

Peningkatan Kinerja Klasifikasi Kerusakan Jalan Menggunakan VGG-19 Berbasis Spatial Attention

Richie Jonathan Chaniago¹⁾; Tinaliah²⁾

^{1,2)} Program Studi Informatika, Ilmu Komputer dan Rekayasa, Universitas Multi Data Palembang

Email: ¹⁾ richiejonathanchaniago_2226250017@mhs.mdp.ac.id ; ²⁾ tinaliah@mdp.ac.id

How to Cite :

Chaniago, R, J., Tinaliah. (2026). Peningkatan Kinerja Klasifikasi Kerusakan Jalan Menggunakan VGG-19 Berbasis Spatial Attention. Jurnal Media Computer Science, 5(2)

ARTICLE HISTORY

Received [03 Maret 2026]

Revised [07 April 2026]

Accepted [10 April 2026]

KEYWORDS

Road Damage, Deep Learning, Spatial Attention, VGG-19, Image Classification.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



ABSTRAK

Kerusakan infrastruktur jalan merupakan tantangan serius yang mengancam keselamatan pengguna jalan. Penelitian ini bertujuan untuk meningkatkan akurasi dari klasifikasi kerusakan jalan menggunakan *Deep Learning* dengan arsitektur *VGG-19* yang dimodifikasi dengan mekanisme *spatial attention* untuk menyeleksi fitur yang relevan. Penelitian ini menggunakan dataset sebanyak 3.760 citra kerusakan jalan yang terdiri dari empat kelas (*Crack*, *Pothole*, *Rutting*, dan *Normal*). Dataset dibagi menjadi 70% data latih dan 30% data uji, kemudian melalui tahapan preprocessing berupa *resize*, *mean normalization*, dan *standard deviation*. Dataset dilatih menggunakan *optimizer Adam* dan *SGD*, serta variasi ukuran *batch*. Hasil pengujian menunjukkan bahwa model *VGG-19* dengan *spatial attention* menggunakan *optimizer Adam* dan *batch size* 8 mencapai akurasi tertinggi sebesar 91,67%, mengungguli model tanpa *attention* yang memperoleh akurasi 89,89%. Dapat disimpulkan bahwa penambahan mekanisme *attention* efektif meningkatkan kinerja model dalam mengenali pola kerusakan, sehingga direkomendasikan untuk pengembangan sistem pemantauan infrastruktur cerdas yang lebih akurat. Penelitian ini memberikan kontribusi dengan menunjukkan bahwa integrasi mekanisme *spatial attention* pada *VGG-19* secara konsisten meningkatkan akurasi klasifikasi dibandingkan model *VGG-19* yang tidak ditingkatkan dengan mekanisme *attention*, khususnya pada skenario *batch* kecil.

ABSTRACT

Road infrastructure damage is a serious challenge that threatens the safety of road users. This study aims to improve the accuracy of road damage classification using *Deep Learning* with a *Visual Geometry Group-19* architecture modified with a *spatial attention* mechanism to select relevant features. The study utilizes a dataset of 3,760 road damage images consisting of four classes (*Crack*, *Pothole*, *Rutting*, and *Normal*). The dataset is divided into 70% training data and 30% testing data, followed by preprocessing stages including *resizing*, *mean normalization*, and *standard deviation normalization*. The dataset is trained using the *Adam* and *SGD* optimizers, along with variations in *batch size*. The experimental results show that the *VGG-19* model with *spatial attention* using the *Adam* optimizer and a *batch size* of 8 achieved the highest accuracy of 91.67%, outperforming the model without *attention*, which obtained an accuracy of 89.89%. It can be concluded that the addition of the *attention* mechanism effectively improves the model's performance in recognizing damage patterns. Therefore, it is recommended for the

development of more accurate intelligent infrastructure monitoring systems. This study contributes by demonstrating that the integration of a spatial attention mechanism into VGG-19 consistently enhances classification accuracy compared to the standard VGG-19 model without attention, particularly in small batch size scenarios.

PENDAHULUAN

Perkembangan teknologi kecerdasan buatan, khususnya dalam bidang computer vision, telah membawa kemajuan pesat dalam proses analisis visual otomatis untuk pemeliharaan infrastruktur publik. Secara global, kerusakan infrastruktur jalan merupakan tantangan serius yang jika tidak ditangani melalui pemantauan berkala, dapat menimbulkan biaya perbaikan yang besar dan mengurangi kenyamanan mobilitas (Yamaguchi & Mizutani, 2024). Pemanfaatan teknologi untuk mendeteksi kerusakan secara dini menjadi krusial karena perawatan jalan yang tepat waktu dapat secara signifikan mengurangi risiko bahaya bagi para pengguna jalan raya (Yu et al., 2023).

Deteksi dan klasifikasi jenis kerusakan jalan secara spesifik menjadi aspek fundamental dalam sistem manajemen pemeliharaan infrastruktur. Hal ini dikarenakan setiap jenis kerusakan merepresentasikan tingkat keparahan dan kebutuhan perbaikan yang berbeda. Dalam studi literatur terkait, kerusakan jalan umumnya dikategorikan menjadi tiga jenis utama: *Crack* (retakan) sebagai jenis kerusakan paling umum yang sering menjadi indikator awal degradasi struktur jalan (Benedetto et al., 2023); *Pothole* (lubang) yang terbentuk ketika material jalan terlepas akibat pelapukan atau beban lalu lintas (Usanga, 2021); dan *Rutting* (deformasi) yang terjadi akibat penurunan volume atau pemadatan lapisan perkerasan jalan pada jalur roda (Albayati, 2023).

LANDASAN TEORI

Untuk mengatasi permasalahan klasifikasi kerusakan tersebut secara otomatis, Deep Learning dengan arsitektur Convolutional Neural Network (CNN) sering digunakan untuk melakukan klasifikasi seperti ResNet, AlexNet, MobileNet, dan VGG-19. VGG-19 (Visual Geometry Group 19) memiliki keuntungan seperti memiliki struktur yang dalam tetapi seragam dengan kedalaman 19 lapisan (16 konvolusi dan 3 fully connected), serta terdapat Lapisan max-pooling yang dapat mengurangi dimensi spasial antara blok sehingga mampu mengekstrak fitur dari tingkat sederhana hingga kompleks (Nguyen et al., 2022).

Penelitian sebelumnya oleh (Wang et al., 2023) telah menguji klasifikasi lima jenis kerusakan jalan menggunakan modifikasi model VGG-19 yang terdiri dari model pertama yang menggunakan VGG-19 tradisional dengan akurasi sebesar 97%, model kedua yang menambahkan sebuah layer Batch Normalization pada akhir struktur VGG-19 tradisional didapatkan akurasi sebesar 98%, model ketiga menambahkan layer Batch Normalization sebelum setiap fungsi aktivasi dalam VGG-19 tradisional hingga mendapatkan akurasi sebesar 98%, model keempat menambahkan dua layer Batch Normalization pada VGG-19 tradisional serta memodifikasi batch size menjadi 64 sebelum dua layer fully connected terakhir yang mendapatkan akurasi 99%, dan model kelima berbasis VGG-19 tradisional yang dimodifikasi menjadi 19 layer dengan struktur yang pada sama seperti model keempat sehingga didapatkan akurasi sebesar 98%. Hasil penelitian tersebut menunjukkan bahwa modifikasi arsitektur mampu memberikan hasil yang lebih baik dibandingkan model tradisional. Namun, penelitian tersebut menggunakan batch size yang diseragamkan, yaitu 64 pada seluruh model sehingga belum memberikan perbandingan mengenai pengaruh variasi batch size yang berbeda terhadap kinerja masing-masing model.

Penelitian lainnya yang dilakukan oleh (Satchithanatham, 2024) hanya dapat melakukan klasifikasi terhadap dua kelas kerusakan jalan yaitu jalan normal dan jalan berlubang dengan menggunakan dataset Pothole Detection Dataset dan Pothole Detection pada beberapa model yaitu VGG16 pre-trained (128×128) menghasilkan akurasi sebesar 95.57%, model VGG16 pre-trained

(224×224) mendapatkan hasil akurasi sebesar 97.47%, model VGG16 (128×128) menghasilkan akurasi sebesar 89.87%, model VGG16 pre-trained (224×224) dengan akurasi 87.97% dan Modified VGG16 dengan dilakukan modifikasi pada ukuran input menjadi (118×128) serta modifikasi pada layer Fully Connected sehingga mendapatkan akurasi sebesar 89.87%. Hasil yang didapatkan dari penelitian ini, menunjukkan bahwa model pra-latih lebih unggul daripada model yang dimodifikasi. Kekurangan dari penelitian tersebut adalah kurangnya variasi model yang beragam dan hanya satu model yang dimodifikasi, penelitian tersebut juga tidak menguji hal lain yang dapat mempengaruhi akurasi model seperti optimizer yang digunakan serta batch size dalam melakukan pelatihan.

Hasil penelitian yang dilakukan oleh (Pardeshi et al., 2025) menunjukkan perbandingan performa dari 10 model (dengan dan tanpa self-supervised learning/SSL) pada subset India dari RDD2022. Model MobileNetV2 dengan SSL memperoleh akurasi 78,00%, sedangkan tanpa SSL sebesar 56,10%. MobileNetV3-Large dengan SSL mencapai akurasi 77,60% dan tanpa SSL 69,80%. MobileNetV3-Small dengan SSL memperoleh 76,42% dan tanpa SSL 70,01%. EfficientNet-B0 dengan SSL mencapai 78,90% dan tanpa SSL 75,40%. Sementara itu, ResNet-18 dengan SSL menghasilkan akurasi tertinggi sebesar 80,30% dan tanpa SSL 77,60%. Secara keseluruhan, penggunaan SSL terbukti meningkatkan akurasi pada seluruh arsitektur yang diuji, dengan peningkatan paling signifikan terjadi pada MobileNetV2.

Selain itu, berdasarkan penelitian-penelitian sebelumnya, penggunaan arsitektur VGG-16 dan VGG-19 dalam klasifikasi kerusakan jalan diketahui mampu menghasilkan akurasi yang tinggi dibandingkan berbagai model arsitektur CNN lainnya, terutama karena kedalaman jaringan dan kemampuannya dalam mengekstraksi fitur spasial secara lebih mendalam.

Namun, tantangan dalam ekstraksi fitur yang optimal masih sering terjadi akibat adanya fitur berlebih (redundant features) yang dapat menurunkan akurasi. Solusi potensial untuk mengatasi redundansi fitur tersebut adalah penerapan mekanisme attention. Hal ini dibuktikan dalam penelitian terpisah pada bidang medis (Ali, 2022), di mana integrasi mekanisme attention pada decoder VGG-19 untuk deteksi tumor otak berhasil meningkatkan akurasi hingga 99%. Penambahan gerbang perhatian (attention gate) terbukti efektif menyeleksi fitur yang relevan dan menekan fitur yang tidak perlu (Fan et al., 2022).

Meskipun berbagai penelitian telah menerapkan berberapa arsitektur CNN dan VGG untuk klasifikasi kerusakan jalan, sebagian besar penelitian tersebut belum secara eksplisit mengintegrasikan mekanisme spatial attention untuk mengurangi redundansi fitur. Penelitian terdahulu belum melakukan uji coba terhadap perbandingan ukuran batch dalam proses pelatihan model, sehingga mempengaruhi variasi ukuran batch terhadap performa model. Beberapa penelitian lainnya juga hanya menggunakan satu optimizer, yaitu Adam, tanpa membandingkannya dengan optimizer lain, sehingga belum diketahui bagaimana variasi optimizer dapat memengaruhi kinerja model. Berdasarkan penelitian yang dilakukan oleh (Susanto & Tinaliah, 2024) yang menguji kombinasi berbagai parameter, seperti batch size, jumlah epoch, dan optimizer dalam klasifikasi penyakit cacar menggunakan arsitektur AlexNet, diperoleh hasil bahwa pemilihan parameter yang tepat dapat secara signifikan memengaruhi performa arsitektur yang digunakan. Sejauh ini, belum ada literatur yang secara eksplisit mendiskusikan hubungan antara pemilihan optimizer dan konfigurasi batch size terhadap kinerja arsitektur VGG-19 yang diintegrasikan dengan mekanisme attention. Oleh karena itu, evaluasi mengenai pengaruh kombinasi optimizer dan ukuran batch terhadap kinerja VGG-19 berbasis attention masih jarang dikaji dan menjadi celah penelitian yang relevan untuk diteliti lebih lanjut.

Berdasarkan celah penelitian (research gap) dan urgensi keselamatan jalan, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi kerusakan jalan menggunakan arsitektur VGG-19 yang ditingkatkan dengan mekanisme spatial attention, sekaligus mengevaluasi pengaruh kombinasi optimizer dan ukuran batch terbaik. Melalui optimasi ini, penelitian diharapkan dapat berkontribusi pada pengembangan sistem pemantauan infrastruktur cerdas dengan mengenali pola kerusakan jalan secara lebih akurat dan efisien.

METODE PENELITIAN

Dalam pelaksanaan penelitian ini, diterapkan perancangan metode terlebih dahulu untuk meminimalisir kesalahan dalam proses penelitian, tahapannya adalah sebagai berikut:

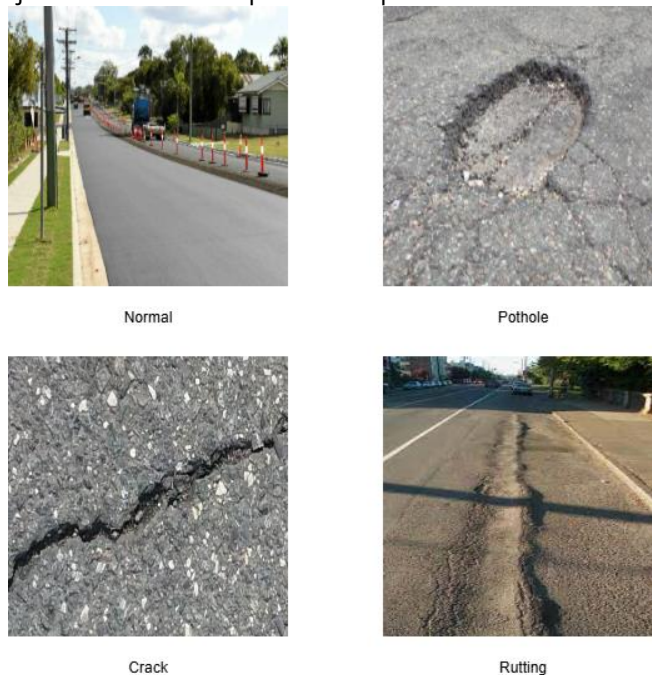
Pengumpulan Dataset

Pada tahap ini, dilakukan pengumpulan dataset jenis kerusakan jalan yang bersifat publik. Beberapa dataset utama yang digunakan pada penelitian ini adalah Crack500 dan dua variasi dataset Pothole Detection dari Kaggle (dapat diakses melalui <https://www.kaggle.com/datasets/vangiap/crack500-dataset>, <https://www.kaggle.com/datasets/atulyakumar98/pothole-detection-dataset>, dan <https://www.kaggle.com/andrewmvd/pothole-detection>). Selain itu, digunakan dataset RoadRuttingDatasetSekilab dari Mendeley Data (<https://data.mendeley.com/datasets/v8mbnvx8pv/1>) serta dataset RCSD (<https://thursxd.com/rscd/>). Data yang terkumpul dibagi menjadi empat kategori kerusakan dengan distribusi masing-masing 940 gambar per kelas yang dapat dilihat pada tabel 1.

Tabel 1. Distribusi Dataset

Jenis Kerusakan	Total Data
Normal	940
Crack	940
Pothole	940
Rutting	940
Jumlah keseluruhan data	3760

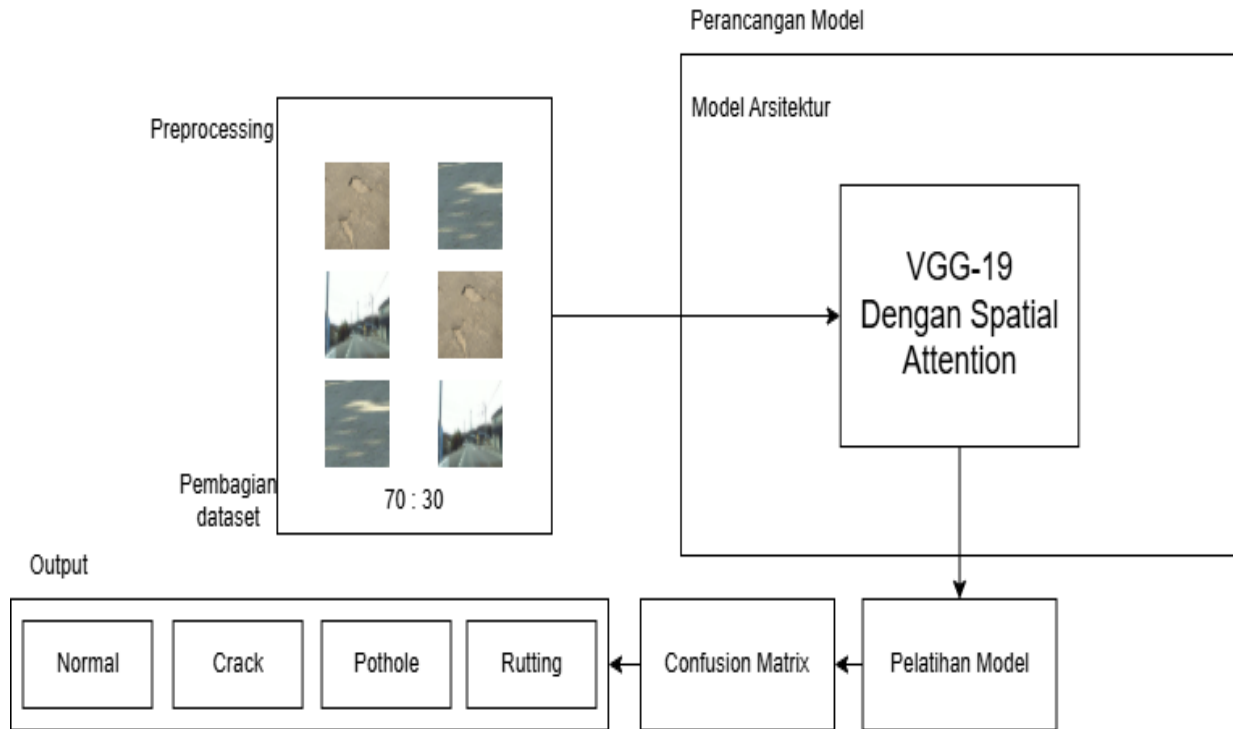
Contoh visualisasi jenis kerusakan dapat dilihat pada Gambar 1.



Gambar 1. Dataset Kerusakan Jalan

Perancangan

Tahapan perancangan sistem klasifikasi kerusakan jalan menggunakan asitektur VGG-19 dimulai dari tahap *preprocessing* dengan melakukan *resize* gambar ke ukuran 224 x 224 serta melakukan *Mean Normalization* dan *Standard Deviation*. Setelah dilakukan *preprocessing*, setiap kelas dilakukan *RandomSplit* untuk membagi dataset tersebut menjadi dua bagian yaitu data latih sebesar 70% dan data uji sebesar 30%. Selanjutnya pada data latih dilakukan training model VGG-19 dengan beberapa parameter. Perancangan dapat dilihat pada Gambar 2.

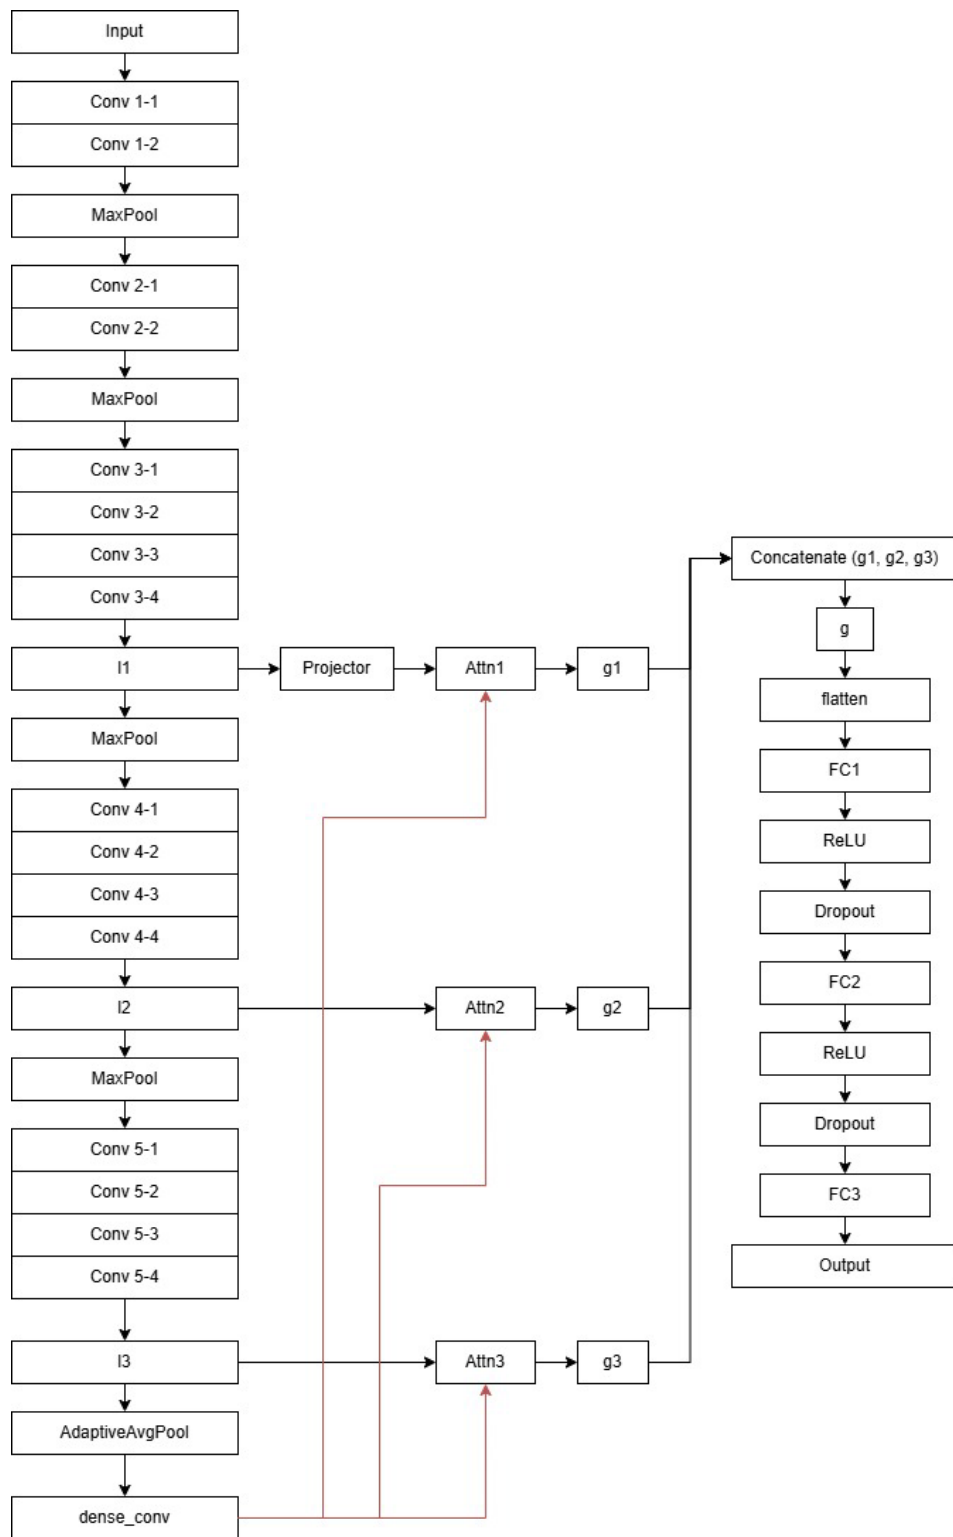


Gambar 2. Perancangan Model Dengan Attention

Implementasi

Penelitian ini menerapkan mekanisme *Spatial Attention* secara strategis pada tiga tingkatan blok konvolusi yang berbeda (I1, I2, dan I3). Setiap modul *attention* dirancang untuk menangkap hubungan spasial yang kompleks dengan mengolah fitur lokal dan global melalui kombinasi operasi *pooling* dan konvolusi. Melalui proses ini, model mampu mengekstraksi informasi penting dari setiap tingkatan yang kemudian menghasilkan tiga output *attention* utama, yaitu *g1*, *g2*, dan *g3*.

Ketiga hasil dari blok *attention* tersebut kemudian digabungkan melalui operasi *concatenate* untuk menghasilkan representasi fitur yang kaya dan komprehensif. Penggabungan fitur ini sangat krusial karena membantu model agar lebih fokus pada tekstur kerusakan jalan dalam berbagai skala sebelum masuk ke lapisan *Fully Connected* (FC). Model dapat dilihat pada Gambar 3.



Gambar 3. Arsitektur VGG-19 Dengan Attention

Untuk menjaga konsistensi pengujian, digunakan beberapa *hyperparameter* tetap, yaitu *learning rate* sebesar 0.0001, penggunaan *Cross-Entropy* sebagai *loss function*, serta durasi pelatihan selama 15 *epoch*. Implementasi seluruh sistem ini dijalankan melalui skenario pengujian dengan variasi parameter yang meliputi ukuran *batch*, penggunaan mekanisme *Spatial Attention*, serta penerapan dua jenis *optimizer*, yaitu *Adam* dan *SGD*, dengan rincian konfigurasi yang tersedia pada Tabel 2.

Tabel 2. Skenario Pengujian

No	Skenario	Batch Size	Spatial Attention	Optimizer
1	Skenario 1	8	✓	Adam
2	Skenario 2	8	x	
3	Skenario 3	16	✓	
4	Skenario 4	16	x	
5	Skenario 5	8	✓	SGD
6	Skenario 6	8	x	
7	Skenario 7	16	✓	
8	Skenario 8	16	x	

Pengujian

Pada Tahapan ini sistem akan diuji dengan menggunakan *confusion matrix* untuk membandingkan semua skenario dalam *accuracy*, *recall*, *precision* dan *F1-Score* untuk mencari skenario yang terbaik.

HASIL DAN PEMBAHASAN

Hasil

Pada tahap ini dilakukan implementasi sistem klasifikasi kerusakan jalan dengan arsitektur VGG-19 yang ditingkatkan dengan mekanisme *attention* yaitu *spatial attention*. Pada tahap *preprocessing*, dilakukan *Resize* pada gambar dengan ukuran 224 x 224 serta dilakukannya *Mean Normalization* dan *Standard Deviation*. Setelah dilakukan normalisasi, setiap kelas dilakukan *RandomSplit* untuk membagi dataset tersebut menjadi dua bagian yaitu data latih sebesar 70% dan data uji sebesar 30%.

Selanjutnya data akan dilatih dengan model VGG-19 yang telah ditingkatkan menggunakan *spatial attention* dengan 3 *attention gate* untuk mengklasifikasikan kerusakan jalan. Pada saat proses pelatihan dilakukan, digunakannya fungsi kehilangan *CrossEntropyLoss* dan *Optimizer* berupa *Adam* dan *SGD* agar mendapatkan model dengan akurasi terbaik. Hasil pengujian tersebut dianalisis dengan menggunakan *confusion matrix* untuk membandingkannya dalam *accuracy*, *recall*, *precision* dan *F1-Score* untuk mencari model yang terbaik dalam mengklasifikasi kerusakan jalan.

Analisis Hasil Akurasi Skenario

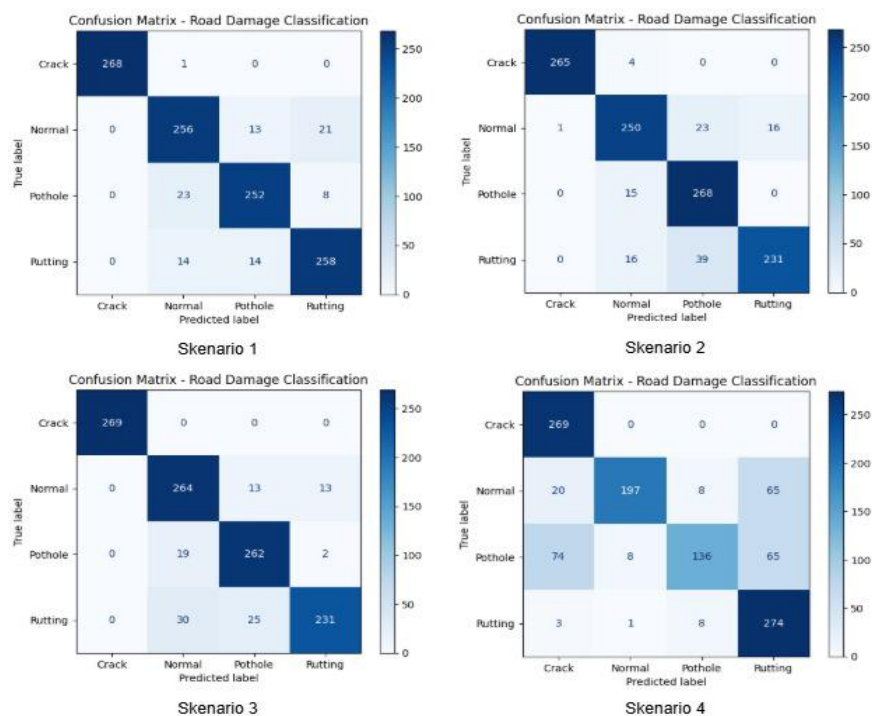
Tabel 3 menyajikan hasil pengujian dari 8 skenario yang telah diuji dengan variasi ukuran *batch*, *optimizer* serta penggunaan *attention*. Evaluasi model tersebut menggunakan *confusion matrix* untuk mendapatkan hasil *accuracy*, *recall*, *precision* dan *F1-Score*.

Tabel 3. Hasil Pengujian

No	Skenario	Accuracy	Precision	Recall	F1-Score
1	Skenario 1	0.9167	0.9169	0.9167	0.9167
2	Skenario 2	0.8989	0.9040	0.8989	0.8989
3	Skenario 3	0.9096	0.9125	0.9096	0.9093
4	Skenario 4	0.7766	0.8176	0.7766	0.7645
5	Skenario 5	0.7926	0.7963	0.7926	0.7900
6	Skenario 6	0.6871	0.7556	0.6871	0.6565
7	Skenario 7	0.6764	0.6948	0.6764	0.6502
8	Skenario 8	0.6303	0.7401	0.6303	0.5824

Berdasarkan hasil pengujian terhadap delapan skenario yang dilakukan, didapatkan akurasi tertinggi pada Skenario 1 untuk penggunaan *optimizer Adam*, yaitu sebesar 0,9167 (91,67%). Skenario ini menerapkan mekanisme spatial attention dengan ukuran batch sebesar 8. Tingginya akurasi pada skenario tersebut menunjukkan bahwa kombinasi mekanisme attention dan batch size yang lebih kecil mampu mengoptimalkan proses pembaruan bobot pada *Adam*, sehingga model dapat mengekstraksi fitur secara lebih efektif dan meminimalkan kesalahan dalam klasifikasi antar kelas.

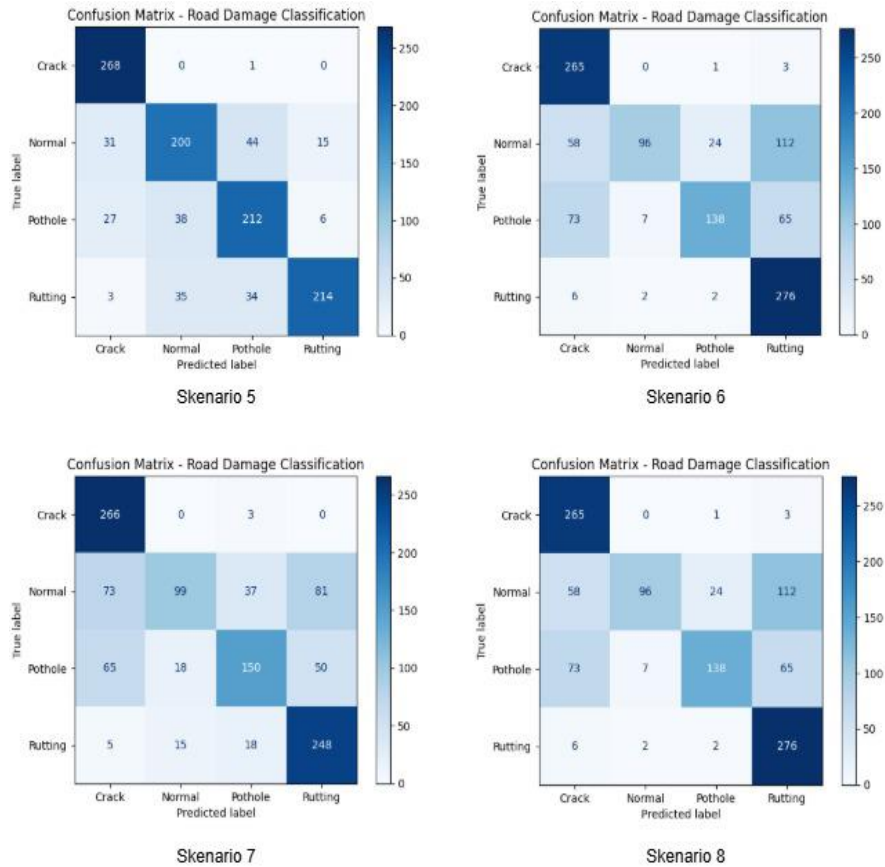
Sementara itu, untuk optimizer SGD, didapatkan akurasi tertinggi pada Skenario 5, yaitu sebesar 0,7926 (79,26%), dengan ukuran batch 16 serta menggunakan mekanisme spatial attention. Meskipun nilai akurasi tersebut masih berada di bawah performa terbaik *Adam*, Skenario 6 menunjukkan hasil paling optimal di antara seluruh konfigurasi yang menggunakan SGD. Dengan demikian, dapat disimpulkan bahwa performa terbaik masing-masing optimizer diperoleh pada Skenario 1 untuk *Adam* dan Skenario 5 untuk SGD. Confusion Matrix yang dapat dilihat pada Gambar 4 dan Gambar 5.



Gambar 4. Confusion Matrix Optimizer Adam

Berdasarkan Gambar 4 (model dengan *optimizer Adam*), terlihat bahwa performa klasifikasi cukup baik pada beberapa kelas, khususnya kelas *Crack* yang memiliki jumlah prediksi benar sangat tinggi dan hampir tidak mengalami kesalahan klasifikasi. Namun, pada kelas *Normal* dan *Pothole* masih ditemukan kesalahan prediksi yang cukup signifikan, terutama kecenderungan data *Normal* yang salah diklasifikasikan sebagai *Rutting* yang dikarenakan kemiripan karakteristik visual antara kedua kelas sehingga model sulit membedakan ketika citra yang digunakan memiliki kualitas yang kurang baik, serta data *Pothole* yang tersebar ke kelas lain disebabkan oleh karakteristik kerusakan yang dimiliki *Pothole* serupa dengan kelas *Crack* jika terdapat retakan yang cukup besar hingga tampak seperti lubang dan kelas *Rutting* yang mirip dengan lubang yang memanjang sehingga dapat terjadi kesalahan dalam klasifikasi.

Meskipun demikian, distribusi nilai pada diagonal utama tetap lebih dominan dibandingkan nilai di luar diagonal, yang menunjukkan bahwa *optimizer Adam* masih mampu mempelajari pola fitur dengan cukup efektif. Secara umum, *Adam* menghasilkan performa yang relatif stabil meskipun belum sepenuhnya meminimalkan kesalahan dalam klasifikasi.



Gambar 5. Confusion Matrix Optimizer SGD

Sementara itu, pada Gambar 5 (model dengan *optimizer SGD*), terlihat bahwa tingkat kesalahan klasifikasi lebih tinggi dibandingkan dengan *Adam*. Hal ini ditunjukkan oleh meningkatnya nilai pada sel di luar diagonal utama, khususnya pada kelas Normal dan Pothole yang sering tertukar dengan kelas lainnya. Meskipun kelas Rutting masih menunjukkan jumlah prediksi benar yang cukup tinggi, ketidakseimbangan distribusi prediksi pada kelas lain mengindikasikan bahwa model dengan optimizer SGD belum mampu mengoptimalkan pembelajaran bobot secara maksimal. Secara keseluruhan, dibandingkan dengan *Adam*, penggunaan SGD pada skenario ini menghasilkan performa klasifikasi yang lebih rendah dan tingkat kesalahan dalam klasifikasi yang lebih besar.

Pembahasan

Analisis Kontribusi Mekanisme Spatial Attention pada VGG-19

Tabel 4 menyajikan hasil perbandingan model VGG-19 yang menggunakan mekanisme *attention* maupun yang tidak, serta perbandingan antara ukuran *batch* dan *optimizer*.

Tabel 4. Perbandingan Akurasi Model VGG-19

Batch Size	Optimizer	Akurasi Model	
		Dengan Attention	Tanpa Attention
8	Adam	0.9167	0.8989
16	Adam	0.9096	0.7766
8	SGD	0.7926	0.6871
16	SGD	0.6764	0.6303

Berdasarkan hasil yang didapatkan, penggunaan *spatial attention* secara konsisten meningkatkan akurasi model. Hal ini disebabkan oleh karakteristik arsitektur VGG-19 yang sangat dalam namun cenderung memperlakukan seluruh fitur spasial secara merata. Mekanisme *spatial attention* bekerja dengan melakukan pembobotan ulang pada peta fitur, sehingga model dapat secara dinamis memfokuskan ekstraksi pada area kerusakan jalan yang relevan dan mengabaikan informasi latar belakang (*noise*) yang tidak penting. Hal ini terbukti efektif menaikkan akurasi tertinggi dari 89,89% menjadi 91,67%.

Evaluasi Kinerja Optimizer Adam terhadap SGD

Dalam seluruh skenario pengujian, *optimizer Adam* menunjukkan hasil yang lebih baik dibandingkan SGD dalam hal akurasinya. Hal ini berkaitan dengan cara kerja mekanisme *adaptive learning rate* yang terdapat pada *optimizer Adam* yang dapat menghitung laju pembelajaran secara individual untuk setiap parameter yang ada. Berbeda dengan SGD yang menggunakan *learning rate* yang bersifat statis dan sering kali terjebak dalam titik optimal lokal (*local minima*) pada arsitektur *deep learning*. *Adam* menggabungkan keunggulan antara momentum dan RMSProp sehingga perpaduan tersebut memungkinkan model VGG-19 dapat menavigasi *error landscape* yang kompleks dengan lebih stabil dan mencapai konvergensi optimal lebih cepat.

Pengaruh Ukuran Batch terhadap Akurasi dan Generalisasi

Hasil pengujian menunjukkan bahwa penggunaan *batch* dengan ukuran 8 menghasilkan akurasi yang lebih tinggi dibandingkan dengan ukuran *batch* 16. Menggunakan ukuran *batch* yang lebih kecil memperkenalkan variasi gradien yang lebih tinggi pada setiap proses pembaruan bobot. *Noise* yang dihasilkan oleh ukuran *batch* kecil berfungsi sebagai penyeimbang alami yang mendorong model untuk keluar dari titik optimal lokal (*local minima*) yang tajam dan menuju ke daerah titik minimum yang toleran (*flat minima*).

Hal ini sangat penting dalam proses klasifikasi kerusakan jalan, dikarenakan model dituntut untuk agar dapat mengenali kerusakan secara akurat meskipun menghadapi gambar jalan dengan kondisi yang beragam, seperti perbedaan pencahayaan serta objek yang mengganggu pada gambar.

KESIMPULAN DAN SARAN

Kesimpulan

Penelitian ini menunjukkan bahwa penggunaan mekanisme *spatial attention* pada arsitektur VGG-19 dapat mempengaruhi akurasi dan efektivitas secara signifikan dalam melakukan klasifikasi kerusakan jalan dengan hasil akurasi 89,89% meningkat menjadi 91,67% untuk *optimizer Adam* dan 68,71% meningkat menjadi 79,26% untuk *optimizer SGD*. Peningkatan ini menunjukkan bahwa keterbatasan dari arsitektur VGG-19 tradisional dalam membedakan fitur yang lebih kompleks dapat diatasi dengan melalui pembobotan fitur yang lebih dinamis, hal ini memungkinkan model untuk fokus dalam melakukan ekstraksi pada area kerusakan yang relevan dan mereduksi gangguan yang terjadi pada latar belakang gambar (*noise*).

Perpaduan antara penggunaan *optimizer Adam* yang memiliki laju pembelajaran yang adaptif (*adaptive learning rate*) serta pemilihan ukuran *batch* yang sesuai terbukti menjadi faktor untuk mencapai hasil akurasi yang lebih baik. Kombinasi antara parameter tersebut tidak hanya meningkatkan akurasi, tetapi juga memperkuat kemampuan model VGG-19 dalam generalisasi sehingga model tetap tangguh dalam menghadapi variasi data uji yang bervariasi, dibandingkan penggunaan *optimizer SGD* yang lebih sensitif terhadap penentuan parameter.

Saran

Sebagai langkah pengembangan selanjutnya, disarankan untuk memperluas variasi dari dataset kerusakan jalan seperti jenis kerusakan jalan lainnya. Selain itu, eksplorasi terhadap arsitektur *deep learning* yang lebih ringan namun tetap dapat dimodifikasi dengan mekanisme *attention*. Penggunaan jenis mekanisme *attention* lainnya dapat dilakukan, supaya dapat mengetahui perbandingan performa antara banyak mekanisme *attention* lainnya. Hal ini juga dapat berpotensi memberikan peningkatan performa yang lebih baik dan tidak terpaku pada satu jenis mekanisme *attention* dalam mengenali karakteristik kerusakan jalan yang lebih spesifik di masa mendatang.

DAFTAR PUSTAKA

- Ali, T. M., Nawaz, A., Ur Rehman, A., Ahmad, R. Z., Javed, A. R., Gadekallu, T. R., Wu, C. M. (2022). A Sequential Machine Learning-cum-Attention Mechanism for Effective Segmentation of Brain Tumor. *Frontiers in Oncology*, 12. <https://doi.org/10.3389/fonc.2022.873268>
- Azhari, F. A., Rohana, T., Baihaqi, K. A., & Fauzi, A. (2025). Road Damage Detection Using Yolov9-Based Imagery. *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, 14(2), 196–201. <https://doi.org/10.32736/sisfokom.v14i2.2377>
- Benedetto, A. Di, Fiani, M., & Gujski, L. M. (2023). U-Net-Based CNN Architecture for Road Crack Segmentation. *Infrastructures*, 8(5). <https://doi.org/10.3390/infrastructures8050090>
- Fan, X., Yan, C., Fan, J., & Wang, N. (2022). Improved U-Net Remote Sensing Classification Algorithm Fusing Attention and Multiscale Features. *Remote Sensing*, 14(15). <https://doi.org/10.3390/rs14153591>
- Nguyen, T. H., Nguyen, T. N., & Ngo, B. V. (2022). A VGG-19 Model with Transfer Learning and Image Segmentation for Classification of Tomato Leaf Disease. *AgriEngineering*, 4(4), 871–887. <https://doi.org/10.3390/agriengineering4040056>
- Pardeshi, P. J., Shailja, Chaudhary, A., Arya, & Yadav, M. (2025). Patch-based self-supervised learning for road damage classification: A case study on the RDD2022 dataset of Indian test site. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, X-5/W2-2025, 459–466. <https://doi.org/10.5194/isprs-annals-X-5-W2-2025-459-2025>
- Satchithanantham, U. (2024). Advanced pothole detection using nural network model-VGG16. *International Journal of Communication and Information Technology*, 5(2), 11–16. <https://doi.org/10.33545/2707661x.2024.v5.i2a.86>
- Susanto, R. I., & Tinaliah. (2024). Klasifikasi penyakit cacar menggunakan arsitektur AlexNet. *Jurnal Algoritme*, 5(1), 47–56. <https://doi.org/10.35957/algoritme.v5i1.9045>
- Usanga, I. (2021). Comparative Analysis Of Pothole Formation From Longitudinal And Transverse Crack Using Mechanistic Model. Dalam *Journal of Multidisciplinary Engineering Science and Technology (JMEST)* (Vol. 8). Diambil dari www.jmest.org
- Wang, J., Wang, K., & Li, K. (2023). Research on road damage recognition and classification based on improved VGG-19. *Mathematical Models in Engineering*, 9(4), 115–129. <https://doi.org/10.21595/mme.2023.23455>

- Yamaguchi, T., & Mizutani, T. (2024). Quantitative road crack evaluation by a U-Net architecture using smartphone images and Lidar data. *Computer-Aided Civil and Infrastructure Engineering*, 39(7), 963–982. <https://doi.org/10.1111/mice.13071>
- Yu, G., Dong, J., Wang, Y., & Zhou, X. (2023). RUC-Net: A Residual-Unet-Based Convolutional Neural Network for Pixel-Level Pavement Crack Segmentation. *Sensors*, 23(1). <https://doi.org/10.3390/s23010053>