

Model *Deep Learning* Berbasis *Convolutional Neural Network* (CNN) untuk Identifikasi Tingkat Kerusakan Jalan di Kota Dumai

M. Rizki Adrian^{*1}, Aldhi Albadri², Merina Pratiwi³

^{1,2,3}Program Studi Teknik Informatika Sekolah Tinggi Teknologi (STT) Dumai

*e-mail: rizki9580@gmail.com¹, aldhi.albadri@gmail.com², merinapratiwi1920@gmail.com³

Abstract

This research aims to develop an automatic system to classify road damage levels in Dumai City using Convolutional Neural Network (CNN). This system is expected to improve the efficiency of road maintenance by providing fast and accurate automatic classification. The data used consists of road images classified into three categories: light, moderate, and severe damage. The CRISP-DM methodology was employed in this study to manage the data lifecycle, which includes data collection, understanding, preparation, modeling, and evaluation stages. The results indicate that the CNN model can classify road damage with good accuracy, especially for light and severe damage categories, although there are challenges in recognizing moderate damage. The model achieved an accuracy of over 90%, with the best performance for severe damage, reaching 97.07%. This study suggests further development by increasing the variety of training data to improve the classification of moderate damage.

Keywords: *Deep Learning, CNN, MobileNetV2, Road Damage, Classification.*

Abstrak

Penelitian ini bertujuan untuk mengembangkan sistem otomatis untuk mengklasifikasikan tingkat kerusakan jalan di Kota Dumai menggunakan *Convolutional Neural Network* (CNN). Sistem ini diharapkan dapat meningkatkan efisiensi pemeliharaan jalan dengan cara otomatis dan akurat. Data yang digunakan adalah citra jalan yang diklasifikasikan menjadi tiga kategori: kerusakan ringan, sedang, dan berat. Metode CRISP-DM digunakan dalam penelitian ini untuk mengelola siklus hidup data, yang mencakup tahap pengumpulan data, pemahaman data, persiapan data, pemodelan, dan evaluasi. Hasil penelitian menunjukkan bahwa model CNN dapat mengklasifikasikan kerusakan jalan dengan akurasi yang baik, terutama pada kategori kerusakan ringan dan berat, meskipun masih terdapat tantangan dalam mengenali kerusakan sedang. Model ini menunjukkan akurasi lebih dari 90%, dengan performa terbaik pada kerusakan berat yang mencapai 97.07%. Penelitian ini menyarankan pengembangan lebih lanjut dengan menambah variasi data latih untuk meningkatkan klasifikasi kerusakan sedang.

Kata Kunci: *Deep Learning, CNN, MobileNetV2, Kerusakan Jalan, Klasifikasi.*

1. PENDAHULUAN

Kondisi infrastruktur jalan di Kota Dumai, Provinsi Riau, menjadi salah satu faktor penting dalam menunjang pertumbuhan ekonomi dan kenyamanan masyarakat. Namun, berdasarkan data dari Dinas Pekerjaan Umum (PU) Kota Dumai (2024), sekitar 35% jalan di wilayah ini mengalami kerusakan, mulai dari retak-retak, berlubang, hingga deformasi berat. Kerusakan jalan tidak hanya mengganggu kelancaran transportasi tetapi juga meningkatkan risiko kecelakaan (Tingkat et al., 2025). Selama ini, identifikasi kerusakan masih dilakukan secara manual melalui survei lapangan, yang memakan waktu, biaya, dan bersifat subjektif (Dinas Pekerjaan Umum, 2025). Dampaknya, pengumpulan dan pengklasifikasian data cenderung lama, salah dan terkesan tidak beraturan. Oleh karena itu, diperlukan solusi otomatis berbasis teknologi untuk meningkatkan efisiensi dan akurasi pendeteksian kerusakan jalan agar tim surveyor bekerja secara optimal. (Ulfa et al., 2023).

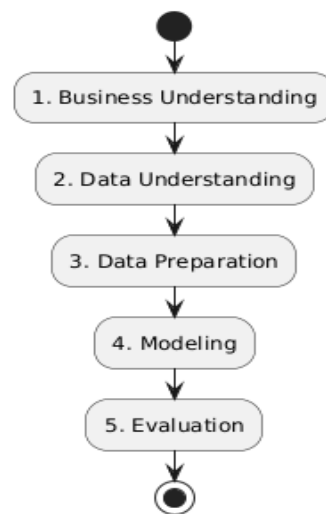
Salah satu pendekatan yang menjanjikan adalah pemanfaatan kecerdasan buatan (AI), khususnya *Convolutional Neural Network* (CNN), untuk menganalisis citra jalan. CNN telah terbukti efektif dalam klasifikasi gambar karena kemampuannya mengekstraksi fitur visual secara otomatis. Beberapa penelitian sebelumnya, seperti studi oleh (Wibowo & Setiyadi, 2023), berhasil mengklasifikasikan kerusakan trotoar dengan menggunakan arsitektur CNN. Namun, implementasi di Kota Dumai masih terbatas, terutama karena karakteristik jalan yang berbeda, seperti pengaruh aktivitas lalu lintas dan beban kendaraan berat (Yanti et al., 2024). Hal ini menunjukkan perlunya pengembangan model yang disesuaikan dengan kondisi lokal.

Diharapkan, hasil penelitian ini dapat berkontribusi pada pengembangan di Dumai, sekaligus menjadi referensi bagi penelitian serupa di wilayah lain dengan tantangan geografis sama. Selain itu, pendekatan berbasis CNN ini dapat dikembangkan lebih lanjut untuk memprediksi kerusakan jalan secara *real-time*.

Berdasarkan permasalahan yang telah diuraikan diatas, oleh karena itu peneliti mengangkat persoalan tersebut untuk dijadikan tugas akhir dengan judul “Model *Deep Learning* Berbasis CNN Untuk Identifikasi Tingkat Kerusakan Jalan di Kota Dumai”.

2. METODE

Metode pengembangan yang digunakan dalam penyusunan Tugas Akhir ini adalah CRISP-DM (*Cross-Industry Standard Process for Data Mining*). CRISP-DM adalah metodologi yang cocok untuk proyek *machine learning* dan *deep learning* karena fokus pada siklus hidup pengembangan model berbasis data (Alden & Sari, 2023). Tahapannya:



Gambar 1. Model CRISP-DM

1. *Business Understanding*

Fase ini memahami tujuan praktis proyek dan kebutuhan pemangku kepentingan. Untuk Kota Dumai, identifikasi kerusakan jalan penting untuk efisiensi perbaikan infrastruktur dan keselamatan berkendara. Di sini, peneliti menentukan bagaimana model CNN dapat membantu pemerintah mengoptimalkan pemeliharaan jalan sekaligus memahami kebutuhan konkret dari dinas terkait dan masyarakat.

2. *Data Understanding*

Tahap pengumpulan dan eksplorasi awal data gambar jalan. Peneliti mengumpulkan foto jalan dari berbagai sumber seperti *drone* atau laporan warga, lalu menganalisis distribusi kerusakan (ringan/sedang/berat), kualitas gambar, dan kelengkapan label. Ini membantu memahami karakteristik dataset sebelum pemrosesan lebih lanjut.

3. *Data Preparation*

Proses penyiapan data untuk pelatihan model. Gambar jalan diolah melalui normalisasi nilai *pixel*, augmentasi (seperti rotasi atau flip untuk memperbanyak data), dan segmentasi area rusak. Dataset kemudian dibagi menjadi tiga bagian: data latih, validasi, dan uji dengan proporsi yang tepat.

4. *Modeling*

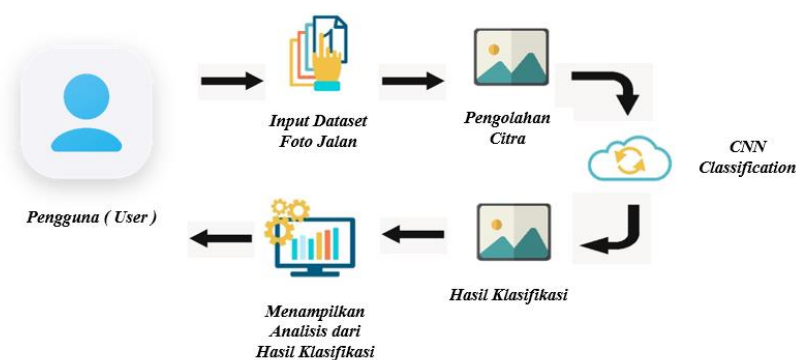
Tahap pemilihan dan pelatihan arsitektur CNN. Peneliti memilih antara membangun model dari awal atau menggunakan *transfer learning* dengan model *pretrained* seperti *ResNet* jika data terbatas. Model kemudian dilatih dengan teknik *fine-tuning* untuk mengoptimalkan performa klasifikasi tiga tingkat kerusakan jalan.

5. *Evaluation*

Pengukuran performa model menggunakan berbagai metrik seperti akurasi, *precision*, *recall*, dan analisis *confusion matrix*. Model juga diuji dengan gambar jalan baru dari Kota Dumai yang belum pernah dilihat sebelumnya untuk memastikan kemampuannya bekerja di kondisi nyata.

Gambaran Sistem

Gambar sistem ini merupakan Gambaran secara keseluruhan sistem yang akan penulis bangun. Untuk Gambaran sistem ini dapat di lihat pada Gambar 2 sebagai berikut:



Gambar 2. Gambaran Sistem

Sistem yang dikembangkan bertujuan untuk membantu proses klasifikasi tingkat kerusakan jalan di Kota Dumai dengan foto menggunakan metode CNN. Adapun keterangan pada gambaran sistem tersebut sebagai berikut:

1. *Pengguna (User)*

Pengguna adalah pihak yang berinteraksi dengan sistem, seperti dinas pekerjaan umum atau masyarakat umum. Mereka bertugas mengunggah foto jalan yang ingin diperiksa ke dalam sistem melalui aplikasi atau website.

2. *Input Dataset (Foto Jalan)*

Sistem menerima gambar jalan sebagai input. Foto ini bisa mencakup berbagai jenis kerusakan, seperti retak kecil, lubang, atau kerusakan parah. Data yang baik harus memiliki pencahayaan yang jelas dan sudut pengambilan yang sesuai agar hasil analisis akurat.

3. *Pengolahan Citra*

Pada tahap ini, gambar diproses untuk disiapkan sebelum dianalisis. Langkah-langkahnya meliputi pengubahan ukuran gambar, normalisasi warna, dan peningkatan kualitas gambar jika diperlukan. Jika sistem dilengkapi fitur tambahan, segmentasi citra dapat digunakan untuk memisahkan area yang rusak dari bagian jalan yang masih baik.

4. *CNN Classification*

Gambar yang sudah diproses kemudian dianalisis oleh model CNN. Jaringan saraf ini akan mengekstrak ciri-ciri penting dari gambar, seperti tekstur dan pola kerusakan, lalu mengklasifikasikannya ke dalam kategori tertentu, seperti kerusakan ringan, sedang, atau berat.

5. Hasil Klasifikasi

Setelah analisis selesai, sistem menghasilkan output berupa prediksi tingkat kerusakan beserta tingkat kepercayaan (*confidence level*). Hasil ini dapat mencakup lokasi kerusakan jika sistem dilengkapi dengan deteksi objek.

6. Menampilkan Analisis

Hasil klasifikasi kemudian ditampilkan kepada pengguna dalam bentuk laporan sederhana. Laporan ini bisa berupa teks, grafik, atau visualisasi gambar dengan tanda area yang rusak. Informasi yang ditampilkan membantu pengguna memahami kondisi jalan dan mengambil tindakan yang diperlukan.

Sistem ini dirancang untuk memberikan identifikasi kerusakan jalan secara otomatis, cepat, dan akurat, sehingga memudahkan dalam pemantauan dan perencanaan perbaikan infrastruktur.

3. HASIL DAN PEMBAHASAN

Analisis sistem ini bertujuan untuk menerapkan sebuah model *deep learning* berbasis *Convolutional Neural Network* (CNN) yang mampu mengidentifikasi tingkat kerusakan jalan di Kota Dumai. Sistem yang dikembangkan akan mengimplementasikan algoritma *deep learning* CNN untuk memproses data citra jalan yang diperoleh dari survei lapangan.

Sistem akan menerima input berupa gambar jalan yang mencakup berbagai kondisi permukaan, di mana setiap citra akan dianalisis berdasarkan fitur visual seperti retakan, lubang, atau deformasi lainnya. *Output* dari sistem adalah klasifikasi tingkat kerusakan jalan, yaitu rusak (ringan, sedang, atau berat) dalam bentuk *Graphical User Interface* (GUI). Hasil identifikasi ini disajikan secara jelas, sehingga dapat digunakan oleh dinas terkait sebagai acuan dalam menentukan prioritas perbaikan, menyusun rencana pemeliharaan yang lebih efektif, serta meningkatkan kualitas infrastruktur jalan di Kota Dumai secara keseluruhan.

Tahapan Pengolahan Citra

Resize Citra Menjadi 224x224



Gambar 5. Citra Sebelum di*resize*

Ukuran 768x459 Menjadi :



Gambar 6. Citra Setelah diresize

Ukuran 224x224

Resize citra adalah proses mengubah ukuran gambar ke dimensi tertentu agar sesuai dengan input yang dibutuhkan oleh arsitektur CNN, seperti *MobileNetV2* yang memerlukan ukuran standar 224x224 piksel. Proses ini penting untuk menyamakan dimensi seluruh dataset sehingga model dapat memproses data secara konsisten tanpa distorsi ukuran yang dapat memengaruhi ekstraksi fitur (Zidan et al., 2024). Selain itu, penggunaan ukuran 224x224 menjaga keseimbangan antara detail citra yang cukup untuk klasifikasi dan efisiensi komputasi (Wijayanto et al., 2025), sehingga pelatihan berjalan lebih cepat dengan kebutuhan memori yang lebih rendah.

Augmentasi Untuk Meningkatkan Normalisasi



Gambar 7. Citra setelah dilakukan augmentasi

Augmentasi untuk meningkatkan normalisasi berarti memodifikasi citra dengan berbagai transformasi (*rotasi, flipping, scaling, brightness adjustment*) agar distribusi data menjadi lebih merata dan representatif terhadap kondisi nyata (Sasongko et al., 2023). Teknik ini membantu model *deep learning* mengenali pola dengan lebih baik meskipun ada variasi pencahayaan, orientasi, atau skala objek. Dengan normalisasi yang lebih baik melalui augmentasi, model CNN dapat mengurangi bias terhadap data tertentu, mempercepat konvergensi saat pelatihan, dan meningkatkan kemampuan generalisasi untuk memprediksi data baru secara akurat (Fahlevi & Rozikin, 2025).

Modelling

Dalam penelitian ini digunakan arsitektur *MobileNetV2* sebagai model dasar untuk klasifikasi citra tingkat kerusakan jalan. *MobileNetV2* adalah salah satu model *Convolutional Neural Network* (CNN) ringan dan efisien yang dikembangkan oleh *Google*, didesain khusus

untuk perangkat dengan keterbatasan sumber daya seperti *smartphone* atau komputer dengan spesifikasi menengah.

Untuk menyesuaikan *MobileNetV2* dengan kebutuhan klasifikasi 3 kelas (rusak ringan, rusak sedang, rusak berat), dilakukan beberapa modifikasi:

1. *Input Layer*: Karena citra awal merupakan RGB dapat menyesuaikan dengan arsitektur *MobileNetV2* yang membutuhkan 3 *channel* (RGB).
2. *GlobalAveragePooling2D*: Digunakan setelah *feature extractor* dari *MobileNetV2* untuk meratakan output fitur menjadi vektor 1 dimensi.
3. *Dense Layer (Fully Connected Layer)*:
 - a. *Dense(128, activation='relu')*: Untuk memproses fitur hasil ekstraksi menjadi representasi lebih dalam.
 - b. *Dropout(0.3)*: Untuk mencegah *overfitting* dengan menonaktifkan beberapa neuron secara acak selama *training*.
 - c. *Dense(3, activation='softmax')*: *Layer output* dengan jumlah neuron sesuai jumlah kelas, menggunakan fungsi aktivasi softmax untuk menghasilkan probabilitas kelas.

Penggunaan *MobileNetV2 pretrained* (pra-latih) didasarkan pada beberapa alasan utama. Pertama, dari segi efisiensi komputasi, *MobileNetV2* memiliki jumlah parameter yang jauh lebih sedikit dibandingkan model besar seperti *ResNet* atau *VGG*, sehingga proses pelatihan lebih cepat dan penggunaan memori lebih rendah, cocok digunakan pada laptop atau PC dengan spesifikasi menengah. Kedua, model ini tetap mampu mencapai akurasi tinggi meskipun dengan data terbatas, karena telah dilatih sebelumnya menggunakan jutaan citra dari *ImageNet* dan mampu mengenali pola visual dasar. Melalui teknik *transfer learning*, hanya lapisan akhir yang perlu disesuaikan dengan dataset kerusakan jalan, yang sangat membantu dalam kondisi data pelatihan yang terbatas seperti dalam penelitian ini. Ketiga, *MobileNetV2* memungkinkan penerapan yang cepat karena dapat langsung diintegrasikan ke aplikasi GUI berbasis Tkinter tanpa memerlukan server eksternal, serta mendukung *real-time inference* (prediksi cepat) yang penting untuk aplikasi praktis di lapangan.

Tabel 1. Modelling CNN

<i>Layer (type)</i>	<i>Output Shape</i>	<i>Param</i>
<i>conv2d_24 (Conv2D)</i>	(None, 222, 222, 32)	896
<i>max_pooling2d_24</i>	(None, 111, 111, 32)	0
<i>conv2d_25 (Conv2D)</i>	(None, 109, 109, 64)	18,496
<i>max_pooling2d_25</i>	(None, 54, 54, 64)	0
<i>conv2d_26 (Conv2D)</i>	(None, 52, 52, 128)	73,856
<i>max_pooling2d_26</i>	(None, 26, 26, 128)	0
<i>conv2d_27 (Conv2D)</i>	(None, 24, 24, 256)	295,168
<i>max_pooling2d_27</i>	(None, 12, 12, 256)	0
<i>flatten_6 (Flatten)</i>	(None, 36864)	0
<i>dense_12 (Dense)</i>	(None, 512)	18,874,880
<i>dropout_6 (Dropout)</i>	(None, 512)	0
<i>dense_13 (Dense)</i>	(None, 3)	1,539


Layer (type)	Output Shape	Param
<i>conv2d_24</i> (Conv2D)	(None, 222, 222, 32)	896
<i>max_pooling2d_24</i>	(None, 111, 111, 32)	0
<i>conv2d_25</i> (Conv2D)	(None, 109, 109, 64)	18,496
<i>max_pooling2d_25</i>	(None, 54, 54, 64)	0
<i>conv2d_26</i> (Conv2D)	(None, 52, 52, 128)	73,856
<i>max_pooling2d_26</i>	(None, 26, 26, 128)	0
<i>conv2d_27</i> (Conv2D)	(None, 24, 24, 256)	295,168
<i>max_pooling2d_27</i>	(None, 12, 12, 256)	0
<i>flatten_6</i> (Flatten)	(None, 36864)	0
<i>dense_12</i> (Dense)	(None, 512)	18,874,880
<i>dropout_6</i> (Dropout)	(None, 512)	0
<i>dense_13</i> (Dense)	(None, 3)	1,539

- *Total params:* 19,264,835 (73.49 MB)
- *Trainable params:* 19,264,835 (73.49 MB)
- *Non-trainable params:* 0 (0.00 B)

Model CNN yang digunakan pada penelitian ini dirancang untuk mengidentifikasi tingkat kerusakan jalan berdasarkan citra digital. Arsitektur model terdiri dari beberapa lapisan utama seperti *Conv2D*, *MaxPooling2D*, *Flatten*, *Dense*, dan *Dropout*. Lapisan konvolusi (*Conv2D*) berfungsi untuk mengekstrak fitur penting dari gambar seperti pola retakan atau bentuk kerusakan, sementara *MaxPooling* membantu mengurangi ukuran data tanpa kehilangan informasi penting. Setelah fitur diekstrak, lapisan *Flatten* mengubah data menjadi bentuk 1 dimensi agar bisa diproses oleh lapisan *Dense*, yang bertugas melakukan klasifikasi ke dalam tiga kelas: rusak ringan, sedang, dan berat.

Evaluation

Grafik Akurasi dan Loss




Gambar 8. Grafik akurasi dan loss

Hasil pelatihan model ditampilkan melalui grafik akurasi dan loss terhadap data pelatihan dan validasi. Dari grafik akurasi, terlihat bahwa model menunjukkan peningkatan yang konsisten selama proses pelatihan, dengan akurasi validasi yang tetap berada pada tingkat yang cukup tinggi, yaitu di atas 60%. Sementara itu, grafik loss menunjukkan tren penurunan baik pada data pelatihan maupun validasi, yang menandakan bahwa model semakin baik dalam melakukan prediksi. Tidak adanya perbedaan yang signifikan antara loss pelatihan dan validasi mengindikasikan bahwa model tidak mengalami *overfitting*, serta memiliki kemampuan generalisasi yang cukup baik terhadap data baru.

Secara keseluruhan, performa model CNN dapat dikatakan baik dan sesuai untuk digunakan dalam sistem klasifikasi tingkat kerusakan jalan. Dengan jumlah parameter yang besar dan arsitektur yang dalam, model ini mampu menangkap pola kompleks dalam gambar dan mengklasifikasikannya secara akurat. Grafik pelatihan juga menunjukkan bahwa strategi pelatihan yang digunakan efektif, ditunjukkan oleh peningkatan akurasi serta penurunan nilai loss dari waktu ke waktu. Kombinasi antara arsitektur yang tepat dan data yang relevan membuat model ini berpotensi untuk diimplementasikan dalam aplikasi nyata seperti sistem monitoring kerusakan jalan secara otomatis.

Confusion Matrix



Gambar 9. *Confusion matrix*

Gambar *confusion matrix* menunjukkan seberapa baik model mampu mengklasifikasikan citra jalan ke dalam tiga kategori: rusak ringan, sedang, dan berat. Pada baris pertama, terlihat bahwa semua citra rusak ringan berhasil diprediksi dengan benar oleh model (akurasi 100%), sehingga tidak ada citra rusak ringan yang salah diklasifikasikan. Untuk kategori rusak sedang, model mampu mengklasifikasikan 70% citra dengan benar, tetapi 10% salah diprediksi sebagai rusak ringan dan 20% sebagai rusak berat. Sedangkan pada rusak berat, sekitar 67% citra diprediksi dengan benar, sementara sisanya salah diprediksi sebagai rusak ringan (17%) dan rusak sedang (17%).

Laporan Precision, Recall, F1-score

Detailed Classification Report:				
	precision	recall	f1-score	support
Rusak Ringan	0.8000	1.0000	0.8889	8
Rusak Sedang	0.8750	0.7000	0.7778	10
Rusak Berat	0.6667	0.6667	0.6667	6
accuracy			0.7917	24
macro avg	0.7806	0.7889	0.7778	24
weighted avg	0.7979	0.7917	0.7870	24
Additional Analysis:				
Total Samples: 24				
Class Distribution (True): {'Rusak Ringan': 8, 'Rusak Sedang': 10, 'Rusak Berat': 6}				
Class Distribution (Predicted): {'Rusak Ringan': 10, 'Rusak Sedang': 8, 'Rusak Berat': 6}				

Gambar 10. Laporan *precision*, *recall* dan *f1-score*

Precision for a class: $\frac{TP}{TP+FP}$

Recall for a class: $\frac{TP}{TP+FN}$

F1-score: $\frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$

TP (*True Positive*): Klasifikasi positif yang diprediksi dengan benar.

FP (*False Positive*): Klasifikasi yang salah diprediksi sebagai positif.

FN (*False Negative*): Klasifikasi yang salah diprediksi sebagai negatif.

TN (*True Negative*): Klasifikasi negatif yang diprediksi dengan benar.

Rusak Ringan:

- *True Positives* (TP): 1.00 (dari baris Rusak Ringan, kolom Rusak Ringan)
- *False Positives* (FP): $0.10 + 0.17 = 0.27$ (dari baris Rusak Sedang dan Rusak Berat, kolom Rusak Ringan)
- *False Negatives* (FN): $0.00 + 0.00 = 0.00$ (dari baris Rusak Ringan, kolom Rusak Sedang dan Rusak Berat)
- *True Negatives* (TN): $0.70 + 0.20 + 0.17 + 0.67 = 1.74$ (nilai yang tersisa setelah mengeluarkan baris dan kolom untuk Rusak Ringan)

Rusak Sedang:

- *True Positives* (TP): 0.70 (dari baris Rusak Sedang, kolom Rusak Sedang)
- *False Positives* (FP): $0.00 + 0.17 = 0.17$ (dari baris Rusak Ringan dan Rusak Berat, kolom Rusak Sedang)
- *False Negatives* (FN): $0.10 + 0.20 = 0.30$ (dari baris Rusak Ringan dan Rusak Berat, kolom Rusak Sedang)
- *True Negatives* (TN): $1.00 + 0.17 + 0.67 = 1.84$ (nilai yang tersisa setelah mengeluarkan baris dan kolom untuk Rusak Sedang)

Rusak Berat:

- *True Positives* (TP): 0.67 (dari baris Rusak Berat, kolom Rusak Berat)
- *False Positives* (FP): $0.00 + 0.10 = 0.10$ (dari baris Rusak Ringan dan Rusak Sedang, kolom Rusak Berat)
- *False Negatives* (FN): $0.17 + 0.20 = 0.37$ (dari baris Rusak Ringan dan Rusak Sedang, kolom Rusak Berat)
- *True Negatives* (TN): $1.00 + 0.70 + 0.10 = 1.80$ (nilai yang tersisa setelah mengeluarkan baris dan kolom untuk Rusak Berat)

Langkah Perhitungan:

1. Untuk Rusak Ringan:

$$\bullet \text{ Precision} = \frac{TP}{TP+FP} = \frac{1.00}{1.00+0.27} = \frac{1.00}{1.27} = 0.787$$

- $Recall = \frac{TP}{TP+FN} = \frac{1.00}{1.00+0.00} = 1.00$
- $F1-score = \frac{2 \times 0.787 \times 1.00}{0.787+1.00} = 0.883$

2. Untuk Rusak Sedang:

- $Precision = \frac{TP}{TP+FP} = \frac{0.70}{0.70+0.17} = \frac{0.70}{0.87} = 0.804$
- $Recall = \frac{TP}{TP+FN} = \frac{0.70}{0.70+0.30} = \frac{0.70}{1.00} = 0.700$
- $F1-score = \frac{2 \times 0.804 \times 0.700}{0.804+0.700} = 0.750$

3. Untuk Rusak Berat:

- $Precision = \frac{TP}{TP+FP} = \frac{0.67}{0.67+0.10} = \frac{0.67}{0.77} = 0.870$
- $Recall = \frac{TP}{TP+FN} = \frac{0.67}{0.67+0.37} = \frac{0.67}{1.04} = 0.644$
- $F1-score = \frac{2 \times 0.870 \times 0.644}{0.870+0.644} = 0.738$

4. Hasil:

- **Rusak Ringan:**
 - *Precision*: 0.787
 - *Recall*: 1.00
 - *F1-score*: 0.883
- **Rusak Sedang:**
 - *Precision*: 0.804
 - *Recall*: 0.700
 - *F1-score*: 0.750
- **Rusak Berat:**
 - *Precision*: 0.870
 - *Recall*: 0.644
 - *F1-score*: 0.738

Laporan klasifikasi memberikan informasi lebih detail terkait kinerja model dalam hal *presisi*, *recall*, dan *f1-score*. Untuk kategori rusak ringan, model memperoleh presisi 0,8 dan *recall* 1,0, artinya semua citra yang benar-benar rusak ringan berhasil dikenali tanpa ada yang terlewat. Pada kategori rusak sedang, presisi sebesar 0,875 menunjukkan sebagian besar prediksi tepat sasaran, meskipun ada beberapa kesalahan klasifikasi ke kelas lain. Untuk kategori rusak berat, nilai presisi dan *recall* berada pada angka 0,667, yang berarti masih ada beberapa citra rusak berat yang salah dikenali.

Secara keseluruhan, akurasi model mencapai sekitar 79%, dengan nilai *f1-score* rata-rata mendekati 0,78. Hasil ini menunjukkan bahwa model sudah cukup baik dalam mengenali tingkat kerusakan jalan, terutama pada kelas rusak ringan yang berhasil dikenali sempurna. Meski begitu, performa pada kelas rusak sedang dan berat masih bisa ditingkatkan, misalnya dengan menambah jumlah data latih pada kelas yang sering salah prediksi atau menggunakan teknik augmentasi data. Dengan perbaikan ini, model berpotensi memberikan hasil prediksi yang lebih seimbang di semua kategori.

Berdasarkan keempat hasil yang ditampilkan, model CNN yang dirancang untuk mengklasifikasikan tingkat kerusakan jalan menunjukkan kinerja yang cukup baik dengan akurasi sekitar 79%, didukung oleh arsitektur jaringan konvolusi yang mampu mengekstraksi fitur penting dari citra secara efektif. Grafik akurasi dan loss menunjukkan tren pembelajaran yang positif tanpa indikasi *overfitting* signifikan, sementara *confusion matrix* mengonfirmasi bahwa model mampu mengenali kelas rusak ringan dengan sempurna dan kelas rusak sedang dengan tingkat ketepatan yang cukup tinggi, meskipun masih ada kesalahan klasifikasi pada kelas rusak berat. Secara keseluruhan, model ini sudah layak digunakan sebagai sistem pendukung identifikasi kerusakan jalan, namun masih berpotensi ditingkatkan melalui penyeimbangan data dan optimasi parameter pelatihan agar prediksi pada semua kelas menjadi lebih konsisten.

Disini akan ditampilkan hasil identifikasi terhadap 3 kategori jalan (ringan, sedang dan berat) menggunakan GUI.

Rusak Ringan

Untuk Rusak Ringan teridentifikasi bahwasannya dari 8 data uji, semuanya menunjukkan prediksi yang benar, artinya akurasi menunjukkan 100%.

No	Data Uji	Persentase Prediksi
1.		63.84%

2.		80.94 %
3.		55.44%
4.		68.38 %
5.		77.74 %

6.		68.94%
7.		63.84 %
8.		68.38 %

Rusak Sedang

Untuk Rusak Sedang teridentifikasi bahwasannya dari 8 data uji, terdapat 5 data teridentifikasi benar dan 5 teridentifikasi salah, artinya tingkat akurasi 50%.





No	Data Uji	Hasil Prediksi
1.	 <p>22/11/23 1°40'35" N 101°26'50" E Kecamatan Dumai Timur Kota Dumai JL Sentosa C+100</p>	55.36 %
2.	 <p>21/11/23 1°40'34" N 101°27'2"E Kecamatan Dumai Timur Kota Dumai JL Singamangaraja C+200</p>	43.79%
3.	 <p>15/11/23 1°40'31" N 101°25'22" E Kecamatan Dumai Barat Kota Dumai JL Dock Yard Husri Termin C+670</p>	43.64 %

4.		50.22 %
----	--	------------

Rusak Berat

Untuk Rusak Berat teridentifikasi bahwasannya dari 8 data uji, semuanya menunjukkan prediksi yang benar, artinya akurasi menunjukkan 100%.

No	Data Uji	Hasil Prediksi
1.		94.94 %
2.		80.63 %

3.	 <p>14/11/23 1°41'50" N 101°24'25" E Kecamatan Dumai Barat Kota Dumai Gg Surau Laut 0-100</p>	82.54 %
4.	 <p>15/11/23 1°40'31" N 101°25'22" E Kecamatan Dumai Barat Kota Dumai JL Dock Yard Husri Termin C-670</p>	68.15%
5.	 <p>19/11/23 1°39'31" N 101°26'27" E Kecamatan Dumai Barat Kota Dumai Gg Selamat 0-100</p>	80.11%
6.	 <p>14/11/23 1°41'55" N 101°24'45" E Kecamatan Dumai Barat Kota Dumai JL Samudera C-100</p>	60.24 %

7.	 <p>22/11/23 1°40'35" N 101°26'50" E Kecamatan Dumai Timur Kota Dumai Jl. Sentosa C-100</p>	38.29%
8.	 <p>21/11/23 1°40'34" N 101°27'2" E Kecamatan Dumai Timur Kota Dumai Jl. Singamangaraja C-200</p>	97.07%

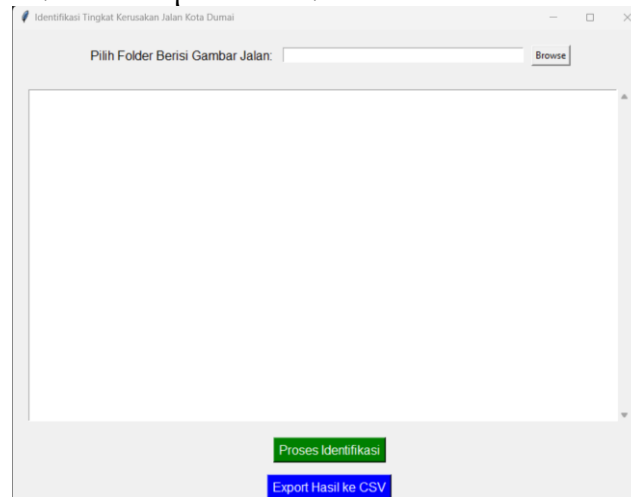
Berdasarkan hasil pengujian terhadap citra jalan dengan label *rusak ringan*, model CNN berhasil mengklasifikasikan seluruh gambar dengan tepat ke dalam kelas yang sesuai. Delapan gambar seperti secara konsisten diprediksi sebagai rusak ringan, dengan tingkat akurasi berkisar antara 55.44% hingga 80.94%. Hasil ini menunjukkan bahwa model mampu mengenali pola-pola kerusakan ringan seperti retakan halus atau lubang kecil dengan cukup baik. Sementara itu, pada kelas rusak berat, seluruh delapan gambar juga berhasil diprediksi ke dalam kelas yang benar dengan akurasi tinggi, bahkan mencapai 97.07% pada gambar 8. Ini menunjukkan bahwa model sangat sensitif terhadap fitur kerusakan berat seperti retakan dalam, pengelupasan aspal besar, atau deformasi jalan yang mencolok, yang secara visual memberikan kontras tinggi terhadap latar belakang jalan.

Sebaliknya, pada kelas rusak sedang, hasil prediksi menunjukkan ketidakkonsistenan dan performa model yang masih perlu ditingkatkan. Dari delapan gambar, hanya empat di antaranya yang berhasil diklasifikasikan dengan benar sebagai rusak sedang, dengan akurasi antara 43.64% hingga 55.36%. Hasil ini mengindikasikan bahwa model mengalami kesulitan dalam mengenali ciri khas kerusakan sedang yang umumnya memiliki bentuk transisi seperti retakan yang mulai melebar, permukaan bergelombang ringan, atau pecahnya aspal dalam skala sedang. Ketidaktepatan ini kemungkinan disebabkan oleh keterbatasan variasi citra latih pada kelas tersebut, sehingga fitur visualnya cenderung tidak terbentuk secara optimal selama proses pelatihan. Maka dari itu, pengayaan data pada kelas rusak sedang, penyesuaian threshold klasifikasi, atau penerapan teknik fine-tuning menjadi langkah penting agar sistem dapat bekerja lebih akurat dan andal dalam skenario nyata di Kota Dumai.

Implementasi Sistem

Tampilan Awal GUI


Berisikan *browse* untuk memilih folder berisi dataset foto jalan, lalu nanti akan dilakukan proses identifikasi dan export hasil ke excel.



Gambar 11. Tampilan awal GUI

Tampilan Select Folder (Input Dataset)


Pada tampilan ini, akan dilakukan select folder untuk menginput dataset.



Gambar 12. Tampilan input dataset

Tampilan Proses Identifikasi

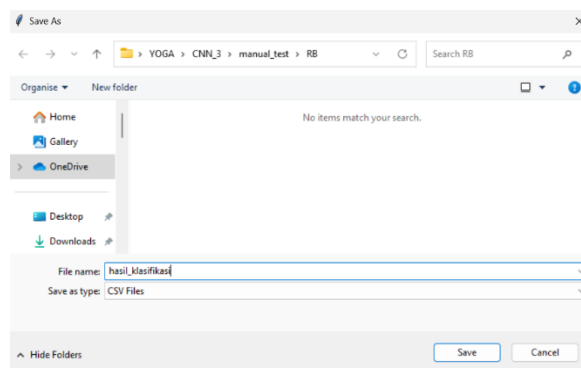
Berikut Adalah tampilan hasil identifikasi, yang mana setelah dataset diinput akan muncul list atau daftar hasil klasifikasi keseluruhan dengan persentasenya.



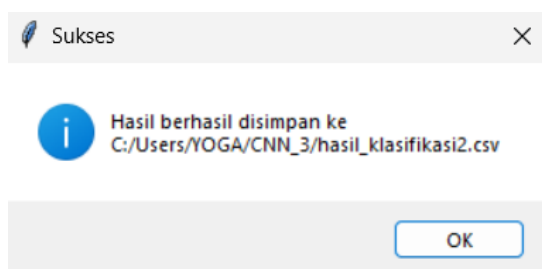
Gambar 13. Hasil identifikasi

Tampilan Hasil *Export* ke .CSV

Berikut Adalah tampilan ketika kita ingin menyimpan hasil prediksi ke Ms. Excel dalam bentuk .CSV.



Gambar 14. Menyimpan hasil identifikasi



Gambar 15. Pesan pemberitahuan

4. PENUTUP

Kesimpulan

Berdasarkan hasil pengklasifikasian tingkat kerusakan jalan di Kota Dumai menggunakan CNN ditarik Kesimpulan sebagai berikut :

1. Model CNN berhasil mengklasifikasikan citra kerusakan jalan ke dalam tiga kelas (ringan, sedang, berat). Performanya sangat baik pada dua kelas ekstrem (ringan dan berat) dengan akurasi tinggi hingga 97.07%, meski masih terdapat kelemahan pada kelas transisi (sedang) akibat fitur visual yang tumpang tindih dan data latih yang terbatas.

2. Implementasi CNN terbukti efektif sebagai metode identifikasi otomatis yang membantu tim surveyor dalam mengklasifikasikan tingkat kerusakan jalan dengan cepat, konsisten, dan efisien, sehingga berpotensi besar diterapkan pada sistem monitoring jalan di Kota Dumai.

Saran

Berdasarkan temuan dari penelitian ini, berikut adalah beberapa saran yang dapat dipertimbangkan untuk pengembangan lebih lanjut dan penerapan praktis:

1. Memastikan data tersebut sudah konsisten dan dalam jumlah banyak agar tidak terjadi kesalahan dalam melatih data.
2. Untuk penelitian selanjutnya, dapat dipertimbangkan untuk mencoba CNN dengan model lain (misalnya, AlexNet, ImageNet, ResNet dan lain-lain) dan membandingkan hasilnya dengan CNN. Perbandingan ini dapat memberikan wawasan tentang algoritma mana yang paling sesuai untuk identifikasi tingkat kerusakan jalan.

DAFTAR PUSTAKA

- Alden, S., & Sari, B. N. (2023). Implementasi Algoritma CNN Untuk Pemilahan Jenis Sampah Berbasis Android Dengan Metode CRISP-DM. *Jurnal Informatika*, 10(1), 62–71. <https://doi.org/10.31294/inf.v10i1.14985>
- Fahlevi, R., & Rozikin, C. (2025). Identifikasi Isyarat Tangan Bisindo Dengan Algoritma Cnn Dan Transfer Learning Menggunakan Mobilenetv2. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(4), 6592–6597. <https://doi.org/10.36040/jati.v9i4.14095>
- Melyssa, W., Dewi, A., Misriana, M., Suryati, M., & Rachmawati, R. (2022). Pengaruh Algoritma Deep Learning dalam Meningkatkan Akurasi Sistem Pendeteksian Kondisi Jalan Raya. *Proceeding Seminar Nasional Politeknik Negeri Lhokseumawe*, 6(1), 12–16. <https://ejurnal.pnl.ac.id/semnaspn/article/view/3426>
- Sasongko, T. B., Haryoko, H., & Amrullah, A. (2023). Analisis Efek Augmentasi Dataset dan Fine Tune pada Algoritma Pre-Trained Convolutional Neural Network (CNN). *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 10(4), 763–768. <https://doi.org/10.25126/jtiik.2024106583>
- Tingkat, A., Jalan, K., Indeks, B., Strategi, D., Jalan, P., Putri, M., 1, P., Bumulo, N., Icshan, I., Nento, S., Dwi Ma'sum, R., & Djunu, M. R. (2025). Analisis Tingkat Kerusakan Jalan Berdasarkan Indeks Kerusakan Jalan Dan Strategi Pemeliharaan Jalan. *J-Innovative.Org*, 5, 1959–1968. <http://j-innovative.org/index.php/Innovative/article/view/19345>
- Ulfa, N., Handayani, T., & Urva, G. (2023). Implementasi Algoritma Frequent Pattern Growth untuk Menganalisa Pola Belanja Konsumen pada Apotek Semoga Jaya. 11(2), 154–165.
- Wibowo, A., & Setiyadi, E. (2023). Klasifikasi Dan Deteksi Keretakan Pada Trotoar Menggunakan Metode Convolutional Neural Network. *Jurnal Teknik Sipil Cendekia (Jtsc)*, 4(1), 412–427. <https://doi.org/10.51988/jtsc.v4i1.116>
- Wijayanto, B., Mahendra, R. M., & Salam, M. I. (2025). Identifikasi Jenis Ikan Cupang Menggunakan Metode CNN Dengan Arsitektur MobileNetV2 Berbasis Mobile. *Prosiding Seminar Nasional Teknologi Dan Sains*, 4, 519–525. <https://medium.com/>
- Yanti, F., Sari, F., & Pratiwi, M. (2024). Penentuan Prioritas Perbaikan Jalan Menggunakan Metode Multi-Objective Optimization on The Basis of Ratio Analysis (Moora) (Studi Kasus : Dinas Pekerjaan Umum dan Penataan Ruang Kota Dumai). 12(02), 171–179.
- Zidan, A., Rahman, M. F., & Puspita Sari, A. (2024). Pemanfaatan Metode Convolutional Neural Network (CNN) Dengan Arsitektur MobileNetV2 Untuk Penilaian Kelayakan Rumah. *ALINIER: Journal of Artificial Intelligence & Applications*, 5(2), 129–139. <https://doi.org/10.36040/alinier.v5i2.11061>