

Analysis of the Effect of Data Augmentation Methods on CCTV Image Face Recognition Attendance Systems Using CNN

Vodka Joe Junior^{a1}, I Gede Santi Astawa ^{a2}, I Ketut Gede Suhartana ^{a3}, Ayu Vida Mastrika Giri ^{a4}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Udayana, Jimbaran, Kuta Selatan, Badung, Bali, Indonesia

¹vodkajoe280@gmail.com

²santi.astawa@unud.ac.id

³ikg.suhartana@unud.ac.id

⁴vida@unud.ac.id

Abstrak

Teknologi pengenalan wajah (*face recognition*) berbasis Convolutional Neural Network (CNN) menjadi salah satu pendekatan efektif untuk sistem presensi otomatis. Namun, implementasi real-time masih menghadapi tantangan terkait efisiensi komputasi, biaya perangkat keras, dan variasi kondisi lingkungan. Penelitian ini bertujuan mengimplementasikan sistem presensi otomatis berbasis face recognition menggunakan arsitektur MobileNetV2 yang ringan. Sistem memanfaatkan smartphone sebagai kamera melalui aplikasi iVCam dan antarmuka web interaktif berbasis Streamlit. Penelitian juga menganalisis pengaruh augmentasi data terhadap performa dan ketahanan model dengan membandingkan model tanpa augmentasi dan model dengan augmentasi berupa rotasi, pergeseran, serta variasi kecerahan. Model dengan augmentasi menghasilkan *validation accuracy* sebesar 98,43% dan *validation loss* sebesar 0,1192, lebih baik dibandingkan model tanpa augmentasi yang memperoleh 97,64% dan 0,1518. Kebaruan penelitian ini terletak pada pendekatan augmentasi berbasis manipulasi matriks piksel *element-wise* dan konversi *pseudo 3-channel* yang dirancang spesifik untuk mensimulasikan anomali lingkungan CCTV aktual (seperti *motion blur* dan derau sensor nirkabel). Integrasi metode ini dengan algoritma *timer* 3 detik dan *frame skipping* pada Streamlit berhasil menghasilkan sistem presensi *real-time* yang tangguh terhadap bias cahaya, transparan, dan bebas lag.

Keywords: Pengenalan Wajah, MobileNetV2, Augmentasi Data, Streamlit, Presensi Real-Time, iVCam.

1. Pendahuluan

Pengenalan wajah (*face recognition*) merupakan teknologi biometrik yang berkembang pesat dalam bidang visi komputer dan kecerdasan buatan untuk mengidentifikasi identitas seseorang secara otomatis. Salah satu metode *deep learning* yang paling efektif dan krusial dalam pengolahan citra digital saat ini adalah *Convolutional Neural Network* (CNN)[1]. Keunggulan utama CNN dibandingkan algoritma konvensional terletak pada kemampuannya melakukan ekstraksi fitur (*feature extraction*) secara mandiri dan mempelajari pola visual kompleks secara hierarkis.

Perkembangan arsitektur CNN melahirkan berbagai model yang lebih ringan dan efisien untuk kebutuhan sistem *real-time*, salah satunya adalah MobileNetV2. Arsitektur ini dirancang khusus untuk perangkat dengan keterbatasan komputasi namun tetap mempertahankan performa klasifikasi yang tinggi. Berbagai penelitian menunjukkan bahwa MobileNetV2 mampu bekerja secara efektif pada sistem pengenalan wajah *real-time* maupun sistem *embedded* dengan konsumsi memori yang jauh lebih rendah dibandingkan model CNN berukuran besar[2]. Dan juga studi komparatif membuktikan bahwa MobileNetV2 memiliki keunggulan dalam efisiensi pemrosesan tanpa mengalami penurunan akurasi yang signifikan apabila dibandingkan dengan arsitektur klasik seperti VGG16[3]. Selain pemilihan arsitektur yang ringan, penerapan transfer learning menggunakan bobot awal (*pre-trained weights*) telah terbukti mampu meningkatkan kemampuan generalisasi model pada dataset berukuran terbatas serta mempercepat proses konvergensi selama pelatihan [4]. Di sisi lain, penelitian mengenai

deep face recognition menunjukkan bahwa representasi fitur wajah berbasis CNN modern mampu menghasilkan embedding wajah yang lebih diskriminatif sehingga meningkatkan akurasi identifikasi pada berbagai variasi pose, pencahayaan, maupun ekspresi wajah[5].


Dalam implementasi sistem presensi cerdas di lingkungan akademik, penggunaan kamera *Closed-Circuit Television* (CCTV) pengawas menjadi komponen utama untuk menangkap aliran citra secara *real-time*. Pemanfaatan *smartphone* dengan bantuan aplikasi iVCam sebagai substitusi kamera CCTV aktual telah terbukti menjadi solusi pemantauan yang praktis, ekonomis, dan terintegrasi[6]. Selain perangkat keras, visualisasi antarmuka sistem juga memegang peran krusial. Oleh karena itu, penelitian ini memanfaatkan *framework* Python bernama Streamlit, yang sangat mumpuni dalam membangun aplikasi *machine learning* interaktif untuk mempermudah *monitoring* log kehadiran secara transparan[7].

Tantangan terbesar dalam sistem *face recognition* di lingkungan nyata adalah ketidakkonsistenan posisi objek dan fluktuasi pencahayaan. Meskipun penggunaan MobileNetV2 dan teknik augmentasi telah banyak dieksplorasi pada penelitian terdahulu, sebagian besar pendekatan masih mengandalkan pustaka augmentasi otomatis secara acak tanpa penyesuaian terhadap karakteristik gangguan spesifik dari kamera pengawas. Oleh karena itu, kebaruan (*novelty*) dari penelitian ini terletak pada strategi hibrida pra-pemrosesan dan manipulasi data yang disesuaikan secara spesifik (*domain-specific*) untuk simulasi CCTV ruang kelas.

Secara metodologis, penelitian ini merancang ekstraksi fitur dengan menerapkan konversi *pseudo 3-channel* dari citra *grayscale* untuk mengeliminasi bias iluminasi warna kulit dan cahaya, yang kemudian dikombinasikan dengan teknik augmentasi manipulasi matriks piksel tingkat rendah berbasis elemen (menggunakan operasi NumPy). Strategi augmentasi ini tidak hanya memodifikasi geometri, tetapi difokuskan untuk merekonstruksi anomali aktual pada lingkungan CCTV, seperti *Gaussian noise* akibat kualitas sensor nirkabel yang rendah, *motion blur* akibat pergerakan mahasiswa, dan pergeseran spasial. Selain itu, dari sisi implementasi, kebaruan sistem ini terletak pada integrasi arsitektur ringan tersebut dengan algoritma *frame-skipping* dan logika penguncian berwaktu (*hold-time timer* 3 detik) untuk menciptakan mekanisme *anti-lag* yang kebal terhadap deteksi palsu (*false positive*) pada aliran video resolusi standar. Berdasarkan hal tersebut, penelitian ini difokuskan untuk menguji sejauh mana kebaruan metodologi augmentasi manual ini berpengaruh terhadap akurasi dan ketahanan (*robustness*) model dalam sistem presensi *real-time* terintegrasi.

2. Metode Penelitian

2.1. Tahapan Penelitian



Gambar 1 Alur Tahapan Penelitian

Penelitian ini dilakukan melalui tujuh tahapan yang disusun secara sistematis, yaitu pengumpulan data primer, pra-pemrosesan citra (*preprocessing*), pembagian dataset, penerapan teknik augmentasi data, perancangan dan pelatihan model *Convolutional Neural Network* (CNN) menggunakan arsitektur MobileNetV2, penyusunan skenario evaluasi model, serta implementasi antarmuka sistem absensi. Tahapan tersebut dirancang sebagai rangkaian proses komputasi untuk mengembangkan dan mengevaluasi sistem presensi otomatis *real-time* yang tangguh terhadap variasi kondisi lingkungan kelas.

Berdasarkan Gambar 1, tahap awal dimulai dengan akuisisi data mentah melalui aplikasi iVCam untuk mensimulasikan tangkapan kamera CCTV. Selanjutnya, citra diproses melalui tahap *preprocessing* untuk mendeteksi lokasi, memotong area, dan menyeragamkan ukuran wajah. Dataset yang telah diproses kemudian dibagi menjadi data latih dan data uji. Alur penelitian terbagi menjadi dua skenario pengujian utama: Skenario 1 (*baseline*) di mana data latih murni digunakan tanpa modifikasi, dan Skenario 2 yang menerapkan tahapan augmentasi data berbasis manipulasi matriks pada data latih. Kedua skenario tersebut kemudian dilatih menggunakan arsitektur MobileNetV2. Tahap akhir adalah

evaluasi performa model menggunakan metrik akurasi dan matriks konfusi untuk membandingkan hasil klasifikasi dari kedua skenario tersebut.

2.2. Pengumpulan Data dan Preprocessing



Gambar 2 Contoh Data

Data primer dikumpulkan secara mandiri menggunakan kamera sensor *smartphone* iPhone 14 melalui integrasi aplikasi iVCam. Metode ini dipilih secara khusus untuk menyimulasikan sudut pandang, karakteristik, dan kualitas tangkapan dari kamera CCTV aktual di dalam ruangan kelas. Total dataset yang berhasil diakuisisi adalah 700 citra wajah dari 7 subjek mahasiswa, di mana setiap subjek diklasifikasikan ke dalam kelas berdasarkan Nomor Induk Mahasiswa (NIM).

Sebelum diekstraksi oleh model, citra mentah harus melalui tahap pra-pemrosesan (*preprocessing*). Tahapan ini diawali dengan penerapan algoritma *Haar Cascade Classifier* untuk mendeteksi lokasi wajah pada bingkai kamera, yang dilanjutkan dengan proses pemotongan area wajah (*cropping*). Citra wajah tersebut kemudian diubah ukuran dimensi spasialnya menjadi seragam 224x224 piksel agar kompatibel dengan standar masukan (*input layer*) dari arsitektur MobileNetV2[8]. Setelah ukurannya seragam, citra dikonversi ke dalam ruang warna *grayscale* untuk menyederhanakan intensitas cahaya, dan kemudian digabungkan ulang menjadi matriks *3-channel* tiruan. Visualisasi dari tahapan *preprocessing* ini dapat dilihat pada Gambar 3. Dataset murni ini selanjutnya dibagi menggunakan proporsi 80% data latih (*training data*) dan 20% data uji (*testing data*).


VISUALISASI 1: TAHAPAN PREPROCESSING WAJAH



Gambar 3 Tahapan Preprocessing Wajah

2.3. Skenario Augmentasi dan Pelatihan Model

Untuk mengevaluasi secara objektif mengenai pengaruh keberagaman data terhadap kemampuan sistem, penelitian ini merancang dua skenario utama. Skenario 1 merupakan model *baseline* yang dilatih menggunakan data latih murni tanpa penambahan augmentasi apa pun. Sebaliknya, Skenario 2 menerapkan teknik augmentasi data berlapis secara artifisial pada subset data latih. Teknik augmentasi yang digunakan meliputi rotasi geometris (15 derajat), translasi pergeseran horizontal (20 piksel), penyesuaian intensitas cahaya (*brightness*), pembalikan arah (*horizontal flipping*), dan penambahan derau bintik (*Gaussian Noise*). Contoh visualisasi dari hasil eksekusi teknik augmentasi data ini dapat dilihat pada Gambar 4.wajah.




Gambar 4 Visualisasi Hasil Implementasi Augmentasi Data

Melalui teknik modifikasi matriks berbasis elemen ini, jumlah data latih pada Skenario 2 berhasil diekspansi secara masif menjadi 4.572 citra, yang bertujuan untuk meningkatkan ketahanan (*robustness*), memperkaya distribusi data pelatihan, serta mengurangi kecenderungan *overfitting*, sebagaimana telah banyak dilaporkan pada penelitian mengenai *image data augmentation* untuk model *deep learning*[9]. Proses pelatihan model pada kedua skenario tersebut menggunakan arsitektur *Convolutional Neural Network* tipe MobileNetV2 dengan pendekatan *transfer learning* dari pembobotan ImageNet. Konfigurasi *hyperparameter* yang digunakan meliputi *optimizer* Adam dengan laju pembelajaran (*learning rate*) sebesar 0.0001, fungsi kerugian *categorical crossentropy*, dan dilatih secara iteratif selama 20 *epochs*. Sistem absensi ini kemudian diimplementasikan menjadi aplikasi *real-time* berbasis web menggunakan Streamlit. Untuk menjamin kelancaran *streaming* CCTV, sistem antarmuka dioptimasi dengan teknik pembatasan bingkai (*frame skipping rate* sebesar 3) serta logika penahanan algoritma validasi kehadiran (*hold-time timer* selama 3 detik).

2.4. Perancangan Antarmuka Sistem

Sistem klasifikasi wajah yang telah dilatih selanjutnya diimplementasikan menjadi aplikasi *dashboard* absensi *real-time* berbasis web interaktif menggunakan *framework* Streamlit. Aplikasi ini berfungsi untuk menghubungkan aliran video langsung (*live feed*) dari kamera iVCam dengan model MobileNetV2. Secara keseluruhan, alur kerja dari aplikasi absensi ini mulai dari aktivasi kamera hingga perekaman data dirancang secara sistematis seperti yang dapat dilihat pada Gambar 4.



Gambar 4 Diagram Alur Aplikasi

Untuk menjaga stabilitas kecepatan komputasi dan menghindari penumpukan memori antrian (*lagging*) pada perangkat lokal, sistem ini dioptimasi menggunakan teknik pembatasan bingkai (*frame skipping rate*) sebesar 3. Artinya, proses inferensi pengenalan wajah hanya dieksekusi pada setiap kelipatan tiga bingkai video. Selain itu, sistem mengimplementasikan logika validasi kehadiran berwaktu (*hold-time timer*) sebagai fitur keamanan dari salah deteksi. Apabila wajah mahasiswa berhasil terdeteksi dengan probabilitas keyakinan (*confidence threshold*) di atas 80% secara konsisten selama 3 detik penuh, maka data presensi yang memuat identitas NIM, waktu, dan status akan secara otomatis terekam ke dalam log kehadiran digital.

2.5. Evaluasi Sistem

Tahap akhir dari metode penelitian ini adalah evaluasi performa model. Evaluasi dilakukan menggunakan subset data uji (testing data) sebesar 20% yang telah dipisahkan sejak awal tahap pembagian data. Karena data uji ini bersifat murni dan tidak dilibatkan selama masa pelatihan, metrik yang dihasilkan mampu memberikan gambaran objektif mengenai kemampuan generalisasi arsitektur MobileNetV2 terhadap variasi citra wajah baru (unseen data).


Kinerja model diukur secara menyeluruh dengan memetakan perbandingan antara label identitas aktual dan label hasil prediksi sistem menggunakan matriks konfusi (Confusion Matrix). Berdasarkan pemetaan pada matriks tersebut, kemampuan klasifikasi sistem kemudian dievaluasi menggunakan empat metrik pengujian ilmiah utama, yaitu Accuracy, Precision, Recall, dan F1-Score. Evaluasi terhadap metrik-metrik ini dilakukan secara komparatif antara model Skenario 1 (Tanpa Augmentasi) dan model Skenario 2 (Dengan Augmentasi) untuk membuktikan secara empiris sejauh mana teknik augmentasi data mampu meningkatkan ketahanan (robustness) model dalam mengenali subjek pada berbagai kondisi lingkungan.

3. Hasil dan Pembahasan

3.1. Hasil Pelatihan Model


Kurva pelatihan merepresentasikan dinamika proses belajar model dari *epoch* pertama hingga *epoch* ke-20. Pemantauan dilakukan secara komparatif pada dua metrik utama, yaitu akurasi data latih (*Train Accuracy*) dan akurasi data validasi (*Validation Accuracy*). Hasil evaluasi performa model pada Skenario 1 (Tanpa Augmentasi) dapat dilihat pada Gambar 5.

Berdasarkan Gambar 5, proses pelatihan Skenario 1 menunjukkan peningkatan akurasi yang cukup stabil di awal *epoch*. Model berhasil mencapai nilai akurasi validasi puncak sebesar 97,64%. Namun, pada grafik *Loss*, terlihat adanya kerenggangan (*gap*) yang mulai terbentuk antara kurva *Train Loss* dan *Validation Loss* pada fase akhir *epoch*. Hal ini mengindikasikan bahwa model *baseline* mulai mengalami kecenderungan menghafal data latih murni yang terbatas (*mild overfitting*), sehingga tingkat kerugian pada data validasi tertahan di angka 0,1518.



Gambar 2 Grafik Accuracy dan Loss pada Skenario 1 (Tanpa Augmentasi)

Sebaliknya, kurva pelatihan pada Skenario 2 (Gambar 6) memperlihatkan stabilitas konvergensi yang jauh lebih optimal. Pasokan 4.572 citra hasil augmentasi membuat kurva validasi bergerak sangat rapat dan harmonis mengikuti kurva data latih, meminimalisir jarak *gap* secara signifikan. Model Skenario 2 mencatatkan rekor akurasi validasi yang lebih tinggi, yaitu 98,43%, diiringi dengan tingkat kerugian validasi (*val loss*) yang mampu ditekan hingga 0,1192. Hal ini membuktikan secara empiris bahwa penambahan variasi data berhasil meningkatkan kemampuan generalisasi arsitektur MobileNetV2 secara masif. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa penerapan data augmentation mampu meningkatkan kemampuan generalisasi model CNN melalui peningkatan variasi distribusi data pelatihan sehingga model menjadi lebih stabil terhadap perubahan kondisi lingkungan [10]. Selain itu, perkembangan metode deep face recognition modern seperti ArcFace menunjukkan bahwa penggunaan representasi fitur wajah (face embedding) yang lebih diskriminatif mampu meningkatkan akurasi identifikasi pada berbagai variasi pose dan pencahayaan [5].




Gambar 3 Grafik Accuracy dan Loss pada Skenario 2 (Dengan Augmentasi)

3.2. Hasil Evaluasi Confusion Matrix


Untuk melihat rincian performa klasifikasi pada masing-masing kelas identitas mahasiswa, dilakukan pemetaan visual menggunakan *Confusion Matrix* terhadap 127 citra uji murni (*testing data*).

Berdasarkan Gambar 7 (Skenario 1), model menghasilkan metrik akurasi pengujian rata-rata sebesar 98%. Namun, model mengalami misklasifikasi krusial pada dua kelas, yaitu 2 citra milik NIM 2208561036 yang salah diklasifikasikan sebagai NIM 2208561126, dan 1 citra milik NIM 2208561073 yang salah ditebak sebagai NIM 2208561089. Kesalahan ini terjadi karena terbatasnya variasi sudut pandang citra latih pada Skenario 1, sehingga model rentan tertipu oleh kemiripan fitur geometris parsial antar-subjek.



Gambar 7 Confusion Matrix Skenario 1 (Tanpa Augmentasi)

Penerapan Skenario 2 (Gambar 8) terbukti secara efektif mengatasi bias prediksi tersebut. Kualitas pembagian presisi jauh lebih merata, dan masalah misklasifikasi pada kelas NIM 2208561036 berhasil diselesaikan secara sempurna (akurasi kelas naik menjadi 100%). Meskipun muncul bias minor baru berupa 1 citra yang salah tertebak akibat kemiripan fitur geometris dari sudut pandang spesifik (kasuistik), secara keseluruhan analisis *f1-score* memvalidasi bahwa ekspansi dimensi spasial melalui augmentasi berhasil menyempurnakan struktur ekstraksi ciri biometrik pada jaringan MobileNetV2.



Gambar 8 Confusion Matrix Skenario 2 (Dengan Augmentasi)

3.3. Pengujian Sistem dan Ketahanan (Robustness) Real-Time

Model arsitektur MobileNetV2 yang telah dilatih selanjutnya diimplementasikan ke dalam *dashboard* absensi antarmuka Streamlit. Untuk membuktikan ketahanan sistem di lingkungan nyata, pengujian lapangan dilakukan menggunakan kamera iVCam secara *real-time* dengan menghadirkan variasi posisi (*pose*) dan fluktuasi intensitas pencahayaan (*illumination*).

Pada pengujian variasi posisi wajah (setengah profil maupun mendongak 15 derajat), model Skenario 1 mengalami degradasi performa yang sangat curam, di mana probabilitas pengenalan merosot drastis hingga menyentuh angka 56,9%, menyebabkan sistem gagal mengunci identitas (diklasifikasikan sebagai *Unknown*). Sebaliknya, seperti yang ditunjukkan pada Gambar 9, model Skenario 2 membuktikan ketangguhannya (*robustness*) dengan tetap berhasil mempertahankan nilai probabilitas pengenalan identitas yang stabil di atas ambang batas 80% meskipun fitur geometris wajah subjek mengalami distorsi kemiringan secara dinamis.



Gambar 4 Kepala Miring Menggunakan Augmentasi

Ketangguhan model Skenario 2 juga terbukti pada pengujian kondisi pencahayaan ruang kelas yang minim (Gambar 10). Model Skenario 2 berhasil melewati tantangan pengurangan intensitas cahaya dan tetap memusatkan perhatian klasifikasi pada struktur morfologi wajah subjek, berbeda dengan Skenario 1 yang langsung gagal menangkap kontur rahang akibat tertutup bayangan tebal. Keberhasilan pengenalan konsisten di atas 80% ini secara otomatis memicu algoritma validasi berwaktu (*hold-time timer* 3 detik) untuk merekam presensi mahasiswa ke dalam log kehadiran secara sukses, membuktikan kelancaran sistem (*anti-lag*) secara menyeluruh.



Gambar 10 Menggunakan Augmentasi (Kondisi Gelap)

4. Kesimpulan

Berdasarkan hasil implementasi dan pengujian yang telah dilakukan, dapat disimpulkan bahwa arsitektur jaringan saraf tiruan MobileNetV2 terbukti kapabel untuk mengklasifikasikan identitas wajah mahasiswa pada sistem presensi *real-time* dengan tingkat akurasi pengujian keseluruhan mencapai **98%**. Berdasarkan analisis komparatif, model Skenario 2 (Dengan Augmentasi) menunjukkan performa generalisasi yang jauh lebih unggul dengan nilai *validation accuracy* sebesar **98,43%** dan *validation loss* yang dapat ditekan hingga **0,1192**. Performa tersebut mengungguli model Skenario 1 (Tanpa Augmentasi) yang hanya mendapatkan *validation accuracy* sebesar **97,64%** dan *validation loss* **0,1518**.

Hasil eksperimen secara empiris membuktikan bahwa penerapan teknik augmentasi data (variasi rotasi, pergeseran, dan kecerahan) berpengaruh langsung dalam mengatasi masalah misklasifikasi bias pada kelas tertentu dan meningkatkan ketahanan (*robustness*) model secara signifikan. Pada pengujian *real-time*, model dengan augmentasi terbukti sangat stabil dalam mengenali wajah subjek pada variasi kemiringan posisi dan fluktuasi intensitas cahaya minim. Lebih lanjut, integrasi model ke dalam antarmuka web interaktif Streamlit yang dikombinasikan dengan algoritma penahanan waktu (*hold-time timer* 3 detik) dan optimasi pembatasan bingkai (*frame skipping rate* 3) berhasil menciptakan sistem absensi otomatis berbasis *smartphone* (iVCam) yang fungsional, transparan, dan terhindar dari kendala penumpukan memori (*anti-lag*). Untuk pengembangan penelitian selanjutnya, disarankan untuk memperluas cakupan data latih dengan jumlah subjek yang lebih masif (>7 kelas) guna meningkatkan keberagaman fitur biometrik, serta menghubungkan sistem secara langsung ke dalam basis data seperti MySQL agar perekaman log kehadiran menjadi sepenuhnya otomatis.

Referensi

- [1] N. Ketkar and J. Moolayil, Deep Learning with Python: Learn Best Practices of Deep Learning Models with PyTorch. Apress Media LLC, 2021.
- [2] I. M. S. Sandhiyasa and D. V. Waas, "Real Time Face Recognition for Mobile Application Based on MobileNetV2," Jurnal Multidisiplin Madani, vol. 3, no. 9, pp. 1855–1864, 2023.
- [3] F. D. Adhinata, N. A. F. Tanjung, W. Widayat, G. R. Pasfica, and F. R. Satura, "Comparative Study of VGG16 and MobileNetV2 for Masked Face Recognition," Jurnal Ilmiah Teknik Elektro Komputer Dan Informatika, vol. 7, no. 2, 2021.
- [4] M. Tan and Q. V. Le, "EfficientNetV2: Smaller Models and Faster Training," in Proceedings of the 38th International Conference on Machine Learning (ICML), vol. 139, 2021, pp. 10096–10106.
- [5] J. Deng, J. Guo, N. Xue, and S. Zafeiriou, "ArcFace: Additive Angular Margin Loss for Deep Face Recognition," in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019, pp. 4690–4699.

[6] A. Prasetyo, H. Nugroho, and R. Saputra, "Implementasi CCTV Berbasis Smartphone untuk Monitoring Real-Time," *Jurnal Teknologi Informasi dan Komunikasi*, vol. 12, no. 1, pp. 45–53, 2021.

[7] A. Faisal and R. Maulana, "Implementasi Streamlit pada Pengembangan Aplikasi Machine Learning Interaktif," *CODEX: Jurnal Ilmiah Teknologi Informasi*, 2026.

[8] A. Semma, N. Nurdin, and K. Kusri, "Pengaruh Resize Citra terhadap Akurasi Klasifikasi Menggunakan Convolutional Neural Network," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 4, pp. 755–762, 2021.

[9] K. C. Kirana and S. A. K. Abdulrahman, "Random Multi-Augmentation to Improve TensorFlow-Based Vehicle Plate Detection," *Buletin Ilmiah Sarjana Teknik Elektro*, vol. 6, no. 2, 2024, doi: 10.12928/biste.v6i2.10542.

[10] N. A. Rahmatika, F. Arnia, and M. Oktiana, "Cross-Spectral Cross-Distance Face Recognition via CNN with Image Augmentation Techniques," *Jurnal RESTI*, vol. 8, no. 5, 2024, doi: 10.29207/resti.v8i5.5929.

