

# Perbandingan Klasifikasi Kerusakan Jalan Model CNN VGG19 dan ResNet50

Revanza Raditya Putra Yanni<sup>1</sup>, Iffatul Mardhiyah<sup>2</sup>, Dyah Cita Irawati<sup>3</sup>, Rifki Kosasih<sup>4\*</sup>, Dyan Prawita Sari<sup>5</sup>

<sup>1,4,5</sup> *Fakultas Teknologi Industri, Universitas Gunadarma, Jl. Margonda Raya No.100, Depok, Indonesia*  
E-mail: revanza.rpy@gmail.com, rifki\_kosasih@staff.gunadarma.ac.id, wprawita@staff.gunadarma.ac.id

<sup>2</sup> *Fakultas Magister Manajemen Sistem Informasi, Universitas Gunadarma, Jl. Margonda Raya No.100, Depok, Indonesia*  
E-mail: iffatul@staff.gunadarma.ac.id

<sup>1</sup> *Fakultas Ilmu Komputer, Universitas Gunadarma, Jl. Margonda Raya No.100, Depok, Indonesia*  
E-mail: dyahcita@staff.gunadarma.ac.id

\*Penulis Korespondensi

---

**Abstrak**— Masalah kerusakan jalan pada jalan utama adalah salah satu gangguan saat berkendara dan dapat menyebabkan kecelakaan. Identifikasi kerusakan jalan masih dilakukan secara manual oleh pemerintah daerah dengan penyisiran jalan. Penggunaan teknologi kecerdasan buatan untuk identifikasi kerusakan jalan, sangat diperlukan. Algoritma CNN dapat melakukan identifikasi dan klasifikasi kerusakan jalan. Beberapa arsitektur pada CNN yang sering digunakan untuk klasifikasi diantaranya VGG19 dan ResNet50. Penelitian ini bertujuan untuk mengetahui perbandingan klasifikasi antara VGG19 dan ResNet50 pada kerusakan jalan. Perbandingan dilakukan dengan membedakan jumlah *epoch*nya untuk setiap arsitektur. Jumlah dataset yang digunakan sebanyak 1656 citra. Model yang dibentuk bertujuan mengklasifikasikan kerusakan jalan menjadi tiga klasifikasi yaitu, kerusakan\_besar, kerusakan\_sedang, dan kerusakan\_kecil. Jumlah *epoch* yang digunakan pada model adalah sebesar 10, 50, dan 100. Hasil dari penelitian arsitektur VGG19 dengan *epoch* 10 mendapatkan akurasi sebesar 79%, *epoch* 50 sebesar 73%, dan *epoch* 100 sebesar 76%. Arsitektur ResNet50 memperoleh hasil akurasi sebesar 75% dengan *epoch* 10, untuk *epoch* 50 sebesar 78%, dan *epoch* 100 sebesar 79%. Kesimpulan penelitian perbandingan klasifikasi kerusakan jalan, VGG19 dapat mengklasifikasikan lebih baik jika proses pelatihan yang lebih sederhana, sedangkan ResNet50 dapat melakukan klasifikasi lebih baik jika proses pelatihan yang lebih kompleks.

**Kata Kunci** — CNN, Klasifikasi, Kerusakan Jalan, ResNet50, VGG19

**Abstract**— The problem of road damage on main roads is one of the distractions when driving and can cause accidents. Identification of road damage is still carried out manually by local governments by sweeping roads. The use of artificial intelligence technology to identify road damage is very necessary. The CNN algorithm can identify and classify road damage. Several CNN architectures that are often used for classification include VGG19 and ResNet50. This study aims to determine the classification comparison between VGG19 and ResNet50 on road damage. Comparisons are made by differentiating the number of epochs for each architecture. The number of datasets used is 1656. The model created aims to classify road damage into three classifications, namely, large\_damage, medium\_damage, and small\_damage. The number of epochs used in the model is 10, 50, and 100. The results of research on the VGG19 architecture with epoch 10 obtained an accuracy of 79%, epoch 50 of 73%, and epoch 100 of 76%. The ResNet50 architecture obtained accuracy results of 75% with epoch 10, 78% for epoch 50, and 79% for epoch 100. Conclusion of comparative research on road damage classification, VGG19 can classify better if the training process is simpler, while ResNet50 can perform better classification if the training process is more complex.

**Keywords** — CNN, Classification, Road Damage, ResNet50, VGG19

---

## I. PENDAHULUAN

Kondisi jalan merupakan hal penting dalam mendukung semua bidang potensial suatu negara, diantaranya adalah bidang transportasi dan bidang perekonomian. Identifikasi kerusakan jalan adalah langkah pertama dalam menjaga kondisi jalan. Salah satu metode yang sering digunakan dalam memperhatikan kondisi jalan adalah metode Bina Marga, yang melibatkan penilaian kondisi jalan berdasarkan volume lalu lintas Harian Rata-Rata (LHR) dan jenis kerusakan yang terjadi [1]. Sebagian besar jalan rusak disebabkan oleh lalu lintas kendaraan dengan bobot besar atau muatan besar dengan intensitas yang cukup sering, serta bencana alam, seperti banjir dan gempa bumi [2].

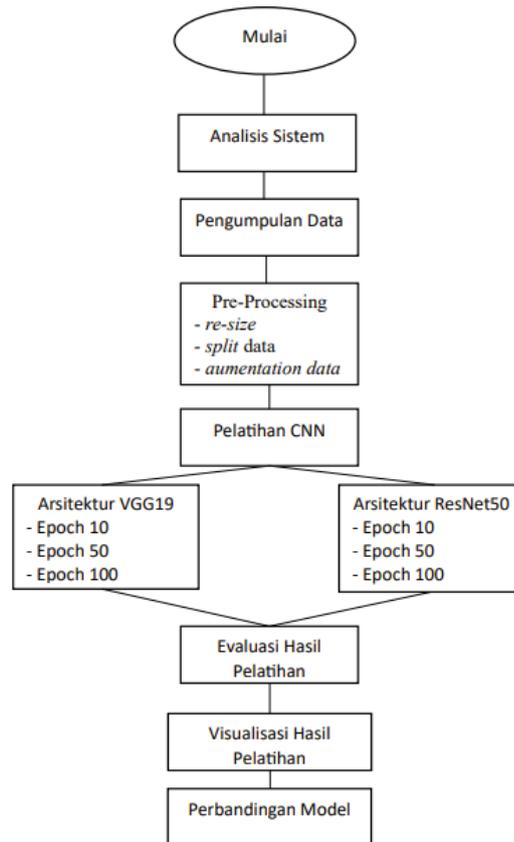
Metode manual terdiri dari menyusuri jalan, mengukur area kerusakan, mengambil citra dengan kamera dari kerusakan, menghitung tingkat kerusakan sesuai dengan jenis kerusakan [3], [4]. Metode manual masih kurang efisiensi waktu, karena masuknya era digital saat ini metode manual tersebut dapat dipercepat dengan adanya teknologi pembelajaran mendalam atau *Deep learning*. *Deep learning* merupakan sekumpulan algoritma pembelajaran mesin yang berusaha untuk belajar dalam berbagai tingkat abstraksi, biasanya menggunakan jaringan syaraf tiruan. Dalam model statistik yang dipelajari, tingkat konsep ditentukan oleh tingkat yang lebih rendah, dan tingkat yang lebih tinggi dapat membantu mendefinisikan banyak konsep tingkat yang lebih rendah [5].

Salah satu algoritma dalam *deep learning* yaitu CNN. Analisis perbandingan dilakukan dalam beberapa kasus kerusakan jalan dengan menggunakan algoritma CNN. Terdapat beberapa metode analisis, salah satunya metode analisis Uji-T berpasangan dengan tingkat signifikansi alpha sebesar 0,05 diterapkan dalam mengidentifikasi kerusakan jalan membandingkan kinerja dua algoritma yaitu *Convolutional Neural Network* (CNN) dan *You Only Look Once* (YOLO) [6]. *Convolutional Neural Network* (CNN) atau *ConvNets*, terdiri atas beberapa lapisan, biasanya jenis algoritma *deep learning* digunakan untuk memproses data berupa citra [5], [7], [8]. Klasifikasi citra lesi kulit serupa virus monkeypox menggunakan VGG19 *Convolutional Neural Network* mendapatkan hasil tingkat akurasi sebesar 76% [9]. Terdapat beberapa model arsitektur dalam arsitektur CNN yang dapat digunakan diantaranya yaitu VGG19 dan ResNet50. Model tersebut terkenal memiliki Tingkat akurasi yang lumayan tinggi dalam mengklasifikasi objek. Deteksi banjir berbasis citra dengan CNN VGG19 mendapatkan hasil tingkat akurasi sebesar 98.78% [10]. Klasifikasi sidik jari menggunakan ResNet50 mendapatkan hasil akurasi sebesar 83.26% [11]. Selain itu, deteksi keretakan jalan aspal menggunakan metode CNN mendapatkan hasil tingkat akurasi sebesar 92.9% [3]. Penelitian lain membahas penerapan CNN dalam membangun model segmentasi citra dengan tensorflow [12]–[14]. Oleh karena itu, penelitian ini melakukan perbandingan klasifikasi kerusakan jalan menggunakan model CNN VGG19 dan ResNet50. Diharapkan penelitian ini dapat memberikan informasi tentang hasil perbandingan akurasi model CNN VGG19 dan ResNet50.

## II. METODE PENELITIAN

Metode Penelitian yang digunakan untuk klasifikasi kerusakan jalan menggunakan model CNN VGG19 dan ResNet50. Model VGG19 dan ResNet50 biasa dipilih untuk perbandingan model CNN, salah satunya perbandingan model CNN pada klasifikasi wajah orang Papua dan etnis lainnya [15]. Pada penelitian perbandingan klasifikasi ini terdapat tiga tahapan penting dalam metode *machine learning life cycle*, yaitu persiapan data (*preprocessing* data), perancangan model, dan perbandingan model. Tahap pertama, persiapan data (*preprocessing* data) terdiri dari pengumpulan data, pelabelan data (*labeling* data), pembagian data (*split* data) memperbanyak data (*augmentation* data). Tahapan kedua perancangan model, tahapan perancangan model melakukan proses pembuatan model VGG19 dan ResNet50, lalu masuk kedalam proses pelatihan (*training*) dan evaluasi (*evaluation*). Tahap terakhir yaitu perbandingan model, tahapan perbandingan model melakukan perbandingan dari hasil pelatihan yang telah dilakukan untuk mencari perbedaan tingkat akurasi dari VGG19 dan ResNet50.

Gambar 1 menunjukkan alur penelitian yang dilakukan untuk perbandingan klasifikasi kerusakan jalan dengan arsitektur VGG19 dan ResNet50. Tahapan awal penelitian klasifikasi kerusakan jalan menggunakan model CNN VGG19 dan ResNet50 dengan melakukan analisis sistem, analisis sistem ini berfungsi untuk mengidentifikasi kebutuhan apa saja yang diperlukan untuk penelitian ini. Kebutuhan yang pertama adalah perangkat keras (*hardware*) berupa pc/laptop yang berfungsi untuk menjalankan Google Colab, kedua perangkat lunak (*software*) berupa *Google Colab*, *roboflow*, dan *kaggle*. Dalam penggunaan Google Colab tidak diperlukan konfigurasi apapun, namun dapat melakukan penginstallan library di Google Colab [16]. Tahap kedua pada penelitian yaitu pengumpulan data. Pengumpulan data didapatkan pada *website* bernama *kaggle* dan *roboflow*.



**Gambar 1. Alur Penelitian Perbandingan Klasifikasi Kerusakan Jalan**

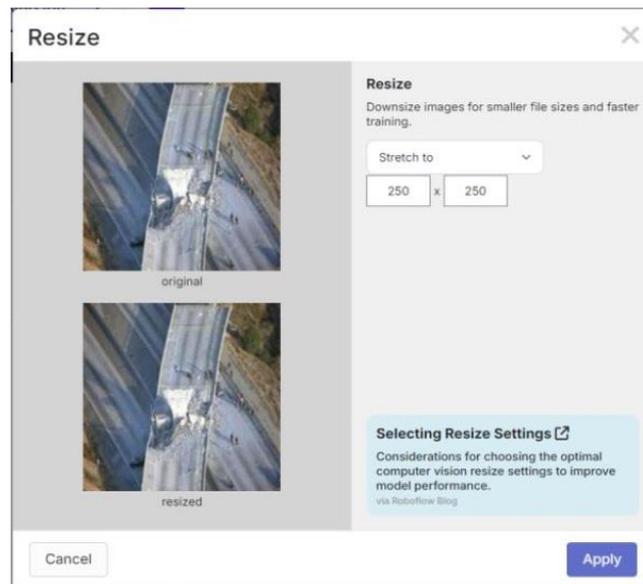


**Gambar 2. Dataset Kerusakan Jalan**

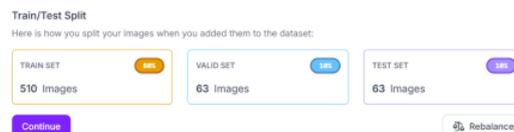
Gambar 2 menunjukkan contoh *dataset* yang telah diambil melalui *website kaggle* dan *roboflow*. Total pengumpulan data dari *website kaggle* dan *roboflow* sebanyak 642 citra. Tahap ketiga pelabelan data (*labeling data*), tahap ini melakukan pelabelan pada data yang telah dikumpulkan menjadi tiga label, label pertama kerusakan\_besar, label kedua kerusakan\_sedang, label ketiga kerusakan\_kecil. Acuan pelabelan ini berdasarkan pada Badan Pusat Statistik (BPS) Indonesia, diantaranya jalan rusak adalah jalan yang dapat dilalui kendaraan dengan kecepatan 20-40 km per jam dan perlu perbaikan pondasi jalan. Jalan rusak berat adalah jalan yang dapat dilalui kendaraan dengan kecepatan 0-20 km per jam [17]. Data yang digunakan tersebut merupakan data kerusakan jalanan secara umum, jadi data tersebut dapat mewakili data-data kerusakan jalan lain jika memiliki fitur dan karakteristik yang sama.

Tabel 1 menunjukkan contoh pelabelan *dataset*. Berdasarkan hal itu, jalan rusak menggambarkan kelas kerusakan\_sedang, sedangkan jalan rusak besar menggambarkan kelas kerusakan\_besar, untuk lainnya masuk kedalam kelas kerusakan\_kecil. Tahap keempat, *preprocessing data*, tahap ini dilakukan melalui *website* bernama *roboflow*. Proses *preprocessing* ada tiga tahapan yang pertama *re-size*, tahap ini berguna untuk mengubah resolusi *dataset* keukuran tertentu berfungsi untuk membuat semua *dataset* tidak ada citra yang berbeda resolusi.

Tabel 1. Pelabelan Data	
Kelas	Citra
Kerusakan_besar	
Kerusakan_sedang	
Kerusakan_kecil	



Gambar 3. Proses *re-size*



Gambar 4. Proses *Split Data*

Gambar 3 menunjukkan proses *re-size dataset* pada *website roboflow*. Berdasarkan gambar 3. Proses *re-size* perubahan resolusi citra dari 256x256 menjadi 250x250. Tahap kedua dari *preprocessing*, yaitu split data atau pembagian data, pembagian data membagi *dataset* menjadi 3 folder yaitu, *train set*, *validation set*, dan *testing set*. Pembagian *dataset* pada penelitian ini 80% untuk *train set*, 10 % untuk *validation set*, dan *testing set* sebesar 10%, yakni dengan perbandingan 8:1:1. Gambar 4 menunjukkan proses Split data.

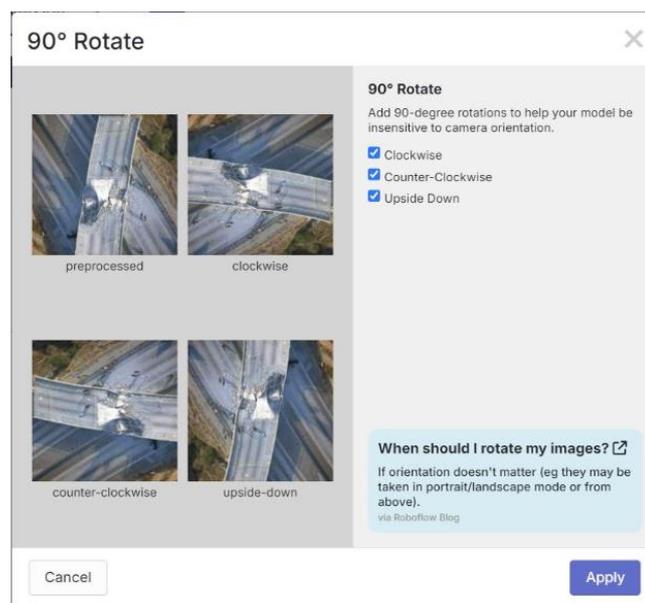
Gambar 4 menunjukkan proses Split data. Berdasarkan Gambar 4. proses *split data*, jumlah pembagian untuk *folder train set* sebanyak 510 data, *validation set* sebanyak 63 data, dan *testing set*

sebanyak 63 data. Tahap terakhir dari *preprocessing* data yaitu, *augmentation* data. *Augmentation* data berguna untuk menambahkan variasi data yang ada pada *folder train set*.

Gambar 5 menunjukkan proses variasi yang digunakan. Berdasarkan Gambar 5, terdapat tiga variasi yang digunakan yaitu, pertama memutar citra 90 derajat searah jarum jam (*Clockwise*), kedua memutar citra 90 derajat berlawanan arah jarum jam (*Counter-Clockwise*), dan ketiga memutarbalikkan (*Upside Down*) citra. Variasi diperbanyak sebanyak tiga kali dari *dataset* awal. Gambar 6 menunjukkan total citra yang diaugmentasi pada penelitian klasifikasi kerusakan jalan ini. Berdasarkan Gambar 6, total hasil augmentasi yang dilakukan didalam *website roboflow* yaitu sebanyak 1,656 citra.

### III. HASIL DAN PEMBAHASAN

Setelah proses *preprocessing*, masuk ke tahap pelatihan, pelatihan model CNN VGG19 dan ResNet50 dalam klasifikasi kerusakan jalan dilakukan di *Google Colab*. Tabel 2, menunjukkan parameter pelatihan yang digunakan untuk pelatihan VGG19 dan ResNet50. Pelatihan klasifikasi kerusakan jalan menggunakan model CNN VGG19 dan ResNet50 dilakukan sebanyak tiga kali untuk setiap model dengan *epoch* yang berbeda, *epoch* yang digunakan dalam penelitian ini yaitu 10, 50, dan 100. Pemilihan *epoch* berdasarkan hasil percobaan yang dilakukan dan menjadi batasan pada penelitian ini. Tabel 3 menunjukkan waktu yang diperlukan model VGG19 dan ResNet50 untuk menyelesaikan pelatihan.



Gambar 5. Variasi *Augmentation* Data



Gambar 6. Total *Augmentasi* Citra

**Tabel 2. Parameter Pelatihan**

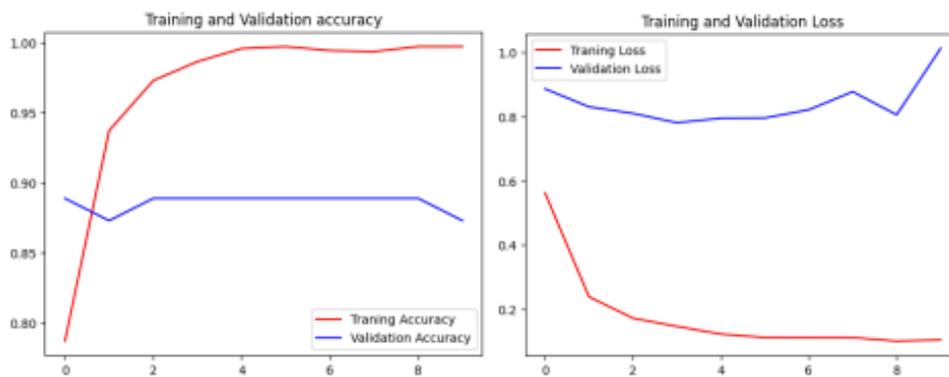
Parameter	Keterangan
Optimizer	Adam
Step per <i>epoch</i>	44
Batch size	32

**Tabel 3. Waktu Pelatihan**

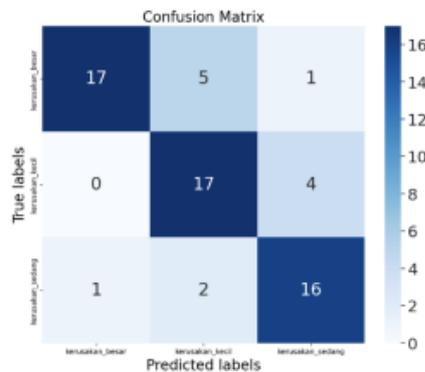
Epoch	Waktu	
	VGG19	ResNet50
10	6 menit 36 detik	4 menit
50	±30 menit	±20 menit
100	±1 jam 3 menit	±40 menit

**Tabel 4. Evaluasi Pelatihan**

Epoch	VGG19			ResNet50		
	Presisi	Recall	F1-score	Presisi	Recall	F1-Score
10	80%	79%	79%	73%	77%	75%
50	75%	76%	73%	78%	79%	78%
100	78%	76%	76%	79%	81%	79%



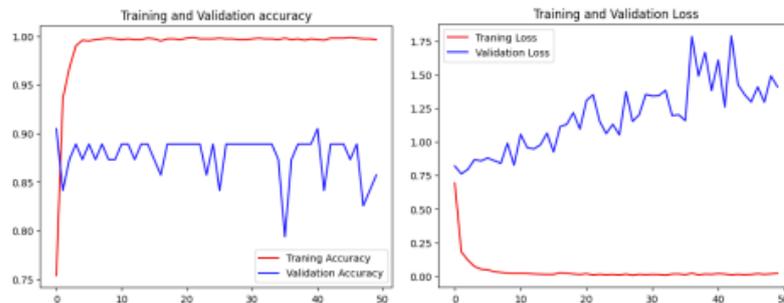
**Gambar 7. Kurva VGG19 Epoch 10**



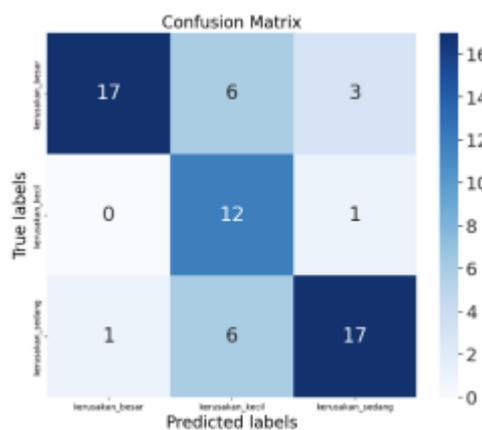
**Gambar 8. Confusion Matrix VGG19 Epoch 10**

Berdasarkan Tabel 3 waktu pelatihan, pelatihan pertama dengan *epoch* 10 VGG19 membutuhkan waktu 6 menit 36 detik, sedangkan ResNet50 membutuhkan waktu 4 menit. Pada pelatihan kedua dengan *epoch* 50 VGG19 membutuhkan waktu ±30 menit, sedangkan ResNet50 membutuhkan waktu ± 20 menit. Pelatihan ketiga dengan *epoch* 100 VGG19 membutuhkan waktu ±1 jam 3 menit, sedangkan ResNet50 membutuhkan ±40 menit. Evaluasi model arsitektur VGG19 dan ResNet50 diukur kinerjanya menggunakan metrik seperti akurasi, *presisi*, *recall*, dan *F1-score*. Visualisasi model berupa sebuah kurva dan *Confusion Matrix*, evaluasi dan perbandingan berupa tabel yang memperlihatkan hasil *fl-score*, *recall*, *presisi*, yang ditunjukkan pada Tabel 4.

Gambar 7 menunjukkan bahwa pada pelatihan VGG19 dengan 10 *epoch*, *training accuracy* terus meningkat sementara *validation accuracy* mendatar setelah peningkatan awal. *Validation loss* juga naik drastis setelah *epoch* ketiga, mengindikasikan model mulai mengalami *overfitting*. *Overfitting* terjadi dapat disebabkan karena data pelatihan yang terbatas, sehingga model terlalu sesuai dengan data pelatihan.



Gambar 9. Kurva VGG19 Epoch 50



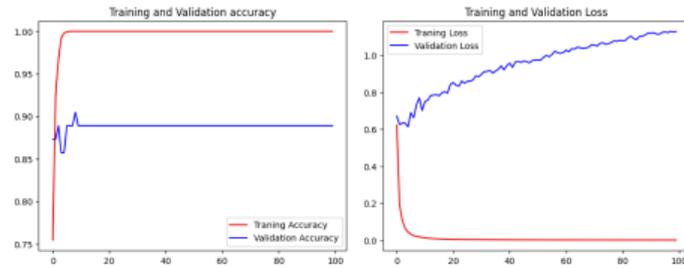
Gambar 10. Confusion Matrix VGG19 Epoch 50

*Confusion Matrix* merupakan salah satu metode yang digunakan untuk mengevaluasi tingkat akurasi suatu model [2], [18], [19]. Penggunaan confusion matrix juga digunakan untuk mengukur prediksi sistem prioritas tagihan pembayaran rumah sakit berdasarkan tingkat kepentingannya menggunakan algoritma Data mining dengan algoritma K means Clustering dan Naïve Bayes Classifier [20]. Gambar 8 menunjukkan Confusion Matrix VGG19 dengan epoch 10, dari 63 data testing set yang digunakan model dapat memprediksi 50 citra dengan benar dan berdasarkan dengan label sebenarnya. Sebanyak 17 citra pada klasifikasi kerusakan\_besar berhasil diprediksi dengan benar oleh model, sementara 1 citra lainnya diprediksi salah. Selanjutnya, 17 citra pada klasifikasi kerusakan\_kecil berhasil diprediksi dengan benar oleh model, sementara 7 citra lainnya diprediksi salah. Pada klasifikasi kerusakan\_sedang dengan 16 citra berhasil diprediksi dengan benar oleh model, sementara 5 citra lainnya diprediksi salah.

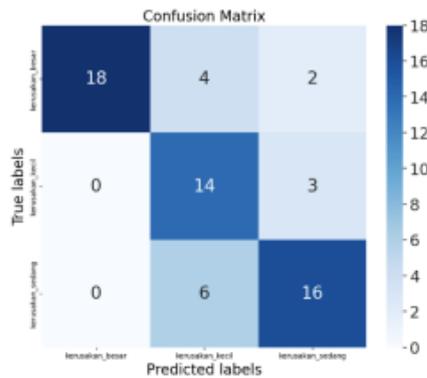
Gambar 9 menunjukkan bahwa pada pelatihan VGG19 dengan 50 epoch, training accuracy cepat mencapai 100%, sementara validation accuracy tidak menunjukkan peningkatan signifikan. Training loss menurun cepat, tetapi validation loss terus meningkat, mengindikasikan model mengalami overfitting.

Gambar 10 menunjukkan Confusion Matrix VGG19 epoch 50, dari 63 citra yang disiapkan untuk testing set, model dapat memprediksi citra dengan benar sebanyak 46 citra yang Berdasarkan dengan labelnya. Sebanyak 17 citra pada klasifikasi kerusakan\_besar berhasil diprediksi dengan benar oleh model, sementara 1 citra lainnya diprediksi salah. Selanjutnya, 12 citra pada klasifikasi kerusakan\_kecil berhasil diprediksi dengan benar oleh model, sementara 12 citra lainnya diprediksi salah. Pada klasifikasi kerusakan\_sedang dengan 17 citra berhasil diprediksi dengan benar oleh model, sementara 4 citra lainnya diprediksi salah. Gambar 11 menunjukkan bahwa pada pelatihan VGG19 dengan 100 epoch, training accuracy cepat mencapai 100%, sementara validation accuracy tetap di sekitar 90% tanpa perbaikan. Training loss menurun cepat, tetapi validation loss terus meningkat, menunjukkan model mengalami overfitting.

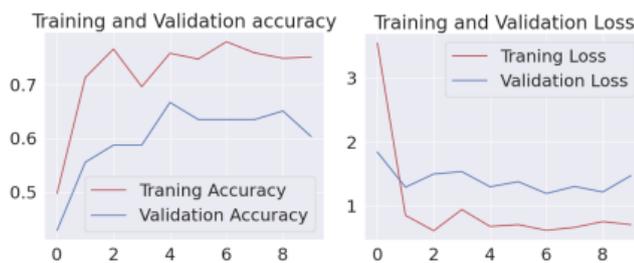
Gambar 12 menunjukkan *Confusion Matrix* VGG19 *epoch* 100, dari 63 citra yang disiapkan untuk *testing set*, model dapat memprediksi citra dengan benar sebanyak 48 citra yang Berdasarkan dengan labelnya. Sebanyak 18 citra pada klasifikasi kerusakan\_besar berhasil diprediksi dengan benar oleh model. Selanjutnya, 14 citra pada klasifikasi kerusakan\_kecil berhasil diprediksi dengan benar oleh model, sementara 10 citra lainnya diprediksi salah. Pada klasifikasi kerusakan\_sedang dengan 16 citra berhasil diprediksi dengan benar oleh model, sementara 5 citra lainnya diprediksi salah.



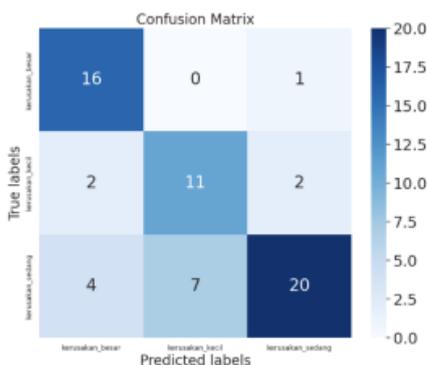
**Gambar 11. Kurva VGG19 Epoch 100**



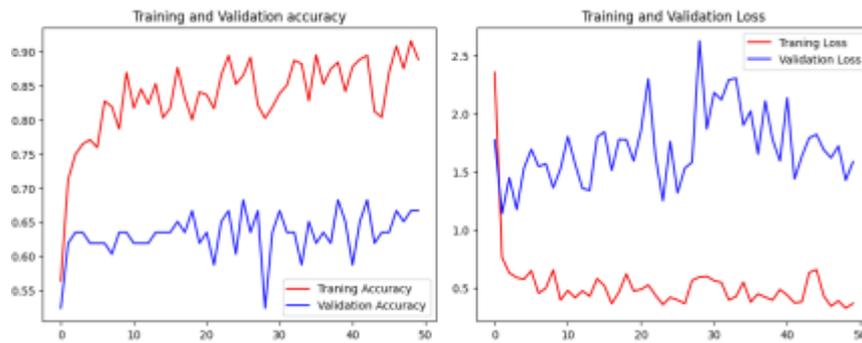
**Gambar 12. Confusion Matrix VGG19 Epoch 100**



**Gambar 13. Kurva Resnet50 Epoch 10**



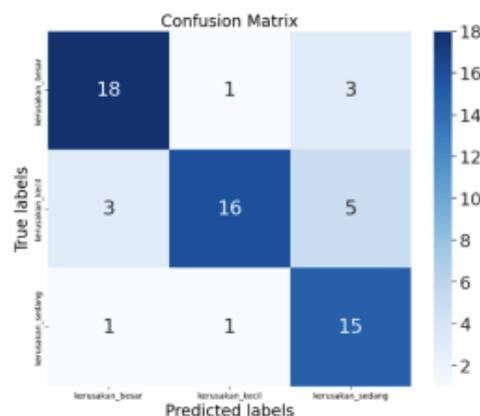
**Gambar 14. Confusion Matrix Resnet50 Epoch 10**



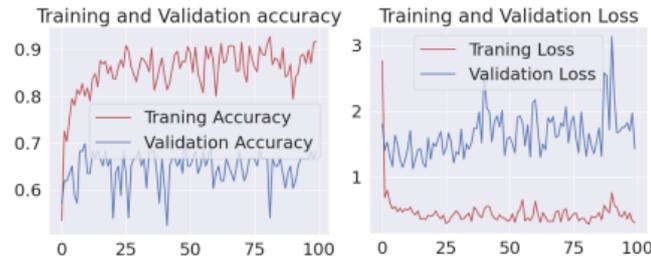
Gambar 15. Kurva Resnet50 Epoch 50

Gambar 13 menunjukkan bahwa pada pelatihan ResNet50 dengan 10 *epoch*, *training accuracy* meningkat cepat hingga sekitar 70%, dan *validation accuracy* juga meningkat meski sedikit menurun di akhir. *Training loss* menurun tajam lalu stabil, sementara *validation loss* tetap stabil, menunjukkan model belajar dan menggeneralisasi dengan baik. Gambar 14 menunjukkan *Confusion Matrix* ResNet50 *epoch* 10, dari 63 citra yang disiapkan untuk *testing set*, model dapat memprediksi citra dengan benar sebanyak 47 citra yang berdasarkan dengan labelnya. Sebanyak 16 citra pada klasifikasi kerusakan\_besar berhasil diprediksi dengan benar oleh model, sementara 6 citra lainnya diprediksi salah. Selanjutnya, 11 citra pada klasifikasi kerusakan\_kecil berhasil diprediksi dengan benar oleh model, sementara 7 citra lainnya diprediksi salah. Pada klasifikasi kerusakan\_sedang dengan 20 citra berhasil diprediksi dengan benar oleh model, sementara 3 citra lainnya diprediksi salah.

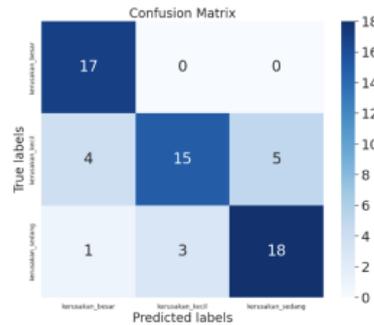
Gambar 15 menunjukkan bahwa pada pelatihan ResNet50 dengan 50 *epoch*, *training accuracy* tidak stabil tapi mencapai sekitar 90%, sementara *validation accuracy* tetap lebih rendah di kisaran 70-80%. *Training loss* menurun dan stabil, namun *validation loss* tidak stabil, menunjukkan model adanya *overfitting*. Gambar 16 menunjukkan *Confusion Matrix* ResNet50 *epoch* 50, dari 63 citra yang disiapkan untuk *testing set*, model dapat memprediksi citra dengan benar sebanyak 49 citra yang berdasarkan dengan labelnya. Sebanyak 18 citra pada klasifikasi kerusakan\_besar berhasil diprediksi dengan benar oleh model, sementara 4 citra lainnya diprediksi salah. Selanjutnya, 16 citra pada klasifikasi kerusakan\_kecil berhasil diprediksi dengan benar oleh model, sementara 2 citra lainnya diprediksi salah. Pada klasifikasi kerusakan\_sedang dengan 15 citra berhasil diprediksi dengan benar oleh model, sementara 8 citra lainnya diprediksi salah. Gambar 17 menunjukkan bahwa pada pelatihan ResNet50 dengan 100 *epoch*, *training accuracy* stabil di sekitar 90% setelah 20 *epoch*, sementara *validation accuracy* berfluktuasi antara 60% hingga 80%. *Training loss* menurun dan stabil, tetapi *validation loss* tetap tidak stabil, menunjukkan model mengalami *overfitting*.



Gambar 16. Confusion Matrix Resnet50 Epoch 50



Gambar 17. Kurva Resnet50 Epoch 100



Gambar 18. Confusion Matrix Resnet50 Epoch 100

Tabel 5. Hasil Perbandingan Model

Epoch	Akurasi	
	VGG19	ResNet50
10	79%	75%
50	73%	78%
100	76%	79%

Gambar 18. menunjukkan *Confusion Matrix* ResNet50 epoch 100, dari 63 citra yang disiapkan untuk *testing set*, model dapat memprediksi citra dengan benar sebanyak 50 citra yang berdasarkan dengan labelnya. Sebanyak 17 citra pada klasifikasi kerusakan\_besar berhasil diprediksi dengan benar oleh model, sementara 5 citra lainnya diprediksi salah. Selanjutnya, 15 citra pada klasifikasi kerusakan\_kecil berhasil diprediksi dengan benar oleh model, sementara 3 citra lainnya diprediksi salah. Pada klasifikasi kerusakan\_sedang dengan 18 citra berhasil diprediksi dengan benar oleh model, sementara 5 citra lainnya diprediksi salah.

Perbandingan dilakukan dengan membandingkan klasifikasi antara arsitektur VGG19 dan ResNet50 dalam klasifikasi kerusakan jalan berdasarkan jumlah *epoch* yang digunakan. Tabel 5 menunjukkan perbandingan antara model VGG19 dan ResNet50. Berdasarkan Tabel 5 hasil perbandingan dapat dilihat bahwa, model VGG19 mengalami penurunan akurasi saat jumlah *epoch* diperbesar, sedangkan model ResNet50 mengalami kenaikan akurasi saat jumlah *epoch* diperbesar. Pelatihan pertama dengan *epoch* 10, VGG19 mendapatkan akurasi yang lebih tinggi daripada ResNet50 yaitu sebesar 79%, sedangkan ResNet50 mendapatkan akurasi sebesar 75%. Pelatihan kedua dengan *epoch* 50, VGG19 mengalami penurunan, sedangkan ResNet50 menalami peningkatan yang menyebabkan ResNet50 lebih tinggi daripada VGG19 dengan akurasi sebesar 78% sedangkan VGG19 mendapatkan akurasi sebesar 73%. Pelatihan ketiga dengan *epoch* 100, terjadi kenaikan akurasi pada VGG19 dan ResNet50, namun VGG19 mendapatkan akurasi yang lebih kecil daripada ResNet50 yaitu sebesar 76%, sedangkan ResNet50 mendapatkan akurasi sebesar 79%.

#### IV. KESIMPULAN

Klasifikasi kerusakan jalan menggunakan model CNN VGG19 dan ResNet50 berhasil dilakukan. Hasil pelatihan pertama dengan *epoch* 10, VGG19 mendapatkan akurasi 79% sedangkan ResNet50 75%. Pelatihan kedua dengan *epoch* 50 VGG19 mendapatkan akurasi 73%, sedangkan

ResNet50 mendapatkan akurasi 78%. Pelatihan ketiga dengan *epoch* 100 VGG19 mendapatkan akurasi 76% sedangkan ResNet50 79%. Kedua model VGG19 dan ResNet50 dapat mengklasifikasikan kerusakan jalan dengan baik, hanya saja ResNet50 lebih unggul dalam klasifikasi saat jumlah *epoch* yang digunakan 50 dan 100, sedangkan VGG19 unggul dalam klasifikasi saat jumlah *epoch* yang digunakan 10. Berdasarkan hal tersebut dapat disimpulkan bahwa VGG19 dapat melakukan klasifikasi lebih baik jika proses pelatihan yang lebih sederhana atau simple, sedangkan ResNet50 dapat melakukan klasifikasi lebih baik jika proses pelatihan yang lebih kompleks. Adapun saran untuk penelitian ini, model VGG19 dan ResNet50 masih kurang dari kata bagus dan terdapat banyak kekurangan, seperti terjadinya *overfitting* pada model saat penggunaan jumlah *epoch* yang terlalu banyak. Diperlukan optimisasi lebih lanjut untuk model supaya tidak mengalami *overfitting* yaitu, meningkatkan kualitas *dataset* yang digunakan untuk proses pelatihan, mengubah beberapa *hyperparameter* seperti *optimizer*, *batch size* dan *epoch*, lalu membuat fungsi *early stop* dimana ini berfungsi menghentikan pelatihan jika model sudah mengalami *overfitting*.

#### DAFTAR PUSTAKA

- [1] Richard W. V. Uguy and Vanda . Rompis, “Penentuan Jenis Pemeliharaan Jalan dengan Menggunakan Metode Bina Marga (Studi Kasus: Ruas Jalan Kelurahan Tondangow Kecamatan Tomohon Selatan),” *J. Ilm. Realt.*, vol. 17, no. 2, pp. 34–38, 2021, [Online]. Available: <http://ejournal.unikadelasalle.ac.id/index.php/realtech/article/view/72%0Ahttp://ejournal.unikadelasalle.ac.id/index.php/realtech/article/download/72/76>.
- [2] D. I. Mulyana and I. Wahyudi, “Deteksi Kerusakan Jalan Berdasarkan Citra Digital Menggunakan Convolutional Neural Network ( CNN ),” vol. 6, no. 1, pp. 294–302, 2025.
- [3] A. Wibowo and Y. Yulianto, “Deteksi Keretakan Jalan Aspal Menggunakan Metode Convolutional Neural Network,” *J. Tek. Sipil Cendekia*, vol. 4, no. 2, pp. 581–593, 2023, doi: 10.51988/jtsc.v4i2.132.
- [4] U. Shodiq *et al.*, “Klasifikasi Jalan Rusak Menggunakan Transfer Learning Arsitektur VGG16,” *JOISIE (Journal Inf. Syst. Informatics Eng.)*, vol. 8, no. 1, 2024.
- [5] A. Raup, W. Ridwan, Y. Khoeriyah, S. Supiana, and Q. Y. Zaqiah, “Deep Learning dan Penerapannya dalam Pembelajaran,” *JiIP - J. Ilm. Ilmu Pendidik.*, vol. 5, no. 9, pp. 3258–3267, 2022, doi: 10.54371/jiip.v5i9.805.
- [6] N. Khairunisa, . C., and A. Jamaludin, “Analisis Perbandingan Algoritma Cnn Dan Yolo Dalam Mengidentifikasi Kerusakan Jalan,” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, 2024, doi: 10.23960/jitet.v12i3.4434.
- [7] P. Asnur, R. Kosasih, S. Madenda, and D. A. Rahayu, “Identification of mangrove tree species using deep learning method,” *Int. J. Adv. Appl. Sci.*, vol. 12, no. 2, pp. 163–170, 2023, doi: 10.11591/ijaas.v12.i2.pp163-170.
- [8] D. P. Lestari and R. Kosasih, “Comparison of two deep learning methods for detecting fire hotspots,” *Int. J. Electr. Comput. Eng.*, vol. 12, no. 3, pp. 3118–3128, 2022, doi: 10.11591/ijece.v12i3.pp3118-3128.
- [9] L. A. Susanto, A. Nilogiri, and L. Handayani, “Klasifikasi Citra Lesi Kulit Serupa Virus Monkeypox Menggunakan VGG-19 Convolutional Neural Network,” *JUSTINDO (Jurnal Sist. dan Teknol. Inf. Indones.)*, vol. 8, no. 1, pp. 1–9, 2023, doi: 10.32528/justindo.v8i1.168.
- [10] Habibullah Akbar, Diah Aryani, and Muhamad Bahrul Ulum, “Deteksi Banjir Area Perkotaan Berbasis Citra Digital Convolutional Neural Network (Vgg19),” *J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 2, no. 3, pp. 82–91, 2022, doi: 10.55606/teknik.v2i3.798.
- [11] N. D. Miranda, L. Novamizanti, and S. Rizal, “Convolutional Neural Network Pada Klasifikasi Sidik Jari Menggunakan Resnet-50,” *J. Tek. Inform.*, vol. 1, no. 2, pp. 61–68, 2020, doi: 10.20884/1.jutif.2020.1.2.18.
- [12] T. Sulistyorini, E. Sova, N. Sofie, and R. I. Napitupulu, “Penerapan Hyperparameter Convolutional Neural Network (Cnn) Dalam Membangun Model Segmentasi Gambar Menggunakan Arsitektur U-Net Dengan Tensorflow,” *J. Ilm. Inform. Komput.*, vol. 28, no. 2, pp. 112–121, 2023, doi: 10.35760/ik.2023.v28i2.6959.
- [13] B. Sasmito, B. H. Setiadji, and R. Isnanto, “Deteksi Kerusakan Jalan Menggunakan Pengolahan

- Citra Deep Learning di Kota Semarang,” *Teknik*, vol. 44, no. 1, pp. 7–14, 2023, doi: 10.14710/teknik.v44i1.51908.
- [14] A. W. Mulia, I. Ruslianto, and D. M. Midyanti, “Klasifikasi Kerusakan Jalan Pada Citra Jalan Raya Pontianak dan Sekitarnya dengan Menggunakan Convolutional Neural Network,” *Coding J. Komput. dan Apl.*, vol. 11, no. 01, pp. 11–20, 2023.
- [15] Y. N. Yenusi, Suryasatriya Trihandaru, and A. Setiawan, “Comparison of Convolutional Neural Network (CNN) Models in Face Classification of Papuan and Other Ethnicities,” *JST (Jurnal Sains dan Teknol.*, vol. 12, no. 1, pp. 261–268, 2023, doi: 10.23887/jstundiksha.v12i1.46861.
- [16] B. U. Manalu, “Modul : Pengantar Python dengan Google Colab,” 2020. [Online]. Available: [https://figshare.com/articles/book/Modul\\_Pengantar\\_Python\\_dengan\\_Google\\_Colab/12683627?file=24018779](https://figshare.com/articles/book/Modul_Pengantar_Python_dengan_Google_Colab/12683627?file=24018779).
- [17] H. Usman, *Statistik transportasi kabupaten gowa 2015*. Gowa: Badan Pusat Statistik Kabupaten Gowa, 2015.
- [18] R. Kosasih, Sudaryanto, and A. Fahrurrozi, “Classification of Six Banana Ripeness Levels Based on Statistical Features on Machine Learning Approach,” *Int. J. Adv. Appl. Sci.*, vol. 12, no. 4, pp. 317–326, 2023, doi: 10.11591/ijaas.v12.i4.pp317-326.
- [19] D. P. Lestari, R. Kosasih, T. Handhika, Murni, I. Sari, and A. Fahrurrozi, “Fire Hotspots Detection System on CCTV Videos Using You only Look Once (YOLO) Method and Tiny YOLO Model for High Buildings Evacuation,” in *2nd International Conference of Computer and Informatics Engineering IC2IE*, 2019, pp. 87–92.
- [20] W. I. Rahayu, C. Prianto, and E. A. Novia, “Perbandingan Algoritma K-Means dan Naive Bayes untuk Memprediksi Prioritas Pembayaran Tagihan Rumah Sakit Berdasarkan Tingkat Kepentingan pada PT. Pertamina (Persero),” *J. Tek. Inform.*, vol. 13, no. 2, pp. 1–8, 2021.