

# Analisis dan Implementasi Metode Incremental Enrollment pada Sistem Pengenalan Wajah Berbasis Edge Computing untuk Smart Door Lock

M. Berryl Muchtada

Teknik Multimedia dan Jaringan, Teknik Informatika dan Komputer, Politeknik Negeri Jakarta

Depok, Jawa Barat

[m.berryl.muchtada.tik22@mhsw.pnj.ac.id](mailto:m.berryl.muchtada.tik22@mhsw.pnj.ac.id)

*Abstract – Conventional mechanical locks provide limited protection because they cannot verify user identity or automatically record access history, which makes biometric-based smart door lock systems an attractive alternative for building security. This study designs, implements, and evaluates a face recognition-based smart door lock system that runs entirely on an edge device, combining a MobileFaceNet architecture pretrained with ArcFace loss in TensorFlow Lite format on a Raspberry Pi 4B with an ESP32-CAM as the image acquisition module. The system applies an Incremental Enrollment method that allows new user identities to be added by storing face embeddings in an SQLite database without retraining the model, supported by a preprocessing pipeline consisting of face alignment, super resolution, quality assessment, Contrast Limited Adaptive Histogram Equalization (CLAHE), denoising, and sharpening. Evaluation results show that the ArcFace-pretrained model achieves a maximum accuracy of 96.68% with an Equal Error Rate (EER) of 0.0600 on the LFW dataset, and reaches 97.54% accuracy on CFP-FP and 97.42% on AgeDB-30. System testing shows a recognition accuracy of 98% across 100 test images from five users, while the combination of alignment, super resolution, and CLAHE yields the highest preprocessing accuracy of 93.75%. Enrollment latency increases from 436.5 ms to 1,800.6 ms and recognition latency from 311.2 ms to 1,645.3 ms when super resolution is enabled, while memory consumption remains within 13.9%–16.0% of total RAM without swap usage. Black box testing confirms that all functional scenarios operate as expected. Overall, the developed system shows that Incremental Enrollment enables flexible on-device user management while maintaining reliable recognition performance suitable for resource-constrained edge computing platforms.*

**Keywords:** Smart Door Lock, Face Recognition, MobileFaceNet, ArcFace, Incremental Enrollment, Edge Computing, TensorFlow Lite, Raspberry Pi 4B.

*Abstrak – Sistem kunci pintu mekanis konvensional memiliki keterbatasan karena tidak mampu memverifikasi identitas pengguna maupun mencatat riwayat akses secara otomatis, sehingga sistem smart door lock berbasis biometrik menjadi alternatif yang menarik untuk meningkatkan keamanan bangunan. Penelitian ini merancang, mengimplementasikan, dan mengevaluasi sistem smart door lock berbasis pengenalan wajah yang berjalan sepenuhnya pada perangkat edge, dengan menggabungkan arsitektur MobileFaceNet berbasis pretrained ArcFace Loss dalam format TensorFlow Lite pada Raspberry Pi 4B serta ESP32-CAM sebagai modul akuisisi citra. Sistem menerapkan metode Incremental Enrollment yang memungkinkan penambahan identitas pengguna baru melalui penyimpanan embedding wajah ke dalam basis data SQLite tanpa melakukan pelatihan ulang model, didukung oleh pipeline preprocessing yang terdiri atas face alignment, super resolution, quality assessment, Contrast Limited Adaptive Histogram Equalization (CLAHE), denoising, dan sharpening. Hasil evaluasi menunjukkan bahwa model dengan pretrained ArcFace Loss mencapai akurasi puncak 96,68% dengan Equal Error Rate (EER) sebesar 0,0600 pada dataset LFW, serta memperoleh akurasi 97,54% pada CFP-FP dan 97,42% pada AgeDB-30. Pengujian sistem menunjukkan akurasi pengenalan sebesar 98% dari 100 citra uji milik lima pengguna, sedangkan kombinasi alignment, super resolution, dan CLAHE menghasilkan akurasi preprocessing terbaik sebesar 93,75%. Latensi enrollment meningkat dari 436,5 ms menjadi 1.800,6 ms dan latensi recognition meningkat dari 311,2 ms menjadi 1.645,3 ms ketika super resolution diaktifkan, sementara konsumsi memori tetap berada pada kisaran 13,9%–16,0% dari total RAM tanpa penggunaan swap. Pengujian black box menunjukkan bahwa seluruh skenario fungsional berjalan sesuai harapan. Secara keseluruhan, sistem yang dikembangkan menunjukkan bahwa metode Incremental Enrollment memungkinkan pengelolaan pengguna secara fleksibel langsung pada perangkat tanpa mengorbankan performa pengenalan wajah, sehingga sesuai diterapkan pada platform edge computing dengan sumber daya terbatas.*

**Kata Kunci:** Smart Door Lock, Pengenalan Wajah, MobileFaceNet, ArcFace, Incremental Enrollment, Edge Computing, TensorFlow Lite, Raspberry Pi 4B.

## I. PENDAHULUAN

Keamanan akses pintu merupakan salah satu aspek penting dalam sistem keamanan bangunan karena pintu berperan sebagai titik utama keluar dan masuknya pengguna. Sistem kunci mekanis konvensional masih memiliki berbagai kelemahan, seperti risiko kehilangan atau pencurian kunci, potensi duplikasi oleh pihak yang tidak berwenang, serta tidak tersedianya mekanisme untuk memverifikasi identitas pengguna maupun mencatat riwayat akses secara otomatis, sehingga tingkat keamanan menjadi kurang optimal pada lingkungan yang membutuhkan pengawasan akses secara berkelanjutan [1], [2].

Perkembangan Internet of Things (IoT) mendorong munculnya berbagai perangkat pintar yang mampu melakukan pemantauan dan pengendalian akses secara otomatis, termasuk pada sistem keamanan pintu [3]. Dibandingkan dengan kunci fisik maupun token, autentikasi berbasis pengenalan wajah dinilai memiliki tingkat keamanan yang lebih tinggi karena karakteristik biometrik setiap individu bersifat unik dan relatif sulit dipalsukan [4]. Secara umum, sistem pengenalan wajah terdiri atas empat tahapan utama, yaitu deteksi wajah, preprocessing, ekstraksi embedding, dan pencocokan identitas [5], [6].

Meskipun menawarkan berbagai keunggulan, implementasi pengenalan wajah secara lokal pada perangkat edge computing seperti Raspberry Pi masih menghadapi tantangan berupa keterbatasan komputasi dan memori, serta kualitas citra yang dipengaruhi oleh kondisi pencahayaan maupun karakteristik kamera [7]. Untuk mengatasi hal tersebut, penelitian ini menggunakan MobileFaceNet berbasis TensorFlow Lite sebagai model ringan yang tetap mempertahankan akurasi pengenalan wajah yang tinggi [8], dikombinasikan dengan fungsi loss ArcFace yang memperbesar margin sudut antar identitas sehingga embedding yang dihasilkan menjadi lebih diskriminatif [9]. Sebelum ekstraksi embedding, citra wajah juga diproses melalui pipeline preprocessing berupa face alignment, super resolution, quality assessment, CLAHE, denoising, dan sharpening untuk meningkatkan stabilitas pengenalan pada kondisi pencahayaan yang kurang ideal [10].

Di samping performa pengenalan, efisiensi pengelolaan data pengguna juga menjadi perhatian utama. Penelitian ini menerapkan metode Incremental Enrollment, bagian dari incremental learning, yang memungkinkan sistem menambahkan data wajah pengguna baru secara bertahap tanpa melakukan pelatihan ulang terhadap keseluruhan model [11], sehingga kebutuhan komputasi dapat ditekan dan lebih sesuai diterapkan pada perangkat edge dengan sumber daya terbatas [12].

Penelitian-penelitian terdahulu umumnya membahas model ringan, pipeline preprocessing, atau metode

incremental learning secara terpisah, sehingga belum tersedia gambaran yang komprehensif mengenai integrasi ketiganya dalam satu sistem smart door lock berbasis edge computing. Untuk mengatasi kesenjangan tersebut, penelitian ini mengintegrasikan MobileFaceNet dengan pretrained ArcFace Loss, pipeline preprocessing enam tahap, dan metode Incremental Enrollment dalam satu sistem yang berjalan sepenuhnya secara on-device pada Raspberry Pi 4B, kemudian mengevaluasi efektivitasnya berdasarkan akurasi pengenalan, waktu inferensi, penggunaan sumber daya perangkat, dan pengujian fungsional sistem.

Berdasarkan uraian tersebut, penelitian ini berupaya menjawab pertanyaan penelitian: bagaimana penerapan metode Incremental Enrollment yang didukung oleh pipeline preprocessing pada sistem pengenalan wajah berbasis MobileFaceNet dan ArcFace dapat meningkatkan fleksibilitas pengelolaan pengguna tanpa menurunkan performa autentikasi pada perangkat edge computing. Penelitian ini bertujuan merancang, mengimplementasikan, dan mengevaluasi sistem smart door lock berbasis pengenalan wajah tersebut ditinjau dari aspek akurasi, waktu inferensi, penggunaan sumber daya, dan fungsionalitas sistem.

## II. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimental. Pendekatan kuantitatif dipilih karena penelitian berfokus pada pengukuran kinerja model kecerdasan buatan, sedangkan desain eksperimental digunakan untuk menguji hubungan sebab-akibat antara perlakuan yang diberikan pada sistem (preprocessing, skema enrollment, jumlah identitas terdaftar) dan hasil yang dapat diukur secara numerik, yaitu akurasi pengenalan, latensi inferensi, serta pemanfaatan sumber daya perangkat.

Variabel bebas pada penelitian ini adalah citra wajah berbeda yang ditangkap kamera ESP32-CAM, sedangkan variabel terikat meliputi akurasi recognition, waktu proses enrollment dan recognition, serta beban CPU dan memori pada Raspberry Pi 4B. Variabel kontrol yang dijaga tetap selama pengujian meliputi perangkat Raspberry Pi 4B, kamera ESP32-CAM, model MobileFaceNet berbasis TensorFlow Lite, metode pencocokan cosine similarity, pipeline preprocessing yang diterapkan, serta kondisi pengambilan citra pada jarak sekitar 50–100 cm dengan pencahayaan normal hingga cukup terang.

Objek penelitian adalah sistem pengenalan wajah berbasis edge computing pada Raspberry Pi 4B menggunakan model MobileFaceNet berbasis TensorFlow Lite. Sistem melakukan pemrosesan secara lokal melalui tahapan akuisisi citra menggunakan ESP32-CAM, preprocessing, ekstraksi embedding wajah, penyimpanan

embedding ke dalam basis data SQLite, serta pencocokan identitas menggunakan metode cosine similarity, tanpa memerlukan layanan cloud eksternal. Aktivitas akses dicatat secara otomatis ke dalam basis data PostgreSQL sebagai log sistem.

Tahapan penelitian meliputi studi literatur mengenai smart door lock, autentikasi biometrik, edge computing, dan model lightweight; identifikasi kebutuhan perangkat keras dan perangkat lunak; pengujian model MobileFaceNet pretrained menggunakan dataset benchmark; implementasi pipeline preprocessing dan metode Incremental Enrollment pada perangkat edge; pengembangan manajemen data dan logging; serta integrasi dan pengujian menyeluruh terhadap sistem. Pengujian dilakukan pada kondisi pencahayaan normal hingga cukup terang dengan jarak pengguna sekitar 50 cm hingga kurang dari 100 cm, dan tidak mencakup kondisi pencahayaan ekstrem, wajah tertutup sebagian, anti-spoofing, maupun implementasi aktuator fisik seperti relay atau kunci pintu.

Efektivitas sistem dievaluasi melalui lima pengujian, yaitu pengujian akurasi pengenalan wajah, pengujian pengaruh pipeline preprocessing terhadap akurasi, pengujian waktu inferensi pada tahap enrollment dan recognition, pengujian penggunaan sumber daya perangkat (CPU dan RAM) menggunakan utilitas htop, serta pengujian fungsional sistem menggunakan metode black box testing.

### III. HASIL DAN PEMBAHASAN

#### A. Implementasi Model Pengenalan Wajah

Model pengenalan wajah dibangun menggunakan arsitektur MobileFaceNet yang dikombinasikan dengan fungsi loss ArcFace [13], kemudian dikonversi ke format TensorFlow Lite agar dapat dijalankan pada Raspberry Pi 4B dengan konsumsi sumber daya yang rendah. Proses pelatihan menggunakan dataset MS1M-Refine-V2 yang terdiri atas 5.822.653 citra wajah dari 85.742 identitas berbeda, dengan format TFRecord serta normalisasi citra ke ukuran 112×112 piksel dan augmentasi horizontal flipping.

Evaluasi embedding dilakukan pada dataset LFW menggunakan skema pasangan genuine dan impostor untuk menghitung False Acceptance Rate (FAR), False Rejection Rate (FRR), dan Equal Error Rate (EER). Tabel I menunjukkan perbandingan performa model MobileFaceNet sebelum dan sesudah pretraining menggunakan ArcFace.

| Parameter              | Sebelum | Sesudah | Selisih |
|------------------------|---------|---------|---------|
| Equal Error Rate (EER) | 0,0615  | 0,0600  | ↓0,0015 |
| Threshold saat EER     | 0,2403  | 0,2450  | ↑0,0047 |
| Threshold Terbaik      | 0,359   | 0,403   | ↑0,044  |
| Accuracy Maksimum      | 95,41%  | 96,68%  | ↑1,27%  |

| Parameter   | Sebelum | Sesudah | Selisih |
|-------------|---------|---------|---------|
| FAR Minimum | 0,0000  | 0,0000  | Tetap   |
| FRR Minimum | 0,0173  | 0,0236  | ↑0,0063 |

Tabel I. Hasil Evaluasi Model pada Dataset LFW

Berdasarkan Tabel I, model yang telah dipretrain menggunakan ArcFace Loss menunjukkan peningkatan accuracy maksimum dari 95,41% menjadi 96,68% serta penurunan EER dari 0,0615 menjadi 0,0600, yang menunjukkan peningkatan kemampuan model dalam membedakan wajah dari identitas yang sama maupun berbeda. Model yang sama juga memperoleh akurasi sebesar 97,54% pada dataset CFP-FP yang menguji pasangan citra dengan perbedaan pose frontal dan profile, serta 97,42% pada dataset AgeDB-30 yang menguji perbedaan usia pada citra wajah.

#### B. Pengujian Akurasi Pengenalan Wajah

Pengujian akurasi dilakukan terhadap 100 citra wajah dari 5 pengguna berbeda, masing-masing diuji menggunakan 20 citra dengan variasi arah pandang dan kondisi pencahayaan. Setiap citra diproses melalui preprocessing, ekstraksi embedding, dan pencocokan menggunakan cosine similarity terhadap embedding yang tersimpan pada basis data hasil proses Incremental Enrollment.

| No    | Nama       | Dikenali | Tdk Dikenali | Cosine Sim. |
|-------|------------|----------|--------------|-------------|
| 1     | Beryl      | 20/20    | 0            | 0,90        |
| 2     | Haikal     | 19/20    | 1            | 0,89        |
| 3     | Rafi       | 19/20    | 1            | 0,86        |
| 4     | Varo       | 20/20    | 0            | 0,98        |
| 5     | Wibi       | 20/20    | 0            | 0,98        |
| Total | 5 Pengguna | 98/100   | 2            | 0,92        |

Tabel II. Hasil Pengujian Akurasi Pengenalan Wajah

Berdasarkan Tabel II, sistem berhasil mengenali seluruh citra milik Beryl, Varo, dan Wibi dengan tingkat keberhasilan 100%, sedangkan Haikal dan Rafi masing-masing memiliki satu citra yang gagal dikenali sehingga keberhasilannya mencapai 95%. Secara keseluruhan, dari 100 data uji diperoleh 98 citra dikenali dengan benar sehingga sistem memperoleh akurasi pengenalan sebesar 98%. Hasil ini menunjukkan bahwa metode Incremental Enrollment mampu menambahkan data pengguna baru tanpa menurunkan kemampuan sistem dalam mengenali pengguna yang telah terdaftar sebelumnya.

#### C. Pengujian Pengaruh Preprocessing terhadap Akurasi

Pengujian ini dilakukan untuk mengukur efektivitas pipeline preprocessing dengan membandingkan akurasi pengenalan pada beberapa skenario menggunakan dataset uji yang sama sebanyak 100 citra dari 5 pengguna. Skenario alignment sebagai baseline menghasilkan akurasi sebesar

75,00%. Penambahan super resolution meningkatkan akurasi menjadi 87,50%, sedangkan penerapan CLAHE bright maupun CLAHE dark masing-masing menghasilkan akurasi 81,25%. Kombinasi super resolution dengan CLAHE memberikan performa terbaik sebesar 93,75%, sehingga menunjukkan bahwa peningkatan resolusi disertai perbaikan kontras mampu meningkatkan kualitas citra wajah untuk proses pengenalan.

Sebaliknya, penggunaan denoising maupun sharpening tidak memberikan peningkatan akurasi yang signifikan; skenario alignment + denoising dan alignment + sharpening tetap menghasilkan akurasi 75,00%, sedangkan alignment + sharpening + super resolution hanya mencapai 81,25%. Berdasarkan hasil tersebut, kombinasi alignment + super resolution + CLAHE merupakan konfigurasi preprocessing yang paling efektif meningkatkan performa pengenalan wajah pada penelitian ini.

#### D. Pengujian Waktu Inferensi

Pengujian waktu inferensi mengukur latensi setiap tahapan pipeline, mulai dari preprocessing, deteksi wajah menggunakan Haar Cascade, ekstraksi embedding menggunakan MobileFaceNet, hingga perhitungan cosine similarity, menggunakan 100 sampel citra wajah. Proses enrollment memerlukan rata-rata waktu 1.800,6 ms, terdiri atas preprocessing sebesar 1.625,7 ms dan ekstraksi embedding sebesar 174,9 ms; tanpa super resolution, total waktu enrollment hanya sekitar 436,5 ms. Proses recognition memerlukan rata-rata 1.645,3 ms, terdiri atas preprocessing 1.593,8 ms, deteksi wajah 22,3 ms, ekstraksi embedding 16,6 ms, dan perhitungan cosine similarity 8,1 ms; tanpa super resolution, waktu recognition berkurang menjadi sekitar 311,2 ms.

Preprocessing merupakan komponen utama penyumbang latensi, mencapai sekitar 90,3% dari total waktu pada proses enrollment dan 96,9% pada proses recognition, dengan super resolution sebagai tahapan paling dominan (rata-rata 1.364,1 ms pada enrollment dan 1.333,9 ms pada recognition). Sebaliknya, tahapan lain seperti face alignment, CLAHE, dan sharpening hanya memerlukan beberapa milidetik. Dengan demikian, penggunaan super resolution dapat disesuaikan dengan kebutuhan implementasi: diaktifkan bila sistem memprioritaskan akurasi, atau dinonaktifkan bila sistem mengutamakan kecepatan respons.

#### E. Pengujian Penggunaan Sumber Daya

Pengujian ini mengukur konsumsi CPU dan memori pada Raspberry Pi 4B menggunakan utilitas htop pada tiga kondisi, yaitu idle, proses enrollment, dan proses recognition. Tabel III menyajikan ringkasan hasil pengujian.

| Parameter       | Idle   | Enroll. | Recog. |
|-----------------|--------|---------|--------|
| CPU Tertinggi   | 3,2%   | 94,8%   | 67,3%  |
| Penggunaan RAM  | 454 MB | 595 MB  | 516 MB |
| Persentase RAM  | 12,2%  | 16,0%   | 13,9%  |
| Load Average    | 0,26   | 0,28    | 0,93   |
| Penggunaan Swap | 0 KB   | 0 KB    | 0 KB   |

Tabel III. Hasil Pengujian Penggunaan Sumber Daya

Berdasarkan Tabel III, penggunaan memori meningkat dari 12,2% pada kondisi idle menjadi 16,0% pada proses enrollment dan 13,9% pada proses recognition, sedangkan penggunaan CPU meningkat hingga 94,8% pada enrollment dan 67,3% pada recognition. Tidak ditemukan penggunaan swap memory pada seluruh kondisi pengujian, dan nilai load average tertinggi sebesar 0,93 masih jauh di bawah jumlah inti prosesor Raspberry Pi 4B yang berjumlah empat inti. Hasil ini menunjukkan bahwa sistem mampu beroperasi secara stabil dan efisien pada perangkat edge computing dengan sumber daya terbatas.

#### F. Pengujian Fungsional Sistem (Black Box Testing)

Pengujian black box dilakukan untuk memverifikasi bahwa fungsi utama sistem, meliputi enrollment, recognition, pengelolaan data pengguna, dan penyimpanan embedding, berjalan sesuai kebutuhan yang dirancang. Sebanyak sembilan skenario diujikan, mencakup penambahan pengguna baru, penolakan enrollment ketika wajah tidak terdeteksi atau citra blur, pengenalan pengguna terdaftar, penampilan status unknown untuk pengguna tidak terdaftar, penolakan recognition pada citra buram atau tanpa wajah, penghapusan data pengguna, serta penyimpanan embedding ke basis data. Tabel IV menyajikan sebagian skenario yang representatif.

| No | Skenario                              | Hasil Diharapkan                   | Status |
|----|---------------------------------------|------------------------------------|--------|
| 1  | Penambahan pengguna baru (enrollment) | Data pengguna berhasil ditambahkan | Valid  |
| 2  | Enrollment, wajah tidak terdeteksi    | Enrollment ditolak                 | Valid  |
| 3  | Recognition pengguna terdaftar        | Identitas berhasil dikenali        | Valid  |
| 4  | Recognition pengguna tidak terdaftar  | Status Unknown ditampilkan         | Valid  |

Tabel IV. Ringkasan Hasil Pengujian Fungsional (Black Box Testing)

Seluruh sembilan skenario pengujian black box memperoleh hasil yang sesuai dengan keluaran yang diharapkan sehingga tingkat keberhasilan pengujian mencapai 100%. Hasil ini menunjukkan bahwa mekanisme pengelolaan data pengguna, proses enrollment, dan proses recognition pada sistem telah berfungsi sesuai dengan rancangan.

#### G. Pembahasan

Secara keseluruhan, hasil pengujian menunjukkan bahwa penerapan MobileFaceNet dengan pretrained

ArcFace Loss mampu menghasilkan embedding wajah yang diskriminatif dengan akurasi tinggi pada perangkat edge computing yang memiliki keterbatasan sumber daya, sejalan dengan temuan Zhang dkk. [8] yang menunjukkan bahwa MobileFaceNet sesuai diimplementasikan pada perangkat edge tanpa mengorbankan akurasi. Penerapan pipeline preprocessing, khususnya kombinasi super resolution dan CLAHE, terbukti meningkatkan akurasi pengenalan secara signifikan, namun turut meningkatkan latensi sistem, sehingga mendukung temuan Setiawan dkk. [9] mengenai adanya trade-off antara kualitas citra dan efisiensi komputasi pada sistem pengenalan wajah berbasis edge.

Metode Incremental Enrollment yang diterapkan pada penelitian ini terbukti mampu menambahkan identitas pengguna baru melalui penyimpanan embedding pada basis data SQLite tanpa memerlukan retraining model, sehingga proses pendaftaran pengguna menjadi lebih fleksibel. Temuan ini konsisten dengan penelitian Wang dkk. [12] yang menunjukkan bahwa pendekatan incremental learning dapat mengurangi kebutuhan komputasi pada perangkat edge dengan sumber daya terbatas. Dengan penggunaan memori yang tetap berada pada kisaran 13,9%–16,0% dan tanpa penggunaan swap memory, sistem yang dikembangkan dinilai layak diimplementasikan sebagai solusi autentikasi lokal pada smart door lock berbasis edge computing.

#### IV. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa sistem smart door lock berbasis pengenalan wajah berhasil dirancang dan diimplementasikan pada Raspberry Pi 4B menggunakan ESP32-CAM dan model MobileFaceNet berbasis TensorFlow Lite, dengan seluruh proses autentikasi berjalan secara lokal tanpa server cloud eksternal. Pipeline preprocessing yang terdiri atas face alignment, super resolution, quality assessment, CLAHE, denoising, dan sharpening berhasil diintegrasikan, dengan kombinasi alignment, super resolution, dan CLAHE memberikan akurasi terbaik sebesar 93,75% dibandingkan 75,00% pada penggunaan alignment saja. Metode Incremental Enrollment berhasil diterapkan sehingga sistem mampu menambahkan pengguna baru secara dinamis tanpa retraining model, dengan akurasi pengenalan keseluruhan sistem mencapai 98%.

Model MobileFaceNet yang dipretrain menggunakan ArcFace memperoleh akurasi 97,54% pada dataset CFP-FP dan 97,42% pada AgeDB-30, serta meningkatkan accuracy maksimum pada dataset LFW dari 95,41% menjadi 96,68% dengan penurunan EER dari 0,0615 menjadi 0,0600. Penggunaan memori selama proses enrollment dan recognition berada pada rentang 13,9%–16,0% tanpa swap memory, dan seluruh pengujian fungsional black box testing

berhasil dijalankan sesuai harapan. Penerapan super resolution meningkatkan akurasi pengenalan namun juga meningkatkan waktu pemrosesan, sehingga pipeline preprocessing memberikan pengaruh terhadap keseimbangan antara akurasi dan waktu inferensi sistem.

Penelitian selanjutnya disarankan menggunakan kamera dengan resolusi dan kualitas sensor yang lebih baik untuk meningkatkan kualitas citra wajah, mengeksplorasi model face recognition yang lebih modern dibandingkan MobileFaceNet, serta mengembangkan metode preprocessing yang lebih cepat mengingat proses super resolution berbasis FSRCNN pada penelitian ini masih memerlukan waktu komputasi yang relatif lama.

#### V. REFERENSI

- [1] M. A. Rahman, A. T. Asyhari, and P. Leong, "Smart Building Security: Integrated Access Control and Identity Management Using Edge IoT," *IEEE Internet of Things Journal*, vol. 10, no. 2, pp. 1145–1158, 2023.
- [2] S. Kumar, P. Singh, and A. Sharma, "Vulnerabilities in Traditional Access Control Systems and The Shift Towards IoT-Based Smart Locks," *International Journal of Network Security*, vol. 23, no. 4, pp. 677–685, 2021.
- [3] A. M. Hassan, A. B. Ali, and H. Mohammed, "IoT-Based Smart Home Security Systems: A Comprehensive Review and Future Directions," *IEEE Access*, vol. 10, pp. 45678–45695, 2022.
- [4] A. Alarifi, A. Tolba, and Z. Al-Makhadmeh, "Robust Biometric Authentication System for Smart Buildings based on Deep Learning," *Journal of Information Security and Applications*, vol. 64, 103068, 2022.
- [5] M. Wang and W. Deng, "Deep Face Recognition: A Survey," *Neurocomputing*, vol. 429, pp. 215–244, 2021.
- [6] Authme, "Face Recognition Technology and Authentication Steps," 2024. [Online]. Available: <https://authme.com>
- [7] Y. Liu, C. Yang, L. Jiang, S. Xie, and Y. Zhang, "Edge Intelligence: Architectures, Challenges, and Applications," *IEEE Communications Surveys & Tutorials*, vol. 23, no. 4, pp. 2826–2865, 2021.
- [8] H. Zhang, J. Wu, and M. Li, "Lightweight Face Recognition for Edge Computing based on MobileFaceNet," *Pattern Recognition Letters*, vol. 158, pp. 120–127, 2022.
- [9] B. Setiawan, A. Pratama, and T. Widodo, "Optimization of Face Recognition on Edge Devices Using ArcFace and Lightweight CNNs," *Journal of Computer Science and Information*, vol. 15, no. 1, pp. 45–56, 2023.
- [10] F. Boutros, N. Damer, F. Kirchbuchner, and A. Kuijper, "ElasticFace: Elastic Margin Loss for Deep Face Recognition," in *Proc. IEEE/CVF CVPR Workshops*, 2022.
- [11] G. M. Van de Ven, T. Tuytelaars, and A. S. Tolias, "Three Types of Incremental Learning," *Nature Machine Intelligence*, vol. 4, pp. 1185–1197, 2022.
- [12] X. Wang, Y. Chen, and Z. Liu, "Efficient Incremental Learning for Resource-Constrained Edge Devices," in *Proc. IEEE/CVF ICCV*, 2023, pp. 2134–2143.

- [13] J. Guo, J. Deng, A. Lattas, and S. Zafeiriou, "ArcFace: Additive angular margin loss for deep face recognition," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 43, no. 2, pp. 596–610, 2021.
- [14] P. K. Ayuningtyas, D. Atmodjo, and P. Rachmadi, "Performance And Functional Testing With The Black Box Testing Method," *International Journal of Progressive Sciences and Technologies (IJPSAT)*, vol. 39, no. 2, pp. 212–218, 2023.
- [15] A. Pratama, B. Setiawan, and T. Widodo, "Enhancing IoT Smart Door Lock Security using Image Enhancement and Cosine Similarity," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 2, pp. 310–318, 2023.