

Sistem Presensi Otomatis Berbasis Pengenalan Wajah dengan Database Real-Time

I Putu Elba Duta Nugraha¹, Gede Sukadarmika²

^{1,2}Program Studi Teknik Elektro, Fakultas Teknik, Universitas Udayana, Jl. Raya Kampus Unud No.88, Badung, 80361, Indonesia

Info Artikel

Riwayat Artikel:

Received 2025-05-20

Revised 2025-09-17

Accepted 2025-09-17

Corresponding Author:

I Putu Elba Duta Nugraha

Email: elba.nugraha@unud.ac.id



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

Abstract – Traditional attendance systems often suffer from inefficiency, inaccuracy, and hygiene concerns, especially when they require manual recording or physical contact such as fingerprint scanning. This study aims to develop an automatic attendance system that utilizes deep learning-based face recognition integrated with a real-time database to overcome these limitations. The system employs the dlib facial recognition network, which applies deep metric learning for feature extraction and Histogram of Oriented Gradients (HOG) for detection. A quantitative method was used, testing the prototype with a dataset of three identities and 150 test instances (50 per person) under varying lighting and angle conditions. The novelty of this work lies in its optimized implementation on low-power hardware, namely the NVIDIA Jetson Nano, enabling real-time operation with an average processing speed of 14.2 FPS and acceptable latency. Experimental results demonstrated high performance, achieving 99.1% accuracy, 98.7% precision, 98.7% recall, and a 98.7% F1-score at a tolerance threshold of 0.5. However, the current limitation is its vulnerability to spoofing attacks using static photos. Overall, the findings indicate that the proposed system is a viable, efficient, and accurate solution for modern attendance needs, particularly in environments with limited computational resources.

Keywords: Automatic Attendance; Deep Learning; Face Recognition; NVIDIA Jetson Nano; Real-Time Database

Abstrak – Sistem presensi tradisional sering mengalami permasalahan terkait efisiensi dan kebersihan. Penelitian ini bertujuan untuk mengembangkan sistem presensi otomatis dengan memanfaatkan pengenalan wajah berbasis deep learning yang terintegrasi dengan basis data real-time guna mengatasi keterbatasan tersebut. Sistem ini menggunakan jaringan pengenalan wajah dlib berbasis deep metric learning dan Histogram of Oriented Gradients (HOG) untuk deteksi. Metode kuantitatif digunakan dengan pengujian pada dataset yang terdiri dari 3 identitas, dengan total 150 data uji (50 per orang). Kebaruan dari penelitian ini terletak pada implementasi yang dioptimalkan pada perangkat keras berdaya rendah (NVIDIA Jetson Nano) sehingga mampu mencapai kinerja real-time. Sistem menunjukkan akurasi tinggi dengan capaian 99,1% untuk akurasi, 98,7% untuk presisi, 98,7% untuk recall, dan 98,7% untuk skor F1 pada nilai ambang toleransi 0,5. Keterbatasan utama sistem ini adalah kerentanannya terhadap serangan spoofing menggunakan foto statis. Penelitian ini menyimpulkan bahwa sistem yang diusulkan merupakan solusi yang layak, efisien, dan akurat untuk kebutuhan presensi modern, khususnya pada lingkungan dengan keterbatasan sumber daya.

Kata Kunci: Deep Learning, NVIDIA Jetson Nano, Pengenalan Wajah, Presensi Otomatis, Real-Time Database

I. PENDAHULUAN

Sistem presensi atau perekaman kehadiran merupakan salah satu komponen penting dalam operasional berbagai organisasi. Sistem ini membantu organisasi dalam memantau dan mengelola kehadiran karyawan atau anggota secara efektif. Di banyak organisasi, metode presensi manual masih banyak digunakan, di mana pengguna harus mencatat kehadiran secara langsung, baik melalui tanda tangan, memasukkan kode identifikasi, atau menggunakan kartu akses. Meskipun sistem ini efektif dalam beberapa kasus, tantangan utamanya adalah waktu yang dibutuhkan dan risiko kesalahan karena intervensi manual yang dapat terjadi. Terlebih lagi, sistem yang membutuhkan kontak fisik, seperti *fingerprint*, memiliki keterbatasan dalam hal kebersihan dan kenyamanan, terutama di lingkungan yang mengedepankan kontak minimal. Oleh karena itu, dibutuhkan pendekatan baru yang dapat memberikan solusi otomatis, cepat, dan akurat dalam sistem presensi. Sistem ini perlu mampu mempercepat pencatatan kehadiran, menghilangkan kebutuhan akan kontak fisik, dan meminimalkan intervensi manual.

Seiring kemajuan teknologi, berbagai metode presensi otomatis telah diperkenalkan, seperti penggunaan kartu identifikasi otomatis, sidik jari, hingga pengenalan wajah. Sistem presensi otomatis yang melibatkan biometrik seperti sidik jari dan pengenalan iris telah berkembang dengan baik dalam beberapa tahun terakhir. Namun, sistem-sistem ini bersifat *intrusive* dan membutuhkan biaya tinggi untuk implementasi dalam skala besar. Sebagai alternatif, teknologi pengenalan wajah berbasis *deep learning* kini semakin relevan karena dapat mencatat kehadiran tanpa kontak fisik

langsung. Pengenalan wajah melalui biometrik ini melibatkan tahap-tahap seperti akuisisi gambar, deteksi wajah, ekstraksi fitur, klasifikasi wajah, pengenalan wajah, dan akhirnya pencatatan kehadiran [1].

Deteksi dan pengenalan wajah adalah permasalahan yang telah banyak dieksplorasi dalam bidang visi komputer, meskipun masih belum sepenuhnya terpecahkan karena adanya variasi posisi, kondisi pencahayaan yang berbeda, dan oklusi [2]. Beberapa pendekatan, baik yang menggunakan *deep learning* maupun *non-deep learning*, telah diterapkan dalam pengembangan sistem presensi otomatis. Misalnya, [1] menggunakan algoritma seperti Viola-Jones dan fitur Histogram of Oriented Gradients (HOG) yang dipadukan dengan pengklasifikasi Support Vector Machine (SVM). [3] mengembangkan sistem Automated Student Attendance Management System menggunakan infrastruktur *cloud computing* yang disebut Facecube. [4] mengombinasikan Principal Components Analysis (PCA) dengan algoritma Linear Discriminant Analysis (LDA) untuk meningkatkan akurasi pengenalan wajah. [5] menerapkan tiga model Convolutional Neural Network (CNN) *pre-trained*, yaitu AlexNet, GoogleNet, dan SqueezeNet, untuk memperoleh akurasi tinggi dalam waktu pemrosesan yang relatif cepat. Perkembangan terkini mengeksplorasi arsitektur *hybrid* yang menggabungkan keunggulan CNN dan Transformer untuk menciptakan model yang sangat efisien tanpa mengorbankan akurasi, salah satunya adalah EdgeFace [6] yang dirancang khusus untuk perangkat *edge*. [7] menggunakan algoritma Haar Cascade dengan OpenCV, sebuah *open-source image processing library*, untuk mengembangkan konsep pengenalan wajah frontal. Selain itu, [8] menggunakan kombinasi dua algoritma *deep learning*, yaitu Multi-Task Cascaded Convolutional Neural Network (MTCNN) dan FaceNet, untuk pengembangan sistem presensi otomatis berbasis pengenalan wajah.

Akurasi pengenalan wajah dalam sistem presensi otomatis adalah spesifikasi yang sangat krusial untuk mencapai hasil yang andal dan efektif. Beberapa penelitian telah menunjukkan hasil akurasi pengenalan wajah yang relatif baik. Sebagai contoh, [9] menggunakan *video streaming* untuk menangkap gambar yang kemudian diolah untuk pengenalan wajah dan berhasil mencapai akurasi sebesar 94,66%. Dengan menggunakan LFW *face database*, [2] mencapai akurasi 98,67% menggunakan *novel recognition architecture*. Penelitian *e-attendance system* berbasis Convolutional Neural Network (CNN) yang menggunakan remote GPU server oleh [10] melaporkan akurasi sebesar 98%.

Penelitian ini bertujuan untuk mengembangkan aplikasi presensi otomatis dengan memanfaatkan teknologi pengenalan wajah berbasis *deep learning* dan integrasi ke dalam *real-time database*. Sistem ini bertujuan untuk mengatasi keterbatasan pada metode presensi tradisional, sehingga proses pencatatan kehadiran menjadi lebih cepat, akurat, dan praktis. OpenCV dan Python dipilih sebagai *platform* pengembangan karena sifatnya yang *open source*, kemampuan akurasi yang tinggi, dan kecepatan eksekusi *real-time* [11], [12]. Dengan adanya teknologi *deep learning*, sistem pengenalan wajah dapat dibuat dengan akurasi tinggi, memungkinkan implementasi yang lebih luas di lingkungan organisasi modern [13].

Pendekatan modular digunakan dalam pengembangan sistem ini, sehingga memungkinkan penambahan fitur dan peningkatan performa secara bertahap. Pada jangka panjang, penelitian ini diharapkan dapat menghasilkan prototipe sistem presensi otomatis yang tidak hanya akurat tetapi juga fleksibel, dengan kemampuan integrasi yang baik pada perangkat keras dan berbagai fitur tambahan seperti pengamanan data. Dengan demikian, organisasi diharapkan dapat menggunakan sistem ini untuk meningkatkan efisiensi operasional dan efektivitas manajemen kehadiran. Namun, tantangan keamanan berupa serangan *spoofing* menggunakan foto, video, atau masker masih menjadi kelemahan utama pada sistem pengenalan wajah konvensional [14]. Oleh karena itu, integrasi mekanisme *anti-spoofing* yang tangguh menjadi komponen kritis dalam pengembangan sistem presensi yang tidak hanya efisien tetapi juga andal dan aman [15]. Penelitian ini berfokus pada menciptakan solusi yang efisien dan akurat terlebih dahulu, dengan kesadaran penuh bahwa lapisan keamanan *anti-spoofing* merupakan langkah penting berikutnya.

Tujuan khusus dari penelitian ini adalah: (1) Merancang dan membangun prototipe sistem presensi otomatis berbasis pengenalan wajah yang terintegrasi dengan Firebase Realtime Database; (2) Mencapai akurasi pengenalan wajah minimal 98% pada dataset terbatas; (3) Mengimplementasikan sistem pada perangkat NVIDIA Jetson Nano dan mencapai kecepatan pemrosesan minimal 10 *Frame Per Second* (FPS) untuk operasi *real-time*.

Kontribusi penelitian ini adalah: (C1) Sebuah arsitektur sistem lengkap yang mengintegrasikan *pipeline* pengenalan wajah (dlib-HOG) dengan manajemen data *real-time* (Firebase) dalam satu prototipe yang fungsional; (C2) Analisis kinerja komprehensif yang tidak hanya mencakup akurasi tetapi juga metrik komputasional (FPS, *latency*, utilisasi CPU/GPU) pada perangkat berdaya rendah; (C3) Evaluasi sensitivitas *threshold* yang memberikan panduan untuk menyeimbangkan antara *false positive* dan *false negative* dalam penerapan sistem serupa.

II. METODE

Penelitian ini dilakukan di Laboratorium Komputer Program Studi Teknik Elektro, Fakultas Teknik Universitas Udayana dari bulan Januari – Desember 2024.

Aplikasi pengenalan wajah yang dibangun memiliki dua tahapan pengembangan, yakni pelatihan model dan pengujian model. Komputer akan digunakan untuk komputasi pelatihan model. Pengujian model berarti model yang sudah final ditanamkan pada mini prosesor NVIDIA Jetson Nano tanpa melibatkan komputer untuk komputasinya,


sehingga pengenalan wajah dapat diproses langsung oleh mini prosesor NVIDIA Jetson Nano dengan menambahkan kamera sebagai input.

Untuk membangun aplikasi pengenalan wajah dengan *deep learning*, digunakan suatu teknik yang disebut *deep metric learning* yang diterapkan dalam tiga langkah kunci [16]:

- Melakukan deteksi wajah, yang mendeteksi keberadaan dan lokasi wajah dalam sebuah gambar, namun tidak mengidentifikasinya.
- Mengekstrak vektor fitur 128-d (disebut "representasi") yang mengkuantifikasi setiap wajah dalam gambar.
- Melakukan pengenalan wajah pada gambar dan *video stream*.

Model yang bertanggung jawab untuk mengkuantifikasi setiap wajah menjadi representasi 128-d berasal dari *dlib facial recognition network*, suatu *pre-trained network* yang telah dilatih dengan teknik "triplet training step" menggunakan dataset ~3 juta gambar [17].

Selanjutnya untuk representasi wajah yang kita input sendiri, pengenalan wajah dapat dilatih menggunakan algoritma pengklasifikasi *machine learning* standar seperti SVM atau k-NN. Diagram alir yang menjelaskan tahapan-tahapan penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Diagram alir tahapan penelitian

Pengujian sistem dilakukan menggunakan dataset yang berisi citra wajah dari 3 pengguna yang telah terdaftar (selanjutnya disebut sebagai Wajah A, B, dan C). Setiap pengguna menyumbang 50 citra wajah yang berbeda yang diambil dalam variasi kondisi pencahayaan dan sudut yang wajar untuk simulasi lingkungan nyata. Total terdapat 150 sampel uji. Seluruh citra wajah ini telah melalui proses *encoding* sebelumnya dan disimpan dalam *database* sistem. Pengujian dilakukan secara *real-time* menggunakan *video stream* dari *webcam*. Seluruh data uji (150 data) digunakan

untuk evaluasi kinerja model tanpa proses *split training/validation* karena model yang digunakan adalah *pre-trained network* (dlib) yang kemudian dikustomisasi dengan *embedding* dari ketiga wajah tersebut.

Pengujian akurasi sistem dilakukan untuk mengukur seberapa sering prediksi model benar. Pengujian ini dilakukan dengan menggunakan *confusion matrix*. Terdapat empat elemen utama dalam *confusion matrix* [18]:

- True Positive (TP): wajah yang dikenali dengan benar (model memprediksi wajah A, dan benar itu adalah wajah A).
- True Negative (TN): bukan wajah yang dikenali, dan model juga tidak mengidentifikasi wajah (model tidak salah mengenali wajah).
- False Positive (FP): salah mengenali wajah (model memprediksi wajah A, tetapi seharusnya wajah B).
- False Negative (FN): gagal mengenali wajah yang seharusnya dikenali (model tidak memprediksi wajah A padahal itu wajah A).

Perhitungan akurasi keseluruhan dapat diperoleh dari persamaan berikut:

$$Akurasi = \frac{Jumlah\ Prediksi\ Benar}{Total\ Prediksi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Untuk menghitung presisi, *recall*, dan *F1-score* secara keseluruhan dari *confusion matrix*, kita perlu menghitung nilai tersebut untuk masing-masing kelas terlebih dahulu, kemudian menghitung rata-rata tertimbang (*weighted average*) berdasarkan jumlah di setiap kelas. Berikut adalah persamaan yang digunakan:

- Presisi: mengukur seberapa tepat model dalam memprediksi wajah.

$$Presisi = \frac{TP}{TP+FP} \quad (2)$$

- Recall: mengukur seberapa baik model mendeteksi wajah yang seharusnya dikenali.

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

- F1-score: rata-rata harmonis dari presisi dan recall.

$$F1 - score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall} \quad (4)$$


III. HASIL DAN PEMBAHASAN

A. Langkah Pembuatan Sistem

Sistem dikembangkan menggunakan Python dan memanfaatkan library dlib, face_recognition, OpenCV, dan Firebase Admin SDK. Arsitektur sistem terdiri dari tiga modul utama: (1) Modul Pengenalan Wajah, yang menangani *capture image*, deteksi wajah menggunakan HOG, dan ekstraksi fitur menggunakan model *embedding* dlib yang telah dilatih sebelumnya; (2) Modul Manajemen Data, yang mengelola komunikasi dengan Firebase Realtime Database untuk menyimpan dan mengambil data presensi; (3) Modul Antarmuka Pengguna, yang dibangun menggunakan OpenCV untuk menampilkan umpan kamera dan status presensi secara *real-time*.

B. Uji Fungsi Sistem


Pengujian dilakukan menggunakan video dan gambar wajah pengguna yang telah terdaftar dalam *database*. Hasil pengujian terhadap 3 wajah (A, B, dan C) dapat dilihat pada Gambar 2, 3, dan 4.



Gambar 2. Uji fungsi pengenalan wajah A



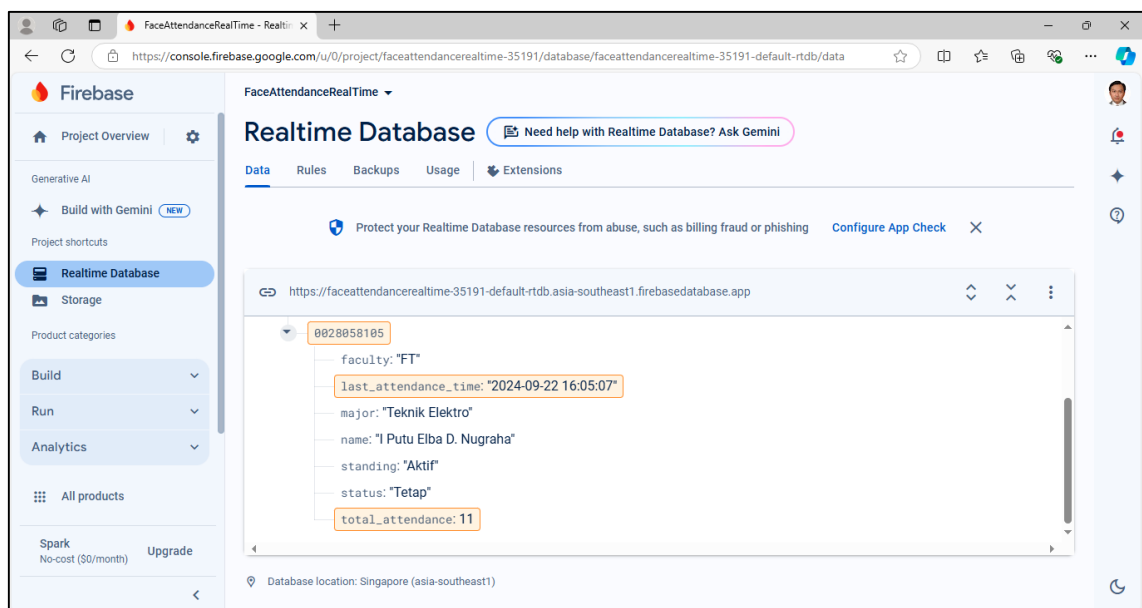
Gambar 3. Uji fungsi pengenalan wajah B



Gambar 4. Uji fungsi pengenalan wajah C

Selama proses pengujian, dilakukan penyesuaian pada nilai toleransi *face distance*. Nilai *default* sebesar 0,6 menghasilkan beberapa kesalahan (False Positive) pengenalan wajah. Setelah serangkaian uji coba, nilai toleransi diubah menjadi 0,5. Dengan nilai ini, hanya wajah dengan *face distance* $\leq 0,5$ yang dianggap sesuai, sehingga sistem menjadi lebih ketat dalam menentukan kecocokan wajah. Hasil pengujian menunjukkan bahwa wajah yang tidak terdaftar dalam *database* tidak dapat melakukan presensi.

Berdasarkan pengujian, sistem presensi berhasil mengenali seluruh wajah dalam *database* secara akurat. Sistem juga mampu memperbarui data kehadiran pada Firebase Realtime Database, termasuk total kehadiran dan waktu presensi terakhir, seperti ditunjukkan pada Gambar 5.



Gambar 5. Pembaruan *realtime database*

C. Pengukuran Metrik Kinerja Sistem

Metrik kinerja sistem yang diukur meliputi akurasi, presisi, *recall*, dan *F1-score*.

1) Pengujian Akurasi

Pengujian akurasi dilakukan untuk mengukur seberapa sering prediksi sistem sesuai dengan kenyataan. Evaluasi dilakukan menggunakan *confusion matrix*, yang mencatat hasil pengenalan wajah. Tabel 1 menunjukkan hasil pengujian *confusion matrix* untuk tiga wajah yang terdapat dalam *database*, yaitu wajah A, wajah B, dan wajah C. Setiap wajah diuji sebanyak 50 kali untuk memastikan validitas hasil.

TABEL 1
HASIL PENGUJIAN MENGGUNAKAN CONFUSION MATRIX

Aktual	Prediksi		
	Wajah A	Wajah B	Wajah C
Wajah A	49	1	0
Wajah B	0	49	1
Wajah C	0	0	50

Berdasarkan data pada Tabel 1, maka akurasi dapat dihitung menggunakan Persamaan (1).

$$\begin{aligned}
 \text{Akurasi} &= \frac{\text{Jumlah Prediksi Benar}}{\text{Total Prediksi}} = \frac{TP+TN}{TP+TN+FP+FN} \\
 &= \frac{148+296}{148+296+2+2} = \frac{444}{448} \approx 0,991 = 99,1\%
 \end{aligned}
 \tag{5}$$

2) Pengujian Presisi:

Untuk menghitung presisi, *recall*, dan *F1-score* secara keseluruhan dari *confusion matrix*, kita perlu menghitung nilai tersebut untuk masing-masing kelas terlebih dahulu, kemudian menghitung rata-rata tertimbang (*weighted average*) berdasarkan jumlah di setiap kelas.

Pengujian presisi dilakukan untuk mengukur seberapa tepat model dalam memprediksi wajah (ditentukan oleh jumlah False Positive-nya). Berdasarkan data pada Tabel 1, maka presisi dapat dihitung menggunakan Persamaan (2).

$$\text{Presisi A} = \frac{TP}{TP+FP} = \frac{49}{49+0} = 1,00
 \tag{6}$$

$$\text{Presisi B} = \frac{TP}{TP+FP} = \frac{49}{49+1} = 0,98
 \tag{7}$$

$$\text{Presisi C} = \frac{TP}{TP+FP} = \frac{50}{50+1} \approx 0,98
 \tag{8}$$

maka presisi keseluruhan,

$$\text{Presisi} = \frac{1,00+0,98+0,98}{3} = \frac{2,96}{3} \approx 0,987 = 98,7\%
 \tag{9}$$

3) Pengujian Recall:

Pengujian *recall* dilakukan untuk mengukur seberapa baik model mendeteksi wajah yang seharusnya dikenali (ditentukan oleh jumlah False Negative-nya). Berdasarkan data pada Tabel 1, maka *recall* dapat dihitung menggunakan Persamaan (3).

$$\text{Recall A} = \frac{TP}{TP+FN} = \frac{49}{49+1} = 0,98
 \tag{10}$$

$$\text{Recall B} = \frac{TP}{TP+FN} = \frac{49}{49+1} = 0,98
 \tag{11}$$

$$\text{Recall C} = \frac{TP}{TP+FN} = \frac{50}{50+0} = 1,00
 \tag{12}$$

maka recall keseluruhan,

$$Recall = \frac{0,98+0,98+1}{3} = \frac{2,96}{3} \approx 0,987 = 98,7\% \quad (13)$$

4) Pengujian F1-score:

Pengujian F1-score dilakukan untuk menghitung rata-rata harmonis dari presisi dan recall. Berdasarkan hasil pengujian presisi dan recall, maka F1-score dapat dihitung menggunakan Persamaan (4).

$$F1 - score A = 2 \times \frac{Presisi A \times Recall A}{Presisi A + Recall A} = 2 \times \frac{1,00 \times 0,98}{1,00 + 0,98} \approx 0,99 \quad (14)$$

$$F1 - score B = 2 \times \frac{Presisi B \times Recall B}{Presisi B + Recall B} = 2 \times \frac{0,98 \times 0,98}{0,98 + 0,98} \approx 0,98 \quad (15)$$

$$F1 - score C = 2 \times \frac{Presisi C \times Recall C}{Presisi C + Recall C} = 2 \times \frac{0,98 \times 1,00}{0,98 + 1,00} \approx 0,99 \quad (16)$$

Maka F1-score keseluruhan,

$$F1 - score = \frac{0,99+0,98+0,99}{3} = \frac{2,96}{3} \approx 0,987 = 98,7\% \quad (17)$$

D. Pengukuran Kinerja Komputasional pada NVIDIA Jetson Nano

Implementasi pada NVIDIA Jetson Nano bertujuan untuk mengevaluasi kinerja sistem dalam lingkungan berdaya rendah. Pengukuran dilakukan selama proses pengenalan wajah *real-time*. Hasil pengukuran menunjukkan kecepatan pemrosesan rata-rata sebesar 14,2 FPS dengan latency 70,4 ms per frame. Utilisasi sumber daya perangkat keras selama operasi dicatat sebagai berikut: CPU digunakan hingga 78%, GPU digunakan sekitar 45%, dan konsumsi RAM sekitar 1,2 GB. Hasil ini membuktikan bahwa model dapat beroperasi secara efisien dan memenuhi target untuk aplikasi *real-time* pada perangkat *edge*.

E. Analisis Sensitivitas Threshold dan Metrik Per-Kelas

Nilai *threshold* toleransi (*face distance*) sangat mempengaruhi kinerja sistem. Untuk memberikan analisis yang komprehensif, evaluasi dilakukan pada variasi *threshold* 0,4, 0,5, dan 0,6. Hasil metrik untuk setiap kelas dan rata-ratanya disajikan pada Tabel 2.

TABEL 2
ANALISIS SENSITIVITAS THRESHOLD PADA METRIK SISTEM

Threshold	Kelas	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
0,4	Wajah A	98,0	100,0	96,0	98,0
	Wajah B	98,7	97,9	98,0	98,0
	Wajah C	99,3	98,0	100,0	99,0
	Rata-rata Tertimbang	98,9	98,6	98,7	98,6
0,5	Wajah A	98,7	100,0	98,0	99,0
	Wajah B	98,7	98,0	98,0	98,0
	Wajah C	100,0	98,0	100,0	99,0
	Rata-rata Tertimbang	99,1	98,7	98,7	98,7
0,6	Wajah A	97,3	94,2	100,0	97,0
	Wajah B	97,3	100,0	94,0	97,0
	Wajah C	100,0	100,0	100,0	100,0
	Rata-rata Tertimbang	98,0	98,3	98,0	98,1

Berdasarkan Tabel 2, terlihat bahwa *threshold* 0,5 menghasilkan kinerja keseluruhan (F1-Score) yang optimal sebesar 98,7%. Pada *threshold* yang lebih ketat (0,4), Recall untuk Wajah A menurun (96,0%), menunjukkan peningkatan False Negatives (FN) dimana sistem lebih sering gagal mengenali wajah yang seharusnya dikenal. Sebaliknya, pada *threshold* yang lebih longgar (0,6), Precision untuk Wajah A menurun (94,2%), menunjukkan peningkatan False Positives (FP) dimana sistem lebih mudah salah mengenali wajah lain sebagai Wajah A. Pemilihan *threshold* 0,5 merupakan *trade-off* yang tepat untuk meminimalkan kedua jenis error (FP dan FN) dalam konteks aplikasi presensi ini.

F. Pertimbangan Etika dan Keamanan Data

Penggunaan data biometrik wajah memerlukan pertimbangan etika dan keamanan yang ketat. Dalam penelitian ini, setiap data wajah yang dikumpulkan merupakan partisipan yang telah menyetujui penggunaan citranya untuk tujuan pengujian akademik ini. Data disimpan dan diproses dengan prinsip *privasi-by-design*. Kredensial akses Firebase (*Private Key*) disimpan secara aman di lingkungan server dan tidak disertakan dalam kode klien untuk mencegah akses yang tidak sah. Seluruh komunikasi antara sistem dan Firebase dienkripsi menggunakan SSL. Data presensi yang tersimpan di *database* hanya dapat diakses oleh administrator yang memiliki kredensial yang sesuai. Meskipun demikian, prototipe ini masih memiliki keterbatasan dalam hal *liveness detection*, yang merupakan fokus untuk pengembangan di masa depan untuk mencegah *spoofing* dengan foto.

IV. SIMPULAN

Prototipe sistem presensi otomatis berbasis pengenalan wajah telah berhasil dikembangkan dengan mengintegrasikan arsitektur *deep learning* (dlib dengan HOG) dan Firebase Realtime Database. Pengujian yang dilakukan pada dataset terbatas yang berisi 3 identitas pengguna membuktikan bahwa sistem mampu mengenali wajah dan mencatat kehadiran secara akurat serta efisien. Tujuan penelitian untuk mencapai akurasi di atas 98% dan implementasi *real-time* pada perangkat berdaya rendah telah terpenuhi. Hasil pengukuran metrik kinerja menunjukkan akurasi 99,1%, presisi 98,7%, recall 98,7%, dan F1-score 98,7% pada threshold toleransi 0,5. Implementasi pada NVIDIA Jetson Nano menunjukkan kinerja komputasional yang memadai untuk operasi *real-time* dengan kecepatan 14,2 FPS dan latency 70,4 ms, meskipun dengan utilisasi sumber daya yang signifikan. Analisis sensitivitas *threshold* lebih lanjut mengungkap *trade-off* antara False Positive dan False Negative, di mana nilai 0,5 dipilih sebagai titik optimal. Namun, sistem ini masih memiliki keterbatasan, terutama dalam hal keamanan terhadap serangan *spoofing* menggunakan media statis seperti foto. Oleh karena itu, untuk penelitian selanjutnya, sangat disarankan untuk mengintegrasikan mekanisme *liveness detection* guna meningkatkan keamanan dan keandalan sistem. Eksplorasi pada model yang lebih ringan tanpa mengorbankan akurasi juga dapat menjadi fokus untuk memperluas penerapan pada perangkat yang lebih terbatas sumber dayanya.

UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) Universitas Udayana atas dukungan pendanaan yang bersumber dari Daftar Isian Pelaksanaan Anggaran (DIPA) Universitas Udayana Tahun Anggaran 2024. Pendanaan tersebut telah memungkinkan terlaksananya penelitian yang menjadi dasar penyusunan makalah ini, sehingga diharapkan hasilnya dapat memberikan kontribusi bagi pengembangan ilmu pengetahuan dan teknologi.

DAFTAR PUSTAKA

- [1] H. Rathod, Y. Ware, S. Sane, S. Raulo, V. Pakhare, and I. A. Rizvi, "Automated attendance system using machine learning approach," in *2017 International Conference on Nascent Technologies in Engineering (ICNTE)*, Jan. 2017, pp. 1–5. doi: 10.1109/ICNTE.2017.7947889.
- [2] P. R. Sarkar, D. Mishra, and G. R. K. S. Subramanyam, "Automatic Attendance System Using Deep Learning Framework," in *Machine Intelligence and Signal Analysis*, M. Tanveer and R. B. Pachori, Eds., Singapore: Springer Singapore, 2019, pp. 335–346.
- [3] G. Ofualagba, O. Osas, I. Orobor, I. Oseikhuemen, and O. Etse, "Automated Student Attendance Management System Using Face Recognition," *Int. J. Educ. Res. Inf. Sci.*, vol. 5, pp. 31–37, 2018.
- [4] M. Abuzar, A. bin Ahmad, and A. A. bin Ahmad, "A Survey on Student Attendance System Using Face Recognition," in *2020 8th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)*, 2020, pp. 1252–1257. doi: 10.1109/ICRITO48877.2020.9197815.
- [5] K. Alhaneef, M. Alhammad, N. Almenhali, and M. Shatnawi, "Face recognition smart attendance system using deep transfer learning," *Procedia Comput. Sci.*, vol. 192, pp. 4093–4102, 2021, doi: 10.1016/j.procs.2021.09.184.
- [6] A. George, C. Ecabert, H. O. Shahreza, K. Kotwal, and S. Marcel, "EdgeFace: Efficient Face Recognition Model for Edge Devices," *IEEE Trans. Biometrics, Behav. Identity Sci.*, vol. 6, no. 2, pp. 158–168, 2024, doi: 10.1109/TBIOM.2024.3352164.
- [7] S. K. Sarangi, A. Paul, H. Kishor, and K. Pandey, "Automatic Attendance System using Face Recognition," in *2021 International Conference in Advances in Power, Signal, and Information Technology (APSIT)*, 2021, pp. 1–5. doi: 10.1109/APSIT52773.2021.9641486.
- [8] I. Al-Amoudi, R. Samad, N. R. H. Abdullah, M. Mustafa, and D. Pebrianti, "Automatic Attendance System Using Face Recognition with Deep Learning Algorithm," in *Proceedings of the 12th National Technical Seminar on Unmanned System Technology 2020*, K. Isa, Z. Md. Zain, R. Mohd-Mokhtar, M. Mat Noh, Z. H. Ismail, A. A. Yusof, A. F. Mohamad Ayob, S. S. Azhar Ali, and H. Abdul Kadir, Eds., Singapore: Springer Singapore, 2022, pp. 573–588.
- [9] J. Joshan Athanesious, Vanitha, S. Adithya, C. A. Bhardwaj, J. S. Lamba, and A. V. Vaidehi, "Deep Learning Based Automated Attendance System," *Procedia Comput. Sci.*, vol. 165, no. 2019, pp. 307–313, 2019, doi: 10.1016/j.procs.2020.01.045.
- [10] Y. J. Modi, K. Rana, T. Trivedi, D. Patel, and M. Sagar, "E-Attendance System Using Machine Learning," in *Futuristic Trends for Sustainable Development and Sustainable Ecosystems*, F. Ortiz-Rodriguez, S. Tiwari, S. Iyer, and J. M. Medina-Quintero, Eds., Hershey, PA, USA: IGI Global, 2022, pp. 60–75. doi: 10.4018/978-1-6684-4225-8.ch004.
- [11] A. Kaehler and G. Bradski, *Learning OpenCV 3: computer vision in C++ with the OpenCV library*. "O'Reilly Media, Inc.," 2016.
- [12] S. Muges, "Hands-on ML Projects with OpenCV: Master computer vision and Machine Learning using OpenCV and Python," *Orange Educ. Pvt Ltd, AVA*, 2023.
- [13] A. Rosebrock, *Deep learning for computer vision with python: Starter bundle*. PyImageSearch, 2017.
- [14] H. Xing, S. Y. Tan, F. Qamar, and Y. Jiao, "Face Anti-Spoofing Based on Deep Learning: A Comprehensive Survey," *Appl. Sci.*, vol. 15,

- no. 12, 2025, doi: 10.3390/app15126891.
- [15] A. E. U. Salam, A. T. K. P. Tarra, and D. Utamidewi, "Automatic Attendance System Using Silent Face Anti-Spoofing to Detect Spoof on Face Recognition," in *2025 International Conference on Smart Computing, IoT and Machine Learning (SIML)*, 2025, pp. 1–5. doi: 10.1109/SIML65326.2025.11081084.
- [16] X. Yang, P. Zhou, and M. Wang, "Person reidentification via structural deep metric learning," *IEEE Trans. neural networks Learn. Syst.*, vol. 30, no. 10, pp. 2987–2998, 2018.
- [17] D. Zhang, J. Li, and Z. Shan, "Implementation of Dlib deep learning face recognition technology," in *2020 International Conference on Robots & Intelligent System (ICRIS)*, IEEE, 2020, pp. 88–91.
- [18] A. Arias-Duart, E. Mariotti, D. Garcia-Gasulla, and J. M. Alonso-Moral, "A confusion matrix for evaluating feature attribution methods," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2023, pp. 3709–3714.