

# EFEKTIVITAS PENGGOLONGAN KENDARAAN DENGAN METODE CNN PADA SISTEM TRANSAKSI DI GERBANG TOL

Aditya Pratama<sup>1)</sup>, Hastha Sunardi.<sup>2)</sup>, Ricky Maulana Fajri<sup>3)</sup>

Program Studi Sistem Komputer UNIVERSITAS INDO GLOBAL MANDIRI

JL. Jend Sudirman No. 629, Palembang 30129, Sumatera Selatan

Email: 2019310026@students.uigm.ac.id<sup>1)</sup>, hastha\_s@uigm.ac.id<sup>2)</sup>, rickymaulanafajri@uigm.ac.id<sup>3)</sup>

## ABSTRAK

Penelitian ini mengusulkan penerapan metode klasifikasi citra multikelas untuk meningkatkan efektivitas penggolongan kendaraan dalam sistem transaksi di gerbang. Metode ini menggunakan pendekatan pembelajaran mesin untuk mengenali dan mengelompokkan kendaraan berdasarkan citra yang diperoleh dari sistem pengawasan gerbang. Penelitian ini bertujuan untuk meningkatkan akurasi dan kecepatan penggolongan kendaraan, sehingga dapat mendukung efisiensi dalam proses transaksi gerbang. Pengujian dilakukan menggunakan dataset beragam kendaraan dan hasilnya menunjukkan peningkatan yang signifikan dalam klasifikasi kendaraan secara akurat. Implementasi metode ini diharapkan dapat memberikan kontribusi positif terhadap pengembangan sistem transaksi di gerbang, meningkatkan keandalan dan kecepatan layanan.

Kata Kunci: *Convolutional Neural Network, CNN, Multiclass Image Classification, Jalan Tol.*

## ABSTRACT

*This research proposes the application of a multiclass image classification method to increase the effectiveness of vehicle classification in the gate transaction system. This method uses a machine learning approach to recognize and classify vehicles based on images obtained from the gate monitoring system. This research aims to increase the accuracy and speed of vehicle classification, so that it can support efficiency in the gate transaction process. Testing was carried out using a diverse vehicle dataset and the results showed significant improvements in accurate vehicle classification. The implementation of this method is expected to make a positive contribution to the development of the transaction system at the gateway, increasing the reliability and speed of service.*

*Keywords: Convolutional Neural Network, CNN, Multiclass Image Classification, Toll Road.*

## 1. PENDAHULUAN

### 1.1 Latar Belakang

Gerbang tol adalah tempat di mana transaksi dan pembayaran tol dilakukan sebelum pengguna jalan tol melewati pintu masuk atau keluar jalan tol. Gerbang tol dilengkapi dengan berbagai fasilitas dan sistem untuk memfasilitasi pembayaran tol, serta memeriksa kelengkapan dokumen kendaraan dan memastikan pembayaran tol telah dilakukan dengan benar. Penting untuk diingat bahwa gerbang tol sangat berperan dalam mengatur lalu lintas jalan tol dan memastikan keamanan serta kenyamanan pengguna jalan tol[1].

Transaksi di gerbang tol pada awalnya adalah menggunakan transaksi tunai (menggunakan uang kertas) untuk dapat melintas, pengguna jalan tol harus membayar dengan uang tunai sesuai dengan tarif yang berlaku (tarif berdasarkan asal gerbang dan jenis golongan kendaraan). Transaksi secara tunai kerap kali menimbulkan antrean karena petugas harus memastikan kembali nominal uang dan keaslian uang adalah asli[2].

Sistem pembayaran jalan tol di Indonesia berubah menjadi sistem pembayaran *Multi Lane Free Flow* (MLFF) Pada akhir tahun 2022. electronic payment system adalah implementasi

teknologi pada sistem pembayaran yang dapat membuat aktivitas perbankan menjadi lebih cepat, tepat, dan akurat serta dapat meningkatkan produktivitas perbankan.

Untuk melakukan pembayaran secara elektronik maka diberlakukan pembayaran menggunakan E-Toll. E-toll merupakan alat pembayaran berupa kartu elektronik yang dapat digunakan untuk pembayaran saat masuk jalan tol. Selain sebagai sistem pembayaran di gerbang tol kehadiran E-toll juga diharapkan dapat mengurangi kemacetan pada saat antre di gerbang tol dan sebagai satu langkah modernisasi dari sistem pembayaran[3].

Penggolongan kendaraan juga penting untuk Badan Usaha Jalan Tol (BUJT) karena kendaraan dihitung dan dipisahkan berdasarkan kelasnya, untuk analisis terkait kerugian, pendapatan, serta menghukum kendaraan yang memiliki berat atau panjang kendaraan yang tidak semestinya[4].

Untuk mengurangi kesalahan dalam pemilihan golongan di gerbang tol penelitian ini menggunakan metode *Convolutional Neural Network* (CNN). Metode CNN adalah metode deep learning yang

dapat belajar sendiri untuk mengenali objek, mengekstraksi objek, dan mengklasifikasikannya. Metode ini juga bisa digunakan pada citra dengan resolusi tinggi dan memiliki pola distribusi yang tidak terbatas oleh parameter. Penelitian ini menggunakan foto objek kendaraan yang dipotret dari samping. Dengan metode CNN tersebut diharapkan untuk mengurangi hasil kesalahan dari pemilihan golongan di gerbang tol.

Penelitian ini dilatar belakangi oleh penelitian-penelitian terdahulu. Berdasarkan penelitian yang dilakukan oleh Febri Hanifah, Sayuti Rahman, dan Munjiat Setiani Asih, mereka memperoleh kesimpulan bahwa pendeteksian jenis kendaraan sangat dibutuhkan untuk dapat diaplikasikan di berbagai bidang, salah satunya mengatur lalu lintas dengan cara mendeteksi bentuk fisik atau jenis dari kendaraan yang lewat sehingga dapat mengurangi kemacetan[5]. penelitian ini mengusulkan metode identifikasi ulang kendaraan dengan struktur CNN simetris saluran ganda, algoritma ini memasukkan dia sampel sekaligus yang memiliki karakteristik yang saling melengkapi[6].

## 1.2 Perumusan Masalah

Gerbang tol merupakan aspek penting dalam pengoperasian jalan tol. Salah satu faktor yang menyebabkan kesalahan dalam pemilihan golongan kendaraan di antrian gerbang tol adalah banyaknya kendaraan yang mengantri dengan golongan yang berbeda-beda, tak jarang petugas gerbang tol kesulitan melihat golongan dengan baik sehingga menyebabkan kesalahan dalam pemilihan golongan kendaraan dan menyebabkan komplain pada pihak operasional tol.

Rumusan masalah dalam penelitian ini adalah sebagai berikut :

1. Penggunaan metode CNN sebagai peningkatan akurasi dan kecepatan dalam memproses data kendaraan di antrian gerbang tol.
2. Penggunaan salah satu metode CNN untuk pengklasifikasian kendaraan ke dalam sistem pembayaran di gerbang tol untuk mempermudah dan mengurangi waktu tunggu pada antrian.
3. Agar dapat mengenali berbagai jenis kendaraan pada antrian gerbang tol maka penelitian ini menggunakan salah satu metode CNN untuk mengklasifikasi golongan kendaraan.

## 1.3 Manfaat Penelitian

Adapun manfaat penelitian ini yaitu :

1. Mempermudah penggunaan jalan tol dan mengurangi waktu tunggu pada antrian, sehingga dapat meningkatkan kenyamanan dan efisiensi dalam bertransportasi.
2. Meningkatkan akurasi dan kecepatan dalam proses pembayaran pada gerbang

tol, sehingga dapat mengurangi kemacetan dan kepadatan lalu lintas di gerbang tol.

3. Meningkatkan pengawasan dan pengendalian atas penggunaan jalan tol, sehingga dapat meningkatkan keamanan dan keteraturan dalam penggunaan jalan tol serta meningkatkan pengumpulan pendapatan negara dari sektor transportasi.

## 2. PEMBAHASAN

### 2.1 Jalan Tol

Jalan tol atau jalan bebas hambatan adalah jalan raya yang didesain untuk memudahkan mobilitas antar wilayah, terutama untuk kendaraan bermotor seperti mobil dan truk. Jalan tol biasanya memiliki jalur yang terpisah untuk kendaraan yang berjalan ke arah berlawanan dan juga memiliki akses yang terbatas, sehingga kendaraan hanya bisa keluar atau masuk melalui gerbang tol.[2] .



Gambar 1 Gerbang Tol Kramasan

### 2.2 Gardu Tol Otomatis

Gardu tol otomatis dapat dianggap sebagai peningkatan dari gardu tol sebelumnya karena sistem pembayaran tol yang menggunakan teknologi otomatis ini memberikan beberapa keuntungan dan perbaikan dibandingkan dengan sistem

pembayaran tol yang membutuhkan interaksi langsung antara pengguna tol dan petugas tol seperti pada gardu tol lama. Beberapa keuntungan dari gardu tol otomatis antara lain adalah:

1. *Efisiensi waktu:* Pengguna tol dapat membayar tol secara cepat tanpa harus menunggu petugas tol untuk memproses transaksi.

2. *Kemudahan:* Dengan menggunakan sistem pembayaran elektronik seperti kartu tol atau e-wallet, pengguna tol tidak perlu membawa uang tunai dalam jumlah besar.

3. *Pengurangan antrian:* Dalam sistem pembayaran tol otomatis, gerbang tol dapat menangani volume kendaraan yang lebih besar dalam waktu yang lebih singkat, sehingga mengurangi kemacetan dan antrian pada gerbang tol.

4. *Akurasi:* Dengan penggunaan teknologi otomatis, kesalahan transaksi dapat diminimalkan, seperti kesalahan dalam perhitungan harga tol atau kembalian uang.

Dalam hal ini, gardu tol otomatis memberikan perbaikan dan peningkatan dibandingkan dengan gardu tol lama yang membutuhkan interaksi langsung antara pengguna tol dan petugas tol dalam melakukan transaksi pembayaran tol.[7][8]


### 2.3 Transaksi Non Tunai

Transaksi non-tunai adalah pembayaran dilakukan secara elektronik dan informasi pembayaran diakses melalui sistem teknologi informasi, sehingga dapat dilakukan secara online atau offline. Transaksi non-tunai lebih mudah dan cepat karena tidak memerlukan penghitungan uang secara fisik, sehingga dapat menghemat waktu dan mengurangi risiko kehilangan uang. Selain itu, transaksi non-tunai juga lebih aman.[9]

### 2.4 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu jenis arsitektur Neural Network yang paling sering digunakan dalam pemrosesan citra dan pengenalan pola visual. CNN memproses data input (biasanya gambar) dengan membaginya menjadi beberapa blok kecil, kemudian melakukan operasi konvolusi pada setiap blok tersebut. Proses konvolusi tersebut melibatkan penggunaan kernel (filter) untuk menghasilkan feature map, yaitu representasi numerik dari fitur-fitur visual pada gambar.[12]

CNN terdiri dari beberapa layer, yaitu *Convolutional layer*, *Pooling layer*, dan *Fully Connected layer*. *Convolutional layer* bertanggung jawab untuk mengekstraksi fitur dari input gambar, *Pooling layer* digunakan untuk mengurangi dimensi output dari *Convolutional layer*, dan *Fully Connected layer* bertanggung jawab untuk mengklasifikasikan output dari layer sebelumnya ke dalam kelas-kelas yang sesuai.[8]



Gambar 2 Konsep Dasar CNN

### 2.5 Citra

Citra atau gambar adalah representasi visual dari suatu objek atau data. Dalam pemrograman, citra dapat direpresentasikan dalam format digital atau raster, yang terdiri dari kumpulan piksel atau titik-titik kecil yang membentuk gambar. Citra dapat digunakan dalam berbagai aplikasi pemrograman, termasuk pengolahan citra, pengenalan pola, dan visi komputer.[10]

### 2.6 Jupyter Notebook

Jupyter Notebook adalah aplikasi *web open-source* yang memungkinkan pengguna untuk membuat dan berbagi dokumen yang berisi kode

pemrograman, narasi teks, persamaan matematika, visualisasi, dan konten interaktif lainnya. Aplikasi ini sangat populer di kalangan data scientist, peneliti, dan pengembang perangkat lunak karena memudahkan eksplorasi data dan pengembangan prototipe dengan cepat dan mudah.[11]

### 2.7 Konsep Dasar CNN

Convolutional Neural Network (CNN) adalah salah satu jenis arsitektur jaringan saraf yang telah membawa perubahan besar dalam bidang pengenalan gambar dan pemrosesan visual. Dengan kemampuannya untuk secara efektif mengekstraksi fitur-fitur penting dari data spasial, CNN telah menjadi salah satu alat paling kuat dalam analisis gambar. Berikut ini adalah beberapa konsep dasar Convolutional Neural Network (CNN):

1. **Konvolusi:** Konvolusi adalah operasi matematis yang mendasar dalam CNN. Ini melibatkan menerapkan filter (juga dikenal sebagai kernel) ke data input dengan langkah yang ditentukan. Filter bergerak melintasi input dengan melakukan perkalian titik pada setiap posisi dan menjumlahkan hasilnya untuk menghasilkan fitur teraktivasi pada setiap langkah.
2. **Filter dan fitur:** Filter dalam CNN adalah matriks bobot yang diterapkan pada data input. Setiap filter mempelajari fitur-fitur spesifik dengan menangkap pola-pola dalam data.
3. **Lapisan konvolusi:** Lapisan konvolusi adalah lapisan utama dalam CNN. Setiap lapisan konvolusi terdiri dari beberapa filter yang diterapkan secara paralel pada input untuk menghasilkan fitur-fitur teraktivasi.
4. **Lapisan pooling:** Lapisan *pooling* digunakan untuk mengurangi dimensi spasial dari fitur-fitur yang dihasilkan oleh lapisan konvolusi. Lapisan *pooling* umumnya menerapkan operasi seperti *Max Pooling* atau *Average Pooling*, di mana nilai maksimum atau rata-rata diambil dari sekelompok nilai dalam peta fitur.
5. **Fungsi aktivasi:** Setelah konvolusi, fungsi aktivasi diterapkan pada setiap elemen peta fitur untuk memperkenalkan non-linearitas. Fungsi aktivasi yang umum digunakan dalam CNN adalah ReLU (*Rectified Linear Unit*), yang menghasilkan keluaran nol untuk input negatif dan mengabaikan input negatif lainnya.
6. **Lapisan fully connected:** Setelah melalui beberapa lapisan konvolusi dan pooling, fitur-fitur yang teraktivasi diubah menjadi

representasi vektor dan disampaikan ke dalam lapisan *fully connected*.


## 2.5 Operasi Konvolusi Pada CNN

Operasi konvolusi adalah komponen kunci dalam *Convolutional Neural Network* (CNN). Ini adalah operasi matematis yang digunakan untuk memproses data input dengan menerapkan filter (juga dikenal sebagai kernel) ke seluruh area input. Proses ini menghasilkan peta fitur yang merepresentasikan fitur-fitur yang teraktivasi pada setiap posisi spasial dalam input.[13]

## 2.6 Fungsi Aktifasi Pada CNN

Untuk memahami bagaimana *Convolutional Neural Network* (CNN) dapat menangkap dan memodelkan hubungan yang kompleks dalam data, penting untuk mengetahui peran fungsi aktivasi dalam jaringan ini.

1. Sigmoid: Menghasilkan output antara 0 dan 1. Cocok untuk klasifikasi biner tetapi rentan terhadap masalah vanishing gradient.
2. ReLU (*Rectified Linear Unit*): Menghasilkan output 0 untuk input negatif dan input itu sendiri untuk input positif. Mempercepat konvergensi tetapi bisa mengalami masalah *dying* ReLU.
3. Softmax: Digunakan di lapisan output untuk klasifikasi multikelas, menghasilkan distribusi probabilitas dengan menjumlahkan semua output menjadi 1.
4. Leaky ReLU: Variasi ReLU yang memungkinkan output negatif dengan kemiringan kecil, mengurangi risiko *dying* ReLU.
5. ELU (*Exponential Linear Unit*): Menghasilkan output negatif eksponensial untuk input negatif dan linear untuk input positif. Meningkatkan pembelajaran dan akurasi dengan mengatasi masalah *dying* ReLU.



Gambar 3 Fungsi Aktifasi Pada CNN

## 2.7 Loss

*Loss* pada *Convolutional Neural Network* (CNN) berfungsi sebagai indikator seberapa efektif model CNN dalam memprediksi data latih dibandingkan dengan label yang seharusnya. Selama proses pelatihan, tujuan utama adalah mengurangi nilai *loss* agar model dapat

menghasilkan prediksi yang semakin mendekati label sebenarnya.[15] beberapa *loss* pada CNN antara lain :

1. *Categorical Cross-Entropy Loss* (Entropi Silang Kategorikal) : Fungsi Categorical Crossentropy digunakan sebagai metrik untuk mengukur seberapa baik model klasifikasi dapat menghasilkan prediksi yang mendekati distribusi kelas yang sebenarnya pada masalah klasifikasi multikelas.[16]

$$\text{Loss} = - \sum_{i=1}^{\text{output size}} y_i \cdot \log \hat{y}_i$$

Gambar 4 *Categorical Cross-Entropy Loss*

$y_i$  adalah label sebenarnya untuk kelas  $i$ .  $\hat{y}_i$  adalah probabilitas prediksi model untuk kelas  $i$ .

2. *Binary Crossentropy* : fungsi *loss* yang umum digunakan pada masalah klasifikasi biner. Fungsi ini mengukur seberapa baik model dapat memprediksi label biner (0 atau 1) untuk setiap contoh data.[17]

$$\text{Loss} = - \frac{1}{\text{output size}} \sum_{i=1}^{\text{output size}} y_i \cdot \log \hat{y}_i + (1 - y_i) \cdot \log (1 - \hat{y}_i)$$

Gambar 5 *Binary Cross-Entropy Loss*

3. *Mean Squared Error* (MSE) : fungsi *loss* yang sering digunakan pada masalah regresi. Fungsi ini mengukur seberapa baik model dapat memprediksi nilai numerik (kontinu) dan seberapa besar perbedaan antara prediksi model dengan nilai sebenarnya.[18]

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (\text{Error Squared}) = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

Gambar 6 *Mean Squared Error*

## 2.8 Evaluation Metric Pada CNN

*Evaluation metric* dalam *Convolutional Neural Network* (CNN) adalah metode atau ukuran yang digunakan untuk mengukur kinerja atau performa model CNN dalam tugas pengolahan citra. *Evaluation metric* memberikan pemahaman tentang sejauh mana model mampu menggeneralisasi dan melakukan prediksi yang akurat.

Berikut adalah beberapa *evaluation metric* umum yang digunakan dalam CNN:

1. Akurasi (*Accuracy*) : Akurasi adalah proporsi klasifikasi yang benar dari semua sampel pengujian. Ini merupakan metrik yang paling umum digunakan untuk tugas klasifikasi dan mengukur persentase prediksi yang benar dari seluruh sampel.[14]  
Presisi (*Precision*): Presisi mengukur proporsi positif benar (*True Positive*) dari semua prediksi positif. Ini memberikan indikasi seberapa baik model dalam mengidentifikasi kelas yang benar.
2. Recall (*Recall*): *Recall* (juga dikenal sebagai sensitivitas) mengukur proporsi positif benar yang diidentifikasi dari semua sampel yang sebenarnya positif. *Recall* memberikan gambaran tentang kemampuan model dalam menemukan semua kasus positif.
3. F1-Skor (*F1-Score*) adalah rata-rata harmonik antara presisi dan *recall*. *F1-Score* memberikan keseimbangan antara presisi dan *recall*, dan umumnya digunakan ketika kelas positif dan negatif tidak seimbang.
4. *Mean Average Precision* (MAP): MAP digunakan dalam tugas deteksi objek dan mengukur kualitas peringkat prediksi. Ini menghitung rata-rata presisi pada berbagai tingkat ambang batas dan memberikan gambaran tentang kualitas dan urutan prediksi.
5. *Intersection over Union* (IoU): IoU adalah metrik yang sering digunakan dalam tugas segmentasi citra. Ini mengukur sejauh mana prediksi segmentasi model cocok dengan segmentasi yang sebenarnya. IoU dihitung dengan membagi luas area yang tumpang tindih antara prediksi dan *ground truth* dengan luas total kedua area.

### 3. METODOLOGI PENELITIAN

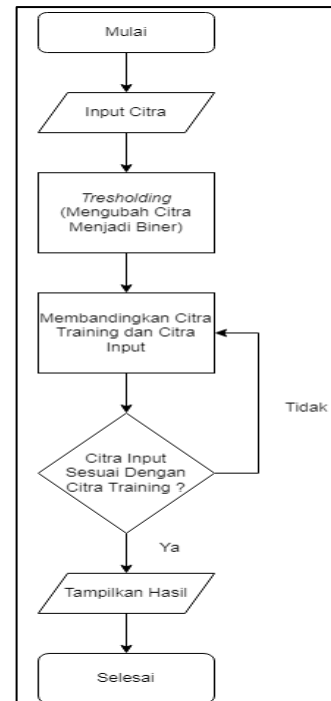
#### 3.1 Identifikasi Masalah

Masalah utama yang diangkat dalam penelitian ini terkait dengan mekanisme pengklasifikasian kendaraan dengan menggunakan salah satu metode CNN untuk pengolahan citra. Untuk mengatasi masalah tersebut, diperlukan sistem penggolongan kendaraan yang terdiri dari kamera yang dilengkapi dengan kualitas baik agar dapat mengidentifikasi kendaraan dengan optimal..

#### 3.2 Kerangka Kerja

Kerangka kerja adalah serangkaian tahapan dalam penelitian yang dirancang untuk mempermudah pemahaman proses penelitian. Penelitian ini memiliki kerangka kerja yang ditampilkan pada gambar 4 Langkah-langkah penelitian ini dijalankan secara berurutan.

Penyusunan kerangka kerja bertujuan agar penelitian ini berjalan lebih terorganisir.



Gambar 7 Flowchart Kerangka Kerja


Pada gambar 4 menjelaskan alur kerja yang akan dilakukan, langkah pertama adalah penginputan citra kendaraan yang akan digunakan dalam penelitian ini citra yang diambil berasal dari gerbang tol kramasan, untuk citra diambil dari kamera CCTV gerbang tol sesuai dengan golongan kendaraan yang mengantre di gerbang tol mulai dari kendaraan golongan I sampai dengan kendaraan golongan V. Setelah citra dikumpulkan sebagai sampel maka langkah selanjutnya adalah mengubah citra tersebut menjadi biner pada CNN agar citra tersebut dapat dipelajari oleh mesin pembelajaran. Langkah selanjutnya adalah mengklasifikasikan gambar menggunakan CNN, pada penelitian ini digunakan 80% citra sebagai citra *training* dan 20% sebagai citra validasi sesuai dengan golongan kendaraan yang selanjutnya akan dibandingkan pada CNN menggunakan ReLU apakah citra yang dibandingkan sudah sesuai dengan citra yang diinginkan, apabila sudah sesuai maka hasil akan ditampilkan, namun jika masih belum sesuai data akan dilatih lagi agar mendapatkan hasil yang sesuai menggunakan metrik akurasi pada CNN.

#### 3.5.1 Proses Klasifikasi Kendaraan

Proses klasifikasi pada klasifikasi kendaraan bertujuan agar CNN dapat menganalisa input citra dan outputnya sesuai dengan hasil output dari beberapa model arsitektur CNN yang digunakan, pada klasifikasi ini menggunakan metrik akurasi untuk menentukan hasil yang diperoleh dari masing masing output.

### 3.6 Arsitektur ConvNet

Arsitektur ConvNet bekerja dengan melakukan ekstraksi fitur secara berurutan melalui lapisan konvolusi dan pooling, diikuti oleh klasifikasi menggunakan lapisan terhubung penuh. Proses ini memungkinkan ConvNet untuk mengenali pola dan objek dalam gambar dengan sangat efisien.



Gambar 8 Arsitektur ConvNet


## 4. HASIL DAN PEMBAHASAN

### 4.1 Data Hasil Pengujian

Pada hasil penelitian ini


Dari penelitian ini digunakan beberapa indikator dalam proses penelitian berupa akurasi dan loss pada saat pengklasifikasian kendaraan dari citra training. Loss function (fungsi kehilangan) pada CNN berfungsi sebagai indikator seberapa baik model dapat mempelajari pola dalam data pelatihan dan meminimalkan perbedaan antara prediksi model dengan nilai yang sebenarnya. Tujuannya adalah untuk menemukan parameter model yang menghasilkan prediksi yang paling akurat.

Pengujian ini menggunakan citra dengan 3 channel (RGB) dengan menggunakan resolusi gambar 159x127 piksel yang akan diubah menjadi 224x224 pixel pada saat proses pelatihan. Sebagai data pembandingan metode ini digunakan 2 metode yakni AlexNet dan ResNet.




Gambar 9 Grafik Akurasi ConvNet

Grafik akurasi pada pengujian menggunakan metode ConvNet menunjukkan hasil yang baik pada saat pelatihan dan saat validasi citra. Percobaan menggunakan metode ConvNet ini menggunakan 10 epoch dengan 8 batch size, dapat disimpulkan bahwa ConvNet mampu mengklasifikasi citra kendaraan dengan sangat baik.



Gambar 10 Grafik Akurasi AlexNet

Pada gambar 10 menunjukkan grafik validasi dari metode AlexNet, dapat dilihat bahwa akurasi pada saat pembelajaran citra dan saat validasi masih belum sesuai, dapat disimpulkan bahwa banyak citra yang mengalami *overfitting* sehingga membuat validasi tidak akurat.



Gambar 11 Grafik Akurasi ResNet

Pada gambar 11 menunjukkan grafik akurasi dari metode ResNet, dengan menggunakan 10 epoch metode ini mampu mempelajari citra dengan baik, hasil validasi citra pada grafik tersebut menunjukkan bahwa ResNet memiliki tingkat akurasi yang tinggi dan tingkat *loss* yang rendah pada saat mempelajari citra.

### 4.2 Perbandingan Seluruh Arsitektur CNN

Berdasarkan gambar 10 dapat dilihat bahwa akurasi klasifikasi menggunakan AlexNet tidak meningkat, dapat diartikan bahwa pelatihan model menggunakan AlexNet pada penelitian ini tidak menghasilkan akurasi yang baik dalam mengelompokkan citra, hal ini dikarenakan model training yang sedikit sehingga membuat validasi pada citra hanya bernilai 0.36 atau 36%. Sedangkan pada gambar 9 dan gambar 11 nilai akurasi yang dihasilkan sangat mendekati 100% dimana ResNet memiliki tingkat akurasi senilai 90.24% dan ConvNet memiliki tingkat akurasi senilai 100%. Dari perbandingan yang telah dilakukan untuk mengklasifikasi citra kendaraan di antrian gerbang tol, ConvNet memiliki tingkat akurasi tertinggi.

## 5 KESIMPULAN

### 5.1 Kesimpulan

Berdasarkan dari penelitian yang sudah dilakukan menggunakan 3 model CNN, dapat disimpulkan :



1. Metode CNN dapat meningkatkan akurasi dan kecepatan dalam memproses data kendaraan di antrian gerbang tol, dengan tingkat akurasi 92%.
2. Penggunaan salah satu metode CNN dapat mengklasifikasikan kendaraan, namun belum bisa diaplikasikan kedalam sistem pembayaran di gerbang tol karena masih memerlukan lebih banyak validasi dari segi lainnya seperti berat kendaraan, tinggi kendaraan, dan panjang kendaraan.
3. Salah satu metode CNN untuk mengklasifikasi golongan kendaraan dapat mengenali berbagai jenis kendaraan pada antrian gerbang tol.

#### DAFTAR PUSTAKA

- [1] M. F. Pradana, D. E. Intari, and F. Kurniawan, "Perencanaan Ulang Kebutuhan Gardu Tol Pada Gerbang Tol Cikande," *J. Fondasi*, vol. 6, no. 2, 2017, doi: 10.36055/jft.v6i2.2478.
- [2] I. Mayasari, "PUASKAH PELANGGAN TOL TERHADAP TRANSAKSI NON TUNAI? (Survey Pada Gerbang Tol Pasteur, Purbaleunyi Bandung)," *J. E-Bis*, vol. 3, no. 2, pp. 119–132, 2019, doi: 10.37339/e-bis.v3i2.125.
- [3] R. N. Muzaki, E. Harahap, F. Badruzzaman, P. Matematika, F. Matematika, and P. Alam, "Efektivitas Penggunaan E-Toll di Gerbang Tol Pasteur dengan Menggunakan Model Antrian," *Pros. Mat.*, vol. 6, no. 2, pp. 74–81, 2020.
- [4] S. K. Rajput *et al.*, "Automatic Vehicle Identification and Classification Model Using the YOLOv3 Algorithm for a Toll Management System," *Sustain.*, vol. 14, no. 15, pp. 1–15, 2022, doi: 10.3390/su14159163.
- [5] F. Hafifah, S. Rahman, and M. S. Asih, "Klasifikasi Jenis Kendaraan Pada Jalan Raya Menggunakan Metode Convolutional Neural Networks (CNN)," vol. 2, no. 5, pp. 292–301, 2021.
- [6] L. Yang and T. Huang, "A Vehicle Reidentification Algorithm Based on Double-Channel Symmetrical CNN," vol. 2021, 2021.
- [7] Y. Baharuddin, A. Sofwan, and W. A. Syaifei, "Perancangan Perangkat Lunak Pendukung Etc (Electronic Toll Collection) Dengan Notifikasi Melalui Social Messenger," *Transient*, vol. 7, no. 1, p. 55, 2018, doi: 10.14710/transient.7.1.55-61.
- [8] S. Awang and N. M. A. Nik Azmi, "Automated Toll Collection System based on Vehicle Type Classification using Sparse-Filtered Convolutional Neural Networks with Layer-Skipping Strategy (SF-CNNLS)," *J. Phys. Conf. Ser.*, vol. 1061, no. 1, 2018, doi: 10.1088/1742-6596/1061/1/012009.
- [9] M. N. R. FATMAWATI and I. Yuliana, "Pengaruh Transaksi Non Tunai Terhadap Jumlah Uang Beredar Di Indonesia Tahun 2015- 2018 Dengan Inflasi Sebagai Variabel Moderasi," *Eksposisi J. Ekon. Keuangan, Perbank. dan Akunt.*, vol. 11, no. 2, pp. 269–283, 2019, doi: 10.35313/ekspansi.v11i2.1608.
- [10] S. Ratna, "Pengolahan Citra Digital Dan Histogram Dengan Phyton Dan Text Editor Phycharm," *Technol. J. Ilm.*, vol. 11, no. 3, p. 181, 2020, doi: 10.31602/tji.v11i3.3294.
- [11] F. Hardino, "mencapai derajat Sarjana S1 Disusun oleh : Jurusan Teknik Elektro Fakultas Teknologi Industri Universitas Islam Indonesia Yogyakarta," 2020.
- [12] B. Shokeen and D. Chawla, "Review of Road Detection and Segmentation Technique Using CNN," *Int. J. Res. Eng. Appl. Manag.*, no. 02, pp. 161–165, 2020, doi: 10.35291/2454-9150.2020.0383.
- [13] A. Alhudhaif *et al.*, "A particle swarm optimization based deep learning model for vehicle classification," *Comput. Syst. Sci. Eng.*, vol. 40, no. 1, pp. 223–235, 2022, doi: 10.32604/CSSE.2022.018430.
- [14] M. R. A. Yudianto, K. Kusriani, and H. Al Fatta, "Analisis Pengaruh Tingkat Akurasi Klasifikasi Citra Wayang dengan Algoritma Convolutional Neural Network," *J. Teknol. Inf.*, vol. 4, no. 2, pp. 182–191, 2020, doi: 10.36294/jurti.v4i2.1319.
- [15] Q. Zhu and X. Zu, "Fully Convolutional Neural Network Structure and Its Loss Function for Image Classification," *IEEE Access*, vol. 10, pp. 35541–35549, 2022, doi: 10.1109/ACCESS.2022.3163849.
- [16] E. Gordon-Rodriguez, G. Loaiza-Ganem, G. Pleiss, and J. P. Cunningham, "Uses and Abuses of the Cross-Entropy Loss: Case Studies in Modern Deep Learning," *Proc. Mach. Learn. Res.*, vol. 137, pp. 1–10, 2020.
- [17] Y. Ho and S. Wookey, "The Real-World-Weight Cross-Entropy Loss Function: Modeling the Costs of Mislabeling," *IEEE Access*, vol. 8, pp. 4806–4813, 2020, doi: 10.1109/ACCESS.2019.2962617.
- [18] T. Kim, J. Oh, N. Y. Kim, S. Cho, and S. Y. Yun, "Comparing Kullback-Leibler Divergence and Mean Squared Error Loss in Knowledge Distillation," *IJCAI Int. Jt. Conf. Artif. Intell.*, pp. 2628–2635, 2021, doi: 10.24963/ijcai.2021/362.