

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

**KLASIFIKASI TINGKAT KERUSAKAN JALAN BERBASIS
CITRA DIGITAL MENGGUNAKAN ALGORITMA
CONVOLUTIONAL NEURAL NETWORK**

TUGAS AKHIR

Diajukan Sebagai Salah Satu Syarat
untuk Memperoleh Gelar Sarjana Komputer pada
Program Studi Sistem Informasi



Oleh:

RIFKA ANRAHVI
12250321100



UIN SUSKA RIAU

UIN SUSKA RIAU

FAKULTAS SAINS DAN TEKNOLOGI

**UNIVERSITAS ISLAM NEGERI SULTAN SYARIF KASIM RIAU
PEKANBARU**

2026

LEMBAR PERSETUJUAN

KLASIFIKASI TINGKAT KERUSAKAN JALAN BERBASIS CITRA DIGITAL MENGGUNAKAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK*

TUGAS AKHIR


Oleh:

RIFKA ANRAHVI

12250321100

Telah diperiksa dan disetujui sebagai laporan tugas akhir
di Pekanbaru, pada tanggal 15 Januari 2026

Ketua Program Studi



Anraini, S.Kom., M.Eng., Ph.D.
NIP. 198408212009012008

Pembimbing



Mustakim, ST., M.Kom.
NIP. 198807022025211003

LEMBAR PENGESAHAN

KLASIFIKASI TINGKAT KERUSAKAN JALAN BERBASIS CITRA DIGITAL MENGGUNAKAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK*

TUGAS AKHIR

Oleh:

RIFKA ANRAHVI


12250321100

Telah dipertahankan di depan sidang dewan penguji
sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer
Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau
di Pekanbaru, pada tanggal 07 Januari 2026

Pekanbaru, 07 Januari 2026

Mengesahkan,


Dekan



Dr. Yuslenita Muda, S.Si., M.Sc.

NIP. 197701032007102001

Ketua Program Studi



Angraini, S.Kom., M.Eng., Ph.D.

NIP. 198408212009012008

DEWAN PENGUJI:

Ketua : Syaifullah, SE., M.Sc.

Sekretaris : Mustakim, ST., M.Kom.

Anggota 1 : Dr. Rice Novita, S.Kom., M.Kom.

Anggota 2 : Inggih Permana, ST., M.Kom.

Lampiran Surat :
Nomor : Nomor 25/2021
Tanggal : 10 September 2021

SURAT PERNYATAAN

Saya yang bertandatangan di bawah ini:

Nama : Rifka Anrahvi
NIM : 12250321100
Tempat/Tgl. Lahir : UJUNGBATU / 13 APRIL 2004
Fakultas/Pascasarjana : SAINS dan TEKNOLOGI
Prodi : SISTEM INFORMASI

Judul Disertasi/Thesis/Skripsi/Karya Ilmiah lainnya*:


KLASIFIKASI TINGKAT KERUSAKAN JALAN BERBASIS CITRA DIGITAL
MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK

Menyatakan dengan sebenar-benarnya bahwa :

1. Penulisan ~~Disertasi/Thesis/Skripsi/Karya Ilmiah~~ lainnya* dengan judul sebagaimana tersebut di atas adalah hasil pemikiran dan penelitian saya sendiri.
2. Semua kutipan pada karya tulis saya ini sudah disebutkan sumbernya.
3. Oleh karena itu ~~Disertasi/Thesis/Skripsi/Karya Ilmiah~~ lainnya* saya ini, saya nyatakan bebas dari plagiat.
4. Apa bila dikemudian hari terbukti terdapat plagiat dalam penulisan ~~Disertasi/Thesis/Skripsi/(Karya Ilmiah lainnya)*~~ saya tersebut, maka saya bersedia menerima sanksi sesuai peraturan perundang-undangan.

Demikianlah Surat Pernyataan ini saya buat dengan penuh kesadaran dan tanpa paksaan dari pihak manapun juga.

Pekanbaru, 21 Januari 2026
Yang membuat pernyataan


Rifka Anrahvi
NIM : 12250321100



*pilih salah satu sesuai jenis karya tulis



LEMBAR HAK ATAS KEKAYAAN INTELEKTUAL

Tugas Akhir yang tidak diterbitkan ini terdaftar dan tersedia di Perpustakaan Universitas Islam Negeri Sultan Syarif Kasim Riau adalah terbuka untuk umum, dengan ketentuan bahwa hak cipta ada pada penulis. Referensi kepustakaan diperkenankan dicatat, tetapi pengutipan atau ringkasan hanya dapat dilakukan atas izin penulis dan harus dilakukan mengikuti kaedah dan kebiasaan ilmiah serta menyebutkan sumbernya.

Penggandaan atau penerbitan sebagian atau seluruh Tugas Akhir ini harus memperoleh izin tertulis dari Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau. Perpustakaan dapat meminjamkan Tugas Akhir ini untuk anggotanya dengan mengisi nama, tanda peminjaman dan tanggal pinjam pada *form* peminjaman.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.






LEMBAR PERNYATAAN

Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya yang pernah diajukan untuk memperoleh gelar kesarjanaan di suatu Perguruan Tinggi, dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan di dalam daftar pustaka.

Pekanbaru, 15 Januari 2026

Yang membuat pernyataan,

RIFKA ANRAHVI
NIM. 12250321100



UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



LEMBAR PERSEMBAHAN

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Dengan menyebut nama Allah Yang Maha Pengasih lagi Maha Penyayang

Assalamu'alaikum Warahmatullahi Wabarakatuh

Alhamdulillah Rabbil 'Alamiin, segala puji bagi Allah Subhanahu Wa Ta'ala, Tuhan semesta alam. Sujud syukur hamba persembahkan sebagai bentuk rasa terima kasih atas segala nikmat, kekuatan, dan kemudahan yang telah Engkau berikan tanpa kurang sedikitpun, sehingga hamba dapat menyelesaikan tugas akhir ini. Shalawat beserta salam senantiasa tercurah kepada junjungan kita, Nabi Muhammad Shallallahu 'Alaihi Wa Sallam, dengan melafazkan "Allahumma Sholli'ala Sayyidina Muhammad Wa'ala Ali Sayyidina Muhammad". Semoga kita semua senantiasa mendapat syafaat beliau di dunia maupun di akhirat kelak. Aamiin ya Rabbal'aalamiin.

Karya sederhana ini kupersembahkan dengan segenap cinta dan ketulusan kepada Ibunda tercinta dan Adikku tersayang atas doa, pengorbanan, kasih sayang, serta bimbingan yang tak pernah terputus. Berkat ridho dan dukungan kalian, peneliti dapat menuntaskan tanggung jawab akademik dan meraih gelar Sarjana. Tiada kata yang mampu membalas jasa-jasa tersebut, selain doa agar Allah SWT senantiasa menganugerahkan kesehatan, kebahagiaan dunia dan akhirat, serta menempatkan Ayah dan Ibu di tempat terbaik di sisi-Nya. Gelar ini adalah milik kalian, serta terima kasih kepada Adikku tercinta atas dukungan dan kebersamaan yang penuh makna.

Kepada Bapak dan Ibu Dosen Program Studi Sistem Informasi Universitas Islam Negeri Sultan Syarif Kasim Riau yang telah memberikan ilmu pengetahuan bermanfaat, pengalaman berharga dan kebaikan yang tulus selama perkuliahan, saya ucapkan terima kasih banyak dan semoga menjadi amal jariyah. *aamiin*.

Sahabat-sahabat terdekat yang tidak bisa saya sebutkan satu persatu dan pastinya juga teman-teman seperjuangan, terima kasih berkat kalian masa perkuliahan menjadi lebih bermakna dan menyenangkan semoga di masa mendatang kita bisa bertemu lagi dalam keadaan yang lebih baik.

Wassalamu'alaikum Warahmatullahi Wabarakatuh



KATA PENGANTAR

Assalammu'alaikum wa rahmatullahi wa barakatuh

Alhamdulillah rabbil 'alamin, bersyukur kehadiran Allah Subhanahu Wa Ta'ala atas segala rahmat dan karunia-Nya sehingga peneliti dapat menyelesaikan Tugas Akhir dengan hasil yang baik dan tepat waktu. Shalawat serta salam kita ucapkan kepada Nabi Muhammad Shallallahu 'Alaihi Wa Sallam dengan mengucapkan *Allahumma Sholli 'Ala Sayyidina Muhammad Wa 'Ala Ali Sayyidina Muhammad*. Tugas Akhir ini dibuat sebagai salah satu syarat untuk mendapatkan gelar Sarjana Komputer di Program Studi Sistem Informasi Universitas Islam Negeri Sultan Syarif Kasim Riau.

Pada penelitian Tugas Akhir ini, banyak pihak yang sudah berkontribusi, membantu serta mendukung peneliti baik berupa materi, moril, dan motivasi. Peneliti ingin mengucapkan banyak terima kasih kepada:

1. Ibu Prof. Dr. Hj. Leny Nofianti, MS, SE., M.Si., Ak., CA sebagai Rektor Universitas Islam Negeri Sultan Syarif Kasim Riau.
2. Ibu Dr. Yuslenita Muda, S.Si., M.Sc sebagai Dekan Fakultas Sains dan Teknologi.
3. Ibu Angraini, S.Kom., M.Eng., Ph.D sebagai Ketua Program Studi Sistem Informasi.
4. Ibu Dr. Rice Novita, S.Kom., M.Kom sebagai Sekretaris Program Studi Sistem Informasi sekaligus Dosen Penguji I yang telah meluangkan waktu untuk memberikan arahan, masukan, dan saran yang membangun dalam proses evaluasi, sehingga Tugas Akhir ini dapat tersusun dengan lebih baik dan sistematis
5. Bapak Muhammad Jazman, S.Kom., M.Infosys sebagai Kepala Laboratorium Program Studi Sistem Informasi.
6. Bapak Saide, S.Kom., M.Kom., M.I.M., Ph.D sebagai Dosen Pembimbing Akademik yang telah memberikan arahan, masukan, dan motivasi selama masa perkuliahan. Beliau juga menjadi salah satu sosok yang pertama kali membuka wawasan peneliti terhadap berbagai ilmu dan cara berpikir baru, sehingga menumbuhkan semangat belajar, rasa ingin tahu, serta keberanian peneliti untuk terus berkembang secara akademik.
7. Bapak Mustakim, ST., M.Kom sebagai Dosen Pembimbing peneliti yang telah banyak meluangkan waktu dalam memberikan arahan, masukan, saran, nasihat, dan motivasi kepada peneliti dalam penyelesaian Tugas



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Akhir ini. Dengan sikap yang rendah hati dan penuh kesabaran, beliau senantiasa membimbing peneliti dalam memahami proses penelitian serta penulisan karya ilmiah, yang menjadi pengalaman dan bekal berharga bagi peneliti dalam perjalanan akademik.

8. Bapak Syaifullah, SE., M.Sc., Ph.D sebagai Ketua Sidang yang telah meluangkan waktu serta memberikan arahan dan nasihat kepada peneliti dalam penyelesaian Tugas Akhir ini.
9. Bapak Inggh Permana, ST., M.Kom sebagai Dosen Penguji 2 peneliti yang telah banyak meluangkan dalam waktu memberikan arahan, masukan, dan saran yang membangun dalam penyelesaian Tugas Akhir ini
10. Bapak dan Ibu Dosen Program Studi Sistem Informasi atas segala ilmu dan pengalaman berharga yang telah diberikan kepada peneliti selama masa perkuliahan.
11. Kepada Cinta pertamaku, Ayahanda Rahmad, A.Md peneliti sangat berterima kasih sudah bekerja keras hingga bisa menguliahkan anak pertama mu ini. Meskipun beliau yang awalnya tidak yakin dengan dirinya untuk menguliahkan anaknya pertamanya, terimakasih sudah selalu memberikan motivasi, dukungan dan mendidik peneliti hingga peneliti mampu menyelesaikan studi ini hingga sarjana. Terima kasih, Ayah. Gadis kecilmu kini telah tumbuh dewasa dan siap melangkah untuk meraih mimpi-mimpi yang lebih tinggi.
12. Kepada pintu surgaku, Ibunda tercinta Epi Ratmiza, peneliti mengucapkan terima kasih yang tak terhingga atas peran, kasih sayang, dan doa yang tidak pernah terputus dalam proses penyelesaian studi ini. Beliau senantiasa memberikan dukungan, semangat, serta doa yang tulus, yang menjadi kekuatan bagi peneliti dalam menjalani kerasnya perjalanan hidup. Meskipun beliau tidak berkesempatan mengenyam pendidikan hingga bangku perkuliahan, namun semangat, motivasi, dan doa yang selalu terselip di setiap sujudnya menjadi bekal terbesar bagi peneliti untuk terus berjuang menempuh pendidikan hingga meraih gelar sarjana. Terima kasih, Ibu. Atas berkat dan ridhomu, anak perempuan pertamamu yang selama ini dituntut untuk selalu kuat dan tegar, kini telah mampu menyelesaikan studi dan meraih gelar Sarjana Komputer. Ibu adalah pengingat, penguat, dan sumber kekuatan terbesar dalam hidup peneliti.
13. Kepada Adikku, Bintang Ikhrum Anrahvi, terima kasih atas dukungan dan kebersamaan yang tidak selalu diungkapkan dengan kata-kata, namun selalu



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Hak cipta milik UIN Suska Riau

State Islamic University of Sultan Syarif Kasim Riau

terasa dan berarti bagi peneliti.

14. Kepada Nenek Rahma, peneliti mengucapkan terima kasih yang tulus atas doa, perhatian, dan dukungan yang senantiasa diberikan selama proses penyelesaian studi ini. Meskipun tidak selalu diungkapkan melalui kata-kata, dukungan beliau, baik secara moral maupun materi, menjadi bagian penting yang menguatkan peneliti hingga mampu menyelesaikan pendidikan sampai jenjang sarjana.
15. Kepada Kak Nisa, sepupu yang telah peneliti anggap sebagai kakak sekaligus panutan, peneliti mengucapkan terima kasih yang tulus atas perhatian, dukungan, dan bantuan yang tidak pernah terputus sejak awal perjalanan pendidikan peneliti. Sejak proses persiapan hingga pelaksanaan ujian masuk perguruan tinggi, hingga masa perkuliahan dan kehidupan di perantauan, beliau senantiasa hadir memberikan dukungan dan tempat berbagi. Kepedulian serta pendampingan yang diberikan menjadi penguat bagi peneliti dalam menjalani perjalanan ini hingga mampu menyelesaikan studi. Terimakasih mama syila.
16. Terimakasih kepada keluarga besar Nenek Rahma yang selalu memberikan support kepada peneliti.
17. Kepada Ayah Amir, peneliti mengucapkan terima kasih atas kepedulian, bantuan, serta nasihat dan motivasi yang diberikan sejak awal perkuliahan, yang menjadi dukungan berarti bagi peneliti hingga dapat menyelesaikan studi ini.
18. Kepada Stevani, Aulia, Novila, Febbi, Irma, Eser, Rahmanur, dan Amel yang telah menjadi teman peneliti sejak awal perkuliahan, terima kasih atas kebersamaan dan dukungan yang berarti dalam perjalanan akademik hingga peneliti mampu menyelesaikan Tugas Akhir ini.
19. Kepada teman-teman SMP peneliti, Dayang, Alya, Esah, Jasmin, Angel, dan Mela terima kasih atas kebersamaan dan dukungan yang masih terjalin hingga saat ini.
20. Terima kasih kepada kakak, abang serta teman seangkatan, seperbimbingan yang telah banyak memberikan saran, serta dukungan kepada peneliti dalam penyelesaian Tugas Akhir ini.
21. Kepada Teman-teman Sistem Informasi Angkatan 2022 terkhusus teman seperjuangan di Kelas B yang selalu mendukung, berbagi informasi, dan membantu peneliti dalam menjalankan masa perkuliahan.
22. Peneliti menyampaikan terima kasih kepada keluarga besar *Puzzle Research*



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Data Technology (Predattech) yang telah menjadi ruang bertumbuh bagi peneliti dalam mengasah minat dan bakat serta memberikan kepercayaan sebagai bendahara umum. Kebersamaan, dukungan, dan kerja sama yang terjalin menjadi pengalaman berharga yang sangat berarti dalam perjalanan akademik dan profesional peneliti.

23. Terakhir, peneliti ingin menyampaikan rasa terimakasih yang mendalam kepada diri sendiri, Rifka Anrahvi. Terimakasih telah bertahan sejauh ini. Untuk setiap malam yang dihabiskan dalam kelelahan, setiap pagi yang disambut dengan keraguan namun tetap dijalani, serta setiap ketakutan yang berhasil dilawan dengan keberanian. Terimakasih kepada hati yang tetap ikhlas, meski tidak semua hal berjalan sesuai harapan. Terimakasih kepada raga yang terus melangkah, meski lelah sering tak terlihat. Peneliti bangga kepada diri sendiri yang telah mampu melewati berbagai fase sulit dalam kehidupan ini. Semoga ke depannya, raga ini tetap kuat, hati tetap tegar, dan jiwa tetap lapang dalam menghadapi setiap proses kehidupan. Mari terus bekerja sama untuk tumbuh dan berkembang, menjadi pribadi yang lebih baik dari hari ke hari.

Semoga segala do'a dan dorongan yang telah diberikan selama ini menjadi amal kebajikan dan mendapat balasan setimpal dari Allah *Subhanahu Wa Ta'ala*. Peneliti menyadari bahwa penelitian Tugas Akhir ini masih banyak terdapat kekurangan dan jauh dari kata sempurna. Untuk itu, kritik dan saran atau pertanyaan dapat diajukan melalui e-mail 12250321100@students.uin-suska.ac.id. Semoga Tugas Akhir ini bermanfaat bagi kita semua. Akhir kata peneliti ucapkan terima kasih.

Wassalamu'alaikum Warahmatullahi Wabarakaatuh

Pekanbaru, 15 Januari 2026

Peneliti,

RIFKA ANRAHVI
NIM. 12250321100


Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

KLASIFIKASI TINGKAT KERUSAKAN JALAN BERBASIS CITRA DIGITAL MENGGUNAKAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK*

RIFKA ANRAHVI
NIM: 12250321100

Tanggal Sidang: 07 Januari 2026
 Periode Wisuda:

Program Studi Sistem Informasi
 Fakultas Sains dan Teknologi
 Universitas Islam Negeri Sultan Syarif Kasim Riau
 Jl. Soebrantas, No. 155, Pekanbaru

ABSTRAK

Kondisi jalan yang baik merupakan faktor penting dalam memastikan keselamatan, kenyamanan, dan aktivitas ekonomi masyarakat. Identifikasi kondisi jalan di lapangan masih sebagian besar dilakukan secara manual, sehingga membutuhkan waktu dan biaya yang besar. Penelitian ini bertujuan untuk menerapkan serta membandingkan performa beberapa arsitektur *Convolutional Neural Network* (CNN) dalam mengklasifikasikan kondisi jalan berdasarkan citra digital ke dalam empat kelas, yaitu *good*, *satisfactory*, *poor*, dan *very poor*. Penelitian ini menggunakan lima arsitektur CNN, yaitu InceptionV3, DenseNet201, VGG16, EfficientNetB0, dan ResNet50V2, dengan tiga *optimizer*, yaitu Adam, SGD, dan RMSprop. *Dataset* yang digunakan berjumlah 2.074 data citra, yang bersumber dari *dataset* publik Kaggle dan digunakan sebagai data pelatihan serta pengujian model. Eksperimen dilakukan melalui tiga skenario, meliputi tanpa augmentasi dan tanpa *preprocessing input*, tanpa augmentasi dengan *preprocessing input*, serta dengan augmentasi dan *preprocessing input*. Evaluasi performa model dilakukan menggunakan metrik akurasi, serta analisis *confusion matrix*, *classification report*, dan kurva ROC-AUC. Hasil penelitian menunjukkan bahwa arsitektur DenseNet201 dengan *optimizer* RMSprop dan *preprocessing input* mencapai performa terbaik dengan tingkat akurasi sebesar 94,31%. Model terbaik selanjutnya diimplementasikan ke dalam sistem berbasis *web* sebagai bentuk penerapan praktis. Penelitian ini menunjukkan bahwa metode CNN efektif untuk klasifikasi kondisi jalan multikelas dan berpotensi untuk mendukung sistem pemantauan infrastruktur jalan berbasis citra.

Kata Kunci: Convolutional Neural Network, deep learning, klasifikasi citra, kondisi jalan, transfer learning



CLASSIFICATION OF ROAD DAMAGE LEVELS BASED ON DIGITAL IMAGES USING CONVOLUTIONAL NEURAL NETWORK ALGORITHMS

RIFKA ANRAHVI
NIM: 12250321100

Date of Final Exam: January 07th 2026
Graduation Period:

Department of Information System
Faculty of Science and Technology
State Islamic University of Sultan Syarif Kasim Riau
Soebrantas Street, No. 155, Pekanbaru

ABSTRACT

Good road conditions are a critical factor in ensuring public safety, travel comfort, and economic activities. The identification of road conditions in the field is still largely conducted manually, resulting in significant time and cost requirements. This study aims to implement and compare the performance of several Convolutional Neural Network (CNN) architectures in classifying road conditions based on digital images into four classes, namely good, satisfactory, poor, and very poor. This research employs five CNN architectures, namely InceptionV3, DenseNet201, VGG16, EfficientNetB0, and ResNet50V2, using three optimization algorithms: Adam, SGD, and RMSprop. The dataset consists of 2,074 image samples, sourced from the public Kaggle dataset and used as training and testing data for the model. Experiments were conducted under three scenarios: without data augmentation and without input preprocessing, without data augmentation but with input preprocessing, and with both data augmentation and input preprocessing. Model performance was evaluated using accuracy as the primary metric, along with confusion matrix analysis, classification reports, and ROC-AUC curves. The experimental results indicate that the DenseNet201 architecture with the RMSprop optimizer and input preprocessing achieved the best performance, attaining an accuracy of 94.31%. The best-performing model was subsequently implemented into a web-based system as a practical application. Overall, this study demonstrates that CNN-based methods are effective for multi-class road condition classification and have strong potential to support image-based road infrastructure monitoring systems.

Keywords: *convolutional neural network, deep learning, image classification, road condition, transfer learning*



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

DAFTAR ISI

LEMBAR PERSETUJUAN	ii
LEMBAR PENGESAHAN	iii
LEMBAR HAK ATAS KEKAYAAN INTELEKTUAL	iv
LEMBAR PERNYATAAN	v
LEMBAR PERSEMBAHAN	vi
KATA PENGANTAR	vii
ABSTRAK	xi
ABSTRACT	xii
DAFTAR ISI	xiii
DAFTAR GAMBAR	xvi
DAFTAR TABEL	xvii
DAFTAR SINGKATAN	xviii
1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	3
1.3 Batasan Masalah	4
1.4 Tujuan	4
1.5 Manfaat	5
1.6 Sistematika Penulisan	5
2 LANDASAN TEORI	6
2.1 Kerusakan Jalan	6
2.2 Studi Kasus: Klasifikasi Citra Kerusakan Jalan	7
2.3 <i>Deep Learning</i>	8
2.4 <i>Convolutional Neural Network</i> (CNN)	8
2.5 Pengolahan Citra Digital	9



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

2.6	Klafisikasi Citra Digital	10
2.7	<i>Preprocessing Input</i>	10
2.8	InceptionV3	11
2.9	DenseNet201	12
2.10	VGG16	13
2.11	EfficientNetB0	13
2.12	ResNet50V2	15
2.13	<i>Adaptive Moment Estimation</i>	15
2.14	<i>Stochastic Gradient Descent</i>	16
2.15	RMSprop	17
2.16	<i>Confussion Matrix</i>	18
2.17	<i>Framework Flask</i>	19
2.18	Penelitian Terdahulu	20
3	METODOLOGI PENELITIAN	25
3.1	Tahap Perencanaan Penelitian	25
3.2	<i>Data Collection</i>	26
3.3	<i>Split Data (80:20)</i>	27
3.4	<i>Preprocessing Data</i>	27
3.5	<i>CNN Architecture Model</i>	28
3.6	<i>Optimizer</i>	29
3.7	Evaluasi Model	29
3.8	Tahap <i>Deployment</i>	29
3.9	Tahap Dokumentasi dan Laporan Akhir	30
4	HASIL DAN PEMBAHASAN	31
4.1	Analisis dan Tahap Perencanaan	31
4.2	Pengumpulan Data	31
4.3	<i>Preprocessing Data</i>	33
4.3.1	Resize Image	33
4.3.2	Normalisasi	33
4.3.3	Augmentasi Data	34
4.4	Proses Pembagian Data	35
4.5	Implementasi Model <i>Convolutional Neural Network (CNN)</i>	35
4.5.1	Arsitektur Model CNN	35
4.5.2	Konfigurasi dan Proses Pelatihan Model	44
4.5.3	<i>Optimizer</i> yang Digunakan	45

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

4.6	Hasil Evaluasi Model	45
4.7	Perbandingan Hasil dan Analisis	52
4.7.1	Pengaruh <i>Preprocessing Input</i>	53
4.7.2	Pengaruh Augemntasi Data	53
4.7.3	Perbandingan <i>Optimizer</i>	54
4.7.4	Perbandingan Arsitektur CNN	54
4.7.5	Analisis komparatif Arsitektur dan <i>Optimizer</i>	55
4.8	Diskusi	56
4.9	Tahap <i>Deployment</i>	58
4.9.1	Batasan Implementasi Sistem	58
4.9.2	Lingkungan Implementasi	58
4.9.3	Tampilan data Pengujian Sistem	59
5	PENUTUP	61
5.1	Kesimpulan	61
5.2	Saran	61

DAFTAR PUSTAKA

LAMPIRAN A	SURAT IZIN PENELITIAN	A - 1
LAMPIRAN B	WAWANCARA	B - 1
LAMPIRAN C	DOKUMENTASI KEGIATAN	C - 1

DAFTAR GAMBAR

© Hak cipta milik UIN Suska Riau

State Islamic University of Sultan Syarif Kasim Riau

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

2.1	Arsitektur <i>Convolutional Neural Network</i> (CNN) (Patra, Middy, dan Roy, 2021)	9
2.2	Arsitektur InceptionV3 (Patra dkk., 2021)	12
2.3	Arsitektur DenseNet201 (X. Zhao dkk., 2024)	13
2.4	Arsitektur VGG16 (Patra dkk., 2021)	13
2.5	Arsitektur EfficientB0	14
2.6	Arsitektur ResNet50V2 (Hamida, El Gannour, Cherradi, Ouajji, dan Raihani, 2023)	15
2.7	Confusion Matrix (Valero-Carreras, Alcaraz, dan Landete, 2023)	18
3.1	Metodologi Penelitian	25
4.1	Visualisasi Data Kaggle	32
4.2	Visualisasi Citra Augmentasi Jalan	34
4.3	<i>Model Loss</i> dan <i>Accuracy</i> DenseNet201	50
4.4	<i>Confusion Matrix</i> Model DenseNet201	50
4.5	<i>Classification Report</i> Model DenseNet201	51
4.6	Kurva ROC (AUC) Model DenseNet201	52
4.7	Perbandingan Rata-rata Akurasi Arsitektur CNN	55
4.8	Perbandingan Rata-Rata Akurasi <i>Optimizer</i>	56
4.9	Tampilan Halaman Awal	59
4.10	Tampilan Pratinjau Citra Jalan yang Diunggah ke Sistem	60
4.11	Tampilan Klasifikasi Citra Jalan	60
A.1	Surat Izin Penelitian	A - 1
B.1	Hasil Wawancara 1	B - 1
B.2	Hasil Wawancara 2	B - 2
B.3	Hasil Wawancara 3	B - 3
C.1	Dokumentasi 1	C - 1
C.2	Dokumentasi 2	C - 1
C.3	Dokumentasi 3	C - 2
C.4	Dokumentasi 4	C - 2
C.5	Dokumentasi 5	C - 2




Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

DAFTAR TABEL

2.1	Kategori Kondisi Berdasarkan Nilai SDI	6
2.2	Ringkasan Penelitian Terdahulu	22
4.1	Data yang digunakan	32
4.2	Penjelasan Implementasi Arsitektur CNN	36
4.3	Parameter Pelatihan Model CNN	45
4.4	Hasil Evaluasi Model CNN pada Berbagai Skenario, <i>Optimizer</i> , dan Arsitektur	46
4.5	Hasil Pengujian Model CNN	48
4.6	Ringkasan Perbandingan Hasil Eksperimen	53



UIN SUSKA RIAU



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

DAFTAR SINGKATAN

AI	: <i>Artificial Intelligence</i>
AUC	: <i>Area Under the Curve</i>
CNN	: <i>Convolutional Neural Network</i>
CPU	: <i>Central Processing Unit</i>
DL	: <i>Deep Learning</i>
FN	: <i>False Negative</i>
FP	: <i>False Positive</i>
GPU	: <i>Graphics Processing Unit</i>
IKP	: Indeks Kondisi Perkerasan
LR	: <i>Learning Rate</i>
PCI	: <i>Pavement Condition Index</i>
PUPR	: Pekerjaan Umum dan Perumahan Rakyat
RAM	: <i>Random Access Memory</i>
ReLU	: <i>Rectified Linear Unit</i>
RMSprop	: <i>Root Mean Square Propagation</i>
ROC	: <i>Receiver Operating Characteristic</i>
SDI	: <i>Surface Distress Index</i>
SGD	: <i>Stochastic Gradient Descent</i>
TN	: <i>True Negative</i>
TP	: <i>True Positive</i>
UIN	: Universitas Islam Negeri
UMKM	: Usaha Mikro, Kecil, dan Menengah
VGG	: <i>Visual Geometry Group</i>

UIN SUSKA RIAU

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Kehidupan sehari-hari masyarakat sangat bergantung pada infrastruktur, khususnya jaringan jalan. Infrastruktur sangat penting bagi pertumbuhan sebuah negara karena berperan sebagai dasar yang mendukung kelancaran berbagai kegiatan ekonomi dan sosial serta meningkatkan mobilitas (Swain dan Tripathy, 2024). Kondisi jalan yang baik sangat penting untuk pertumbuhan ekonomi dan peningkatan konektivitas antar wilayah. Namun, kerusakan seperti retakan dan lubang yang disebabkan oleh cuaca ekstrem, beban kendaraan yang berlebihan, dan kurangnya pemeliharaan sering menyebabkan gangguan distribusi logistik dan meningkatkan risiko kecelakaan. Pemeliharaan jalan di banyak kota sulit, terutama saat kerusakan meningkat sementara sumber daya dan dana terbatas (Chu dkk., 2023).

Di Indonesia, khususnya di Provinsi Riau, kerusakan jalan telah menjadi isu serius. Menurut BPK RI Perwakilan Provinsi Riau (2024) ratusan kilometer jalan di Pekanbaru mengalami kerusakan parah, berdampak pada kenyamanan dan keselamatan pengguna jalan serta mengganggu aktivitas ekonomi, khususnya Usaha Mikro, Kecil, dan Menengah (UMKM) dan distribusi logistik (BPK RI Perwakilan Provinsi Riau, 2024; Julianita dan Putrie, 2025). Merespons hal tersebut, Pemerintah Kota Pekanbaru telah memulai proses lelang untuk memperbaiki jalan yang rusak di beberapa kecamatan. Dalam upaya untuk meningkatkan infrastruktur lokal, proses ini direncanakan dimulai pertengahan Juli 2025. Namun, langkah ini belum bisa mencakup semua jalan sekaligus karena terbatasnya dana dan kemampuan pemerintah daerah (Pemerintah Kota Pekanbaru, 2025).

Di sisi lain, pemantauan kondisi jalan masih dilakukan secara manual, yang memerlukan waktu, tenaga, dan biaya besar, ini tidak sebanding dengan keterbatasan sumber daya daerah (Sari, Astor, Awaludin, dan Shalabuddin, 2025). Kondisi ini menunjukkan bahwa diperlukan metode pemantauan kondisi jalan yang lebih cepat, efisien, dan mampu menjangkau area yang lebih luas tanpa tergantung pada inspeksi manual di lapangan. Untuk memastikan proses deteksi kerusakan berlangsung secara konsisten dan secara *real-time*, diperlukan pendekatan yang otomatis (Ranyal, Sadhu, dan Jain, 2022). Menggunakan gambar digital menjadi salah satu pilihan yang mudah diperoleh dan dapat merepresentasikan kondisi permukaan jalan secara gambaran visual (Guo, Tian, Li, dan Sui, 2024). Namun, karena jumlah data yang besar dan variasi bentuk kerusakan yang kompleks, analisis citra mem-

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

butuhkan metode komputasi yang dapat mengenali pola visual secara otomatis dan akurat (W. Wang dkk., 2025). Variasi kerusakan jalan, terutama pada tingkat menengah, sering memiliki perbedaan visual yang halus. Hal ini menyulitkan proses mengenali kerusakan tersebut jika dilakukan secara manual atau cara tradisional (Jonathan Estilong, 2025). Karena itu, pendekatan berbasis pola visual yang mendalam justru semakin penting (Chai, Zeng, Li, dan Ngai, 2021).

Seiring kemajuan teknologi, pendekatan *deep learning* khususnya *Convolutional Neural Network* (CNN), semakin diandalkan dalam menganalisis citra digital untuk mendeteksi kerusakan jalan secara cepat dan presisi. Selain memungkinkan pelatihan *end-to-end*, CNN memiliki performa yang lebih baik dibandingkan dengan metode konvensional dan metode *machine learning* lainnya (D. R. Chen dan Chiu, 2023; Jakubec, Lieskovská, Bučko, dan Záborská, 2023). CNN dapat digunakan untuk mendeteksi kerusakan jalan seperti lubang, terutama di genangan air yang tertutup. Kekurangan sumber daya manusia membuat pendekatan otomatis berbasis CNN dapat membantu deteksi dini (Chun dan Ryu, 2019; Denaro dan Lim, 2025)

Berbagai studi sebelumnya telah menunjukkan efektivitas CNN dalam klasifikasi kerusakan jalan dengan hasil yang menjanjikan. Menurut penelitian Arafin, Billah, dan Issa (2024) model InceptionV3 dengan *optimizer* SGD memiliki akurasi 91% dalam klasifikasi cacat beton, sedangkan Adam lebih optimal untuk segmentasi retakan Arafin dkk. (2024). Matarneh, Elghaish, Pour Rahimian, Abdellatif, dan Abrishami (2024) mengevaluasi berbagai arsitektur CNN dan menemukan bahwa DenseNet201 menunjukkan performa klasifikasi yang sangat baik, dengan nilai F1-score sebesar 98,73% serta tingkat akurasi yang tinggi (Matarneh dkk., 2024). Selanjutnya Swain dan Tripathy (2024), menunjukkan bahwa penerapan CNN berbasis VGG-16 mampu mencapai akurasi hingga 97,3%, dan meningkat hingga 99,23% dengan pendekatan *transfer learning* pada deteksi lubang jalan (Swain dan Tripathy, 2024). Sementara itu, Chaudhary dan Verma (2024) mengusulkan penggunaan EfficientNet-B0 sebagai arsitektur CNN yang ringan dan efisien, yang mampu mencapai tingkat akurasi di atas 96% dalam klasifikasi permukaan jalan, sehingga berpotensi untuk diterapkan pada sistem berbasis aplikasi dengan kebutuhan komputasi yang lebih rendah (Chaudhary dan Verma, 2024).

Banyak penelitian sebelumnya telah menunjukkan keefektifan CNN dalam mendeteksi kerusakan jalan, namun sebagian penelitian hanya membahas beberapa jenis kerusakan tertentu, seperti *crack* dan *spalling* (Arafin dkk., 2024), tiga jenis retak (Matarneh dkk., 2024), atau lubang jalan (Swain dan Tripathy, 2024). Selain itu



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

beberapa studi hanya memakai satu arsitektur CNN, sehingga perbandingan model kurang komprehensif (Chaudhary dan Verma, 2024; Swain dan Tripathy, 2024). Beberapa dataset yang digunakan tidak mencerminkan kondisi umum permukaan jalan karena berasal dari lingkungan terkontrol atau berfokus pada material tertentu seperti beton (Arafin dkk., 2024).

Meskipun demikian, variasi tingkat kerusakan jalan di dunia nyata tetap memerlukan penilaian yang lebih mendalam agar lembaga terkait dapat mengambil keputusan yang lebih baik. Selain temuan dalam literatur, kondisi nyata di lapangan juga memperlihatkan kendala serupa. Wawancara dengan Dinas Pekerjaan Umum dan Perumahan Rakyat (PUPR) Pekanbaru menunjukkan bahwa evaluasi kondisi jalan di lapangan masih mengalami hambatan karena faktor cuaca, pencahayaan, dan perbedaan karakteristik kerusakan di setiap lokasi. Meskipun kerusakan dapat diamati secara langsung, penyelarasan penilaian antar lokasi masih menjadi tantangan. Penelitian ini dilaksanakan setelah peneliti memperoleh izin penelitian dari instansi terkait, yaitu Dinas PUPR. Surat izin penelitian tersebut disajikan pada Lampiran A.

Berdasarkan permasalahan tersebut, penelitian ini berfokus pada klasifikasi tingkat kerusakan jalan menggunakan gambar digital ke dalam empat kategori, yaitu *good*, *satisfactory*, *poor*, dan *very poor*. Untuk mendapatkan model dengan performa terbaik, penelitian ini juga membandingkan lima arsitektur CNN yang telah terbukti efektif pada penelitian sebelumnya yaitu InceptionV3, DenseNet201, VGG16, EfficientNetB0, ResNet50V2. Setiap model diuji dengan tiga jenis *optimizer* (Adam, SGD, dan RMSprop) untuk menemukan kombinasi yang paling optimal. Pendekatan ini diharapkan dapat berkontribusi pada identifikasi digital kondisi jalan dan berfungsi sebagai acuan awal bagi lembaga terkait dalam pengambilan keputusan.

1.2 Perumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan, rumusan masalah dalam penelitian ini adalah bagaimana performa lima arsitektur CNN, yaitu InceptionV3, DenseNet201, VGG16, EfficientNetB0, ResNet50V2 dalam mengklasifikasikan kondisi jalan berdasarkan citra digital ke dalam kategori *good*, *satisfactory*, *poor*, dan *very poor*, serta arsitektur mana yang menghasilkan performa terbaik berdasarkan metrik evaluasi seperti akurasi, *precision*, *recall*, *F1-score*, dan *confusion matrix*.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

1.3 Batasan Masalah

Dalam melakukan penelitian, penting untuk menetapkan batasan-batasan masalah agar tetap terfokus pada rencana yang telah ditetapkan. Oleh karena itu, batasan masalah pada penelitian ini yaitu:

1. Penelitian ini menggunakan lima arsitektur CNN yaitu InceptionV3, DenseNet201, VGG16, EfficientNetB0, ResNet50V2 serta menggunakan *optimizer* Adam, SGD dan RMSprop. Perbandingan antar arsitektur dilakukan dari segi performa klasifikasi citra kondisi jalan.
2. Proses pelatihan model dilakukan dengan metode *Hold-Out* dalam perbandingan 80:20. Teknik augmentasi data digunakan, yaitu rotasi acak hingga 30 derajat, *shear* hingga 15%, *zoom* hingga 15%, serta *flipping* untuk meningkatkan variasi dan keberagaman data pelatihan.
3. Evaluasi dari model menggunakan *confusion matrix* yang terdiri dari *accuracy*, *precision*, *recall*, dan F-1 *score* serta ROC, sebagai dasar perbandingan performa antar model.
4. *Dataset* yang digunakan dalam penelitian ini berasal dari *dataset* terbuka Kaggle dengan nama Road Damage Classification and Assessment, dengan jumlah sebanyak 2.074 data citra, yang terdiri dari empat kategori tingkat kerusakan jalan, yaitu *good*, *satisfactory*, *poor*, dan *very poor* sesuai dengan tingkat kerusakannya dengan link *dataset* yaitu <https://www.kaggle.com/datasets/prudhvignv/road-damage-classification-and-assessment> *dataset* ini digunakan sebagai data pelatihan model CNN.
5. Tools yang digunakan adalah *Google Colab*, *Library TensorFlow*, *framework Flask* dan Keras
6. Implementasi sistem dilakukan menggunakan model terbaik hasil evaluasi untuk mengklasifikasikan citra kondisi jalan berbasis web.

1.4 Tujuan

Tujuan dari penelitian ini adalah untuk:

1. Menerapkan dan membandingkan performa lima arsitektur CNN yaitu InceptionV3, DenseNet201, VGG16, EfficientNetB0, ResNet50V2, dengan menggunakan optimzer Adam, SGD, dan RMSProp dalam mengklasifikasikan tingkat kerusakan jalan berbasis citra digital ke dalam kategori *good*, *satisfactory*, *poor*, dan *very poor* serta menentukan kombinasi arsitektur CNN dan *optimizer* yang menghasilkan performa terbaik berdasarkan



1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Confusion Matrix.

2. Memberikan gambaran awal tentang penerapan klasifikasi citra untuk mendukung identifikasi kondisi jalan secara digital, sehingga dapat membantu instansi terkait, seperti Dinas PUPR Pekanbaru, dalam mengambil keputusan terkait pemeliharaan jalan.

1.5 Manfaat

Manfaat dari penelitian ini adalah:

1. Memberikan gambaran komparatif performa lima arsitektur CNN dalam klasifikasi multikelas kondisi jalan berbasis citra.
2. Menjadi referensi dalam pengembangan model klasifikasi jalan yang lebih akurat untuk keperluan pemetaan atau monitoring infrastruktur.
3. Mendukung instansi seperti Dinas PUPR dalam pengambilan keputusan teknis dengan menyediakan informasi awal mengenai kondisi jalan melalui pendekatan berbasis citra digital.

1.6 Sistematika Penulisan

Adapun sistematika penulisan dari laporan Tugas Akhir ini yaitu:

BAB I. PENDAHULUAN

Pada bab ini akan membahas latar belakang masalah, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, dan sistematika penulisan.

BAB II. LANDASAN TEORI

Bab ini akan menguraikan secara teoritis konsep-konsep dan teori-teori yang mendukung penelitian tugas akhir ini yang berasal dari jurnal ilmiah, prosiding, buku serta studi kepustakaan yang digunakan sebagai tinjauan dalam pembuatan Tugas Akhir ini.

BAB III. METODOLOGI PENELITIAN

Bab ini memaparkan mengenai tentang alur penelitian peneliti mulai dari pengumpulan data hingga hasil prediksi.

BAB IV. HASIL DAN ANALISIS

Pada bab ini memaparkan mengenai hasil yang merupakan implementasi dari algoritma CNN dengan beberapa arsitektur dalam klasifikasi gambar tingkat kerusakan jalan.

BAB V. PENUTUP

Dalam bab ini, disajikan rangkuman dari kesimpulan yang dihasilkan dari Tugas Akhir yang dilakukan, serta saran untuk penelitian lanjutan berdasarkan temuan yang telah diperoleh dalam penelitian ini.

BAB 2

LANDASAN TEORI

2.1 Kerusakan Jalan

Kerusakan jalan adalah kondisi di mana struktur atau fungsi permukaan jalan mengalami perubahan dari kondisi semula. Menurut Pedoman Perencanaan Perkerasan Jalan Raya Nomor 01/PR/M/2012 (Bina Marga), kerusakan jalan didefinisikan sebagai tanda-tanda atau kondisi yang menunjukkan turunnya kualitas permukaan jalan. Kerusakan tersebut bisa berupa retakan, perubahan bentuk, lubang, atau pengelupasan lapisan permukaan (Kementerian Pekerjaan Umum dan Perumahan Rakyat Republik Indonesia, 2012).

Kementerian Pekerjaan Umum dan Perumahan Rakyat (PUPR) telah mengeluarkan Surat Edaran Nomor 12/SE/Db/2024 tentang Pedoman Leger Jalan untuk menjelaskan parameter kondisi jalan yang digunakan *Surface Distress Index* (SDI) dan *Pavement Condition Index* (PCI) untuk menilai tingkat kerusakan tersebut. SDI menunjukkan tingkat kerusakan secara cepat di lapangan dengan menggunakan hasil pengamatan visual terhadap jenis dan tingkat kerusakan pada permukaan jalan. SDI dihitung berdasarkan jumlah lubang per 100 meter panjang jalan, kedalaman alur roda (*rutting*), dan retak permukaan (luas dan lebar rata-rata retak) (Kementerian Pekerjaan Umum dan Perumahan Rakyat, 2024)

Sementara itu, *Pavement Condition Index* (PCI) adalah angka yang digunakan untuk menunjukkan kondisi permukaan jalan. Angka ini didasarkan pada pengamatan visual terhadap jenis, tingkat kerusakan, dan sebaran masalah pada jalan tersebut (sesuai dengan Petunjuk Penentuan Indeks Kondisi Perkerasan (KP) dalam Surat Edaran Menteri Pekerjaan Umum dan Perumahan Rakyat Nomor 19/SE/M/2016 tentang penerapan 10 pedoman di bidang jalan dan jembatan, tanggal 11 Oktober 2016) (Kementerian Pekerjaan Umum dan Perumahan Rakyat, 2016). Tabel 2.1 berikut menunjukkan penggunaan parameter ini untuk membagi tingkat kerusakan permukaan jalan ke dalam beberapa kategori.

Tabel 2.1. Kategori Kondisi Berdasarkan Nilai SDI

Nilai SDI	Kategori Kondisi
< 50	Baik
50–100	Sedang
100–150	Rusak Ringan
> 150	Rusak Berat



Kategori kondisi jalan pada metode *Surface Distress Index* (SDI) yang digunakan oleh Kementerian Pekerjaan Umum dan Perumahan Rakyat secara konseptual memiliki kesesuaian dengan pembagian kelas kondisi jalan pada *dataset Road Damage Classification and Assessment*, yaitu *good*, *satisfactory*, *poor*, dan *very poor*. Kesamaan tersebut terletak pada tujuan pengelompokan kondisi jalan berdasarkan tingkat kerusakan permukaan yang dapat diamati secara visual. Namun demikian, penelitian ini tidak melakukan perhitungan nilai SDI secara langsung, melainkan menggunakan pendekatan klasifikasi visual berbasis citra digital untuk mengelompokkan tingkat kondisi jalan.

Dalam konteks penelitian ini, istilah rusak mengacu pada kondisi permukaan jalan yang menunjukkan adanya kerusakan yang dapat diamati secara visual melalui citra digital. Kerusakan tersebut meliputi indikasi seperti retakan yang terlihat jelas, lubang pada permukaan jalan, pengelupasan lapisan perkerasan, atau ketidakrataan permukaan jalan yang berpotensi mengganggu fungsi dan kenyamanan pengguna jalan (Kusumaningrum, Madenda, Karmilasari, dan Nahdalina, 2022). Pengelompokan kondisi jalan ke dalam kategori baik, sedang, rusak ringan, dan rusak berat didasarkan pada tingkat keparahan kerusakan permukaan yang tampak secara visual, bukan pada hasil pengukuran struktural jalan atau perhitungan teknis secara langsung.

Penyebab utama kerusakan jalan antara lain kemacetan lalu lintas yang berlebihan, kualitas bangunan atau bahan yang kurang baik, cuaca yang ekstrem, serta kurangnya perawatan. Metode pemeriksaan secara manual membutuhkan waktu dan biaya yang besar serta rentan terhadap penilaian subjektif di lapangan (Kementerian Pekerjaan Umum, 2011; Kementerian Pekerjaan Umum dan Perumahan Rakyat Republik Indonesia, 2012). Oleh karena itu, penggunaan gambar digital dan algoritma *Convolutional Neural Network* (CNN) sangat diperlukan untuk mengklasifikasikan kerusakan jalan secara otomatis dan lebih efisien.

2.2 Studi Kasus: Klasifikasi Citra Kerusakan Jalan

Klasifikasi citra kerusakan jalan adalah cara penting untuk memantau kondisi jalan, terutama untuk membantu proses inspeksi jalan secara otomatis menggunakan teknologi penglihatan komputer dan pembelajaran mesin. Dengan memanfaatkan foto dari kamera kendaraan atau *smartphone*, berbagai jenis kerusakan permukaan seperti retak longitudinal, retak *transversal*, retak *alligator*, serta lubang jalan bisa terdeteksi dengan efisien (Kulambayev dkk., 2022).

Sebagai bagian dari proses pengolahan citra digital, klasifikasi kerusakan



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

jalan dilakukan dengan menggunakan algoritma *Convolutional Neural Network* (CNN). CNN mampu mengambil ciri-ciri dari gambar permukaan jalan sehingga bisa mengelompokkan kondisi jalan ke dalam berbagai tingkat kerusakan berdasarkan data visual yang didapat. Jenis kerusakan yang biasanya diteliti mencakup retakan, pelepasan permukaan, retakan di tepi jalan, hingga lubang jalan. Jika dibandingkan dengan metode manual atau pendekatan tradisional, CNN terbukti memberikan hasil yang lebih akurat dalam mengidentifikasi jenis dan tingkat kerusakan (Bouhsissin, Assemblali, dan Sael, 2025; Kulambayev dkk., 2022).

2.3 Deep Learning


Deep learning adalah jenis pembelajaran mesin yang memiliki kemampuan untuk merepresentasikan fitur secara akurat melalui proses representasi non-linear (Ahmed dkk., 2023). *Deep learning* memiliki kemampuan untuk secara otomatis mengekstraksi fitur dari data mentah seperti gambar atau sinyal. Ini berbeda dengan metode *machine learning* tradisional yang bergantung pada fitur buatan (hand-crafted features) (Alzubaidi dkk., 2021). Penelitian Y. Li, Wei, Han, Huang, dan Wang (2020) telah berhasil dilakukan dalam berbagai tugas, termasuk identifikasi target, deteksi objek, klasifikasi citra, pemrosesan bahasa alami, dan pengenalan suara (Y. Li dkk., 2020). Keuntungan utama dari *Deep learning* adalah kemampuannya untuk memproses data yang besar dan kompleks secara efisien dan meningkatkan akurasi pemrosesan data, menjadikannya alat yang berguna untuk banyak aplikasi AI, seperti mengklasifikasikan kerusakan jalan (S. Li dan Zhang, 2025).

2.4 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah model pembelajaran mendalam yang paling representatif untuk pengolahan data citra (X. Zhao dkk., 2024). CNN adalah jaringan saraf berlapis yang dirancang khusus untuk mengenali dan mengklasifikasikan gambar, dengan arsitektur yang efisien dalam mengurangi jumlah parameter dan mempermudah pelatihan, sehingga meningkatkan akurasi klasifikasi (Y. Li dkk., 2020). CNN dirancang untuk mengolah data seperti gambar dengan mengekstraksi fitur secara bertahap melalui konvolusi. Teknik seperti *parameter sharing* dan koneksi terbatas membuatnya lebih efisien secara komputasi (Z. Li, Lu, Yang, Peng, dan Zhou, 2022; Raj dan Kos, 2025). CNN umumnya memiliki arsitektur berlapis yang mencakup tahap ekstraksi fitur dan klasifikasi akhir. Gambar 2.1 menunjukkan struktur jaringan yang umum, menunjukkan jalan dari input gambar hingga proses klasifikasi.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Gambar 2.1. Arsitektur *Convolutional Neural Network* (CNN) (Patra dkk., 2021)

Struktur utama CNN terdiri dari *convolutional layer* untuk mendeteksi pola lokal, *pooling layer* untuk mengurangi dimensi dan mencegah *overfitting*, *flatten layer* untuk mengubah data menjadi vektor, serta *fully connected layer* untuk menghasilkan prediksi akhir. Contohnya, *filter* 5×5 dapat mengekstrak fitur dasar, dan *average pooling* terbukti efektif mempertahankan informasi penting seperti pada klasifikasi kerusakan jalan (Anton, Nissa, Janiati, Cahya, dan Astuti, 2021; W. Wang dkk., 2025). Fungsi aktivasi yang sering digunakan dalam CNN adalah *ReLU*, yang menjaga nilai positif dan menghilangkan nilai negatif untuk mempercepat pelatihan dan mencegah *vanishing gradient*. Untuk mencegah *overfitting*, digunakan teknik *dropout* yang secara acak menonaktifkan neuron saat pelatihan guna meningkatkan generalisasi model (Salehin dan Kang, 2023). Keunggulan CNN dalam klasifikasi citra adalah kemampuannya mengekstraksi fitur secara otomatis tanpa rekayasa manual, serta performanya yang unggul dalam tugas visual seperti klasifikasi, deteksi objek, dan segmentasi (X. Zhao dkk., 2024).

2.5 Pengolahan Citra Digital

Sebelum model pembelajaran mendalam seperti *Convolutional Neural Network* (CNN) dapat digunakan untuk pelatihan dan prediksi, pengolahan citra digital adalah tahap awal penting dalam pemrosesan data citra yang meningkatkan kualitas data dan menyesuaikan formatnya (Liu, Soh, dan Lorang, 2021). Prapemrosesan, atau *preprocessing*, adalah tahap penting dalam pengolahan gambar. Tahap ini mencakup penyesuaian ukuran gambar (*resizing*) agar sesuai dengan arsitektur CNN, biasanya menjadi 224×224 piksel, dan penggunaan *padding* untuk menjaga proporsi objek. Untuk mempercepat proses pelatihan dan menjaga kestabilan numerik, normalisasi digunakan, baik dengan membagi intensitas piksel dengan 255 maupun dengan menggunakan standarisasi berbasis nilai rata-rata dan standar deviasi (Krichen, 2023). Teknik augmentasi gambar dapat meningkatkan generalisasi dan mengurangi *overfitting*. Teknik-teknik ini termasuk transformasi geometrik (*rotasi*, *flip*, *zoom*, *cropping*), serta penyesuaian visual (*perubahan warna*, *kecerahan*, dan penambahan *noise*). Teknik ini bertujuan untuk meningkatkan variasi data



latih agar model lebih sesuai dengan situasi dunia nyata (Shorten dan Khoshgof-taar, 2019). *Preprocessing* sangat penting untuk meningkatkan generalisasi model, mengurangi *overfitting*, dan mensimulasikan kondisi nyata, terutama dalam situ-asi dengan data terbatas, seperti deteksi kerusakan jalan. Selama tahap ini, CNN dapat belajar dengan lebih baik dan menghasilkan klasifikasi yang lebih akurat (G.-H. Chen dkk., 2022).

2.6 Klafisikasi Citra Digital

Klasifikasi citra digital adalah proses pengelompokan gambar berdasarkan karakteristik visual seperti pola, tekstur, warna, dan bentuk. Meskipun penting dalam berbagai bidang seperti pengawasan lalu lintas dan deteksi medis, pen-dekatan konvensional masih terbatas dalam menangani citra kompleks beresolusi tinggi (Solihin, Syarief, Rochman, dan Rachmad, 2023). Proses klasifikasi citra menjadi jauh lebih efisien dan akurat berkat kemajuan teknologi pembelajaran men-dalam, terutama dengan munculnya *Convolutional Neural Network* (CNN). Dengan kemampuan nya untuk membentuk representasi citra secara hierarki dan semantik, CNN sangat informatif untuk sistem pengenalan visual. CNN mengekstraksi berba-gai fitur secara bertahap, mulai dari fitur tingkat rendah seperti tepi dan warna, hing-ga fitur tingkat tinggi seperti pola atau bentuk kompleks (Z. Q. Zhao, Zheng, Xu, dan Wu, 2019).

2.7 *Preprocessing Input*

Preprocessing input adalah analisis awal data sebelum dimasukkan ke dalam model pembelajaran mendalam atau *deep learning*. Tujuannya adalah un-tuk meningkatkan kualitas data dan menyesuaikannya dengan kebutuhan algoritma yang digunakan (Kim, 2024). Dalam konteks pengolahan citra, *preprocessing* men-cakup langkah-langkah seperti menormalisasi nilai piksel, menyesuaikan ukuran gambar, meningkatkan kualitas citra, dan mengurangi *noise* sebelum citra diproses lebih lanjut oleh jaringan saraf. Dalam *deep learning*, *preprocessing input* dianggap sebagai langkah penting dalam *pipeline* pemodelan karena pemilihan teknik yang tepat dapat membantu mempercepat konvergensi, mengurangi tantangan pembe-lajaran, dan meningkatkan kemampuan model untuk generalisasi pada data baru (Nguyen-Tat, Hung, Nam, dan Ngo, 2025). Sebagai contoh penerapan *preprocess-ing input* dalam *transfer learning*, Keras/TensorFlow menyediakan fungsi berna-ma *preprocess_input* yang dapat digunakan untuk mengekstrak data sebelum dima-sukkan ke dalam model seperti VGG, ResNet, Inception, dan EfficientNet, fungsi ini bukanlah model baru atau lapisan tambahan, melainkan bagian dari fase pemros-



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

esan data (Keras Team, 2024b). Fungsi *preprocess_input* memastikan bahwa format dan distribusi piksel citra sesuai dengan konvensi yang digunakan saat model diterapkan pada *dataset ImageNet*, sehingga fitur yang telah dipelajari sebelumnya dapat digunakan secara optimal selama proses *fine-tuning* (TensorFlow Team, 2024).


Setiap arsitektur CNN memiliki karakteristik *preprocessing* yang berbeda. Misalnya, EfficientNet umumnya menerapkan proses *rescaling* dalam arsitekturnya (*pass-through*), sementara arsitektur CNN lainnya, seperti ResNet dan VGG, menerapkan pengurangan nilai rata-rata atau saluran warna (Keras Team, 2024a). Beberapa penelitian terdahulu menunjukkan bahwa teknik *preprocessing*, seperti normalisasi dan homogenisasi citra, memiliki dampak yang signifikan terhadap performa *transfer learning* di domain yang relevan. Oleh karena itu, *preprocessing* harus dipertimbangkan dengan cermat sebagai bagian dari metodologi eksperimen (Singh, 2023; Ul Huda, Gade, dan Moeslund, 2021).

2.8 InceptionV3

InceptionV3 merupakan arsitektur CNN yang dirancang untuk meningkatkan akurasi pengenalan citra dengan efisiensi komputasi tinggi. Arsitektur ini menggunakan modul *inception*, yaitu blok konvolusi paralel dengan berbagai ukuran *kernel* untuk menangkap fitur multi-skala (Abd Zaid, Mohammed, dan Sumari, 2025). GoogLeNet pertama kali memperkenalkan modul ini, yang memanfaatkan konvolusi 1×1 untuk mengurangi dimensi sebelum menerapkan konvolusi 3×3 atau 5×5 . Ini meningkatkan efisiensi model (Patra dkk., 2021). InceptionV3 kemudian menggunakan konvolusi faktorisasi untuk mengembangkan metode ini. Ini termasuk memecah *kernel* 3×3 menjadi 1×3 dan 3×1 , dan mengganti *kernel* 5×5 dengan dua lapisan 3×3 secara berurutan. Selain itu, InceptionV3 memiliki klasifikator pendukung yang meningkatkan aliran gradien dan mempercepat proses pelatihan (Abd Zaid dkk., 2025). Ukuran *input* diperbesar menjadi 299×299 piksel guna menangkap fitur kompleks (Z. Li dkk., 2022), dan bagian akhir menggunakan *AVN* dan fungsi aktivasi *softmax* untuk klasifikasi (Joshi, Tripathi, Bose, dan Bhardwaj, 2020). Dengan menggunakan pemrosesan multi-skala baik di modul utama maupun cabangnya, desain InceptionV3 mendukung representasi fitur berdimensi tinggi (Y. Li dkk., 2020). Arsitektur utama model InceptionV3 beserta komponen-komponennya ditampilkan pada Gambar 2.2.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Gambar 2.2. Arsitektur InceptionV3 (Patra dkk., 2021)


2.9 DenseNet201

DenseNet201 adalah varian dari arsitektur *Dense Convolutional Network* dengan 201 lapisan. Dibangun untuk mengatasi masalah yang sering terjadi pada CNN dalam, seperti kehilangan gradien, duplikasi fitur, dan jumlah parameter yang besar. Dengan menghubungkan setiap lapisan ke lapisan sebelumnya, arus informasi dan gradien dapat mengalir dengan lebih efisien (Huang, Liu, van der Maaten, dan Weinberger, 2018). Arsitektur ini terdiri dari *Dense Blocks* dan *Transition Layers*, di mana setiap lapisan blok menerima *input* dari seluruh lapisan sebelumnya. Ini membantu mengurangi parameter dan *overfitting* (Zhou dkk., 2024). *Transition layers* juga berperan dalam mengatur jumlah saluran dan mengurangi dimensi spasial.

DenseNet201 efisien secara komputasi karena hanya membutuhkan satu lapisan *fully connected*, serta umum digunakan dengan *input* citra 224 x 224 x 3 dan konvolusi awal 7 x 7 (Apeagyei, Ademolake, dan Adom-Asamoah, 2023). Dengan berfokus pada aspek konektivitas piksel, fungsi *loss* yang baru dapat meningkatkan deteksi gambar pada DenseNet201 sehingga menghasilkan prediksi retakan yang lebih koheren dan akurat (Mei, Gül, dan Azim, 2020). Keunggulan lainnya adalah berbagi fitur lapisan, yang mempercepat pelatihan dan mempertahankan performa tinggi dengan parameter yang relatif sedikit (Adam, Mohamed, dan Ibrahim, 2021). Karena memiliki akses langsung ke citra dan gradien *input* di setiap lapisan, DenseNet mengurangi biaya komputasi (Rahman dkk., 2020). Arsitektur DenseNet201 secara umum terlihat pada Gambar 2.3, yang menunjukkan hubungan yang padat antar lapisan untuk membantu proses pelatihan yang lebih efisien dan penggunaan fitur secara maksimal. Pilihan arsitektur yang bijak ini memudahkan penyebaran dan pembagian fitur di berbagai lapisan. Desain yang saling terhubung ini adalah karakteristik DenseNet201 (Adam dkk., 2021). Arsitektur utama DenseNet201 secara umum ditunjukkan pada Gambar 2.3.

Hak Cipta Dilindungi Undang-Undang


1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Gambar 2.3. Arsitektur DenseNet201 (X. Zhao dkk., 2024)

2.10 VGG16

VGG16 merupakan arsitektur CNN yang dapat mengekstraksi fitur hierarkis dari data piksel, menjadikannya arsitektur yang banyak digunakan dalam klasifikasi gambar. Model ini terdiri dari 13 lapisan konvolusional dan 3 *fully connected*. Model ini disusun dalam lima blok konvolusi, dengan filter 3×3 di setiap akhir blok dan maksimum penggabungan 2×2 di akhir blok (Patra dkk., 2021). VGG16 mampu membuat representasi fitur kompleks dengan aktivasi *ReLU* dan *softmax* untuk klasifikasi akhir. Dalam beberapa situasi tertentu, dua lapisan yang benar-benar terhubung diganti dengan satu lapisan yang memiliki 256 *node* untuk keperluan deteksi khusus, seperti jalan berlubang (Patra dkk., 2021; Theckedath dan Sedamkar, 2020). Strukturnya yang cukup dalam namun sederhana membuatnya stabil, menghindari *overfitting* dan hilangnya gradien (Priyanka, Lakshmi, Vyshnavi, Suresha, dan Jipeng, 2025). VGG16 menunjukkan performa lebih baik dari VGG19 pada deteksi kerusakan jalan (Yin, Qu, Huang, dan Chen, 2021), serta tetap akurat meski diterapkan pada *dataset* kecil (Ichsan, Riyadi, dan Pardede, 2024). Arsitektur VGG16 secara umum ditunjukkan pada Gambar 2.4.



Gambar 2.4. Arsitektur VGG16 (Patra dkk., 2021)


2.11 EfficientNetB0

EfficientNetB0 adalah arsitektur CNN yang bertujuan untuk mencapai akurasi tinggi sambil meningkatkan efisiensi komputasi. Model ini menggunakan

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.


pendekatan penskalaan majemuk untuk menyeimbangkan kedalaman, lebar, dan resolusi jaringan, dan menghasilkan performa yang sangat baik dengan jumlah parameter dan *FLOPS* yang jauh lebih rendah dibandingkan dengan CNN konvensional (Chaudhary & Verma, 2024). Arsitekturnya terdiri dari konvolusi awal 3×3 , 16 blok *MBConv*, konvolusi 1×1 , *global average pooling*, dan klasifikasi akhir. Untuk stabilitas pelatihan, *Swish activation* dan *batch normalization* digunakan (Sudan Wang, 2020). Blok *MBConv* memiliki modul *Squeeze-and-Excitation* untuk mengatur fitur penting dengan cara yang berbeda. Model ini memiliki sekitar 66 juta parameter, yang membuatnya lebih cepat dan sederhana daripada banyak CNN lainnya (Mirzaei, Mohammed, Sekeroglu, dan Ilhan, 2025). Selain memperluas jaringan, penskalaan parameter yang seimbang membantunya menghindari *overfitting* pada *dataset* yang lebih kecil (Hassan dkk., 2025). EfficientNetB0 cocok untuk sistem dengan daya terbatas seperti perangkat *mobile* dan aplikasi deteksi jalan karena ringan dan fleksibel (Chaudhary dan Verma, 2024). Model arsitektur EfficientNetB0 ditunjukkan pada Gambar 2.5.



Gambar 2.5. Arsitektur EfficientB0

2.12 ResNet50V2

ResNet50V2 adalah modifikasi ResNet50 yang menggunakan metode *pre-activation*. Aktivasi dan normalisasi *batch* dilakukan sebelum konvolusi. Metode ini mempercepat konvergensi model dan membantu mengatasi *gradient* yang hilang. Model ini terdiri dari 50 lapisan dan sejumlah blok *residual* dengan *connection skip*, yang memungkinkan aliran data langsung ke lapisan lebih dalam tanpa kehilangan konteks penting. Ini membuat pelatihan jaringan dalam lebih stabil dan efektif (Mangeri, Gnana Prakasi, Kanmani, dan Puppala, 2021). ResNet50V2 digunakan secara luas dalam berbagai tugas visi komputer karena menawarkan keseimbangan antara akurasi dan efisiensi. Dibandingkan dengan versi lain, seperti ResNet18 atau ResNet101, ResNet50V2 memiliki kedalaman yang cukup untuk menghasilkan klasifikasi yang akurat tanpa beban komputasi yang berlebihan. ResNet50V2 dapat digunakan dengan baik dalam *transfer learning* dengan bobot pra-latih dari *dataset* besar seperti ImageNet. Ini memiliki kemampuan untuk menerima *input* gambar dengan resolusi yang berbeda, mulai dari 224×224 piksel hingga 256×256 piksel, tanpa mengurangi ketepatan fitur (Daoud dkk., 2025). Model arsitektur EfficientNetB0 ditunjukkan pada Gambar 2.6



Gambar 2.6. Arsitektur ResNet50V2 (Hamida dkk., 2023)

2.13 Adaptive Moment Estimation

Adaptive Moment Estimation (Adam) adalah algoritma optimasi berbasis *gradient descent* yang banyak digunakan dalam pelatihan CNN. Algoritma ini menggabungkan keunggulan *Momentum* dan RMSprop untuk mempercepat konvergensi dan meningkatkan stabilitas pelatihan (Arafin dkk., 2024). Ada dua estimasi momen yang digunakan Adam untuk menyesuaikan laju pembelajaran untuk setiap parameter. Ini adalah rata-rata gradien pertama dan kuadrat gradien kedua, yang keduanya dihitung dengan eksponensial dari gradien sebelumnya. Metode ini menjaga kestabilan pembaruan bobot dan membantu menghindari *gradient* yang hilang (Soujanya dan Sitamahalakshmi, 2020). Dalam klasifikasi multikelas, Adam sering digunakan sebagai fungsi *loss* kategoris *cross-entropy*, keduanya terbukti efektif dalam mempercepat pelatihan dan menghasilkan akurasi tinggi (Shamila Ebenezer

dkk., 2021).

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (2.1)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (2.2)$$

Keterangan:

m_t rata-rata eksponensial dari gradien pada iterasi ke- t

 v_t rata-rata eksponensial dari kuadrat gradien pada iterasi ke- t

g_t nilai gradien pada iterasi ke- t

β_1 parameter peluruhan untuk momen pertama (biasanya mendekati 1, misalnya 0,9)

β_2 parameter peluruhan untuk momen kedua (biasanya mendekati 1, misalnya 0,999)

 t indeks iterasi atau langkah pelatihan ke- t

2.14 Stochastic Gradient Descent

Stochastic Gradient Descent (SGD) adalah algoritma optimasi dasar yang sering digunakan dalam pelatihan jaringan saraf karena mudah dan efisien untuk data berskala besar. Ia memperbarui parameter model secara iteratif dengan menggunakan subset acak dari data pelatihan, sehingga hemat memori dan cepat (Wulandari, Sari, Al-sawaff, dan Manickam, 2025). Namun, performanya sensitif terhadap pemilihan *learning rate*, nilai yang salah dapat menyebabkan perkembangan yang lambat atau tidak stabil (Chakroun, Haber, dan Ashby, 2017). Meskipun varian seperti *Momentum* dan *Nesterov* telah dikembangkan untuk meningkatkan performa, tetapi algoritma ini masih kurang adaptif dibandingkan dengan Adam atau AdaMax (Soydaner, 2020). Karena SGD banyak digunakan dalam model pembelajaran mesin, pengembangan algoritma SGD privat sangat penting untuk mengurangi kebocoran privasi yang diposting oleh gradien (P. Wang, Lei, Ying, dan Zhou, 2024).

$$\hat{g} = \frac{1}{m} \sum_i \nabla_{\theta} L(f(x^{(i)}; \theta), y^{(i)}) \quad (2.3)$$

$$\theta \leftarrow \theta - \varepsilon_k \hat{g} \quad (2.4)$$



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Keterangan:

- $\hat{g}$ estimasi gradien rata-rata dari fungsi kerugian
- m ukuran *minibatch*
- ∇_{θ} turunan (gradien) terhadap parameter θ
- L fungsi kerugian (*loss function*)
- $f(x^{(i)}; \theta)$ *output* model untuk *input* ke- i dengan parameter θ
- $y^{(i)}$ label target untuk data ke- i
- θ parameter model
- ϵ_k laju pembelajaran (*learning rate*) pada iterasi ke- k
- k indeks iterasi pelatihan ke- k

2.15 RMSprop

RMSprop adalah algoritma optimasi turunan dari *gradient descent* yang dimaksudkan untuk mengatasi penurunan kecepatan belajar yang signifikan, seperti yang terlihat pada Adagrad. Ia menormalkan pembaruan parameter, mempercepat konvergensi, dan menjaga stabilitas (Soujanya dan Sitamahalakshmi, 2020). Berbeda dari Adagrad, RMSprop mengurangi osilasi dan mempercepat penyatuan arah pembelajaran dengan menyesuaikan kecepatan pembelajaran untuk setiap parameter (Soydaner, 2020). Algoritma ini juga berfungsi dengan baik dalam lingkungan non-konveks seperti pelatihan jaringan saraf dalam, di mana permukaan kehilangan fungsi lokal minimal dan kompleks (Z. Li dkk., 2022).

$$v_t = \rho v_{t-1} + (1 - \rho) g_t^2 \quad (2.5)$$

$$\Delta w_t = -\frac{\eta}{\sqrt{v_t + \epsilon}} g_t \quad (2.6)$$

Keterangan:

- v rata-rata eksponensial dari kuadrat gradien pada iterasi ke- t
- ρ faktor peluruhan (*decay rate*) untuk rata-rata kuadrat gradien
- g nilai gradien pada iterasi ke- t



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Δw_t perubahan bobot (parameter) pada iterasi ke- t
 η laju pembelajaran (*learning rate*)
 ϵ konstanta kecil untuk mencegah pembagian dengan nol
 t indeks iterasi pelatihan ke- t

2.16 Confussion Matrix

Confusion Matrix adalah salah satu teknik evaluasi untuk mengklasifikasi performa berdasarkan benar dan salah. Empat *output* dihasilkan dari perhitungan rumus ini yaitu *recall*, akurasi, presisi, dan tingkat kesalahan. Penilaian akurasi dan kesalahan item tes menjadi dasar untuk mengevaluasi model klasifikasi (Dwinnie dkk., 2023). *Confusion matrix* terdiri dari empat komponen utama, yaitu *true positive* (TP) dan *true negative* (TN) yang menunjukkan prediksi benar oleh model, serta *false positive* (FP) dan *false negative* (FN) yang menunjukkan prediksi keliru (Valero-Carreras dkk., 2023). Diagram *confusion matrix* dapat dilihat pada Gambar 2.7

		ACTUAL VALUE	
		POSITIVE	NEGATIVE
PREDICTED VALUE	POSITIVE	TP	FP
	NEGATIVE	FN	TN

Gambar 2.7. Confusion Matrix (Valero-Carreras dkk., 2023)

Persamaan evaluasi kerja dapat dihitung sebagai berikut (Alzubaidi dkk., 2021):

1. Akurasi = Mengukur tingkat ketepatan model dalam mengklasifikasikan



1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

seluruh data.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.7)$$

2. *Specificity* = Mengukur kemampuan model dalam mengidentifikasi data negatif dengan benar.

$$Specificity = \frac{TN}{FP + TN} \quad (2.8)$$

3. *Recall* = Mengukur kemampuan model dalam mendeteksi data positif.

$$Recall = \frac{TP}{TP + FN} \quad (2.9)$$

4. *Precision* = Mengukur ketepatan model dalam memprediksi data positif.

$$Precision = \frac{TP}{TP + FP} \quad (2.10)$$

5. *F1-Score* = Merupakan rata-rata harmonik antara presisi dan *recall*.

$$F1-score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2.11)$$

2.17 Framework Flask

Framework Flask adalah kerangka kerja *web* mikro berbasis bahasa pemrograman Python yang fleksibel dan ringan, sehingga banyak digunakan dalam pengembangan aplikasi dan layanan *online* berbasis *Application Programming Interface* (API). Sifat minimalis yang dimiliki *Flask* memberikan para pengembang kesempatan untuk menambahkan berbagai *library* atau *extension* sesuai dengan kebutuhan aplikasi, sehingga *framework* ini dapat digunakan dalam sistem yang memerlukan tingkat kustomisasi tinggi dan integrasi dengan basis data atau layanan pihak ketiga (Suraya dan Sholeh, 2022). *Framework* ini menyediakan fitur inti seperti *routing*, pengelola *request-respons*, dan integrasi *template* yang memungkinkan pengembang untuk membuat aplikasi *web* secara terstruktur tanpa perlu memeriksa setiap komponen sistem dari awal (Walingkas dan Saian, 2023).

Selain itu, *Flask* tidak mengharuskan proyek untuk mengikuti pola atau struktur tertentu, sehingga pengembang dapat menyesuaikan arsitektur aplikasi secara fleksibel sesuai dengan kompleksitas dan tujuan sistem. Karakteristik tersebut menunjukkan bahwa *Flask* sering digunakan dalam aplikasi *machine learning*, di mana kerangka kerja ini berfungsi sebagai *backend* untuk menghubungkan mod-



el yang telah dikembangkan dengan data pengguna atau sistem *eksternal* melalui layanan API (Albeshier dan Alfayez, 2024; Braganca dan Kho, 2023). Dengan kemampuannya untuk menangani permintaan pengguna secara efisien dan memfasilitasi integrasi berbagai komponen, *Flask* dianggap sebagai solusi yang cocok untuk mengimplementasikan sistem cerdas berbasis *web* dalam penelitian atau aplikasi dunia nyata (Mani dan Shenoy, 2025).

2.18 Penelitian Terdahulu

Penelitian terdahulu yang dilakukan oleh Arafin dkk. (2024) menyelidiki klasifikasi dan segmentasi cacat beton, khususnya retakan dan *spalling*, menggunakan pendekatan *deep learning* berbasis (CNN). Untuk klasifikasi menggunakan tiga arsitektur CNN yaitu VGG-19, ResNet50, dan InceptionV3. *Dataset* berjumlah 4087 citra retakan dan 1100 citra *spalling* beresolusi 224 x 224 piksel RGB, yang dibagi ke dalam data pelatihan, validasi, dan pengujian. Model klasifikasi diuji menggunakan *optimizer* SGD dan RMSprop dengan variasi *learning rate*. Hasil penelitian ini menunjukkan bahwa InceptionV3 dengan RMSprop memberikan performa klasifikasi terbaik dengan akurasi sebesar 91,98% (Arafin dkk., 2024). Temuan ini menegaskan keunggulan SGD dalam hal generalisasi dan stabilitas model serta menunjukkan bahwa pemilihan arsitektur dan *optimizer* yang tepat sangat berpengaruh pada performa model.

Swain dan Tripathy (2024) melakukan penelitian tentang deteksi otomatis lubang jalan dengan menggunakan model VGG-16 yang telah dilatih sebelumnya sebagai metode *transfer learning* dan CNN untuk klasifikasi. *Dataset* terdiri dari 1441 gambar lubang jalan 720 × 720 piksel, yang dibagi menjadi 20% pengujian dan 80% pelatihan. Selama 100 *epoch*, pelatihan dilakukan menggunakan *optimizer* Adam dengan ukuran *batch* 32, *learning rate* 0.001. *ReLU* di seluruh lapisan dan *softmax* di lapisan *output* digunakan untuk aktivasi. Hasil penelitian menunjukkan akurasi klasifikasi sebesar 97,3%, dan dengan teknik *transfer learning*, model mencapai akurasi tertinggi 99,23% dengan waktu inferensi 0,008 detik dan ukuran model hanya 8,33 MB. Studi ini menunjukkan bahwa kombinasi VGG-16 dan CNN efektif dalam deteksi lubang jalan secara *real-time* (Swain dan Tripathy, 2024).

Penelitian yang dilakukan oleh Matarneh dkk. (2024) melakukan analisis terhadap sepuluh arsitektur CNN yang telah dilatih sebelumnya untuk klasifikasi retakan pada perkerasan aspal. Arsitektur yang dievaluasi meliputi AlexNet, VGG16, VGG19, GoogleNet, ResNet101, ShuffleNet, InceptionV3, DenseNet201, DarkNet19, dan Xception. *Dataset* yang digunakan mencakup retakan diagonal, longitu-



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

dinal, dan horizontal yang diambil dari *CrackTree*, GAP, dan CRACK500. Evaluasi model dilakukan menggunakan metrik akurasi, presisi, *recall*, skor F1, dan spesifisitas. Hasil pengujian awal menunjukkan bahwa DenseNet201 mencapai akurasi tinggi sebesar 94,12%, diikuti oleh ShuffleNet dengan 94,07% dan ResNet101 dengan 93,83%, sementara arsitektur VGG16 dan VGG19 menunjukkan performa yang sedikit lebih rendah. Hal ini menunjukkan bahwa arsitektur CNN dengan kedalaman yang lebih besar, seperti DenseNet201, memiliki potensi yang baik untuk mengklasifikasikan retakan jalan (Matarneh dkk., 2024).

Chaudhary dan Verma (2024) mengembangkan sistem klasifikasi permukaan jalan berbasis citra untuk membantu navigasi tunanetra, dengan menggunakan arsitektur *Convolutional Neural Network* EfficientNetB0. Arsitektur ini dipilih karena ringan, dengan 5,3 juta parameter dan 350 MB serta cocok untuk perangkat *embedded*. *Dataset* yang digunakan terdiri dari 5.558 citra permukaan jalan yang diklasifikasikan ke dalam tiga kategori, yaitu aspal, beraspal, dan tidak beraspal, dengan pembagian data pelatihan, validasi, dan pengujian. Selain itu, proses augmentasi seperti *flip* acak, rotasi, dan *zoom* digunakan. Pelatihan dilakukan menggunakan *optimizer* Adam dan RMSprop dengan *learning rate* $1e-5$ dan ukuran *batch* 10. Hasil penelitian menunjukkan bahwa EfficientNetB0 tanpa mekanisme tambahan mampu mencapai akurasi sebesar 96,85%, yang menunjukkan bahwa arsitektur ini memiliki performa yang baik dalam klasifikasi permukaan jalan berbasis citra (Chaudhary dan Verma, 2024).

Abd Zaid dkk. (2025) menawarkan pendekatan yang menggunakan *transfer learning* untuk klasifikasi fitur jalan seperti *flyover*, bundaran, dan penyeberangan. Metode ini menggunakan arsitektur CNN seperti InceptionV3, ResNet50, MobileNetV2, dan VGG19, serta model CNN khusus. *Dataset* 7.616 gambar 256×256 piksel dikumpulkan dari MLRSNet dan gambar satelit Google Earth, dengan pembagian data pelatihan, validasi, dan pengujian. InceptionV3 memiliki hasil terbaik pada validasi (98,9%), dan ResNet50 memiliki hasil terbaik pada pengujian (98,7%) (Abd Zaid dkk., 2025). Senada dengan penelitian Vaz, Gasparello, de Gouveia, dan Senger (2023) melakukan penelitian tentang deteksi kerusakan jalan menggunakan MobileNetV3, ResNet50V2, dan versi modifikasinya, ResNet50V2(M), dengan *dataset grayscale* dari sistem LabPavi. Model terbaik, ResNet50V2(M), menunjukkan akurasi rata-rata 80% untuk lubang dan eksudasi, tetapi yang kurang optimal membedakan subtype retakan dengan akurasi di bawah 70%. Kedua studi ini menegaskan bahwa pemilihan arsitektur dan desain model sangat memengaruhi efektivitas klasifikasi fitur dan kerusakan jalan (Vaz dkk., 2023).

Sementara itu, Shamila Ebenezer dkk. (2021) mengklasifikasikan berbagai jenis kerusakan infrastruktur dengan menggunakan model kelompok yang menggabungkan CNN kustom, Xception, dan AlexNet. *Dataset* yang digunakan terdiri dari 1.176 gambar yang dibagi menjadi 90% data pelatihan dan 10% data pengujian, dan model yang diusulkan mencapai akurasi validasi sebesar 87,1%. Studi ini menunjukkan bahwa CNN dapat digunakan untuk mendeteksi kerusakan infrastruktur jalan, meskipun pendekatan yang digunakan melibatkan penggabungan beberapa model (Shamila Ebenezer dkk., 2021). Ringkasan penelitian terdahulu yang relevan disajikan pada Tabel 2.2.

Tabel 2.2. Ringkasan Penelitian Terdahulu

No	Peneliti dan Tahun	Objek Penelitian	Arsitektur C-NN	Optimizer	Hasil dan Keterangan
1	Arafin dkk. (2024)	Retakan dan <i>palling</i> beton	VGG-19, ResNet50, InceptionV3	SGD, RM-Sprop, Adam	Akurasi tertinggi diperoleh menggunakan InceptionV3 untuk klasifikasi dan segmentasi kerusakan beton.
2	Swain dan Tripathy (2024)	Lubang jalan	VGG-16	Adam	Akurasi berkisar antara 97,3% hingga 99,23% dengan pendekatan CNN berbasis <i>transfer learning</i> .
	Matarneh dkk. (2024)	Retakan jalan aspal	DenseNet201, VGG16, dan arsitektur CNN lainnya	Optimizer standar	Akurasi awal sebesar 94,12% diperoleh menggunakan DenseNet201 dengan evaluasi multi-arsitektur CNN.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber.

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Tabel 2.2 Ringkasan Penelitian Terdahulu (Tabel lanjutan...)

No	Peneliti dan Tahun	Objek Penelitian	Arsitektur C-NN	Optimizer	Hasil dan Keterangan
4	Chaudhary dan Verma (2024)	Permukaan jalan	EfficientNet-B0	Adam, RMSprop	Model CNN ringan dan efisien dengan akurasi lebih dari 96%.
5	Abd Zaid dkk. (2025)	Fitur jalan	InceptionV3 dan ResNet50	Optimizer standar	Pendekatan <i>transfer learning</i> menghasilkan akurasi hingga 98,9% pada klasifikasi kondisi jalan.
6	Vaz dkk. (2023)	Kerusakan jalan	ResNet50V2	Optimizer standar	Akurasi sekitar 80% dengan tantangan pada klasifikasi subtype kerusakan jalan.
7	Shamila Ebenezer dkk. (2021)	Kerusakan infrastruktur	CNN dan Xception	Optimizer standar	Pendekatan CNN menghasilkan akurasi sebesar 87,1% untuk deteksi kerusakan jalan.
8	Yusup Yulianto dan Ari Wibowo (2023)	Kerusakan jalan aspal	CNN	Optimizer standar	Menggunakan <i>dataset</i> publik Kaggle yang sama dengan hasil akurasi yang bervariasi.

Berdasarkan ringkasan penelitian terdahulu yang disajikan pada Tabel 2.2, dapat disimpulkan bahwa pendekatan *Convolutional Neural Network* (CNN) telah banyak diterapkan dalam mendeteksi dan mengklasifikasikan kerusakan jalan dengan hasil yang cukup baik. Namun, sebagian besar penelitian masih berfokus pada jenis kerusakan tertentu, menggunakan satu arsitektur CNN, atau memanfaatkan *dataset* yang bersifat terkontrol sehingga belum sepenuhnya merepresen-

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

tasikan variasi kondisi jalan di lapangan. Selain itu, perbandingan performa beberapa arsitektur CNN dan pengaruh penggunaan *optimizer* yang berbeda dalam satu kerangka penelitian masih terbatas. Oleh karena itu, penelitian ini berfokus pada klasifikasi tingkat kerusakan jalan berbasis citra digital dengan membandingkan beberapa arsitektur CNN, yaitu InceptionV3, DenseNet201, VGG16, EfficientNetB0, dan ResNet50V2, serta menggunakan *optimizer* Adam, SGD, dan RMSprop, guna memperoleh model yang stabil dan relevan untuk diterapkan pada kondisi nyata.




UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

BAB 3 METODOLOGI PENELITIAN

Adapun tahapan metodologi penelitian yang digunakan dapat dilihat pada Gambar 3.1 berikut.



Gambar 3.1. Metodologi Penelitian

3.1 Tahap Perencanaan Penelitian

1. Identifikasi Masalah

Pada tahap ini, peneliti mengidentifikasi permasalahan terkait klasifikasi tingkat kerusakan jalan berdasarkan informasi yang diperoleh mengenai kon-



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

disi infrastruktur di Indonesia, khususnya di kota Pekanbaru Provinsi Riau. Informasi tersebut dihimpun dari berbagai sumber seperti Perwakilan Badan Pemeriksa Keuangan (BPK) RI di Riau, Kementerian Pekerjaan Umum dan Perumahan Rakyat (PUPR), serta media lokal yang menyoroti kerusakan jalan dan dampaknya terhadap aktivitas masyarakat. Untuk memperkuat proses identifikasi permasalahan, peneliti juga melakukan wawancara dengan pihak terkait guna memperoleh gambaran kondisi lapangan serta kendala dalam evaluasi kerusakan jalan. Pedoman pertanyaan dan ringkasan hasil wawancara disajikan pada Lampiran B. Selain itu, peneliti melampirkan dokumentasi kegiatan pendukung berupa dokumentasi wawancara, komunikasi dengan pihak terkait, serta dokumentasi visual kondisi jalan yang disajikan pada Lampiran C.

2. Studi Literatur.

Studi literatur merupakan langkah awal yang dilakukan sebelum memulai suatu penelitian, yaitu dengan menyusun perencanaan. Tahapan ini dilakukan dengan menelaah berbagai sumber bacaan, baik dari jurnal nasional maupun internasional, yang relevan dengan topik penelitian. Tujuannya adalah untuk memperoleh informasi sebagai dasar dalam membangun kerangka berpikir penelitian.

3.2 Data Collection

Penelitian ini menggunakan *dataset* publik sebagai sumber data utama, dalam proses pelatihan, validasi, dan pengujian model. *Dataset* yang digunakan diperoleh dari *platform* Kaggle dengan nama *Road Damage Classification and Assessment*. *Dataset* ini dipilih karena menyediakan citra kondisi jalan yang telah teranotasi dengan baik dan umum digunakan dalam penelitian klasifikasi kerusakan jalan berbasis citra. *Dataset* ini terdiri dari sekitar 2.078 gambar dan terbagi ke dalam empat kelas kondisi jalan, yaitu *good* berjumlah 845 data, *satisfactory* sebanyak 515 data, *poor* sebanyak 396, dan *very poor* sebanyak 318. Keempat kelasnya merepresentasikan variasi tingkat kerusakan permukaan jalan yang berbeda, sehingga sesuai untuk kebutuhan klasifikasi multikelas.

Citra pada *dataset* ini memiliki variasi sudut pandang, jarak pengambilan gambar, serta kondisi pencahayaan, sehingga mencerminkan kondisi permukaan jalan yang beragam di lapangan. Variasi ini mencerminkan kondisi permukaan jalan yang berbeda-beda dan memberikan tantangan yang realistis bagi model dalam proses pembelajaran. Dengan karakteristik tersebut, *dataset* ini dinilai cukup repre-



sentatif untuk digunakan sebagai dasar pengembangan dan evaluasi model *Convolutional Neural Network* (CNN).

Seluruh citra pada *dataset* selanjutnya diproses melalui tahap *preprocessing*, khususnya penyesuaian ukuran citra (*resize*) menjadi 224×224 piksel, agar sesuai dengan kebutuhan *input* arsitektur CNN yang digunakan. Penyeragaman ukuran citra ini bertujuan untuk memastikan konsistensi dimensi *input* serta mendukung proses pelatihan model yang lebih stabil dan optimal.

3.3 Split Data (80:20)

Pada tahap berikutnya, *dataset* dibagi menjadi tiga bagian yaitu data *training*, data *validation*, dan data *testing*. Sebelum model dijalankan, langkah ini sangat penting dalam proses persiapan data. Dalam penelitian ini, metode *Hold-Out* digunakan dengan perbandingan rasio 80:10:10. Selanjutnya, data yang telah dibagi ditempatkan dalam direktori yang berbeda untuk memudahkan administrasi selama proses pelatihan dan evaluasi. Untuk memastikan bahwa model yang dikembangkan dapat diuji secara objektif dan memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya, serta untuk menghindari *overfitting*.

3.4 Preprocessing Data

Preprocessing data dilakukan untuk meningkatkan kualitas gambar dan mengurangi gangguan (*noise*) yang menghambat performa model. Dalam penelitian ini, tahapan *preprocessing* mencakup penyesuaian ukuran gambar, normalisasi nilai piksel, dan augmentasi data.

1. Resize Image

Penyesuaian ukuran gambar dilakukan untuk menyeragamkan dimensi seluruh citra dalam *dataset*. Semua gambar jalan diubah ukurannya menjadi 224×224 piksel. Ukuran ini dipilih karena sesuai dengan format *input* standar dari beberapa arsitektur *Convolutional Neural Network* (CNN), seperti InceptionV3, DenseNet201, VGG16, EfficientNetB0, ResNet50V2.

2. Normalization

Normalisasi digunakan untuk mengonversi nilai piksel dari setiap gambar ke skala antara 0 dan 1. Proses ini dilakukan dengan cara membagi setiap nilai piksel dengan angka 255, yang merupakan nilai tertinggi dalam format warna RGB. Teknik ini membantu model dalam mempercepat proses pelatihan dan menjaga kestabilan pembelajaran.

3. Augmentation



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Augmentasi data dilakukan untuk meningkatkan variasi dan jumlah citra pelatihan guna mengurangi risiko *overfitting* serta memperkaya representasi visual dari setiap kelas. Teknik ini menciptakan versi modifikasi dari gambar asli melalui penerapan rotasi hingga 30 derajat, pembalikan horizontal, perbesaran (*zoom*) maksimal 15%, pergeseran posisi horizontal, *vertical flip* dinonaktifkan karena tidak sesuai karakteristik data jalan, serta *shear* (kemiringan) sebesar 15%. Area kosong akibat transformasi diisi menggunakan metode *nearest* agar struktur citra tetap terjaga. Selain itu, *preprocessing input* dapat digunakan melalui parameter *preprocessing function* untuk mengubah nilai dan format gambar sesuai dengan arsitektur CNN yang digunakan. Proses *preprocessing* dan augmentasi ini dilakukan menggunakan modul *ImageDataGenerator* pada *TensorFlow*. Ini meningkatkan kemampuan model untuk diterapkan pada data baru.

3.5 CNN Architecture Model

Pada tahap ini dilakukan pengujian model dengan menerapkan beberapa arsitektur CNN untuk klasifikasi tingkat kerusakan jalan berbasis citra digital. Arsitektur yang digunakan meliputi InceptionV3, DenseNet201, VGG16, EfficientNetB0, ResNet50V2. Untuk mengoptimalkan proses ekstraksi fitur dan mencegah *overfitting*, setiap arsitektur disesuaikan dengan menambahkan lapisan tambahan seperti fungsi aktivasi *ReLU*, *Global Average Pooling*, *Dense layer*, *Batch Normalization*, dan *Dropout*. Seluruh model dilengkapi dengan lapisan *output* yang memiliki empat neuron, menggunakan fungsi aktivasi *softmax* karena penelitian ini bertujuan mengklasifikasikan gambar ke dalam empat kategori kondisi jalan. Pada tahap pemrosesan *input*, digunakan dua pendekatan, yaitu tanpa *preprocessing input* dan dengan *preprocessing input* bawaan dari masing-masing arsitektur CNN. Tujuan penggunaan pemrosesan *preprocessing input* adalah untuk mencocokkan distribusi nilai piksel citra dengan karakteristik model yang telah ditentukan sebelumnya pada *dataset* ImageNet, sehingga *transfer learning* dapat berjalan lebih optimal.

Seluruh model dikompilasi dengan menggunakan fungsi *loss sparse categorical crossentropy*, dengan *learning rate* 0,0001, serta metrik evaluasi berupa akurasi. Pelatihan dilakukan selama 50 *epoch* dengan *batch size* 32, dan menggunakan beberapa *callback* untuk meningkatkan efisiensi serta stabilitas model, seperti *EarlyStopping*, *ReduceLROnPlateau*, *ModelCheckpoint*, *TensorBoard*, serta *TrainingTimeCallback* yang digunakan untuk mengawasi durasi pelatihan. Pendekatan



ini diharapkan dapat menghasilkan performa model yang bagus pada data validasi serta memberikan hasil klasifikasi yang tepat pada gambar kondisi jalan.

3.6 Optimizer

Optimizer digunakan untuk mengurangi nilai *loss function* serta meningkatkan akurasi model selama proses pelatihan. Dalam penelitian ini, digunakan tiga jenis *optimizer*, yaitu *Adaptive Moment Estimation* (Adam), *Root Mean Square Propagation* (RMSProp) dan *Stochastic Gradient Descent* (SGD) yang masing-masing memiliki keunggulan dalam mengatur pembaruan bobot secara adaptif. Pemilihan dan pengaturan *optimizer* sangat penting untuk desain dan implementasi model *deep learning* karena dapat meningkatkan performa model dengan mempercepat proses pelatihan dan meningkatkan akurasi prediksi. Tujuan dari penelitian ini adalah untuk menghasilkan model klasifikasi gambar yang akurat dan efektif dengan menggabungkan keunggulan dari Adam, RMSProp, dan SGD.

Selama proses pelatihan, digunakan teknik *early stopping* dan *model checkpoint* untuk menyimpan model terbaik berdasarkan hasil validasi. Pelatihan dilakukan selama 50 *epoch* hingga model menunjukkan konvergensi atau terjadi peningkatan *error* pada data validasi.

3.7 Evaluasi Model

Setelah berbagai percobaan, fase evaluasi model menjadi komponen penting dari penelitian klasifikasi gambar. Tujuan dari evaluasi ini adalah untuk mengetahui seberapa baik model mampu mengklasifikasikan gambar baru dengan benar. *Confusion matrix* adalah alat penting yang digunakan karena memberikan gambaran rinci tentang performa model. Ini memungkinkan analisis kesalahan dilakukan lebih lanjut untuk menemukan pola kesalahan tertentu, dan berguna untuk menilai dan memperbaiki arsitektur model, pengaturan *hyperparameter*, dan strategi augmentasi data. Hasil dari *confusion matrix* menampilkan *Accuracy*, *Precision*, *Recall* dan *score F1* yang ditampilkan pada *classification report* serta *ROC*.

3.8 Tahap Deployment

Tahap *deployment* merupakan proses implementasi model *Convolutional Neural Network* (CNN) dengan performa terbaik ke dalam sistem klasifikasi tingkat kerusakan jalan berbasis *web* menggunakan *framework Flask*. Sistem ini menerima *input* berupa citra kondisi jalan, kemudian melakukan tahap *preprocessing* sesuai dengan proses pelatihan model. Selanjutnya, citra tersebut diklasifikasikan ke



dalam empat kelas tingkat kerusakan jalan, yaitu *good*, *satisfactory*, *poor*, dan *very poor*. Hasil prediksi ditampilkan sebagai keluaran sistem untuk membantu proses identifikasi dan evaluasi kondisi jalan secara otomatis menggunakan gambar digital.

3.9 Tahap Dokumentasi dan Laporan Akhir

Tahap dokumentasi dan penulisan laporan akhir dilakukan agar seluruh proses dan hasil penelitian dapat disampaikan secara terstruktur. Dokumentasi digunakan untuk mencatat setiap langkah dalam penelitian, mulai dari pengumpulan data, proses pembelajaran dan pengujian model CNN, hingga penerapan sistem klasifikasi berbasis *Flask*. Laporan akhir ini merangkum tujuan penelitian, metode yang digunakan, hasil pengujian, serta analisis kemampuan model yang diperoleh. Selain itu, laporan ini diharapkan bisa menjadi referensi bagi penelitian berikutnya dan dasar pengembangan lebih lanjut.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



UIN SUSKA RIAU

BAB 5

PENUTUP

5.1 Kesimpulan

Penelitian ini dilaksanakan untuk menerapkan dan membandingkan performa beberapa arsitektur *Convolutional Neural Network* (CNN) dalam mengklasifikasi tingkat kondisi jalan berbasis citra digital. Seluruh tahapan penelitian, mulai dari pengumpulan data, *preprocessing*, pelatihan model, evaluasi performa, hingga tahap *deployment* sistem, telah dilakukan secara sistematis sesuai dengan metodologi yang ditetapkan. Berdasarkan hasil penelitian dan analisis sebelumnya, maka dapat ditarik beberapa kesimpulan sebagai berikut:

1. Penelitian ini berhasil menerapkan dan membandingkan lima arsitektur *Convolutional Neural Network* (CNN), yaitu InceptionV3, DenseNet201, VGG16, EfficientNetB0, dan ResNet50V2, dengan tiga *optimizer* yang berbeda, yaitu Adam, SGD, dan RMSprop, dalam mengklasifikasi tingkat kondisi jalan berbasis citra digital ke dalam empat kelas, yaitu *good*, *satisfactory*, *poor*, dan *very poor*.
2. Berdasarkan hasil evaluasi menggunakan *confusion matrix*, diperoleh kombinasi arsitektur dan *optimizer* terbaik, yaitu DenseNet201 dengan *optimizer* RMSprop, yang menghasilkan performa klasifikasi paling optimal dalam penelitian ini.
3. Hasil penelitian ini memberikan gambaran awal mengenai penerapan klasifikasi citra berbasis CNN sebagai pendekatan digital dalam mendukung proses identifikasi kondisi jalan. Pendekatan ini berpotensi membantu instansi terkait, seperti Dinas PUPR Kota Pekanbaru, sebagai bahan pertimbangan dalam pengambilan keputusan pemeliharaan jalan.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, beberapa saran dapat diajukan untuk penelitian di masa depan. Dari aspek data, penelitian di masa depan disarankan untuk memanfaatkan jumlah data yang lebih besar dan lebih beragam, baik dari segi lokasi pengambilan citra, kondisi pencahayaan, maupun karakteristik permukaan jalan, sehingga model yang dikembangkan memiliki kemampuan generalisasi yang lebih baik terhadap berbagai kondisi nyata di lapangan. Dalam konteks pengembangan model, penelitian selanjutnya dapat mengeksplorasi dengan menerapkan teknik seperti penyesuaian *hyperparameter*, metode *ensemble*, atau pendekatan berbasis segmentasi dan deteksi, seperti YOLO atau *semantic segmenta-*



tion, untuk meningkatkan kemampuan mengidentifikasi kondisi kerusakan jalan. Selain itu, dalam hal implementasi sistem, sistem dapat dikembangkan menjadi sistem *real-time* yang terintegrasi dengan kamera atau aplikasi *mobile*. Selain itu, integrasi antara *frontend* dan *backend* dapat ditingkatkan agar sistem dapat digunakan secara lebih efektif dalam lingkungan operasional.



UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



DAFTAR PUSTAKA

- Abd Zaid, M. M., Mohammed, A. A., dan Sumari, P. (2025). Classification of Road Features Using Convolutional Neural Network (CNN) and Transfer Learning. *International Journal of Computing and Digital Systems*, 17(1), 1–12. doi: 10.12785/ijcds/1571031764
- Adam, K., Mohamed, I. I., dan Ibrahim, Y. (2021). A Selective Mitigation Technique of Soft Errors for DNN Models Used in Healthcare Applications: DenseNet201 Case Study. *IEEE Access*, 9, 65803–65823. doi: 10.1109/ACCESS.2021.3076716
- Ahmed, S. F., Alam, M. S. B., Hassan, M., Rozbu, M. R., Ishtiak, T., Rafa, N., ... Gandomi, A. H. (2023). *Deep learning modelling techniques: current progress, applications, advantages, and challenges* (Vol. 56) (No. 11). Springer Netherlands. Retrieved from <https://doi.org/10.1007/s10462-023-10466-8> doi: 10.1007/s10462-023-10466-8
- Albeshier, L., dan Alfayez, R. (2024). An Observational Study on Flask Web Framework Questions on Stack Overflow (SO). *IET Software*, 2024(1), 9–11. doi: 10.1049/sfw2/1905538
- Alzubaidi, L., Duan, Y., Al-Dujaili, A., Ibraheem, I. K., Alkenani, A. H., Santamaria, J., ... Zhang, J. (2021). Deepening into the suitability of using pre-trained models of ImageNet against a lightweight convolutional neural network in medical imaging: an experimental study. *PeerJ Computer Science*, 7, 1–27. doi: 10.7717/peerj-cs.715
- Anton, A., Nissa, N. F., Janiati, A., Cahya, N., dan Astuti, P. (2021). Application of Deep Learning Using Convolutional Neural Network (CNN) Method For Women's Skin Classification. *Scientific Journal of Informatics*, 8(1), 144–153. doi: 10.15294/sji.v8i1.26888
- Apeagyei, A., Ademolake, T. E., dan Adom-Asamoah, M. (2023). Evaluation of deep learning models for classification of asphalt pavement distresses. *International Journal of Pavement Engineering*, 24(1). doi: 10.1080/10298436.2023.2180641
- Arafin, P., Billah, A. M., dan Issa, A. (2024). Deep learning-based concrete defects classification and detection using semantic segmentation. *Structural Health Monitoring*, 23(1), 383–409. doi: 10.1177/14759217231168212
- Bouhsissin, S., Assemlali, H., dan Sael, N. (2025). Enhancing road safety: A convolutional neural network based approach for road damage detec-



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

tion. *Machine Learning with Applications*, 20(February), 100668. Retrieved from <https://doi.org/10.1016/j.mlwa.2025.100668> doi: 10.1016/j.mlwa.2025.100668

BPK RI Perwakilan Provinsi Riau. (2024). *Ratusan Kilometer Jalan di Pekanbaru Kondisi Rusak*. Retrieved from <https://riau.bpk.go.id/ratusan-kilometer-jalan-di-pekanbaru-kondisi-rusak/>

Braganca, W. O., dan Kho, I. E. (2023). Comparative Analysis of Python Microframeworks: Flask, Dash, and CherryPy. *Researchgate.Net*(July). doi: <https://doi.org/10.13140/RG.2.2.17101.82402>

Cao, Y., Schartel, T. E., Houghton, D. C., Ross, J., dan Infante, D. M. (2025). Evaluating machine learning algorithms for accuracy, stability, and among-predictors discriminability in modeling species-richness across ten datasets. *Ecological Informatics*, 90(January), 103323. Retrieved from <https://doi.org/10.1016/j.ecoinf.2025.103323> doi: 10.1016/j.ecoinf.2025.103323

Chai, J., Zeng, H., Li, A., dan Ngai, E. W. (2021). Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*, 6(August), 100134. Retrieved from <https://doi.org/10.1016/j.mlwa.2021.100134> doi: 10.1016/j.mlwa.2021.100134

Chakroun, I., Haber, T., dan Ashby, T. J. (2017). SW-SGD: The Sliding Window Stochastic Gradient Descent Algorithm. *Procedia Computer Science*, 108, 2318–2322. Retrieved from <http://dx.doi.org/10.1016/j.procs.2017.05.082> doi: 10.1016/j.procs.2017.05.082

Chaudhary, A., dan Verma, P. (2024). Improving Freedom of Visually Impaired Individuals with Innovative EfficientNet and Unified Spatial-Channel Attention: A Deep Learning-Based Road Surface Detection System. *TECHNICAL JOURNAL*, 19(1), 17–25. doi: 10.31803/tg-20231018184747

Chen, D. R., dan Chiu, W. M. (2023). Deep-learning-based road crack detection frameworks for dashcam-captured images under different illumination conditions. *Soft Computing*, 27(19), 14337–14360. Retrieved from <https://doi.org/10.21203/rs.3.rs-685762/v1> doi: 10.1007/s00500-023-08738-0

Chen, G.-H., Ni, J., Chen, Z., Huang, H., Sun, Y.-L., Ip, W. H., dan Yung, K. L. (2022). Detection of Highway Pavement Damage Based on a CNN Using Grayscale and HOG Features. *sensors Communication*, 22(7), 1–10. doi: <https://doi.org/10.3390/s22072455>



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

- Chu, H. H., Saeed, M. R., Rashid, J., Mehmood, M. T., Ahmad, I., Iqbal, R. S., dan Ali, G. (2023). Deep Learning Method to Detect the Road Cracks and Potholes for Smart Cities. *Computers, Materials and Continua*, 75(1), 1863–1881. Retrieved from <https://doi.org/10.32604/cmc.2023.035287> doi: 10.32604/cmc.2023.035287
- Chun, C., dan Ryu, S. K. (2019). Road surface damage detection using fully convolutional neural networks and semi-supervised learning. *Sensors (Switzerland)*, 19(24). Retrieved from <https://doi.org/10.3390/s19245501> doi: 10.3390/s19245501
- Daoud, S., Nasayreh, A., Nahar, K. M., Abedalaziz, W. k., Alayasreh, S. M., Gharaibeh, H., ... Abualigah, L. (2025). A novel deep learning-based spider wasp optimization approach for enhancing brain tumor detection and physical therapy prediction. *Computer Methods and Programs in Biomedicine Update*, 7(May), 100193. Retrieved from <https://doi.org/10.1016/j.cmpbup.2025.100193> doi: 10.1016/j.cmpbup.2025.100193
- Denaro, L. G., dan Lim, R. (2025). Analisis Deteksi Kerusakan pada Jalan Aspal menggunakan Deep Learning untuk Mendukung Efisiensi Biaya dan Waktu dalam Pemantauan Berkelanjutan. *Jurnal Dimensi Insinyur Profesional*, 3, 16–25. Retrieved from <https://doi.org/10.9744/jdip.3.1.16-25> doi: doi.org/10.9744/jdip.3.1.16-25
- Dwinnie, Z. C., Khairani, L., Amalia, M., Putri, M., Adhiva, J., Inas, M., dan Tsamarah, F. (2023). Application of the Supervised Learning Algorithm for Classification of Pregnancy Risk Levels. *Public Research Journal of Engineering, Data Technology and Computer Science*, 1(1), 26–33. Retrieved from <https://journal.irpi.or.id/index.php/predatecs/article/view/806> doi: <https://doi.org/10.57152/predatecs.v1i1.806>
- Guo, M., Tian, W., Li, Y., dan Sui, D. (2024). Detection of Road Crack Images Based on Multistage Feature Fusion and a Texture Awareness Method. *Sensors*, 24(11). doi: 10.3390/s24113268
- Hamida, S., El Gannour, O., Cherradi, B., Ouajji, H., dan Raihani, A. (2023). Handwritten computer science words vocabulary recognition using concatenated convolutional neural networks. *Multimedia Tools and Applications*, 82(15), 23091–23117. doi: 10.1007/s11042-022-14105-2
- Hassan, M., Gonzalez Ruiz, J. M., Mohamed, N., Burke, T. N., Mei, Q., dan Westover, L. (2025). Ensemble learning of deep CNN models and two stage level prediction of Cobb angle on surface topography in adolescents with id-



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

iopathic scoliosis. *Medical Engineering and Physics*, 140(April), 104332. Retrieved from <https://doi.org/10.1016/j.medengphy.2025.104332> doi: 10.1016/j.medengphy.2025.104332

Huang, G., Liu, Z., van der Maaten, L., dan Weinberger, K. Q. (2018). Densely Connected Convolutional Networks. *American Journal of Veterinary Research*, 39(9), 1442–1446. doi: 10.1109/CVPR.2017.243

Inhsan, A., Riyadi, S., dan Pardede, D. (2024). Analysis of Logistic Regression Regularization in Wild Elephant Classification with VGG-16 Feature Extraction. *Journal of Computer Networks, Architecture and High Performance Computing*, 6(2), 661–670. doi: <https://doi.org/10.47709/cnahpc.v6i2.3789>

Jakubec, M., Lieskovská, E., Bučko, B., dan Záborská, K. (2023). Comparison of CNN-Based Models for Pothole Detection in Real-World Adverse Conditions: Overview and Evaluation. *Applied Sciences (Switzerland)*, 13(9). Retrieved from <https://doi.org/10.3390/app13095810> doi: 10.3390/app13095810

Jonathan Estilong. (2025). Literature Review on Road Damage Detection and Severity Recognition: Leveraging Computer Vision. *Journal of Information Systems Engineering and Management*, 10(5s), 498–512. doi: 10.52783/jisem.v10i5s.670

Joshi, K., Tripathi, V., Bose, C., dan Bhardwaj, C. (2020). Robust Sports Image Classification Using InceptionV3 and Neural Networks. *Procedia Computer Science*, 167(Iccids 2019), 2374–2381. Retrieved from <http://dx.doi.org/10.1016/j.procs.2020.03.290> doi: 10.1016/j.procs.2020.03.290

Jiianta, I., dan Putrie, F. T. (2025). *Jalan rusak bikin rugi! ekonomi terdampak, umkm dan logistik menjerit*. <https://www.rri.co.id/daerah/1286971/jalan-rusak-bikin-rugi-ekonomi-terdampak-umkm-logistik-menjerit>. (Lembaga Penyiaran Publik Radio Republik Indonesia)

Kementerian Pekerjaan Umum, D. J. B. M. (2011). *Manual Konstruksi dan Bangunan no. 001-02/M/BM/2011 Tentang Perbaikan Standar Jalan* (Tech. Rep.). Kementerian Pekerjaan Umum Republik Indonesia. Retrieved from <https://binamarga.pu.go.id/uploads/files/2057/no-001-02mbm2011-manual-perbaikan-standar-untuk-pemeliharaan-rutin-jalan.pdf>

Kementerian Pekerjaan Umum dan Perumahan Rakyat, D. J. B. M. (2016). *Pedoman Penentuan Indeks Kondisi Perkerasan (IKP)* (Pedoman Te ed.). Jakarta:



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Direktorat Jenderal Bina Marga, Kementerian Pekerjaan Umum dan Perumahan Rakyat. Retrieved from <https://binamarga.pu.go.id/index.php/nspk/detail/pedoman-penentuan-indeks-kondisi-perkerasan-ikp>

Kementerian Pekerjaan Umum dan Perumahan Rakyat, D. J. B. M. (2024). *Pedoman Leger Jalan* (No. 07/P/B ed.) (No. 07). Jakarta: Direktorat Jenderal Bina Marga, Kementerian Pekerjaan Umum dan Perumahan Rakyat. Retrieved from <https://binamarga.pu.go.id/index.php/nspk/detail/07pbm2024-pedoman-leger-jalan>

Kementerian Pekerjaan Umum dan Perumahan Rakyat Republik Indonesia. (2012). *Lampiran Peraturan Menteri Pekerjaan Umum Republik Indonesia Nomor 01/PRT/M/2012 tentang Pedoman Peran Masyarakat dalam Penyelenggaraan Jalan* (Tech. Rep.). Kementerian Pekerjaan Umum Republik Indonesia. Retrieved from <https://peraturan.bpk.go.id/Details/160026/permen-pupr-no-01prtm2012-tahun-2012>

Keras Team. (2024a). *Efficientnet*. <https://keras.io/api/applications/efficientnet/>. (Keras Documentation)

Keras Team. (2024b). *Keras applications*. <https://keras.io/api/applications/>. (Keras Documentation, accessed December 11, 2025)

Kim, H. (2024). Performing a Research Study Using Open-Source Deep Learning Models. *Korean Journal of Radiology*, 25(2), 1–3. doi: 10.3348/kjr.2023.0869

Krichen, M. (2023). Convolutional Neural Networks: A Survey. *Computers*, 12(8), 1–41. doi: 10.3390/computers12080151

Kalambayev, B., Beissenova, G., Katayev, N., Abduraimova, B., Zhaidakbayeva, L., Sarbassova, A., ... Shyrakbayev, A. (2022). A Deep Learning-Based Approach for Road Surface Damage Detection. *Computers, Materials and Continua*, 73(2), 3403–3418. doi: 10.32604/cmc.2022.029544

Kusumaningrum, J., Madenda, S., Karmilasari, dan Nahdalina. (2022). Detection and Classification of Road Damage Based on Image Morphology and K-NN Method (K Nearest Neighbour). *International Journal of Engineering and Advanced Technology*, 11(5), 86–90. doi: 10.35940/ijeat.e3543.0611522

Li, S., dan Zhang, D. (2025). Deep Learning-Based Algorithm for Road Defect Detection. *Sensors*, 25(5), 1–7. Retrieved from <https://www.mdpi.com/1424-8220/25/5/1287> doi: 10.3390/s25051287

Li, Y., Wei, H., Han, Z., Huang, J., dan Wang, W. (2020). Deep Learning-Based Safety Helmet Detection in Engineering Management Based on Convolutional Neural Networks. *Mathematics*, 8(12), 2155. doi: 10.3390/math8122155



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

tional Neural Networks. *Advances in Civil Engineering*, 2020, 1–10. doi: 10.1155/2020/9703560

Lu, Z., Liu, F., Yang, W., Peng, S., dan Zhou, J. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019. doi: 10.1109/TNNLS.2021.3084827

Lu, Y., Soh, L.-K., dan Lorang, E. (2021). Investigating coupling preprocessing with shallow and deep convolutional neural networks in document image classification. *Journal of Electronic Imaging*, 30(04). doi: 10.1117/1.jei.30.4.043024

Mangeri, L., Gnana Prakasi, O. S., Kanmani, P., dan Puppala, N. (2021). Chest Diseases Prediction from X-ray Images using CNN Models: A Study. *International Journal of Advanced Computer Science and Applications*, 12(10), 236–243. doi: 10.14569/IJACSA.2021.0121026

Mani, K., dan Shenoy, A. K. (2025). Machine learning models in web applications: A comprehensive review. *ICT Express*, 11(6), 1110–1119. Retrieved from <https://doi.org/10.1016/j.icte.2025.09.001> doi: 10.1016/j.icte.2025.09.001

Matarneh, S., Elghaish, F., Pour Rahimian, F., Abdellatef, E., dan Abrishami, S. (2024). Evaluation and optimisation of pre-trained CNN models for asphalt pavement crack detection and classification. *Automation in Construction*, 160(December 2023), 105297. Retrieved from <https://doi.org/10.1016/j.autcon.2024.105297> doi: 10.1016/j.autcon.2024.105297

Mei, Q., Gül, M., dan Azim, M. R. (2020). Densely connected deep neural network considering connectivity of pixels for automatic crack detection. *Automation in Construction*, 110(November 2019), 103018. Retrieved from <https://doi.org/10.1016/j.autcon.2019.103018> doi: 10.1016/j.autcon.2019.103018

Mirzaei, O., Mohammed, S. A., Sekeroglu, B., dan Ilhan, A. (2025). Comparison of Intracranial Hemorrhages Detection Performances of Deep Learning Models on CT Images. *Procedia Computer Science*, 258, 3194–3202. Retrieved from <https://doi.org/10.1016/j.procs.2025.04.577> doi: 10.1016/j.procs.2025.04.577

Nguyen-Tat, T. B., Hung, T. Q., Nam, P. T., dan Ngo, V. M. (2025). Evaluating pre-processing and deep learning methods in medical imaging: Combined effectiveness across multiple modalities. *Alexandria Engineering Jour-*



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

nal, 119(February), 558–586. Retrieved from <https://doi.org/10.1016/j.aej.2025.01.090> doi: 10.1016/j.aej.2025.01.090

Patra, S., Middya, A. I., dan Roy, S. (2021). PotSpot: Participatory sensing based monitoring system for pothole detection using deep learning. *Multimedia Tools and Applications*, 80(16), 25171–25195. doi: 10.1007/s11042-021-10874-4

Pemerintah Kota Pekanbaru. (2025). *Perbaikan Jalan Rusak di 15 Kecamatan Pekanbaru, Pertengahan Juli Mulai Pekerjaan* (Tech. Rep.). Pemerintah Kota Pekanbaru. Retrieved from <https://www.pekanbaru.go.id/p/news/perbaikan-jalan-rusak-di-15-kecamatan-pekanbaru-pertengahan-juli-mulai-pekerjaan>

Priyanka, M., Lakshmi, J. C., Vyshnavi, N. B., Suresha, R., dan Jipeng, T. (2025). OrthoXIC: A Fusion Approach for Multi-Implant Classification using X-ray Images. *Procedia Computer Science*, 258, 2455–2468. Retrieved from <https://doi.org/10.1016/j.procs.2025.04.508> doi: 10.1016/j.procs.2025.04.508

Rahman, T., Chowdhury, M. E., Khandakar, A., Islam, K. R., Islam, K. F., Mahbub, Z. B., ... Kashem, S. (2020). Transfer learning with deep Convolutional Neural Network (CNN) for pneumonia detection using chest X-ray. *Applied Sciences (Switzerland)*, 10(9). doi: 10.3390/app10093233

Rainio, O., Teuho, J., dan Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14(1), 1–14. Retrieved from <https://doi.org/10.1038/s41598-024-56706-x> doi: 10.1038/s41598-024-56706-x

Raj, R., dan Kos, A. (2025). An Extensive Study of Convolutional Neural Networks: Applications in Computer Vision for Improved Robotics Perceptions. *Sensors*, 25(4), 1–19. doi: 10.3390/s25041033

Ranyal, E., Sadhu, A., dan Jain, K. (2022). Road Condition Monitoring Using Smart Sensing and Artificial Intelligence: A Review. *Sensors*, 22(8). doi: 10.3390/s22083044

Salehin, I., dan Kang, D. K. (2023). A Review on Dropout Regularization Approaches for Deep Neural Networks within the Scholarly Domain. *Electronics (Switzerland)*, 12(14). doi: 10.3390/electronics12143106

Sari, R. P., Astor, Y., Awaludin, I., dan Shalabuddin, S. (2025). COST AND TIME EFFICIENCY ANALYSIS OF ROAD CONDITION SURVEYS: MANUAL VS SEMI-AUTOMATED METHODS. *Jurnal Pensil : Pendidikan Teknik*



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Sipil, 14(3), 564–578. doi: 10.21009/jpensil.v14i3.58676

Shamila Ebenezer, A., Deepa Kanmani, S., Sheela, V., Ramalakshmi, K., Chandran, V., Sumithra, M. G., ... Murugesan, B. (2021). Identification of Civil Infrastructure Damage Using Ensemble Transfer Learning Model. *Advances in Civil Engineering*, 2021. doi: 10.1155/2021/5589688

Shorten, C., dan Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). Retrieved from <https://doi.org/10.1186/s40537-019-0197-0> doi: 10.1186/s40537-019-0197-0

Singh, P. (2023). Systematic review of data-centric approaches in artificial intelligence and machine learning. *Data Science and Management*, 6(3), 144–157. Retrieved from <https://doi.org/10.1016/j.dsm.2023.06.001> doi: 10.1016/j.dsm.2023.06.001

Selihin, F., Syarief, M., Rochman, E. M. S., dan Rachmad, A. (2023, jun). Comparison of Support Vector Machine (SVM), K-Nearest Neighbor (K-NN), and Stochastic Gradient Descent (SGD) for Classifying Corn Leaf Disease based on Histogram of Oriented Gradients (HOG) Feature Extraction. *Elinvo (Electronics, Informatics, and Vocational Education)*, 8(1), 121–129. doi: 10.21831/elinvo.v8i1.55759

Soujanya, B., dan Sitamahalakshmi, T. (2020). Optimization with ADAM and RMSprop in Convolution neural Network (CNN): A Case study for Telugu Handwritten Characters. *International Journal of Emerging Trends in Engineering Research*, 8(9), 5116–5121. doi: 10.30534/ijeter/2020/38892020

Sydaner, D. (2020). A Comparison of Optimization Algorithms for Deep Learning. *International Journal of Pattern Recognition and Artificial Intelligence*, 34(13). doi: 10.1142/S0218001420520138

Se, C., dan Wang, W. (2020). Concrete Cracks Detection Using Convolutional NeuralNetwork Based on Transfer Learning. *Mathematical Problems in Engineering*, 2020. doi: 10.1155/2020/7240129

Suraya, dan Sholeh, M. (2022). Designing and Implementing a Database for Thesis Data Management by Using the Python Flask Framework. *International Journal of Engineering, Science and Information Technology*, 2(1), 9–14. doi: 10.52088/ijesty.v1i1.197

Swain, S., dan Tripathy, A. K. (2024). Automatic detection of potholes using VGG-16 pre-trained network and Convolutional Neural Network. *Heliyon*, 10(10), e30957. Retrieved from <https://doi.org/10.1016/j.heliyon>



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

- a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
- b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

.2024.e30957 doi: 10.1016/j.heliyon.2024.e30957

- TensorFlow Team. (2024). *Tensorflow keras applications: Resnet preprocess input*. https://www.tensorflow.org/api_docs/python/tf/keras/applications/resnet/preprocess_input. (TensorFlow Documentation, accessed December 11, 2025)
- Theckedath, D., dan Sedamkar, R. R. (2020). Detecting Affect States Using VG-G16, ResNet50 and SE-ResNet50 Networks. *SN Computer Science*, 1(2), 1–7. Retrieved from <https://doi.org/10.1007/s42979-020-0114-9> doi: 10.1007/s42979-020-0114-9
- Ut Huda, N., Gade, R., dan Moeslund, T. B. (2021). Effects of Pre-processing on the Performance of Transfer Learning Based Person Detection in Thermal Images. *2021 IEEE 2nd International Conference on Pattern Recognition and Machine Learning, PRML 2021*, 86–91. doi: 10.1109/PRML52754.2021.9520729
- Valero-Carreras, D., Alcaraz, J., dan Landete, M. (2023). Comparing two SVM models through different metrics based on the confusion matrix. *Computers and Operations Research*, 152(December 2022), 106131. Retrieved from <https://doi.org/10.1016/j.cor.2022.106131> doi: 10.1016/j.cor.2022.106131
- Vaz, E. d. S., Gasparello, L. F., de Gouveia, L. T., dan Senger, L. J. (2023). Detecting Damage in Roads Using Convolutional Neural Networks. *Iberoamerican Journal of Applied Computing*, 11(1), 1–9. Retrieved from <https://revistas.uepg.br/index.php/ijac/article/view/21916>
- Walingkas, H. L., dan Saian, P. O. N. (2023). Penerapan Framework Flask pada Pembangunan Sistem Informasi Pemasok Barang. *Jurnal JTIK (Jurnal Teknologi Informasi dan Komunikasi)*, 7(2), 227–234. doi: 10.35870/jtik.v7i2.729
- Wang, P., Lei, Y., Ying, Y., dan Zhou, D. X. (2024). Differentially private stochastic gradient descent with low-noise. *Neurocomputing*, 585(December 2023), 127557. Retrieved from <https://doi.org/10.1016/j.neucom.2024.127557> doi: 10.1016/j.neucom.2024.127557
- Wang, W., Yu, X., Jing, B., Tang, Z., Zhang, W., Wang, S., ... Yang, L. (2025). YOLO-RD: A Road Damage Detection Method for Effective Pavement Maintenance. *Sensors*, 25(5), 1–19. Retrieved from <https://pmc.ncbi.nlm.nih.gov/articles/PMC11902777/> doi: 10.3390/s25051442
- Wulandari, V., Sari, W. J., Al-sawaff, Z. H., dan Manickam, S. (2025). Compar-



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

- active Analysis of Weather Image Classification Using CNN Algorithm with InceptionV3 , DenseNet169 and NASNetMobile Architecture Models. *Institute of Research and Publication Indonesia (IRPI)*, 2(January), 81–92. doi: <https://doi.org/10.57152/predatecs.v2i2.1609>
- Yin, J., Qu, J., Huang, W., dan Chen, Q. (2021). Road damage detection and classification based on multi-level feature pyramids. *KSII Transactions on Internet and Information Systems*, 15(2), 786–799. doi: 10.3837/tiis.2021.02.022
- Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., dan Parmar, M. (2024). *A review of convolutional neural networks in computer vision* (Vol. 57) (No. 4). Springer Netherlands. Retrieved from <https://doi.org/10.1007/s10462-024-10721-6> doi: 10.1007/s10462-024-10721-6
- Zhao, Z. Q., Zheng, P., Xu, S. T., dan Wu, X. (2019). Object Detection with Deep Learning: A Review. *IEEE Transactions on Neural Networks and Learning Systems*, 30(11), 3212–3232. doi: 10.1109/TNNLS.2018.2876865
- Zhou, J., Gu, X., Gong, H., Yang, X., Sun, Q., Guo, L., dan Pan, Y. (2024). Intelligent classification of maize straw types from UAV remote sensing images using DenseNet201 deep transfer learning algorithm. *Ecological Indicators*, 166(July), 112331. Retrieved from <https://doi.org/10.1016/j.ecolind.2024.112331> doi: 10.1016/j.ecolind.2024.112331



- Hak Cipta Dilindungi Undang-Undang**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
 2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

LAMPIRAN A

SURAT IZIN PENELITIAN



KEMENTERIAN AGAMA REPUBLIK INDONESIA
UNIVERSITAS ISLAM NEGERI SULTAN SYARIF KASIM RIAU
FAKULTAS SAINS DAN TEKNOLOGI

كلية العلوم و التكنولوجيا

FACULTY OF SCIENCES AND TECHNOLOGY

JL. H.R. Soebrantas KM.15 No. 155 Tuah Madani Kec. Tuah Madani- Pekanbaru 28298 PO Box. 1004
 Fax. (0761) 589 025 Web: www.uin-suska.ac.id E-mail: faso@uin-suska.ac.id

Nomor : B- 7138 / F.V/PP.009/10/2025
 Sifat : Biasa
 Hal : Mohon Izin Penelitian dan Pengambilan Data
 Tugas Akhir/Skripsi

Pekanbaru, 10 Oktober 2025

Kepada Yth.
 Kepala Dinas Pekerjaan Umum dan Penataan Ruang
 (PUPR)
 Jl. Abdul Rahman Hamid Komplek Perkantoran Tenayan Raya
 Gedung B9 Lantai 3, Kec. Tenayan Raya Kota Pekanbaru - Riau

Assalamualaikum Wr. Wb.

Dengan hormat, Sehubungan telah dimulainya mata kuliah Tugas Akhir pada Fakultas Sains dan Teknologi UIN Suska Riau, kami bermaksud mengirimkan mahasiswa:

Nama	: Rifka Anrahvi
NIM	: 12250321100
Fakultas	: Sains dan Teknologi
Program Studi/Smt	: Sistem Informasi / 7
No. Hp/E-mail	: 085265259741

untuk pengambilan data yang sangat dibutuhkan dalam Tugas akhir mahasiswa tersebut yang berjudul "KLASIFIKASI TINGKAT KERUSAKAN JALAN BERBASIS CITRA DIGITAL MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK". Kami mohon kiranya saudara berkenan memberikan izin dan fasilitas demi kelancaran Tugas Akhir mahasiswa yang bersangkutan.

Demikian surat ini kami sampaikan, atas bantuan dan kerjasama Saudara kami ucapkan terima kasih.

Wassalam



Dr. Lestari Handayani, ST., M.Kom
 NIP. 198111132007102003



Dokumen ini telah ditanda tangani secara elektronik.

Token : Kt5GCwei

Gambar A.1. Surat Izin Penelitian

LAMPIRAN B

WAWANCARA

PEDOMAN WAWANCARA PENELITIAN

Validasi Pakar Tugas Akhir

A. INFORMASI DASAR DAN NARASUMBER

Instansi Studi Kasus	Dinas Pekerjaan Umum dan Penataan Ruang (PUPR) Kota Pekanbaru
Peneliti	Rifka Anrahvi
Judul Penelitian	Klasifikasi Tingkat Kerusakan Jalan Berbasis Citra Digital Menggunakan Algoritma Convolutional Neural Network (CNN)
Tanggal Wawancara	28 Oktober 2025
Nama Narasumber	Tunaidi
Jabatan/Posisi	Pemeliharaan Jalan
Bidang/Seksi	Bina Marga
Lokasi Wawancara	Jl. Hangtuah, yg. Pendidikan

B. PERTANYAAN WAWANCARA INTI (VALIDASI PAKAR)

B.1. Konteks Tugas dan Pedoman Standar

No	Pertanyaan	Catatan Jawaban Narasumber
1	Bagaimana kondisi umum jalan di Kota Pekanbaru saat ini berdasarkan hasil pemantauan terbaru dari Dinas PUPR?	Kondisi Jalan secara umum sekamang boleh dikatakan sudah jauh lebih bagus, dikarenakan sudah banyak pengaspalan.
2	Bisa dijelaskan, Pak/Bu, apa saja tugas dan tanggung jawab Bidang Bina Marga dalam hal pemeliharaan dan perbaikan jalan di Kota Pekanbaru, khususnya dalam aspek pendataan kerusakan?	Mempelihara jalan yang ada di Pekanbaru, khususnya ruas-ruas jalan milik kota Pekanbaru. Di dalam aspek pendataan kerusakan.
3	Dalam menentukan tingkat kerusakan jalan, apakah Dinas PUPR menggunakan standar atau pedoman tertentu yang sifatnya baku (misalnya Pedoman Bina Marga atau Permen PUPR)? Jika ada, apa nama pedomannya?	Standar baku itu tidak ada. Menggunakan Pemantauan identifikasi melalui Sosmed, Pengaduan Masyarakat ataupun pengaduan website Dinas PU. Lebih ke arah survey ke lokasi.
4	Bagaimana alur data kerusakan jalan (mulai dari ditemukan/didokumentasikan hingga ditetapkan tingkat kerusakannya) diproses di internal Dinas?	Setelah survey, hasilnya baru diidentifikasi. - Kalau rusak sedang, mungkin segera tambal/ulam. - Kalau rusak berat, otomatis melakukan perawatan, berkaitan dengan kegiatan overlay / resensi jalan.

B.2. Validasi Klasifikasi Dataset (Inti Penelitian)

No	Pertanyaan	Catatan Jawaban Narasumber
5	Secara teknis di lapangan, tingkatan atau kategori apa saja yang digunakan oleh	Tergantung kondisi jalannya, 1. rusak parah (pondasi aspal sudah terlihat) 2. rusak sedang (tambal

Gambar B.1. Hasil Wawancara 1



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

	tim survei Dinas PUPR untuk membagi kondisi/kerusakan jalan? (Misalnya: Baik, Sedang, Rusak Ringan, Rusak Berat.)	Salah, 3. rusak ringan berarti kita lanjutkan nanti saja. (rusak biasa) Berarti 3 tiga.
6	Penelitian saya menggunakan 4 kelas: Good, Satisfactory, Poor, dan Very Poor. Menurut Bapak/Ibu sebagai pakar, apakah pengelompokan label ini sudah merepresentasikan klasifikasi yang digunakan oleh Dinas? (Mohon saran penyesuaian istilah bila perlu.)	Kalau Good sudah tidak masuk kategori di Dinas. karena setelah perbaikan jadi fokus ke bagian rusak. Setelah melihat dataset → mirip dengan Dinas Bisa digunakan, hanya beda istilah.
7	Selain tingkat kerusakannya, jenis kerusakan jalan seperti apa (misalnya retak memanjang, lubang/pothole, alligator crack, dsb.) yang paling diprioritaskan untuk segera diidentifikasi atau diperbaiki oleh Dinas?	Prioritas rusak berat kalau lebih mengganggu yang wajib diperbaiki yang ada fasilitas umum seperti sekolah, tempat ibadah, kegiatan sosial.
8	Menurut Bapak/Ibu, mengapa klasifikasi tingkat kerusakan jalan penting dilakukan oleh Dinas PUPR?	Peningkatan, supaya bisa menentukan Perawatannya.
9	Biasanya kenapa dilakukan klasifikasi atau pengelompokan kerusakan jalan oleh Dinas, Pak/Bu? Apakah untuk menentukan prioritas perbaikan, penganggaran, atau pemeliharaan?	Untuk menentukan metode perbaikan
10	Apakah di Dinas terdapat dokumentasi citra atau foto kondisi ruas jalan yang digunakan untuk pemantauan? Jika iya, bagaimana prosedurnya?	Ada, dari yang sebelum - sesudah kondisi 0%, 50%, 100%.
11	Berikut contoh dataset yang saya gunakan dari Kaggle. Apakah tampilan dan kondisi jalan pada dataset ini mirip dengan yang digunakan atau ditemukan oleh Dinas?	Mirip dengan Dinas, Bisa digunakan, hanya berbeda istilah.

B.3. Relevansi dan Masukan Pakar

No	Pertanyaan	Catatan Jawaban Narasumber
12	Menurut Bapak/Ibu, apakah penelitian dengan pendekatan klasifikasi berbasis citra digital dan AI seperti ini memiliki potensi atau manfaat bagi efisiensi kerja Dinas PUPR di masa mendatang?	Pasti banyak positifnya, dan pasti membantu dengan adanya teknologi begini, bisa lebih cepat pengerjaannya. Sangat membantu
13	Menurut Bapak/Ibu, apakah topik klasifikasi tingkat kerusakan jalan ini termasuk sulit untuk diteliti? Faktor apa saja yang membuatnya sulit (misalnya pencahayaan, kondisi cuaca, perbedaan jenis kerusakan, dll.)	Cukup sekarang sulit. faktor yang paling membuat sulit itu adalah cuaca. karena tidak bisa melawan cuaca untuk pemeliharaan jalannya.
14	Adakah saran atau masukan teknis dari Bapak/Ibu, baik terkait metodologi,	Permen PU dipisahkan lagi.

Gambar B.2. Hasil Wawancara 2



Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

sumber data, atau klasifikasi, yang dapat saya gunakan untuk meningkatkan kualitas penelitian ini?	
--	--

C. PENUTUP DAN PENGESAHAN

Catatan Akhir Peneliti:

Saya menyatakan bahwa data yang tercantum dalam pedoman wawancara ini adalah hasil wawancara yang sebenarnya.

Pernyataan Narasumber:

Saya menyatakan bahwa semua informasi yang disampaikan adalah benar dan dapat digunakan untuk keperluan akademik (penyusunan Tugas Akhir).

Pekanbaru, 28 Oktober 2025

	
Peneliti (Ritka Anrahvi) NIM. 12250321100	Narasumber (Junaedi) NIP. 197806032007011004

Gambar B.3. Hasil Wawancara 3

Hak Cipta Dilindungi Undang-Undang


1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

LAMPIRAN C

DOKUMENTASI KEGIATAN




Gambar C.1. Dokumentasi 1




Gambar C.2. Dokumentasi 2

Hak Cipta Dilindungi Undang-Undang


1. Diarangi mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Diarangi mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



Gambar C.3. Dokumentasi 3



Gambar C.4. Dokumentasi 4



Gambar C.5. Dokumentasi 5

DAFTAR RIWAYAT HIDUP



Rifka Anrahvi lahir di Ujungbatu pada tanggal 13 April 2004. Penulis merupakan anak pertama dari dua bersaudara, putri dari pasangan Rahmad, Amd dan Epi Ratmiza, yang senantiasa memberikan dukungan, motivasi, serta dorongan dalam menempuh pendidikan hingga jenjang perguruan tinggi. Pendidikan dasar penulis diselesaikan di SDN 002 Ujungbatu pada tahun 2016, kemudian melanjutkan pendidikan Sekolah Menengah Pertama di MTsN 2 Rokan Hulu dan lulus pada tahun 2019. Selanjutnya, penulis menyelesaikan pendidikan Sekolah Menengah Atas di SMAN 1 Ujungbatu pada tahun 2022. Setelah lulus dari SMA, penulis melanjutkan pendidikan ke jenjang perguruan tinggi di Universitas Islam Negeri Sultan Syarif Kasim Riau melalui jalur SBMPTN, pada Fakultas Sains dan Teknologi, Program Studi Sistem Informasi. Selama menempuh pendidikan di perguruan tinggi, penulis aktif dalam berbagai kegiatan organisasi dan kemahasiswaan, baik di tingkat program studi maupun universitas, di antaranya Himpunan Mahasiswa Program Studi Sistem Informasi, Sanggar Seni Latah Tuah UIN Sultan Syarif Kasim Riau, serta organisasi riset *Puzzle Research Data Technology* (PREDATECH) sebagai Bendahara Umum. Selain aktif berorganisasi, penulis juga aktif dalam kegiatan akademik, khususnya di bidang penelitian, dengan telah menerbitkan sebanyak empat paper penelitian selama masa perkuliahan. Pada tahun 2024, penulis menyelesaikan Kerja Praktek (KP) di UPT Badan Pendapatan Daerah Kecamatan Ujung Batu. Selanjutnya, pada tahun 2025, penulis melaksanakan Kuliah Kerja Nyata (KKN) di Desa Gunung Malelo, Kecamatan Koto Kampar Hulu, Kabupaten Kampar. Penulis juga pernah memperoleh Beasiswa Smart Scholarship dari YBM Bank BRI Pekanbaru selama satu tahun sebagai bentuk dukungan dalam menempuh pendidikan. Gelar Sarjana Komputer (S.Kom) diperoleh pada tahun 2026 setelah penulis berhasil menyelesaikan penelitian Tugas Akhir (TA) dengan judul “Klasifikasi Tingkat Kerusakan Jalan Berbasis Citra Digital Menggunakan Algoritma Convolutional Neural Network.”

Untuk menjalin komunikasi lebih lanjut, penulis dapat dihubungi melalui alamat e-mail 12150321100@students.uin-suska.ac.id.

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
 - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
 - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.