

Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Kerapihan Ruangan

Irfan Andito Mahameru^{1,*}, Mochammad Ravly Dwi Septian², Dwi Roliawati³, Ahmad Yusuf⁴, Mujib Ridwan⁵

^{1,2,3,4,5}Fakultas Sains & Teknologi, Sistem Informasi, UIN Sunan Ampel, Surabaya, Indonesia

Email: ^{1,*}irfanandito2@gmail.com, ²ravly.septian16@gmail.com, ³dwi_roll@uinsa.ac.id, ⁵mujibrw@uinsa.ac.id

(*Email Corresponding Author: irfanandito2@gmail.com)

Received: 11 September 2025 | Revision: 21 September 2025 | Accepted: 22 September 2025

Abstrak

Penelitian ini bertujuan untuk mengimplementasikan Convolutional Neural Network (CNN) dalam klasifikasi citra ruangan ke dalam dua kategori, yaitu *messy* dan *clean*. Model yang digunakan memanfaatkan arsitektur VGG16 sebagai *feature extractor* untuk mengekstraksi ciri visual, kemudian diikuti dengan *fully connected layer* serta fungsi aktivasi sigmoid pada lapisan output. Pendekatan ini dipilih karena lebih sederhana dibandingkan skema *softmax* yang umumnya digunakan pada klasifikasi multi-kelas. Dataset yang digunakan diperoleh dari sumber terbuka dan dilakukan proses *data augmentation* guna meningkatkan kemampuan generalisasi model terhadap variasi citra. Proses pelatihan dilakukan menggunakan *optimizer Adam* dan *loss function binary crossentropy* selama 10 *epoch*. Hasil pengujian menunjukkan akurasi validasi mencapai 98,63%, yang mengindikasikan efektivitas model dalam mengklasifikasikan citra ruangan secara biner. Penelitian ini membuktikan bahwa CNN, khususnya dengan arsitektur VGG16, memiliki potensi besar dalam mendukung otomatisasi penilaian kerapihan ruangan dengan tingkat akurasi yang tinggi.

Kata Kunci: CNN, Kerapihan Ruangan, Sigmoid, Data Augmentation, VGG16

Abstract

This research aims to implement a Convolutional Neural Network (CNN) for classifying room images into two categories, namely messy and clean. The proposed model utilizes the VGG16 architecture as a feature extractor to capture visual features, followed by fully connected layers and a sigmoid activation function in the output layer. This approach is considered simpler compared to the softmax scheme, which is generally applied in multi-class classification tasks. The dataset was obtained from an open-source repository and enhanced through data augmentation techniques to improve the model's generalization ability when facing diverse image variations. The training process employed the Adam optimizer and binary crossentropy loss function for 10 epochs. Evaluation results demonstrated a validation accuracy of 98.63%, indicating the effectiveness of the model in binary classification. This study shows that CNN, specifically with VGG16, has strong potential in supporting automated assessment of room tidiness with a high level of accuracy.

Keywords: CNN, Room Tidiness, Sigmoid, Data Augmentation, VGG16

1. PENDAHULUAN

Kerapihan ruangan merupakan aspek fundamental dalam menciptakan lingkungan yang nyaman, produktif, dan menyenangkan. Ruangan yang rapi, teratur, dan bersih tidak hanya memberikan kesan positif secara visual, tetapi juga memengaruhi kondisi psikologis penghuninya. Berbagai penelitian menunjukkan bahwa ruang yang terorganisir dapat meningkatkan konsentrasi, menurunkan tingkat stres, serta mendukung terciptanya suasana yang kondusif untuk beraktivitas. Sebaliknya, kondisi ruangan yang berantakan cenderung memicu rasa tidak nyaman, menimbulkan distraksi, serta menurunkan motivasi individu dalam bekerja maupun beristirahat. Dalam kehidupan sehari-hari, menjaga kerapihan ruangan sering kali menjadi tantangan, terutama bagi individu dengan rutinitas padat dan mobilitas tinggi, sehingga diperlukan solusi yang dapat membantu mempermudah upaya menjaga kerapihan tersebut. [1]

Dalam sektor perhotelan, kerapihan ruangan memiliki peran yang jauh lebih krusial. Tamu hotel umumnya datang dengan ekspektasi bahwa kamar yang ditempati berada dalam kondisi bersih dan tertata rapi. Kerapihan kamar bukan sekadar standar pelayanan, melainkan indikator kualitas yang berpengaruh langsung terhadap tingkat kepuasan pelanggan. Ketika kamar hotel tidak memenuhi standar kerapihan, hal ini dapat menimbulkan keluhan dari tamu, menurunkan rating di platform ulasan daring, dan bahkan memengaruhi loyalitas pelanggan terhadap hotel tersebut. Oleh karena itu, manajemen hotel memiliki tanggung jawab besar untuk memastikan setiap kamar tetap dalam kondisi yang baik sebelum digunakan. Akan tetapi, mekanisme penilaian kerapihan kamar yang dilakukan secara manual oleh staf housekeeping memiliki berbagai keterbatasan, mulai dari keterpengaruhan subjektivitas penilai, keterbatasan waktu, hingga kebutuhan sumber daya manusia yang cukup besar. [2]

Dalam beberapa tahun terakhir, perkembangan teknologi kecerdasan buatan telah membuka peluang untuk menghadirkan solusi inovatif dalam berbagai bidang, termasuk dalam hal penilaian visual. Salah satu teknologi yang berkembang pesat adalah pembelajaran mesin, khususnya dalam ranah pengolahan citra digital [3]. Convolutional Neural Network (CNN) menjadi algoritma yang paling banyak digunakan dalam tugas-tugas klasifikasi gambar karena

kemampuannya dalam mengekstrak fitur secara otomatis dari data visual. CNN bekerja dengan memanfaatkan lapisan konvolusi untuk mengenali pola-pola penting dalam citra, sehingga mampu membedakan objek, tekstur, maupun kondisi tertentu dengan tingkat akurasi yang tinggi. Berbagai penelitian terdahulu telah membuktikan efektivitas CNN dalam berbagai aplikasi, seperti pengenalan wajah, klasifikasi objek, dan deteksi citra medis.[4]

Penelitian yang dilakukan oleh [5] menunjukkan bahwa CNN dapat digunakan untuk mengembangkan sistem klasifikasi kerapihan kamar hotel dengan hasil yang cukup memuaskan. Hal ini menjadi bukti bahwa CNN memiliki potensi besar untuk diterapkan dalam konteks penilaian kerapihan ruangan, sehingga proses yang selama ini bergantung pada pengamatan manusia dapat digantikan oleh sistem otomatis yang lebih efisien, objektif, dan konsisten. Dengan adanya pendekatan berbasis CNN, penilaian kerapihan kamar tidak lagi semata-mata mengandalkan subjektivitas staf hotel, melainkan berdasarkan analisis visual yang terstandarisasi.[3]

Implementasi teknologi CNN dalam klasifikasi kerapihan ruangan diharapkan mampu menghadirkan berbagai manfaat. Dari sisi efisiensi, sistem ini dapat mengurangi waktu yang dibutuhkan untuk melakukan penilaian karena analisis dilakukan secara otomatis melalui citra yang diambil dari kamera [6]. Dari sisi objektivitas, sistem mampu memberikan hasil klasifikasi yang konsisten tanpa dipengaruhi faktor manusia, seperti kelelahan, perbedaan persepsi, maupun kelalaian. Dari sisi kualitas layanan, penerapan sistem klasifikasi otomatis dapat meningkatkan pengalaman pelanggan karena hotel mampu menjaga standar kebersihan dan kerapihan secara lebih baik. Dengan demikian, CNN tidak hanya memberikan kontribusi dalam hal efisiensi operasional, tetapi juga dalam peningkatan citra dan reputasi hotel di mata pelanggan.[7]

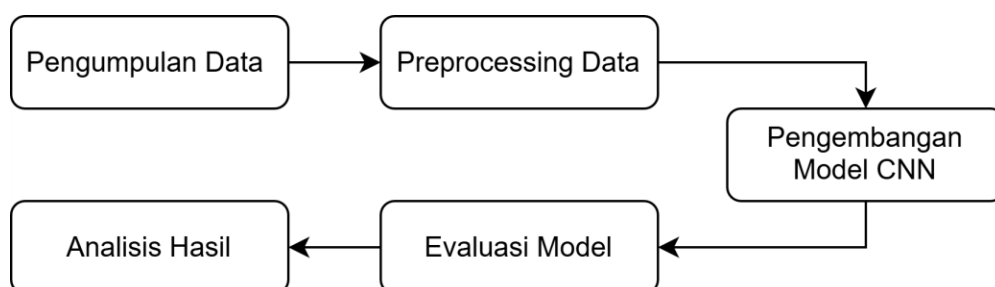
Lebih jauh, penelitian mengenai penerapan CNN untuk klasifikasi kerapihan ruangan juga memiliki relevansi yang lebih luas [8]. Teknologi ini tidak hanya dapat diterapkan pada sektor perhotelan, tetapi juga pada sektor lain yang memerlukan penilaian kondisi ruangan, seperti institusi pendidikan, fasilitas kesehatan, maupun rumah tangga pintar. Dalam konteks sekolah, sistem serupa dapat digunakan untuk memastikan kebersihan ruang kelas. Pada rumah sakit, penilaian otomatis dapat membantu menjaga standar kebersihan ruangan pasien [9]. Sedangkan dalam smart home, sistem ini dapat berfungsi sebagai asisten cerdas yang memberikan peringatan kepada penghuni rumah terkait kondisi ruangan yang tidak rapi. Dengan cakupan aplikasi yang luas, penelitian ini berpotensi memberikan kontribusi besar terhadap perkembangan teknologi pengolahan citra sekaligus memberikan manfaat praktis bagi masyarakat[10].

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengembangkan dan menguji algoritma CNN dalam klasifikasi kerapihan ruangan, khususnya dalam lingkungan perhotelan [11]. Tujuan utama dari penelitian ini adalah menghasilkan sistem yang mampu melakukan penilaian kerapihan secara otomatis dengan tingkat akurasi yang tinggi, sehingga dapat mendukung efisiensi operasional hotel dan meningkatkan kepuasan pelanggan [12]. Selain itu, penelitian ini diharapkan mampu memberikan kontribusi ilmiah dalam pengembangan metode klasifikasi citra serta memberikan gambaran penerapan teknologi kecerdasan buatan dalam penyelesaian masalah nyata yang dihadapi industri jasa [13].

Dengan memanfaatkan CNN sebagai pendekatan utama, penelitian ini diharapkan dapat menjadi langkah awal dalam penerapan teknologi pengolahan citra untuk meningkatkan kualitas layanan perhotelan [14]. Keberhasilan penelitian ini tidak hanya akan memberikan manfaat praktis bagi pihak manajemen hotel, tetapi juga dapat memperkaya khazanah keilmuan dalam bidang kecerdasan buatan. Pada akhirnya, penelitian ini diharapkan mampu menjadi referensi penting dalam upaya transformasi digital di sektor pelayanan publik maupun sektor industri lainnya yang berkaitan erat dengan kualitas lingkungan dan kepuasan pengguna [15].

2. METODOLOGI PENELITIAN

2.1 Alur Penelitian



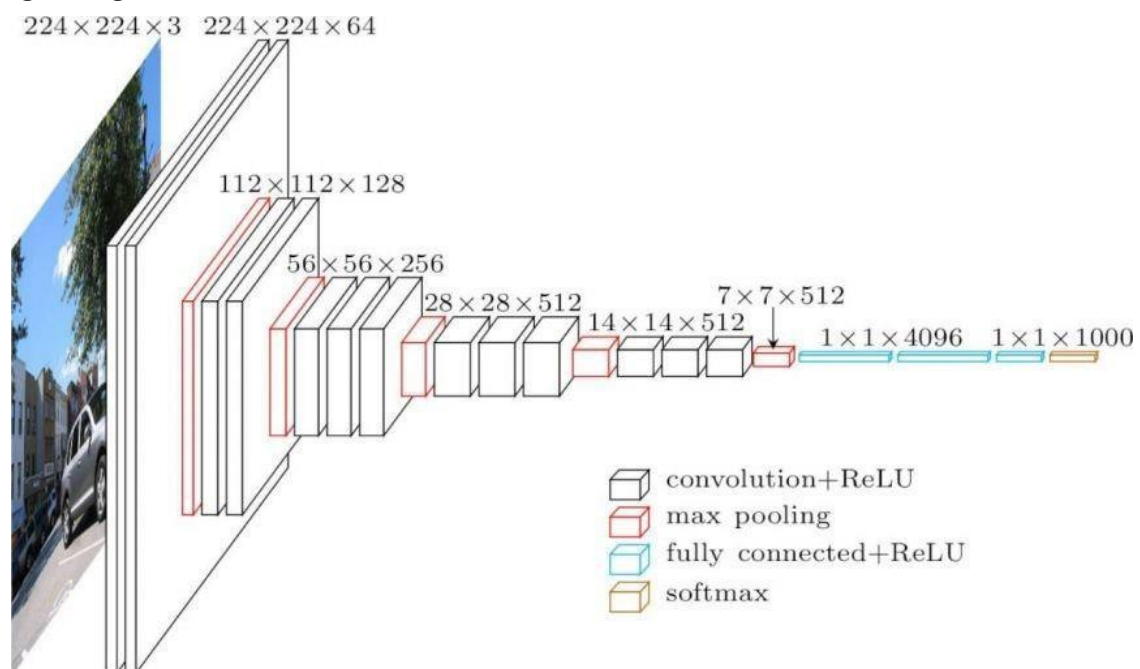
Gambar 1. Alur Penelitian

Penelitian ini dilakukan melalui enam tahap utama, yaitu pengumpulan data, preprocessing data, pengembangan model CNN, pelatihan model, evaluasi model, dan analisis hasil. Tahapan ini dirancang untuk memastikan bahwa model yang dikembangkan dapat mengklasifikasikan citra ruangan dengan akurasi yang memadai.

2.2 Pengumpulan Data

Penelitian ini menggunakan data sekunder yang diperoleh dari Kaggle. Dataset yang digunakan yaitu “Messy and Clean Room” (GuanqiaoDing, 2019). Pengumpulan data dilakukan dengan mengakses dataset yang berisi citra ruangan dalam dua kategori, yaitu messy dan clean. Dataset ini diperoleh dari Open Source website Kaggle serta dilengkapi dengan citra tambahan untuk memastikan distribusi data yang cukup merata pada kedua kategori. Setiap citra kemudian dikelompokkan ke dalam tiga direktori, yaitu direktori pelatihan (training) 192 gambar, validasi (validation) 20 gambar, dan pengujian (testing) 10 gambar. Data pelatihan mencakup 80% dari total dataset, sementara sisanya digunakan untuk validasi dan testing. Dataset ini merupakan data berbasis RGB dengan resolusi yang beragam, sehingga diperlukan langkah preprocessing untuk memastikan semua gambar memiliki ukuran yang seragam.

2.3 Pengembangan Model CNN



Gambar 2. Pengembangan model Softmax

Seperti yang terlihat pada Gambar 2, input untuk lapisan pertama (conv1) berupa citra RGB berukuran 224×224 piksel. Citra tersebut diproses melalui beberapa lapisan konvolusi (digambarkan sebagai blok hitam pada Gambar 2) yang menggunakan filter kecil berukuran 3×3 . Pada lapisan konvolusi pertama, terdapat 64 filter, dengan jumlah filter yang meningkat dua kali lipat di setiap blok hingga mencapai 512 filter dengan dimensi 7×7 di blok terakhir. Ukuran filter tetap 3×3 dengan stride 1 dan setiap lapisan convolutional menggunakan fungsi aktivasi ReLU. Di akhir setiap blok, terdapat lapisan max-pooling (digambarkan sebagai blok merah pada Gambar 2) dengan ukuran 2×2 dan stride sebesar 2. Setiap blok convolutional diakhiri dengan lapisan max-pooling berukuran 2×2 dan stride sebesar 2, yang berfungsi untuk mengurangi dimensi data sekaligus mempertahankan informasi penting. Setelah fitur diekstraksi oleh VGG16, hasilnya diproses melalui lapisan Global Average Pooling, yang meratakan fitur multidimensi menjadi vektor satu dimensi. Vektor ini kemudian diproses oleh lapisan fully connected yang terdiri dari 512 neuron dan menggunakan fungsi aktivasi ReLU. Pada lapisan output, terdapat 1 neuron dengan fungsi aktivasi sigmoid, yang digunakan untuk klasifikasi biner. Berbeda dengan softmax, yang umum digunakan untuk klasifikasi multi-kelas, sigmoid menghasilkan probabilitas biner secara langsung, di mana probabilitas mendekati 0 menunjukkan kelas clean, dan probabilitas mendekati 1 menunjukkan kelas messy.

2.4 Pelatihan Model

Model dilatih menggunakan data pelatihan dan validasi yang telah melalui tahap preprocessing. Proses pelatihan ini menggunakan optimizer Adam, yang merupakan algoritma optimasi berbasis gradien dengan kecepatan konvergensi yang tinggi. Adam dipilih karena kemampuannya dalam menyesuaikan learning rate secara adaptif selama pelatihan, sehingga menghasilkan pembaruan parameter yang lebih stabil. Fungsi loss yang digunakan adalah binary crossentropy, yang sangat sesuai untuk tugas klasifikasi biner. Fungsi ini mengukur perbedaan antara probabilitas prediksi model dan label

sebenarnya, sehingga membantu model mempelajari pola dengan lebih baik. Proses pelatihan dilakukan selama 10 epoch, dengan batch size 32. Batch size menentukan jumlah data yang diproses sebelum model memperbarui parameter, sementara epoch menentukan jumlah iterasi penuh melalui seluruh dataset.

2.5 Evaluasi Model

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	TP (True Positive)	FP (False Positive) <i>Type I Error</i>
	0 (Negative)	FN (False Negative) <i>Type II Error</i>	TN (True Negative)

Gambar 3. prediction values

Menurut T. Fawcett dalam makalahnya yang berjudul "An Introduction to ROC Analysis", kinerja model klasifikasi dapat dievaluasi menggunakan confusion matrix. Confusion matrix mencakup beberapa kategori hasil, seperti prediksi yang benar (True Positive/TP), prediksi salah yang sebenarnya benar (False Negative/FN), prediksi benar yang sebenarnya salah (False Positive/FP), serta prediksi salah (True Negative/TN). Contoh visualisasi hasil tersebut ditampilkan pada Gambar 4 (Fawcett, 2006). Evaluasi model dilakukan menggunakan data pengujian yang berbeda dari data pelatihan dan validasi. Metrik utama yang digunakan adalah akurasi, yang mengukur persentase prediksi yang benar terhadap total prediksi. Selain itu, confusion matrix digunakan untuk memberikan analisis yang lebih mendalam mengenai performa model, termasuk prediksi yang benar maupun salah pada setiap kategori. Confusion matrix terdiri dari empat elemen utama: True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). TP dan TN menunjukkan prediksi yang benar untuk kategori messy dan clean, sedangkan FP dan FN menggambarkan kesalahan prediksi. Melalui analisis confusion matrix, pola kesalahan model dapat diidentifikasi, seperti citra yang sulit diklasifikasikan akibat elemen visual yang ambigu. Berikut adalah beberapa rumus yang telah dijelaskan oleh (Fawcett, 2006) dalam menghitung performa klasifikasi menggunakan confusion matrix;

$$\text{Nilai True Positive (TP)} = \frac{TP}{\sum \text{semua kasus positif}} \quad (1)$$

$$\text{Nilai True Negative (TN)} = \frac{TN}{\sum \text{semua kasus negatif}} \quad (2)$$

$$\text{Nilai Presisi} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{Nilai Akurasi} = \frac{TP + TN}{P + N} \quad (4)$$

$$\text{Nilai Recall} = \frac{TP}{P} \quad (5)$$

$$\text{Nilai F - measure} = \frac{2}{\frac{1}{\text{precision}} + \frac{1}{\text{recall}}} \quad (6)$$

3. HASIL DAN PEMBAHASAN

Proses normalisasi citra merupakan tahap awal yang penting dalam sistem klasifikasi berbasis citra. Normalisasi bertujuan untuk memastikan bahwa semua citra memiliki dimensi dan skala intensitas piksel yang seragam, sehingga model dapat lebih mudah mengenali pola tanpa terpengaruh oleh perbedaan ukuran atau kualitas gambar. Pada penelitian ini, data citra dinormalisasi menjadi ukuran 224x224 piksel menggunakan metode rescaling yang membagi nilai piksel dengan 255 untuk mengubah skala piksel menjadi rentang [0,1]. Setelah normalisasi dilakukan, data citra dibagi ke dalam tiga kelompok utama, yaitu data latih (training), data validasi (validation), dan data uji (testing). Data latih digunakan untuk melatih model, data validasi untuk mengukur kinerja model selama pelatihan, dan data uji untuk mengevaluasi performa akhir model. Tabel 1 menunjukkan distribusi data citra yang digunakan dalam penelitian ini.

Tabel 1. Distribusi Data

Data	Jumlah Images	Persentase	Jumlah Kelas
Training	192	86.49%	2 Kelas
Validation	20	9.01%	2 Kelas
Testing	10	4.50%	1 Kelas

Tabel 1 menunjukkan distribusi data citra yang digunakan dalam proses pelatihan, validasi, dan pengujian model. Sebanyak 222 gambar dibagi menjadi tiga bagian, yaitu 192 gambar (86.49%) untuk pelatihan, 20 gambar (9.01%) untuk validasi, dan 10 gambar (4.50%) untuk pengujian. Setiap subset data terdiri dari 2 kelas kecuali data testing, sesuai dengan kebutuhan klasifikasi biner. Proporsi ini dirancang untuk memastikan model memiliki cukup data untuk belajar (training), Mengevaluasi performa selama pelatihan (validation), dan mengukur kemampuan generalisasi model (testing). Setelah data citra selesai didistribusikan ke dalam tiga set utama yaitu data latih, validasi, dan uji, langkah selanjutnya adalah membangun model klasifikasi menggunakan pendekatan berbasis deep learning. Model ini dirancang dengan memanfaatkan arsitektur pre-trained untuk meningkatkan efisiensi proses pelatihan serta akurasi prediksi. Pada penelitian ini, arsitektur VGG16 dipilih sebagai feature extractor karena memiliki kemampuan yang telah teruji dalam mengekstraksi fitur visual dari data citra. Setelah fitur berhasil diekstraksi, proses klasifikasi dilakukan melalui beberapa layer tambahan yang disesuaikan dengan kebutuhan klasifikasi biner. Berikut ini adalah struktur model yang digunakan beserta jumlah parameter dan proses pengolahan fitur pada setiap layer yang disajikan pada output model. Sebelum menyajikan hasil pelatihan model, perlu diingat bahwa model yang digunakan dalam eksperimen ini merupakan model VGG16 yang telah dilatih dengan data citra yang telah melalui proses normalisasi dan augmentasi. Proses pelatihan dilakukan menggunakan data latih yang terbagi menjadi tiga set: data latih, data validasi, dan data uji. Model ini dikonfigurasi untuk melakukan klasifikasi dengan dua kelas dan dioptimalkan menggunakan fungsi kerugian binary_crossentropy serta metrik accuracy. Selama proses pelatihan, model diuji untuk memastikan bahwa model tidak hanya belajar dari data latih tetapi juga dapat menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya, yaitu data validasi. Untuk memberikan gambaran lebih jelas mengenai performa model selama proses pelatihan, Tabel 2 berikut menyajikan metrik-metrik utama yang mencakup waktu pelatihan, akurasi, dan loss baik pada data latih maupun data validasi di setiap epoch.

```
model.summary()
```

Model: "sequential_14"

Layer (type)	Output Shape	Param #
vgg16 (Functional)	(None, 7, 7, 512)	14,714,688
global_average_pooling2d_7 (GlobalAveragePooling2D)	(None, 512)	0
dense_30 (Dense)	(None, 256)	131,328
dense_31 (Dense)	(None, 1)	257

Total params: 14,846,273 (56.63 MB)
Trainable params: 131,585 (514.00 KB)
Non-trainable params: 14,714,688 (56.13 MB)

Gambar 4. Summary Model

Tabel 2. Validasi Epoch hasil


Epoch	Training Time	Accuracy	Loss	Val_Accuracy	Val_Loss
1	118s	0.9648	0.1261	1.0000	0.0187
2	140s	0.9570	0.0945	1.0000	0.0556
3	144s	0.9683	0.1032	1.0000	0.0329
4	140s	0.9286	0.0949	1.0000	0.0131
5	145s	0.9731	0.0778	1.0000	0.0559
6	114s	0.9430	0.1324	1.0000	0.0222
7	116s	0.9252	0.1671	1.0000	0.0115
8	141s	0.9634	0.0899	1.0000	0.0076
9	114s	0.9797	0.0478	1.0000	0.0203
10	127s	0.9348	0.1485	1.0000	0.0065

Setelah proses pelatihan model selesai, performa model dievaluasi berdasarkan hasil yang ditunjukkan dalam Tabel 2. Tabel tersebut merangkum metrik utama seperti waktu pelatihan (training time), akurasi, dan loss untuk data latih serta akurasi dan loss untuk data validasi di setiap epoch. Dari Tabel 2, terlihat bahwa model menunjukkan performa yang konsisten dengan akurasi validasi mencapai 100% sejak epoch pertama. Hal ini menunjukkan bahwa model berhasil mempelajari pola-pola dari data latih dan mampu menggeneralisasi dengan baik pada data validasi. Selain itu, nilai loss yang semakin rendah di setiap epoch menegaskan keberhasilan model dalam meminimalkan kesalahan prediksi baik pada data latih maupun validasi. Analisis lebih lanjut terhadap hasil pelatihan ini dijelaskan pada bagian berikut, untuk memastikan bahwa performa model tidak hanya baik pada data validasi, tetapi juga mampu memberikan hasil yang akurat pada data uji. Grafik di bawah ini menunjukkan hubungan antara akurasi dan loss pada data latih serta data validasi selama 10 epoch pelatihan. Dari grafik ini, dapat dilihat bahwa akurasi model pada data latih (training accuracy) mengalami fluktuasi yang signifikan pada beberapa epoch, namun secara keseluruhan ada kecenderungan meningkat. Pada epoch pertama, akurasi model di data latih mencapai sekitar 96,48%, yang kemudian sedikit menurun pada epoch kedua, namun kembali meningkat di epoch ketiga hingga mencapai nilai tertinggi pada epoch kesembilan dengan akurasi sebesar 97,97%.



Gambar 5. Training and Validation Loss

Sementara itu, grafik loss pada data latih menunjukkan penurunan secara bertahap, yang menandakan bahwa model semakin baik dalam memprediksi kelas target. Loss pada epoch pertama tercatat 0,1261 dan menurun ke angka 0,0478 pada epoch kesembilan, yang menunjukkan peningkatan performa model.



Gambar 6. Training and Validation Accuracy

Pada sisi lain, akurasi pada data validasi (validation accuracy) tetap stabil pada nilai 1,0000 di semua epoch, yang menunjukkan bahwa model sangat baik dalam memprediksi data yang belum dilihat selama pelatihan. Hal ini bisa menjadi indikasi bahwa model mungkin mengalami overfitting, karena perbedaan antara akurasi pada data latih dan data validasi sangat kecil. Grafik loss pada data validasi (validation loss) cenderung lebih stabil, dengan nilai loss terendah tercatat pada epoch kesepuluh, yang menunjukkan bahwa meskipun model terlihat mengalami peningkatan dalam hal akurasi pada data latih, kemampuan generalisasi terhadap data validasi tetap terjaga. Dengan demikian, grafik ini memberikan gambaran yang jelas mengenai dinamika akurasi dan loss selama pelatihan model, serta menunjukkan adanya pembelajaran yang baik meskipun terjadi fluktuasi kecil pada beberapa epoch.

4. KESIMPULAN

Berdasarkan hasil eksperimen yang telah dilakukan, model klasifikasi citra menggunakan VGG16 dengan fine-tuning menunjukkan performa yang cukup baik dalam memprediksi dua kelas citra. Proses pelatihan model menggunakan data latih yang terdiri dari 192 gambar, data validasi sebanyak 20 gambar, dan data uji sebanyak 10 gambar menghasilkan akurasi yang cukup stabil, meskipun terdapat fluktuasi kecil pada beberapa epoch. Dari grafik yang dihasilkan, dapat dilihat bahwa akurasi pada data latih cenderung meningkat secara signifikan seiring dengan bertambahnya jumlah epoch, dengan nilai tertinggi tercatat pada epoch kesembilan. Sementara itu, loss pada data latih menunjukkan penurunan yang konsisten, yang menandakan bahwa model semakin baik dalam mempelajari pola-pola dalam data citra. Pada data validasi, akurasi model tetap stabil dan mencapai nilai tertinggi, sementara loss tetap rendah. Meskipun demikian, adanya perbedaan kecil antara akurasi dan loss pada data latih dan validasi mengindikasikan bahwa model masih membutuhkan penyesuaian lebih lanjut untuk menghindari potensi overfitting. Dengan demikian, meskipun hasil yang diperoleh cukup memadai, masih ada ruang untuk perbaikan, seperti peningkatan jumlah data latih, penyempurnaan arsitektur model, atau penggunaan teknik regulasi untuk meningkatkan kemampuan generalisasi model. Secara keseluruhan, model ini dapat digunakan untuk tugas klasifikasi citra dengan performa yang dapat ditingkatkan lebih lanjut melalui pengujian lebih lanjut.

REFERENCES

- [1] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognit. Lett.*, vol. 27, no. 8, pp. 861–874, 2006, doi: 10.1016/j.patrec.2005.10.010.
- [2] A. Putri *et al.*, "Komparasi Algoritma K-NN, Naive Bayes dan SVM untuk Prediksi Kelulusan Mahasiswa Tingkat Akhir," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 1, pp. 20–26, 2023, doi: 10.57152/malcom.v3i1.610.
- [3] M. F. Naufal, J. Siswanto, and M. G. K. Wicaksono, "Klasifikasi Tulisan Tangan Pada Resep Obat Menggunakan Convolutional Neural Network," *Techno.Com*, vol. 22, no. 2, pp. 508–526, 2023, doi: 10.33633/tc.v22i2.8075.
- [4] N. Atika, "Evaluation of Service Quality Through ITIL V3 Framework in the Service Design Domain (Case Study: Lazada Application)," *IJIS Int. J. Informatics Inf. Syst.*, vol. 7, no. 1, pp. 29–34, 2024, doi: 10.47738/ijis.v7i1.188.
- [5] L. Vinet and A. Zhedanov, "A 'missing' family of classical orthogonal polynomials," *J. Phys. A Math. Theor.*, vol. 44, no. 8, pp. 1–14, 2011, doi: 10.1088/1751-8113/44/8/085201.
- [6] Hutasuhut, "Implementation of Office Inventory Application for Asset Efficiency," vol. 4, pp. 1–12, 2024.
- [7] N. R. Setyoningrum, "Analisis Tingkat Kepuasan Pengguna Sistem Informasi Kerja Praktek dan Skripsi (SKKP) Menggunakan Metode End User Computing Satisfaction (EUCS)," *J. Appl. Informatics Comput.*, vol. 4, no. 1, pp. 17–21, 2020, doi: 10.30871/jaic.v4i1.1645.
- [8] S. Hastini *et al.*, "Analisis IT Service Management pada Transportasi Online Menggunakan ITIL Versi 3 Domain Service Operation," vol. 6, no. 1, pp. 32–37, 2025.
- [9] A. Rahman, E. Satispi, and D. L. Adiyasha, "Perbandingan E-Government Antara Singapura Dan Jepang: Perspektif Determinan Dan Perannya Dalam Mengefektifkan Pemerintahan Dan Mengendalikan Korupsi," *J. Adm. Publik*, vol. 6, no. 2, pp. 178–199, 2020.
- [10] A. Mulyanto, "Penerapan Technology Acceptance Model (TAM) dalam Pengujian Model Penerimaan Aplikasi MasjidLink," vol. 23, no. 1, pp. 27–38, 2020, doi: 10.18196/st.231253.
- [11] C. Bertagnolli, "Delle vicende dell'agricoltura in Italia; studio e note di C. Bertagnolli.," *Delle vicende dell'agricoltura Ital. Stud. e note di C. Bertagnolli.*, vol. 13, no. 3, pp. 319–340, 2011, doi: 10.5962/bhl.title.33621.
- [12] Rina Noviana, "Pembuatan Aplikasi Penjualan Berbasis Web Monja Store Menggunakan Php Dan Mysql," *J. Tek. dan Sci.*, vol. 1, no. 2, pp. 112–124, 2022, doi: 10.56127/jts.v1i2.128.
- [13] I. N. Pujawan and A. U. Bah, "Supply chains under COVID-19 disruptions: literature review and research agenda," *Supply Chain Forum*, vol. 23, no. 1, pp. 81–95, 2022, doi: 10.1080/16258312.2021.1932568.
- [14] B. Ayan Ahamad, S. Vikas S., and G. Madhusudan Ramdas, "AI Based Smart Robot (Chatbot) using Python," *Int. J. Innov. Sci. Res. Technol.*, vol. 9, no. 3, pp. 569–572, 2024, doi: 10.38124/ijisrt/ijisrt24mar521.
- [15] R. Sabila, A. Pratama, and E. M. Safitri, "Evaluation Virtual Assistant Chatbot Acceptance with an Unified Technology Acceptance and Use of Technology-Based Model," *J. Inf. Syst. Informatics*, vol. 6, no. 2, pp. 919–936, 2024, doi: 10.51519/journalisi.v6i2.744.