra input 96. Sebaliknya, ukuran citra input 96 lebih stabil pada saat pelatihan menggunakan dataset kemudi sebelah kiri dibandingkan dengan ukuran citra input 128. Perbedaan stabilitas pelatihan pada dataset kemudi kiri menunjukkan bahwa resolusi input yang lebih besar tidak selalu menghasilkan kinerja yang lebih baik. Pada kasus ini, ukuran 96×96 memberikan pembelajaran yang lebih stabil karena mampu menekan noise latar belakang dan mempertahankan fitur global yang relevan, seperti pose tangan dan orientasi tubuh pengemudi. Sebaliknya, ukuran 128×128 menangkap lebih banyak detail visual yang tidak relevan sehingga meningkatkan variansi gradien dan menyebabkan fluktuasi pada kurva *loss* dan akurasi validasi.

5. KESIMPULAN DAN SARAN

Hasil penelitian menunjukkan bahwa model Convolutional Neural Network (CNN) mampu melakukan klasifikasi citra secara efektif terhadap aktivitas pengemudi terganggu. Hasil evaluasi menunjukkan performa yang konsisten pada dataset kemudi sebelah kanan maupun kiri dan pada berbagai variasi ukuran citra input, yaitu dengan akurasi sekitar 99%. Lebih lanjut lagi, hasil penelitian ini tidak menunjukkan perbedaan yang signifikan antara dataset kemudi sebelah kanan dengan kiri dari segi nilai akurasi dan performa model. Hal ini dikarenakan kedua dataset yang jumlah dan variasi citra-nya relatif sama dibandingkan dengan penelitian yang dilakukan sebelumnya. Kemudian hasil penelitian ini juga menunjukkan bahwa ukuran citra input tidak mempengaruhi nilai akurasi model CNN secara signifikan, tetapi lebih mempengaruhi durasi waktu pelatihan, semakin tinggi ukuran citra, maka semakin lama juga durasi waktu pelatihannya. Hal tersebut menjadikan ukuran citra input 128×128 piksel paling ideal untuk dataset kemudi kanan, dan ukuran citra input 96×96 piksel paling ideal untuk dataset kemudi kiri.

Meskipun penelitian ini menunjukkan akurasi yang memadai untuk model CNN, penelitian ini juga mengidentifikasi beberapa keterbatasan, yaitu keterbatasan hanya menggunakan model CNN sederhana, penggunaan metode lain dan pengujiannya secara *real-time* dapat dilakukan pada penelitian di masa depan. Karena walaupun model CNN ini dapat menghasilkan nilai akurasi yang baik, jika diimplementasikan pada dunia nyata masih diperlukan penelitian lebih lanjut, dan juga pertimbangan membandingkan dengan metode lainnya seperti ResNet, MobileNet, dan EfficientNet. Secara keseluruhan, hasil penelitian ini

memberikan kontribusi penting dalam pengembangan sistem deteksi distraksi pengemudi, terutama mengenai efek perbedaan kemudi sebelah kanan dan kiri serta variasi ukuran citra input terhadap kinerja model CNN.

DAFTAR REFERENSI

Artikel Jurnal

- Amalia, D., & Utaminingrum, F. (2021). Deteksi Kantuk pada Pengemudi melalui Jumlah Kedipan Mata Menggunakan Facial Landmark berbasis Intel NUC. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 5(12), 5529–5535. Diambil dari <http://j-ptiik.ub.ac.id>
- Anggraini, J., & Alita, D. (2024). Implementasi Metode SVM Pada Sentimen Analisis Terhadap Pemilihan Presiden (Pilpres) 2024 Di Twitter. *Jurnal Informatika: Jurnal Pengembangan IT*, 9(2), 102–111. <https://doi.org/10.30591/jpit.v9i2.6560>
- Faizal Nazili, M., Firmansyah, A. B., & Purbaningtyas, R. (2023). Klasifikasi Keparahan Demensia Alzheimer Menggunakan Metode Convolutional Neural Network pada Citra MRI Otak. *Indonesian Journal of Machine Learning and Computer Science*, 3(1), 1–7.
- Fei, N., Gao, Y., Lu, Z., & Xiang, T. (2021). *Z-Score Normalization, Hubness, and Few-Shot Learning*.
- Firdaus, S., & Artika, K. D. (2021). DETEKSI KELELAHAN PENGEMUDI MOBIL MENGGUNAKAN CITRA WAJAH. *ELEMEN : JURNAL TEKNIK MESIN*, 8(1), 16–21. <https://doi.org/10.34128/je.v8i1.154>
- Hermawan, G. (2024). Klasifikasi Pengemudi Terganggu Berdasarkan Citra Menggunakan ResNet-50. *Jurnal Informatika Komputer, Bisnis dan Manajemen*, 22(3). <https://doi.org/https://doi.org/10.61805/fahma.v22i3.137>
- Hidayat, M. A., Latifah Husni, N., & Damsi, F. (2022). Pendeteksi Banjir dengan Image Processing Berbasis Convolutional Neural Network (CNN) pada Kamera Pengawas. *Indonesian Journal of Machine Learning and Computer Science*, 2(2), 10–18.
- Krisnawan, Rabbani, Z., Trimono, & Idhom, M. (2025). Analisis sentimen program makan bergizi gratis menggunakan bidirectional gated recurrent unit. *IT-EXPLORE*, 4(3). <https://doi.org/10.24246/itexplore.v4i3.2025.pp282-294>
- Linda, K., kusrini, & Hartanto, A. (2024). Studi Literatur Mengenai Klasifikasi Citra Kucing Dengan Menggunakan Deep Learning: Convolutional Neural Network (CNN). *Journal of Electrical Engineering and Computer (JEECOM)*, 6(1). <https://doi.org/10.33650/jeeecom.v4i2>
- Mienye, I. D., Swart, T. G., Obaido, G., Jordan, M., & Ilono, P. (2025, Maret 1). Deep Convolutional Neural Networks in Medical Image Analysis: A Review. *Information (Switzerland)*, Vol. 16. Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/info16030195>
- Minarno, A. E., Fadhlani, M., Munarko, Y., & Chandranegara, R. (2024). Classification of Dermoscopic Images Using CNN-SVM. *INTERNATIONAL JOURNAL ON INFORMATICS VISUALIZATION*, 8(2). Diambil dari www.joiv.org/index.php/joiv

- Nugroho, B., & Yulia, E. (2021). KINERJA METODE CNN UNTUK KLASIFIKASI PNEUMONIA DENGAN VARIASI UKURAN CITRA INPUT. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 8(3), 533–538. <https://doi.org/10.25126/jtiik.202184515>
- Putra, N. S., Hutabarat, B. F., & Khaira, U. (2023). Implementasi Algoritma Convolutional Neural Network Untuk Identifikasi Jenis Kelamin Dan Ras. *Decode: Jurnal Pendidikan Teknologi Informasi*, 3(1), 82–93. <https://doi.org/10.51454/decode.v3i1.123>
- Robot, R. F., Lolowang, K., & Putro, D. (2024). Lightweight Convolutional Neural Network Architecture For Facial Expression Recognition Arsitektur Convolutional Neural Network Ringan Untuk Pengenalan Ekspresi Wajah. *Jurnal Teknik Elektro dan Komputer*, 13(01), 35–40.
- Salakapuri, R., Navuri, N. K., Vobbilineni, T., Ravi, G., Karmakonda, K., & vardhan, K. A. (2025). Integrated deep learning framework for driver distraction detection and real-time road object recognition in advanced driver assistance systems. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-025-08475-4>
- Shevtekar, S., & Gangurde, Y. (2024). Towards Safer Roads: A Deep Learning Approach to Driver Distraction Detection in Four-Wheeler Cars. *International Journal for Multidisciplinary Research*, 6(3). Diambil dari www.ijfmr.com
- Tang, S., Jing, C., Jiang, Y., Yang, K., Huang, Z., Wu, H., ... Dong, F. (2023). The effect of image resolution on convolutional neural networks in breast ultrasound. *Heliyon*, 9(8), e19253. <https://doi.org/10.1016/j.heliyon.2023.e19253>
- Uzzol Hossain, M., Ataur Rahman, M., Manowarul Islam, M., Akhter, A., Ashraf Uddin, M., & Kumar Paul, B. (2022). Automatic driver distraction detection using deep convolutional neural networks. *Intelligent Systems with Applications*, 14, 75. <https://doi.org/10.1016/j.iswa.2022.20>

Artikel Prosiding

- Fauzi Jessar, H., Toto Wibowo, A., & Rachmawati, E. (2021). Klasifikasi Genus Tanaman Sukulen Menggunakan Convolutional Neural Network. *e-Proceeding of Engineering*, 8(2).
- Talebi, H., & Milanfar, P. (2021). *Learning to Resize Images for Computer Vision Tasks*.