

Analisis Komparasi Otsu dan Adaptive Thresholding Pada Pengenalan Wajah Berbasis VGG16

^{1*}Febriyanti Nur Fadillah, ²Made Ayu Dusea Widya Dara, ³Daniel Swanjaya

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹febriyantinf505@gmail.com, ²madedara@gmail.com, ³daniel@unpkediri.ac.id

Penulis Korespondensi : Febriyanti Nur Fadillah

Abstrak— Pengenalan wajah merupakan teknologi biometrik yang banyak digunakan dalam sistem keamanan dan identifikasi digital. Penelitian ini bertujuan menganalisis pengaruh metode segmentasi citra terhadap kinerja sistem pengenalan wajah menggunakan *Convolutional Neural Network* (CNN) berbasis VGG16. Dataset yang digunakan terdiri dari 210 citra wajah yang ditingkatkan melalui augmentasi kecerahan menjadi 630 citra. Tahapan penelitian meliputi deteksi wajah menggunakan *Haar Cascade*, konversi *grayscale*, segmentasi menggunakan *Otsu Thresholding* dan *Adaptive Thresholding*, pelatihan model, serta evaluasi performa. Model dilatih menggunakan optimizer Adam selama 10 *epoch*. Evaluasi dilakukan menggunakan *accuracy*, *confusion matrix*, dan *classification report*. Hasil penelitian menunjukkan bahwa metode *Otsu Thresholding* memperoleh akurasi 90,32%, sedangkan *Adaptive Thresholding* mencapai 98,71% dengan performa yang lebih stabil. Sistem berhasil diimplementasikan pada aplikasi berbasis web menggunakan *Streamlit* untuk mendukung proses pengenalan wajah secara otomatis dan interaktif.

Kata Kunci—Pengenalan wajah, *Convolutional Neural Network*, *Adaptive Thresholding*

Abstract— *Face recognition is a biometric technology widely used in security and digital identification systems. This study aims to analyze the effect of image segmentation methods on the performance of a face recognition system using a Convolutional Neural Network (CNN) based on the VGG16 architecture. The dataset consisted of 210 facial images, which were increased to 630 images through brightness augmentation. The research stages included face detection using Haar Cascade, grayscale conversion, image segmentation using Otsu Thresholding and Adaptive Thresholding, model training, and performance evaluation. The model was trained using the Adam optimizer for 10 epochs. Evaluation was conducted using accuracy, confusion matrix, and classification report. The results showed that Otsu Thresholding achieved an accuracy of 90.32%, while Adaptive Thresholding achieved a higher accuracy of 98.71% with more stable performance. The developed system was successfully implemented in a Streamlit-based web application for automatic and interactive face recognition.*

Keywords— *Face Recognition, Convolutional Neural Network, Adaptive Thresholding*

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Perkembangan teknologi biometrik dalam beberapa tahun terakhir menunjukkan peningkatan yang signifikan, khususnya pada sistem pengenalan wajah yang banyak digunakan dalam berbagai bidang seperti keamanan, absensi, dan verifikasi identitas digital. Pengenalan wajah menjadi salah satu metode identifikasi yang efektif karena memanfaatkan karakteristik fisiologis yang unik, stabil, dan sulit untuk dipalsukan [1]. Sistem pengenalan wajah yang dikombinasikan dengan metode deteksi seperti *Haar Cascade* dan CNN telah terbukti mampu mengotomatiskan proses kehadiran mahasiswa secara *real-time* dengan akurasi validasi mencapai 99% [2]. Namun demikian, implementasi sistem pengenalan wajah masih menghadapi sejumlah tantangan, seperti

variasi pencahayaan, sudut pandang wajah, serta kualitas citra yang dapat mempengaruhi performa sistem dalam melakukan identifikasi secara akurat.

Secara umum, proses pengenalan wajah melibatkan beberapa tahapan penting, yaitu deteksi wajah, segmentasi, ekstraksi fitur, dan klasifikasi. Segmentasi citra berperan memisahkan objek utama dari latar belakang; penerapan metode seperti *Canny Edge Detection* dan *Otsu Thresholding* terbukti efektif meningkatkan ketajaman tepi dan kejernihan objek dalam citra [3]. Berbagai arsitektur *deep learning* seperti CNN, *Vision Transformer*, dan model berbasis *transfer learning* telah dieksplorasi untuk meningkatkan kualitas klasifikasi citra dalam berbagai domain [4].

Sejumlah penelitian terdahulu menunjukkan efektivitas penerapan CNN dalam berbagai domain klasifikasi citra. Arsitektur VGG16 terbukti memberikan performa yang lebih baik dibandingkan *ResNet50* dengan akurasi mencapai 93% pada tugas klasifikasi citra penyakit [5]. Selanjutnya, optimasi CNN berbasis VGG16 menggunakan metode *Grid Search* dan memperoleh akurasi sangat tinggi sebesar 99,59%, yang menunjukkan pentingnya pemilihan *hyperparameter* dalam meningkatkan kinerja model [6]. Pengembangan lebih lanjut menggunakan arsitektur *Vision Transformer* juga telah diterapkan pada identifikasi tanaman herbal Indonesia berbasis citra visual, membuktikan bahwa model berbasis perhatian mampu menangkap fitur visual secara lebih komprehensif [4].

Pada bidang segmentasi citra, penerapan algoritma *deep learning* YOLOv8 pada platform *Roboflow* untuk segmentasi citra panoramik gigi menghasilkan nilai *mean average precision* (mAP) sebesar 95%, menunjukkan potensi metode segmentasi berbasis *deep learning* dalam analisis citra medis secara otomatis [7]. Kajian komparatif berbagai arsitektur *deep learning* untuk aplikasi *computer vision* menunjukkan bahwa setiap arsitektur memiliki karakteristik dan keunggulan tersendiri tergantung pada kebutuhan dan kompleksitas tugas yang dihadapi [8]. Hal ini menunjukkan bahwa keberhasilan klasifikasi berbasis citra, baik menggunakan algoritma pembelajaran mesin konvensional seperti *K-Nearest Neighbors* maupun *deep learning* seperti CNN, sangat bergantung pada kualitas ekstraksi fitur dan tahap praproses citra sebelum data dimasukkan ke dalam model klasifikasi [9].

Penerapan metode *Otsu Thresholding* pada pendeteksian judul buku dengan koefisien korelasi menunjukkan bahwa metode ini efektif dalam proses binarisasi dan segmentasi citra teks [10]. Sementara itu, penerapan segmentasi dengan metode *Adaptive Thresholding* pada citra wajah terbukti efektif dalam memisahkan area wajah dari latar belakang meskipun terdapat variasi pencahayaan [11]. Berdasarkan kajian tersebut, metode segmentasi tradisional seperti *Otsu Thresholding* dan *Adaptive Thresholding* masih dapat digunakan karena memiliki proses yang lebih sederhana serta mampu meningkatkan kualitas *preprocessing* citra sebelum proses klasifikasi menggunakan CNN berbasis VGG16 [3].

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan pengembangan sistem pengenalan wajah berbasis citra digital dengan mengintegrasikan metode segmentasi citra menggunakan *Otsu* dan *Adaptive Thresholding* serta klasifikasi menggunakan *Convolutional Neural Network* dengan arsitektur VGG16. Pendekatan ini diharapkan mampu meningkatkan kualitas citra masukan serta akurasi dalam proses identifikasi wajah. Dengan demikian, sistem yang dikembangkan tidak hanya mampu bekerja secara otomatis, tetapi juga memiliki tingkat ketelitian yang tinggi dan dapat diterapkan pada berbagai kebutuhan identifikasi berbasis biometrik secara lebih efisien dan akurat.

II. METODE

Penelitian ini menggunakan pendekatan eksperimen yang bertujuan untuk menganalisis pengaruh metode *Otsu Thresholding* dan *Adaptive Thresholding* dalam proses segmentasi citra terhadap kinerja sistem pengenalan wajah berbasis *Convolutional Neural Network* (CNN). Pendekatan ini dilakukan melalui perbandingan dua skenario segmentasi guna mengidentifikasi metode yang paling optimal dalam meningkatkan akurasi klasifikasi. Untuk mencapai tujuan tersebut, penelitian ini disusun dalam beberapa tahapan yang saling terintegrasi dan akan dijelaskan pada bagian berikutnya.

A. Persiapan Data

Data yang digunakan dalam penelitian ini berupa citra wajah mahasiswa. Dataset terdiri dari 5 subjek, masing-masing menyediakan 42 citra wajah dengan variasi pencahayaan dan sudut pengambilan, meliputi posisi frontal (0°), 15°, 30°, 45°, serta arah pandang ke atas dan ke bawah. Seluruh citra memiliki resolusi rata-rata sekitar 300×400 piksel [11]. Seluruh citra diperoleh secara mandiri menggunakan kamera *smartphone* Redmi Note 9 Pro dan disimpan dengan file jpg. Rincian pembagian dataset ditampilkan pada Tabel 1.

Tabel 1. Jumlah dan Total Dataset Asli

Kelas / Identitas	Jumlah Data	Data Latih	Data Uji
Dela	42	30	12
Febri	42	30	12
Sephia	42	30	12
Dymas	42	30	12
Yusril	42	30	12
Total	210	150	60

Tabel 2. Gambar Dataset Asli

No	Kelas	Citra					
		0	15	30	45	Keatas	Kebawah
1	Dela						
2	Febri						
3	Sephia						
4	Dymas						
5	Yusril						

Selanjutnya, dilakukan augmentasi data dengan mengatur variasi tingkat kecerahan (*brightness*), yaitu dengan menambah dan mengurangi nilai intensitas sebesar 20 dari citra asli. Teknik ini bertujuan untuk meningkatkan variasi dataset serta mengurangi risiko *overfitting*, sehingga model menjadi lebih adaptif terhadap perubahan kondisi pencahayaan. Maka, jumlah keseluruhan dataset menjadi 630 citra.

B. Preprocessing Data

Pada tahap ini dilakukan serangkaian proses untuk mempersiapkan citra sebelum digunakan dalam pelatihan model. Tahap awal meliputi deteksi area wajah menggunakan metode *Haar Cascade* untuk mengekstraksi bagian wajah sebagai objek utama [2]. Selanjutnya, citra dikonversi ke dalam format *grayscale* guna menyederhanakan informasi warna dan menekankan intensitas piksel.

Untuk memastikan keseragaman data, setiap citra diubah ukurannya menjadi 224×224 piksel sesuai dengan kebutuhan input model CNN [4]. Proses ini penting untuk menjaga konsistensi dimensi data selama pelatihan model. Tahapan *preprocessing* berperan dalam meningkatkan kualitas citra sehingga fitur yang dihasilkan lebih representatif [3]. Setelah seluruh proses *preprocessing*, dataset dibagi menjadi data latih dan data uji dengan perbandingan 70% : 30%. Data latih digunakan untuk proses pembelajaran model, sedangkan data uji dimanfaatkan untuk mengevaluasi kinerja model terhadap data baru sehingga hasil pengujian lebih objektif dan representatif [12].

C. Segmentasi Citra

Segmentasi citra merupakan tahap untuk memisahkan objek wajah dari latar belakang sehingga informasi yang diolah lebih fokus pada area yang relevan. Proses ini penting dalam meningkatkan kualitas citra sebelum dilakukan klasifikasi, karena mampu mengurangi pengaruh noise dan variasi latar belakang [10]. Penelitian ini menggunakan dua metode segmentasi, yaitu *Otsu Thresholding* dan *Adaptive Thresholding*. Metode *Otsu* bekerja menentukan nilai ambang (*threshold*) secara otomatis berdasarkan distribusi histogram citra *grayscale* [10]. Metode *Adaptive Thresholding* digunakan untuk menentukan nilai ambang secara lokal pada setiap wilayah citra, sehingga lebih efektif dalam menangani variasi pencahayaan [11]. Hasil dari kedua metode segmentasi ini kemudian digunakan sebagai *input* pada tahap klasifikasi untuk dibandingkan kinerjanya dalam meningkatkan akurasi model.

D. Klasifikasi CNN VGG16

Tahap selanjutnya adalah proses klasifikasi menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur VGG16. CNN merupakan salah satu metode *deep learning* yang banyak digunakan dalam pengolahan citra karena kemampuannya dalam mengekstraksi fitur secara otomatis dan mendalam [12]. Model ini mampu mengenali pola visual seperti bentuk, tekstur, dan intensitas melalui lapisan konvolusi bertingkat. Secara umum, arsitektur CNN terdiri dari *convolution layer* untuk ekstraksi fitur, *pooling layer* untuk reduksi dimensi, serta *fully connected layer* untuk proses klasifikasi [8].

Pada penelitian ini digunakan arsitektur VGG16 dengan pendekatan *transfer learning*, yaitu memanfaatkan bobot awal (*pre-trained weights*) dari model yang telah dilatih sebelumnya, kemudian menyesuaikan lapisan akhir sesuai jumlah kelas yang digunakan, yaitu lima kelas wajah. Pendekatan ini bertujuan untuk mempercepat proses pelatihan serta meningkatkan

performa model. Arsitektur VGG16 dipilih karena mampu menghasilkan ekstraksi fitur wajah yang stabil dan akurat, serta sesuai digunakan pada dataset berukuran terbatas [5]. Dibandingkan dengan *MobileNet* yang lebih berorientasi pada efisiensi komputasi [8], VGG16 memiliki kemampuan ekstraksi fitur yang lebih mendalam. Sementara itu, *Vision Transformer* (ViT) umumnya memerlukan jumlah data pelatihan dan sumber daya komputasi yang lebih besar agar dapat menghasilkan performa optimal [4]

Parameter pelatihan yang digunakan meliputi *epoch* 10, *optimizer* Adam, dan *learning rate* 0,0001, serta *validation split* 0,2. Penggunaan parameter tersebut mengacu pada penelitian sebelumnya yang menunjukkan bahwa kombinasi ini mampu memberikan performa yang baik dalam klasifikasi citra [6]. Model kemudian dilatih menggunakan data latih dan divalidasi menggunakan data uji untuk mengevaluasi kemampuan generalisasi terhadap data baru.

E. Proses Pelatihan

Pada tahap ini, proses modeling dilakukan menggunakan *Google Colab* sebagai lingkungan komputasi berbasis *cloud* dengan dukungan *Graphics Processing Unit* (GPU) versi GPU NVIDIA Tesla T4 untuk mempercepat pelatihan model [3]. GPU yang digunakan memiliki *driver* versi 580.82.07 dan CUDA versi 13.0 dengan kapasitas memori sebesar 15360 MiB, di mana sebagian memori digunakan untuk menjalankan proses pelatihan model berbasis *Python*. Model dikembangkan menggunakan arsitektur *Convolutional Neural Network* (CNN) berbasis VGG16 dengan data yang telah melalui tahap *preprocessing*. Implementasi model memanfaatkan *TensorFlow* versi 2.20.0 dan *Keras* versi 3.13.2 sebagai *framework* utama dalam proses pelatihan dan klasifikasi citra. Proses pelatihan dilakukan selama 10 *epoch* dengan pembagian data latih dan validasi untuk mengevaluasi performa model. Selanjutnya, model yang telah dilatih diintegrasikan ke dalam aplikasi berbasis *Streamlit* yang dikembangkan menggunakan *Visual Studio Code* untuk menampilkan hasil klasifikasi dan analisis secara interaktif.

F. Evaluasi Model


Evaluasi model dilakukan untuk menilai kinerja klasifikasi citra wajah yang telah dibangun menggunakan arsitektur CNN berbasis VGG16. Pengukuran performa menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* [1] di mana *accuracy* menunjukkan tingkat ketepatan prediksi model terhadap seluruh data, *precision* mengukur ketepatan prediksi pada kelas tertentu, *recall* menunjukkan kemampuan model dalam mengenali seluruh data yang relevan, dan *F1-score* merepresentasikan keseimbangan antara *precision* dan *recall*. Selain itu, evaluasi juga dilakukan menggunakan *confusion matrix* untuk menganalisis hasil klasifikasi pada masing-masing kelas, sehingga dapat diketahui distribusi prediksi benar dan kesalahan model secara lebih rinci.

III. HASIL DAN PEMBAHASAN

Pada penelitian ini, proses klasifikasi citra wajah dilakukan menggunakan arsitektur *Convolutional Neural Network* (CNN) berbasis VGG16 dengan pendekatan *transfer learning*. Dataset terdiri dari lima kelas, yaitu Dela, Dymas, Yusril, Sephia, dan Febri, dengan total 210 citra asli yang dibagi ke dalam data latih dan data uji. Untuk meningkatkan variasi data latih, diterapkan augmentasi berupa penyesuaian tingkat kecerahan (*brightness augmentation*) sebesar 20, sehingga jumlah keseluruhan dataset meningkat menjadi 630 citra.


Tahapan *preprocessing* yang diimplementasikan meliputi deteksi wajah menggunakan *Haar Cascade*, konversi citra ke *grayscale*, serta segmentasi menggunakan metode *Otsu Thresholding* dan *Adaptive Thresholding* sesuai skenario pengujian. Citra hasil segmentasi kemudian dikonversi ke format tiga kanal (RGB) dan dinormalisasi ke rentang [0,1] agar sesuai dengan spesifikasi input model.

Proses pelatihan dilakukan selama 10 *epoch* dengan *validation split* sebesar 20%. Pada tahap *transfer learning*, lapisan dasar VGG16 dibekukan (*freeze*) untuk mempertahankan bobot awal, sedangkan lapisan klasifikasi tambahan digunakan untuk menyesuaikan jumlah kelas pada dataset penelitian.



Gambar 1. a. Hasil Pelatihan Otsu, b. Hasil Pelatihan Adaptive

Berdasarkan hasil pelatihan model pada Gambar 1, grafik akurasi menunjukkan bahwa metode *Otsu Thresholding* dan *Adaptive Thresholding* mengalami peningkatan akurasi pada beberapa *epoch* awal pelatihan. Pada metode *Otsu Thresholding*, *training accuracy* meningkat hingga mendekati 100%, sedangkan *validation accuracy* berada pada kisaran 78%–82% dan cenderung stabil hingga akhir pelatihan. Sementara itu, metode *Adaptive Thresholding* menunjukkan performa yang lebih baik dengan *training accuracy* mendekati 100% dan *validation accuracy* mencapai sekitar 90% secara stabil pada *epoch* berikutnya. Hasil tersebut menunjukkan bahwa metode *Adaptive Thresholding* mampu menghasilkan kualitas segmentasi citra yang lebih baik sehingga proses klasifikasi wajah menggunakan CNN berbasis VGG16 menjadi lebih optimal.



Gambar 2. a. Confusion Matrix Otsu, b. Confusion Matrix Adaptive

=== OTSU ===					=== ADAPTIVE ===				
	precision	recall	f1-score	support		precision	recall	f1-score	support
Dela	1.00	0.85	0.92	20	Dela	1.00	0.90	0.95	20
Dymas	0.71	1.00	0.83	36	Dymas	0.97	1.00	0.99	36
Febri	1.00	1.00	1.00	27	Febri	0.96	1.00	0.98	27
Sephia	1.00	1.00	1.00	36	Sephia	1.00	1.00	1.00	36
Yusril	1.00	0.67	0.80	36	Yusril	1.00	1.00	1.00	36
accuracy			0.90	155	accuracy			0.99	155
macro avg	0.94	0.90	0.91	155	macro avg	0.99	0.98	0.98	155
weighted avg	0.93	0.90	0.90	155	weighted avg	0.99	0.99	0.99	155


a. b.

Gambar 3. a. Hasil *Otsu*, b. Hasil *Adaptive*

Perbedaan performa tersebut juga terlihat pada hasil evaluasi *confusion matrix* dan *classification report* yang ditunjukkan pada Gambar 2 dan Gambar 3. Pada metode *Otsu Thresholding*, sebagian besar kelas seperti Dymas, Febri, dan Sephia berhasil diklasifikasikan dengan baik (*recall* tinggi), meskipun masih terdapat kesalahan pada kelas Dela dan Yusril yang diduga dipengaruhi oleh kemiripan karakteristik citra akibat variasi pencahayaan dan sudut pengambilan wajah sekitar 30°–45°. Berdasarkan *confusion matrix*, sebanyak 3 data Dela terprediksi sebagai Dymas dan 12 data Yusril juga terprediksi sebagai Dymas. Kondisi tersebut menyebabkan nilai *recall* kelas Yusril hanya mencapai 0,67 dengan *f1-score* sebesar 0,80. Kesalahan klasifikasi ini menunjukkan bahwa metode *Otsu* yang menggunakan *threshold* global kurang mampu mempertahankan detail wajah secara optimal pada kondisi pencahayaan yang tidak merata, sehingga beberapa fitur wajah memiliki kemiripan dengan kelas lain.

Sementara itu, metode *Adaptive Thresholding* menunjukkan hasil yang lebih optimal dan konsisten. Hampir seluruh data pada setiap kelas berhasil diprediksi dengan benar, dengan hanya sedikit kesalahan pada kelas Dela yang terprediksi sebagai Dymas dan Febri. Hasil *classification report* menunjukkan bahwa nilai *precision*, *recall*, dan *f1-score* pada sebagian besar kelas berada pada kisaran 0,95 hingga 1,00 dengan akurasi keseluruhan mencapai 98,71%. Hal tersebut menunjukkan bahwa *Adaptive Thresholding* lebih efektif dalam meningkatkan kualitas segmentasi citra wajah sehingga fitur yang dihasilkan menjadi lebih representatif untuk proses klasifikasi menggunakan CNN berbasis VGG16.

Selain menghasilkan akurasi yang lebih tinggi, metode *Adaptive Thresholding* juga menunjukkan performa waktu inferensi yang masih relatif efisien. Model *Otsu* memiliki akurasi sebesar 90,32% dengan total waktu inferensi sekitar 1,25 detik dan rata-rata waktu prediksi per citra sebesar 0,0081 detik. Sementara itu, model *Adaptive* memperoleh akurasi sebesar 98,71% dengan total waktu inferensi sekitar 1,31 detik dan rata-rata waktu prediksi per citra sebesar 0,0085 detik. Meskipun metode *Adaptive* membutuhkan waktu komputasi yang sedikit lebih besar dibandingkan *Otsu*, selisih waktu tersebut tidak terlalu signifikan dibandingkan peningkatan akurasi yang diperoleh, sehingga metode *Adaptive Thresholding* dinilai lebih optimal untuk sistem pengenalan wajah berbasis CNN.



Gambar 4. a. Tampilan Utama, b. Tampilan Analisis, c. Tampilan Perbandingan Hasil, d. Tampilan Deteksi Wajah

Selain dilakukan pengujian menggunakan data uji, model CNN berbasis VGG16 yang telah dilatih juga diimplementasikan ke dalam aplikasi *VisionFace Lite* berbasis *Streamlit* (<https://github.com/febrinf/PengenalanWajah.git>). Implementasi sistem yang ditunjukkan pada Gambar 4 meliputi halaman utama yang memuat informasi metode yang digunakan serta alur sistem, halaman analisis untuk proses unggah citra, hasil *preprocessing* menggunakan *Otsu Thresholding* dan *Adaptive Thresholding* dan klasifikasi wajah lengkap dengan nilai *confidence* serta visualisasi deteksi wajah. Implementasi tersebut menunjukkan bahwa model yang dikembangkan tidak hanya memiliki performa yang baik pada tahap eksperimen, tetapi juga mampu diterapkan secara praktis dalam sistem klasifikasi wajah berbasis web yang interaktif dan mudah digunakan.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa tahapan *preprocessing*, khususnya deteksi wajah menggunakan *Haar Cascade* dan segmentasi citra, memberikan pengaruh terhadap kinerja model CNN berbasis VGG16 dalam proses pengenalan wajah. Berdasarkan hasil evaluasi menggunakan *confusion matrix* dan *classification report*, metode *Otsu Thresholding* memperoleh akurasi sebesar 90,32%, sedangkan metode *Adaptive Thresholding* menghasilkan akurasi yang lebih tinggi yaitu 98,71%. Hasil tersebut menunjukkan bahwa *Adaptive Thresholding* lebih efektif dalam menangani variasi pencahayaan dan mempertahankan detail fitur wajah, sehingga mampu meningkatkan performa klasifikasi secara lebih optimal dibandingkan metode *Otsu Thresholding*.

Untuk penelitian selanjutnya, disarankan menggunakan jumlah dataset yang lebih besar dan lebih bervariasi, baik dari sisi ekspresi wajah, sudut pengambilan, maupun kondisi pencahayaan. Selain itu, pengujian sistem pada lingkungan *real-time* dengan kondisi yang lebih kompleks,

seperti pencahayaan ekstrem, latar belakang dinamis, dan penggunaan aksesoris wajah, juga perlu dilakukan untuk mengetahui tingkat ketahanan dan stabilitas model dalam penerapannya.

DAFTAR PUSTAKA

- [1] E. Fatkhiyah, G. P. Sukmaputra, and R. Y. Ariyana, "Sistem Pengenalan Wajah Menggunakan Algoritma Convolutional Neural Network (CNN)," 2024. doi: 10.34151/prosidingsnast.v1i1.5108.
- [2] N. Rinanto, R. A. Putri, M. Ardiana, A. Khumaidi, E. N. Sholikhah, and R. S. F. Jaelani Putra, "Sistem Deteksi dan Pengenalan Wajah Real-Time dengan Haar Cascade dan CNN Untuk Otomatisasi Kehadiran Mahasiswa," *Jurnal Riset Rekayasa Elektro*, vol. 7, no. 2, pp. 203–210, Dec. 2025, doi: 10.30595/jrre.v7i2.26563.
- [3] D. Prayogi, S. R. Lubis, M. A. Rizko, and A. G. Suteja, "Optimalisasi Segmentasi Citra Digital Metode Canny Edge Detection dan Thresholding," *RIGGS: Journal of Artificial Intelligence and Digital Business*, vol. 4, no. 2, pp. 6334–6339, Jul. 2025, doi: 10.31004/riggs.v4i2.1613.
- [4] Sanjaya I, Lelita T, and Yustiana I, "Application Of Vision Transformer For Identifying Indonesian Herbal Plants Based On Visual Images," *Jurnal Media Computer Science*, 2025, doi: 10.37676/jmcs.v4i2.
- [5] Isvine Zahroya Jazmine Marzuki Fahd, Abdul Rabi, and Elta Sonalitha, "Perbandingan Akurasi Model ResNet50 dan VGG16 dalam Mengklasifikasi Penyakit Cacar Menggunakan Metode Convolutional Neural Network," *Uranus : Jurnal Ilmiah Teknik Elektro, Sains dan Informatika*, vol. 3, no. 1, pp. 170–180, Jan. 2025, doi: 10.61132/uranus.v3i1.679.
- [6] M. Fawzan and D. Udjulawa, "Optimasi Hyperparameter CNN dengan Arsitektur VGG16 Menggunakan Grid Search Untuk Klasifikasi Penyakit Buah Delima," *Arcitech: Journal of Computer Science and Artificial Intelligence*, vol. 5, no. 2, pp. 306–331, Dec. 2025, doi: 10.29240/arcitech.v5i2.15175.
- [7] L. Mahdiyah, S. Oktamuliani, and W. L. Putri, "Penerapan Algoritma Deep Learning YOLOv8 pada Platform Roboflow untuk Segmentasi Citra Panoramik," *Jurnal Fisika Unand*, vol. 14, no. 3, pp. 228–234, May 2025, doi: 10.25077/jfu.14.3.228-234.2025.
- [8] D. B. D. Hanggoro, "Analisis Komparatif Arsitektur Deep Learning Untuk Aplikasi Computer Vision: Studi Literature Review," *Jurnal Komputer Teknologi Informasi Sistem Informasi (JUKTISI)*, vol. 4, no. 2, pp. 1001–1008, Aug. 2025, doi: 10.62712/juktisi.v4i2.542.
- [9] F. H. Adiba, P. Kasih, and M. A. D. W. Dara, "Implementation and Evaluation of the K – Nearest Neighbors Algorithm in Badminton Movement Classification," *Jurnal SISFOKOM (Sistem Informasi dan Komputer)*, vol. 14, no. 4, Dec. 2025, doi: 10.32736/sisfokom.v14i4.2441.
- [10] W. Mellyssa, "Penerapan Metode Otsu Thresholding Dan Koefisien Korelasi Pada Pendeteksian Judul Buku Tugas Akhir Judul Artikel," *Jurnal Elektro dan Telekomunikasi Terapan*, vol. 8, no. 1, p. 925, Jul. 2021, doi: 10.25124/jett.v8i1.3686.
- [11] M. U. Habibah and M. Kurniawan, "Segmentasi Citra Wajah dengan Implementasi Adaptif Threshold–Integral Image," Oct. 2021, doi: 10.25126/jtiik.202183840.
- [12] A. Antoni, T. Rohana, and A. R. Pratama, "Implementasi Algoritma Convolutional Neural Network Untuk Klasifikasi Citra Kemasan Kardus Defect dan No Defect," *Building of Informatics, Technology and Science (BITS)*, vol. 4, no. 4, Mar. 2023, doi: 10.47065/bits.v4i4.3270.