

KLASIFIKASI JALAN RUSAK MENGGUNAKAN TRANSFER LEARNING ARSITEKTUR VGG16

Umar Shodiq¹⁾, Maimunah²⁾, Meidar Hadi Avizenna^{3*)}

^{1,2,3} Fakultas Teknik, Program Studi Teknik Informatika, Universitas Muhammadiyah Magelang, Jl. Mayjen Bambang Soegeng, Glagak, Sumberrejo, Kec. Mertoyudan, Kabupaten Magelang
email: ¹umarshodiq583@gmail.com, ²maimunah@ummgl.ac.id, ³meidar@unimma.ac.id

Abstract

Road damage is a common problem, including in Central Java Province with more than 50% of road conditions still damaged. Nevertheless, the process of recording road damage classification is still manual so it takes a long time and results in low accuracy. To solve the problem, one way is to accelerate the process of recording the type I feel the road by using technology to classify the image of a broken road. The classification method used in this study using the Convolutional Neural Network (CNN) algorithm with the VGG16 architectural transfer learning model. The research also added three scenarios to the preprocessing phase such as the use of histograms CLAHE and green channels, CLAHE and Gamma Correction, as well as Gamma correction and green channel. The data set used consisted of 940 damaged street images divided into three labels: hole, stripping, and cracking. These images will be used to produce models with the best accuracy. The results showed that the second scenario, which uses a combination of CLAHE and Gamma Correction, yielded the best results with an accuracy of 82.98%, an average precision of 83%, and the lowest error based on the analysis of the matrix confusion table. Thus, the second scenario is able to classify the type of road damage quite well and can improve efficiency as well as accuracy in road damage classification...

Keywords: Damaged road, transfer learning, VGG16

Kerusakan jalan merupakan masalah yang sering ditemukan, termasuk di Provinsi Jawa Tengah dengan lebih dari 50% kondisi jalan masih rusak. Namun demikian, proses pencatatan klasifikasi kerusakan jalan masih manual sehingga membutuhkan waktu yang lama dan menghasilkan akurasi yang rendah. Untuk mengatasi masalah tersebut salah satu caranya adalah mempercepat proses pencatatan jenis kurasakan jalan dengan memanfaatkan teknologi untuk melakukan klasifikasi citra jalan rusak. Metode klasifikasi yang digunakan dalam penelitian ini dengan menggunakan algoritma Convolutional Neural Network (CNN) dengan model transfer learning arsitektur VGG16. Penelitian ini juga menambahkan 3 skenario pada tahap preprocessing seperti penggunaan histogram CLAHE dan green channel, CLAHE dan Gamma Correction, serta Gamma correction dan green channel. Dataset yang digunakan berjumlah 940 gambar jalan rusak dibagi menjadi 3 label yaitu berlubang, stripping, dan retak. Gambar tersebut akan digunakan untuk menghasilkan model dengan akurasi yang terbaik. Hasil penelitian menunjukkan bahwa skenario kedua, yang menggunakan kombinasi CLAHE dan Gamma Correction, memberikan hasil terbaik dengan akurasi sebesar 82,98%, nilai rata-rata precision sebesar 83%, dan kesalahan terendah berdasarkan analisis tabel confusion matrix. Dengan demikian, skenario kedua mampu mengklasifikasikan jenis kerusakan jalan dengan cukup baik dan dapat meningkatkan efisiensi serta akurasi dalam klasifikasi kerusakan jalan.

Kata kunci: Jalan rusak, transfer learning, VGG16

1. PENDAHULUAN

Kerusakan jalan merupakan salah satu masalah infrastruktur yang sering ditemukan di setiap negara, termasuk di Indonesia. Jalan memiliki peran sebagai fasilitas yang diperuntukan untuk lalu lintas umum, dan dapat menunjang pertumbuhan ekonomi masyarakat dikarenakan mobilitas yang tinggi. Namun, faktanya kerusakan jalan masih menjadi salah satu masalah yang belum dapat diselesaikan serta menjadi masalah yang serius.

Kerusakan jalan dapat disebabkan oleh beberapa hal, di antaranya beban volume lalu lintas yang tinggi dan berulang, cuaca yang ekstrim, serta konstruksi jalan yang kurang layak (Ersad, 2021).

<https://doi.org/10.35145/joisie.v8i1.4243>

JOISIE licensed under a Creative Commons Attribution-ShareAlike 4.0 International License (CC BY-SA 4.0)

Kerusakan jalan juga dapat mengganggu pertumbuhan ekonomi dan mobilitas masyarakat, serta menyebabkan masalah yang serius terhadap pengguna jalan, salah satunya adalah kecelakaan kendaraan (Suparno, 2023).

Berdasarkan data DPU kerusakan jalan di Jawa Tengah tahun 2024 masih tergolong tinggi dengan panjang 2,50 km rusak parah, 218,73 km rusak ringan, 1258,43 km rusak sedang, hanya 962,63 km kondisi baik, kerusakan tersebut terjadi diruas jalan provinsi dan jalan daerah (Dinas Bina Marga Provinsi Jawa Tengah, 2024). Angka kecelakaan yang tinggi dikarenakan jalan rusak juga masih terhitung tinggi, menurut laporan Kepolisian Negara Republik Indonesia pada tahun 2021 mencatat bahwa terjadi 40 kasus kecelakaan, keseluruhan dari angka tersebut kecelakaan terjadi dikarenakan jalan rusak (M Luthfi Andika, 2021). Ruas jalan yang rusak seperti kondisi jalan yang mengelupas di permukaan, retakan, dan berlubang adalah kerusakan yang umum ditemukan. Terlambatnya proses perbaikan jalan menjadi faktor utama, salah satu penyebab terlambatnya perbaikan kerusakan jalan adalah pencatatan kerusakan masih dilakukan secara manual sehingga memakan waktu yang lebih lama dan tingkat akurasi yang rendah (Marsyanda et al., 2022).

Proses pencatatan perbaikan jalan rusak perlu ditingkatkan, salah satu caranya yaitu dengan mengenali ciri dan pola dari kerusakan jalan tersebut. Pencatatan kondisi jalan rusak dapat menggunakan bantuan teknologi untuk mengklasifikasi citra jalan rusak berdasarkan ciri dan polanya, dengan menggunakan *deep learning* yang merupakan salah satu turunan dari *machine learning* (Ramadhanu et al., 2023). Metode *deep learning* yang sering digunakan untuk klasifikasi citra adalah *Convolutional Neural Network* (CNN) (Sandiwarno, 2024). Salah satu cara untuk meningkatkan kinerja model CNN tanpa melakukan proses pelatihan ulang dari awal adalah menggunakan pendekatan *transfer learning*. *Transfer learning* adalah metode dari satu tugas kemudian mengadaptasi untuk tugas berikutnya. Salah satu arsitektur yang paling populer dan sering digunakan menggunakan *transfer learning* adalah VGG16, yang memiliki total layer sebanyak 16 (Hartati et al., 2022).

Penelitian tentang jalan rusak pernah dilakukan sebelumnya, penelitian tersebut dilakukan (Srinidhi & Devi, 2020) berisi tentang penggunaan 2 pendekatan untuk klasifikasi kerusakan jalan berlubang dengan jumlah dataset 300 gambar. Pendekatan pertama yang digunakan yaitu SC (*Spectral Clustering*) dengan pengoperasian morfologi ambang batas yang berbeda mendapatkan akurasi rata-rata 88%. Pendekatan kedua menggunakan arsitektur *Alexnet* dengan metode CNN (*Convolutional Neural Network*) didapatkan rata-rata akurasi sebesar 87%.

Menurut penelitian yang dilakukan oleh (Rismiyati, 2021), penggunaan *transfer learning* arsitektur VGG16 untuk klasifikasi kualitas buah salak yang membedakan antara kualitas salak baik dan buruk, penelitian tersebut mendapatkan hasil 95,83%. Penelitian lain yang bertujuan untuk mengembangkan model klasifikasi tiga kelas untuk lesi terang dan gelap pada retina menggunakan *transfer learning* dengan model VGG16, dengan menggunakan dataset foto fundus: SUSTech-SYSU exudate dataset, Indian Diabetic Retinopathy Image Dataset (IDRiD), dan Fundus Image Vessel Segmentation (FIVES), mendapatkan hasil akurasi sebesar 93% (Nguyen, 2023). Demikian pula penelitian untuk diagnosis kanker kulit dengan membandingkan efektivitas penggunaan *transfer learning* dengan arsitektur VGG16 dan VGG19 dengan total 2541 dataset mendapatkan akurasi sebesar 92,5% dengan menggunakan model VGG16, dan 93,7% untuk penggunaan model VGG19 (Faghihi et al., 2023).

Berdasarkan permasalahan dan data tersebut, maka dibuatlah studi klasifikasi jalan rusak dengan menggunakan pendekatan CNN dan model *transfer learning* VGG16 dengan menambahkan beberapa kondisi dalam tahap preprocessing yang bertujuan untuk mendapatkan model VGG 16 yang optimal. Pembaharuan dalam penelitian ini menggunakan CNN metode *transfer learning* bisa di prediksi lebih efektif dibandingkan metode CNN klasik karena arsitekturnya terbukti menghemat waktu dan sumber daya komputasi. Penelitian ini diharapkan dapat menghasilkan model terbaik dengan beberapa pengkondisian untuk klasifikasi dalam mengidentifikasi jenis kerusakan jalan dan dapat membantu pihak yang terkait dalam pemeliharaan jalan rusak.


2. METODE PENELITIAN

Penelitian yang dilakukan adalah klasifikasi jenis jalan rusak menggunakan model CNN *transfer learning* arsitektur VGG16 dengan membagi dataset menjadi 3 label yaitu jalan rusak

<https://doi.org/10.35145/joisie.v8i1.4243>

JOISIE licensed under a Creative Commons Attribution-ShareAlike 4.0 International License (CC BY-SA 4.0)

berlubang, jalan rusak *stripping* (permukaan terkelupas), dan jalan rusak retak. Dataset dalam penelitian ini bersumber dari *Kaggle* yang diunggah oleh Marciso dengan nama *Road Damage Tracking Dataset* (Sovit Rath and Marsico, 2023). Dalam penelitian ini, memiliki beberapa tahap dalam mengklasifikasi citra jalan rusak seperti pada Gambar 1.



Gambar 1. Alur Metode Penelitian

Gambar 1. adalah ilustrasi tahapan klasifikasi jalan rusak. Tahapan pertama pengumpulan data, tahapan selanjutnya pemrosesan awal yaitu menyesuaikan warna dan ukuran citra jalan rusak, pembagian data untuk *training*, *testing*, dan *validation*, dilakukan juga melakukan penambahan transformasi buatan dari data yang ada. Selanjutnya mengklasifikasi data menggunakan CNN model *transfer learning* VGG16. Tahap akhir pelatihan ini adalah melakukan evaluasi model.

2.1. PENGUMPULAN DATA

Pengumpulan data merupakan proses mendapatkan data citra jalan rusak untuk dataset yang digunakan dalam penelitian ini. Citra jalan rusak meliputi tiga jenis yaitu berlubang, *stripping* (permukaan terkelupas), dan retak. Berdasarkan tiga jenis jalan rusak tersebut akan menjadi tiga label yang digunakan untuk pembelajaran terawasi (*supervised learning*) (Rozaqi et al., 2021).

Tabel 1. Dataset

Nalam Label	Jumlah Dataset
Berlubang	314
<i>Stripping</i>	333
Retak	293
Total	940

Setiap label memiliki jumlah dataset yang berbeda beda seperti yang terdapat pada Tabel 1. yang meliputi 314 citra jalan rusak berlubang, 333 citra jalan rusak *stripping* (permukaan terkelupas), dan 293 citra jalan rusak retakan atau retak, total citra dari tiga label tersebut adalah 940 citra dengan ukuran citra yang berbeda beda yang akan diubah ukurannya dalam tahap selanjutnya.

2.2. PREPROCESSING

Dataset yang telah dikumpulkan akan melewati tahap *preprocessing*. Tahap *preprocessing* perlu dilakukan sebelum masuk ke tahap pemodelan (Yustika et al., 2019). Pengubahan semua ukuran gambar menjadi 244x244 kesemua citra adalah salah satu proses tahap *preprocessing*, hal tersebut juga dapat meningkatkan kecepatan klasifikasi (Ekananda & Riminarsih, 2022). Setelah pengubahan gambar penelitian ini menggunakan 3 skenario dalam tahap *preprocessing*.


Tabel 2. Skenario *Preprocessing*

Nama Skenario	Skenario
P1	Clahe + <i>Green Channel</i>
P2	Clahe + <i>Gamma Correction</i>
P3	<i>Gamma Correction</i> + <i>Green Channel</i>

Pada Tabel 2. penggunaan *green channel* dalam tahap *preprocessing* karena *green channel* memiliki noise yang lebih sedikit dan keseimbangan warna yang lebih stabil daripada *blue channel* ataupun *red channel* (Tri Sazmita et al., 2020). Sedangkan penggunaan Clahe (*Contrast Limited Adaptive Histogram Equalization*) adalah untuk peningkatan kontras lokal dalam citra yang dapat memunculkan fitur yang lain, dan memperbaiki gambar yang memiliki noise pada gambar jalan (Anavyanto et al., 2023). *Gamma correction* digunakan karena dapat meningkatkan kualitas cahaya dari gambar jalan (Wildah & Kuryanti, 2022). Setelah skenario tersebut, tahap selanjutnya adalah pembagian data menjadi 3 yaitu data *training*, data *testing*, dan data *validation*. Data *training* adalah data yang digunakan untuk melatih model dan biasanya jumlah data yang digunakan lebih banyak, sedangkan data *testing* adalah pembagian sejumlah dataset yang digunakan untuk menguji kinerja model setelah model selesai dilatih dan divalidasi, data validasi sendiri digunakan untuk mengevaluasi model selama proses pelatihan dan membantu dalam *tuning hyperparameter* model dan mencegah *overfitting* (Adi Nugroho et al., 2020). Proses terakhir dalam *preprocessing* adalah augmentasi data yang dapat memperkaya dataset yang digunakan, hal ini dilakukan karena CNN dapat menghasilkan akurasi yang tinggi dengan menggunakan data yang besar (Mulyana & Ferdiansyah Putra, 2024).

2.3. KLASIFIKASI VGG16

Setelah melakukan pembagian data dan augmentasi, dataset citra jalan rusak dilatih menggunakan arsitektur VGG16. Metode *transfer learning* adalah salah satu metode yang terdapat pada arsitektur VGG16. Penggunaan *transfer learning* bertujuan untuk meningkatkan akurasi, metode ini memanfaatkan kecerdasan buatan yang ditentukan sebelumnya. VGG16 sendiri tersusun dari 16 layer yang terdiri dari 13 layer lapisan konvolusi, 2 lapisan *fully connected*, dan 1 lapisan *classifier*.



Gambar 2. Arsitektur VGG16

Pada gambar 2, tiap lapisan konvolusi dalam arsitektur VGG16 memiliki kernel berukuran 3x3, perbedaan yang sangat jelas dalam arsitektur ini adalah jumlah filter disetiap pada tiap susunan konvolusi. Pada lapisan awal arsitektur memiliki 2 lapisan konvolusi dan 64 jumlah filter. Pada lapisan 3 dan 4 memiliki jumlah filter sebanyak 128. Lapisan konvolusi lain juga memiliki jumlah filter yang berbeda beda, seperti 256 terdapat pada lapisan 4 sampai 6 dan 512 pada lapisan 7 sampai 12.

2.4. EVALUASI MODEL

Parameter keberhasilan pembuatan model dapat ditentukan juga ditentukan oleh evaluasi model. Evaluasi dilakukan menggunakan *confusion matrix* seperti pada Tabel 3. dengan memonitor *true positive*, *true negative*, *false positive*, dan *false negative*. *True positive* adalah hasil dari uji atau pengujian yang benar-benar menunjukkan bahwa suatu kondisi atau fakta ada, *false positive* adalah hasil dari uji atau pengujian yang salah menunjukkan bahwa suatu kondisi atau fakta ada, padahal kondisi atau fakta tersebut tidak ada, *true negative* adalah hasil dari uji atau pengujian yang benar-benar menunjukkan bahwa suatu kondisi atau fakta tidak ada, sedangkan *false negative* adalah hasil dari uji atau pengujian yang salah menunjukkan bahwa suatu kondisi atau fakta tidak ada, padahal kondisi atau fakta tersebut ada. *Confusion matrix* biasanya berbentuk tabel yang berisikan hasil prediksi model (Rindya Ella Sari, Solikhun, 2021).

Tabel 3. *Confusion Matrix*


Label	Terklasifikasi Positif	Terklasifikasi Negatif
Positif	<i>True Positive</i>	<i>False Negative</i>
Negatif	<i>False Positive</i>	<i>True Negative</i>

Selain itu tahap evaluasi juga dilakukan menggunakan dengan hasil perhitungan *precision*, *recall*, dan *f1-score*. *Precision* digunakan untuk mengetahui seberapa akurat model dalam mengidentifikasi kasus positif, *recall* adalah metrik yang mengukur proporsi kasus positif yang sebenarnya terdeteksi dengan benar oleh model dari semua kasus positif yang ada, sedangkan *f1-score* adalah metrik yang menggabungkan *precision* dan *recall* menjadi satu nilai tunggal dengan menggunakan rata-rata harmonik dari *precision* dan *recall*.

3. HASIL DAN PEMBAHASAN


3.1. PREPROCESSING

Tahap preprocessing awal adalah mengubah ukuran citra menjadi 244x244 yang diterapkan dalam 3 skenario yang telah ditentukan



Gambar 3. CLAHE + *Green Channel*


Gambar 3. merupakan keluaran skenario P1 dengan menerapkan histogram CLAHE yang memiliki nilai batas kontras atau *clipLimit* 3.0 dan menggunakan *tileGridsize* (8,8) dengan penambahan *green channel*



Gambar 4. CLAHE + *Gamma Correction* Gambar 5. *Gamma Correction* + *Green Channel*

Gambar 4. merupakan keluaran skenario P2 dengan menerapkan histogram CLAHE yang memiliki nilai batas kontras atau *clipLimit* 3.0 dan ditambahkan *gamma correction* dengan nilai gamma 2 untuk membuat gambar menjadi lebih terang.

Gambar 5. merupakan keluaran dari skenario P3 dengan menerapkan *gamma correction* dengan nilai gamma 2 untuk membuat gambar menjadi lebih terang dan *green channel*. Setelah melalui 3 skenario yang telah ditetapkan, data gambar akan dibagi menjadi data *training*, *testing* dan *validation*. Data *training* sebanyak 564 gambar, data *testing* sebanyak 188 gambar, dan data *validation* sebanyak 188 gambar. Proses selanjutnya melakukan augmentasi yang dilakukan untuk memperbanyak citra dari jumlah maupun variasi. Proses augmentasi yang dilakukan adalah *rescale*, *zoom*, dan *flip*, yang dapat dilihat pada Gambar 6



Gambar 6. Penerapan Augmentasi Citra

3.2. KLASIFIKASI ARSITEKTUR VGG16

Model yang dibuat pada penelitian ini adalah model *transfer learning* arsitektur VGG16 yang dibangun dengan menggunakan *library* Keras. Model ini dilatih menggunakan kumpulan data sebanyak 940 gambar jalan rusak. Gambar tersebut dibagi menjadi 3 kelas kategori yaitu jalan rusak berlubang, jalan rusak *stripping*, dan jalan rusak retakan. Input dari model ini adalah keseluruhan citra yang sudah melalui 3 skenario di tahap *preprocessing*. Pelatihan data yang dilakukan penelitian ini menggunakan beberapa *hyperparameter* seperti optimisasi SGD, 100 *epoch*, ukuran *batch size* 32 dan mengontrol keluaran log menggunakan *verbose* 2. Hasil pemodelan data dapat dilihat pada Tabel 4.

Tabel 4. Hasil Ujicoba Setiap Skenario

		Nama Skenario		
		P1	P2	P3
Data Training	Loss	0.2141	0.2144	0.2197
	Accuracy	0,9255	0.9184	0.9228
Data Validation	Val Loss	0.5842	0.5688	0.7076
	Val Accuracy	0.8085	0.8085	0.7766
Data Testing	Loss	0.4215	0.6604	0.6083
	Accuracy	0.8191	0.8298	0.8138

Berdasarkan Tabel 4 skenario 1 (P1) mendapatkan hasil akurasi 0.8191 atau sebesar 81% dengan *loss* atau kerugian sebesar 42% , skenario 2 (P2) mendapatkan hasil akurasi 0.8298 atau sebesar 82% dengan *loss* atau kerugian sebesar 66%, dan skenario 3 (P3) mendapatkan hasil akurasi 0.8138 atau sebesar 81% dengan *loss* atau kerugian sebesar 60%. Dengan demikian disimpulkan bahwa skenario 2 (P2) lebih unggul dari pada skenario 1 (P1) dan skenario 3 (P3).

3.3. HASIL EVALUASI MODEL

Seluruh model skenario yang dibangun pada tahap sebelumnya akan dievaluasi untuk mencari hasil skenario terbaik dengan menggunakan hasil perhitungan *precision*, *recall*, *f1-score*, dan menggunakan tabel *confusion matrix*. Evaluasi model yang dilakukan dapat dilihat sebagai berikut.

a. Nilai *Precision*, *Recall*, dan *F1-score*

Tabel 5. *Precision*, *Recall* dan *F1-score* Skenario 1

Label	Precision	Recall	F1-Score
Berlubang	0.95	0.92	0.94

<i>Stripping</i>	0.79	0.77	0.78
Retakan	0.70	0.86	0.73

Tabel 6. *Precision, Recall dan F1-score Skenario 2*



Label	Precision	Recall	F1-Score
Berlubang	0.83	0.92	0.87
<i>Stripping</i>	0.84	0.77	0.80
Retakan	0.82	0.80	0.81


Tabel 7. *Precision, Recall dan F1-score Skenario 2*

Label	Precision	Recall	F1-Score
Berlubang	0.84	0.83	0.83
<i>Stripping</i>	0.81	0.78	0.79
Retakan	0.79	0.84	0.82

b. *Confusion Matrix*

Penggunaan confusion matrix bertujuan untuk menyajikan informasi tentang prediksi yang dibuat oleh model dengan membandingkan dengan label yang benar dan data uji seperti ditunjukkan Gambar 7.

Gambar 7(a). CLAHE + *Green channel*Gambar 7(b). CLAHE + *Gamma Correction*

Gambar 7(c). *Gamma Correction + Green Channel*

Tabel *confusion matrix* Gambar 7 menunjukkan 3 skenario yang dibuat mengalami beberapa error performa data testing seperti skenario 1 (P1) mendapatkan 154 prediksi benar dan 34 kesalahan prediksi, skenario 2 (P2) mendapatkan 156 prediksi benar dan 32 kesalahan prediksi, dan skenario 3 (P3) mendapatkan 153 prediksi benar dan 35 kesalahan prediksi

4. SIMPULAN

Berdasarkan penelitian yang telah dilakukan dengan mengklasifikasi jenis jalan rusak menggunakan 3 skenario yang berbeda, dan implementasi algoritma CNN model transfer learnig arsitektur VGG16. Hasil yang dilihat dari pengujian 3 skenario yang berbeda didapatkan skenario 2 (P2) menunjukkan performa terbaik dalam hal akurasi dengan mencapai 82.98%, akurasi tersebut lebih tinggi dibandingkan dengan skenario 1 (P1) dan skenario 3 (P3), perolehan analisis *confusion matrix* memberikan hasil bahwa skenario 2 (P2) tidak hanya unggul dalam hal akurasi, tetapi juga memiliki jumlah kesalahan prediksi paling sedikit (32 kesalahan) dibandingkan dengan P1 dan P3. Oleh karena itu, skenario 2 (P2) merupakan skenario terbaik di antara ketiga skenario yang diuji, karena mencapai keseimbangan yang lebih baik antara akurasi dan jumlah kesalahan prediksi yang lebih rendah. Penggunaan CLAHE dan *Gamma correction* sangat mempengaruhi pengenalan citra jalan rusak dalam peningkatan kualitas citra. CLAHE digunakan untuk peningkatan kontras gambar dan dapat menampilkan fitur tersembunyi sehingga memperjelas kerusakan pada citra jalan rusak, sedangkan *Gamma Correction* digunakan untuk meningkatkan kualitas cahaya citra jalan rusak. Dengan melihat hasil yang didapat dalam penelitian ini terdapat beberapa hal yang dapat dikembangkan untuk penelitian berikutnya yaitu menambahkan jumlah data *training* dan data *testing* dengan kerusakan yang lebih beragam agar sistem mampu mengenali lebih banyak jenis kerusakan jalan, sehingga kemampuan sistem semakin meningkat, menggunakan perangkat yang cukup memadai karena penggunaan *tools Google Colaboratory* terbatas dalam gpu yang digunakan, dan melakukan analisis lebih lanjut pengaruh kualitas citra dan kondisi pengambilan data citra terhadap kinerja sistem klasifikasi model VGG 16.

5. DAFTAR PUSTAKA

- Adi Nugroho, P., Fenriana, I., & Arijanto, R. (2020). Implementasi Deep Learning Menggunakan Convolutional Neural Network (Cnn) Pada Ekspresi Manusia. *Jurnal Algor*, 2(1). <https://jurnal.buddhidharma.ac.id/index.php/algor/index>
- Anavyanto, A. F., Maimunah, M., Yudianto, M. R. A., & Sukmasetya, P. (2023). EfficientNetV2M for Image Classification of Tomato Leaf Deseases. *PIKSEL : Penelitian Ilmu Komputer Sistem Embedded and Logic*, 11(1), 55–76. <https://doi.org/10.33558/piksel.v11i1.5925>
- Dinas Bina Marga Provinsi Jawa Tengah. (2024). *Kondisi Jalan Di Provinsi Jateng*. <https://Webgis.Dpubinmarcipka.Jatengprov.Go.Id/Kondisi>.
- Ekananda, N. P., & Rimirasih, D. (2022). Identifikasi Penyakit Pneumonia Berdasarkan Citra Chest X-Ray Menggunakan Convolutional Neural Network. *Jurnal Ilmiah Informatika Komputer*, <https://doi.org/10.35145/joisie.v8i1.4243>

- 27(1), 79–94. <https://doi.org/10.35760/ik.2022.v27i1.6487>
- Ersad, A. I. (2021). Implementasi Geographic Information System Sebagai Media Pelaporan Kerusakan Jalan (Studi Kasus: Dinas PU Bandar Lampung). *Jurnal Informatika Dan Rekayasa Perangkat Lunak (JATIKA)*, 2(4), 526.
- Faghihi, A., Fathollahi, M., & Rajabi, R. (2023). Diagnosis of skin cancer using VGG16 and VGG19 based transfer learning models. *Multimedia Tools and Applications*, 1–15. <https://doi.org/10.1007/s11042-023-17735-2>
- Hartati, E., Kunci, K., & Kupu, K. (2022). MDP STUDENT CONFERENCE (MSC) 2022 Klasifikasi Spesies Kupu Kupu Menggunakan Metode Convolutional Neural Network.
- M Luthfi Andika. (2021, June 29). Duh! Jalan Rusak Jadi Penyebab Banyak Kecelakaan Lalu Lintas di Jakarta. <https://Oto.Detik.Com/Berita/d-5624401/Duh-Jalan-Rusak-Jadi-Penyebab-Banyak-Kecelakaan-Lalu-Lintas-Di-Jakarta>.
- Marsyanda, A. U., Januar, I. Y. D., Said, L. B., Idrus, Y., & Alkam, R. B. (2022). Analisis Kerusakan Jalan dan Cara Penanggulangannya. *Jurnal Teknik Sipil MACCA*, 7(1), 8–17. <https://doi.org/10.33096/jtsm.v7i1.536>
- Mulyana, D. I., & Ferdiansyah Putra, R. (2024). Tinggi Ilmu Komputer Cipta Karya Informatika. *Jurnal Teknologi Informasi Dan Komunikasi*, 8(1). <https://doi.org/10.35870/jti>
- Nguyen, A. K. M. (2023). Transfer learning with VGG16 deep convolutional neural network model effectively differentiates between subtypes of bright and dark lesions. *IOVS*. <https://iovs.arvojournals.org/article.aspx?articleid=2790696>
- Ramadhanu, A., Ayu Mahessya, R., Raihan Zaky, M., Isra, M., Informasi, S., & Putra Indonesia YPTK Padang, U. (2023). Penerapan Teknologi Machine Learning Dengan Metode Vader Pada Aplikasi Sentimen Tamu Di Hotel Dymens. *JOISIE Journal Of Information System And Informatics Engineering*, 7(1), 165–173.
- Rindya Ella Sari , Solikhun, F. R. (2021). Penerapan Algoritma C5.0 dalam Memprediksi Persediaan Buah pada UD. Bunda Syafira Buah. *JUKI : Jurnal Komputer Dan Informatika*, 3(2).
- Rismiyati. (2021). VGG16 Transfer Learning Architecture for Salak Fruit Quality Classification. *Jurnal Informatika Dan Teknologi Informasi*, 18(1), 37–48. <https://doi.org/10.31515/telematika.v18i1.4025>
- Rozaqi, A. J., Sunyoto, A., & Arief, M. R. (2021). Seminar Nasional & Call Paper Fakultas Sains dan Teknologi (SENASAINS 1 st. In *Procedia of Engineering and Life Science* (Vol. 1, Issue 1).
- Sandiwarno, S. (2024). Penerapan Machine Learning Untuk Prediksi Bencana Banjir. *Jurnal Sistem Informasi Bisnis*, 14(1), 62–76. <https://doi.org/10.21456/vol14iss1pp62-76>
- Sovit Rath and Marsico. (2023, July 6). Road Damage Tracking Dataset. <https://Www.Kaggle.Com/Datasets/Mersico/Road-Damage-Tracking-Dataset-Rdtd-V10>.
- Srinidhi, G., & Devi, R. (2020). International Conference on Communication and Information Processing Pothole Detection using CNN and AlexNet. <https://ssrn.com/abstract=3648822>
- Suparno. (2023). Analisa Kerusakan Jalan Kabupaten Ruas Klampok – PG Banjartama Kabupaten Brebes. *Era Sains: Journal of Science, Engineering and Information Systems Research*, 1(1).
- Tri Sazmita, D., Efendi, R., Susilo, B., Studi Informatika, P., Teknik, F., Bengkulu, U., Supratman Kandang Limun Bengkulu, J. W., & Indonesia, A. (2020). Pengolahan Citra Telapak Tangan Manusia Menggunakan Metode Histogram Equalization Dan Homomorphic Filtering. <http://ejournal.unib.ac.id/index.php/rekursif/1>
- Wildah, S. K., & Kuryanti, S. J. (2022). Perbaikan Citra Objek Bawah Air Dengan Menggunakan Metode Implementasi White Balancing Dengan Model Grey World (Wbgw) Metode penelitian yang diterapkan pada penelitian ini dilakukan dengan beberapa tahapan yang bertujuan untuk memberikan hasil penelitian. *Journal Speed – Sentra Penelitian Engineering Dan Edukasi*, 14(3), 75–79.
- Yustika, A. A., Suhartono, E., Rahmania, R., S1, P., & Telekomunikasi, T. (2019). Deteksi Anemia Melalui Citra SEL Darah Menggunakan Metode Discrete Wavelet Transform (Dwt) Dan Klasifikasi Support Vector Machine (Svm) .