

Penerapan Metode Convolutional Neural Network pada Identifikasi Wajah Mahasiswa didalam Ruang Perkuliahan

Rahman M. Abdullah, Mohamad Ilyas Abas, Syahrial*

¹ Fakultas Sains dan Ilmu Komputer, Program Studi Ilmu Komputer, Universitas Muhammadiyah Gorontalo, Gorontalo, Indonesia
Jl. Prof. Dr. H. Mansoer Pateda, Desa Pentadio Timur, Kec. Telaga Biru, Kab. Gorontalo, Indonesia
Email: ¹rahmanabdullah66666@gmail.com, ²ilyasabas@umgo.ac.id, ^{3,*}syahrial@umgo.ac.id

Email Penulis Korespondensi: syahrial@umgo.ac.id

Abstrak—Presensi mahasiswa secara manual masih memiliki berbagai keterbatasan, seperti potensi manipulasi data, *human error*, serta rendahnya efisiensi pada kelas dengan jumlah mahasiswa besar. Penelitian ini bertujuan menerapkan metode *Convolutional Neural Network* (CNN) untuk mengidentifikasi wajah mahasiswa secara simultan di dalam ruang perkuliahan. Dataset penelitian terdiri dari 1.740 citra wajah yang diperoleh dari 58 mahasiswa menggunakan *webcam* 2K Full HD dengan variasi sudut pengambilan dan kondisi pencahayaan berbeda. Tahapan penelitian meliputi pengumpulan data, pra-pemrosesan citra, augmentasi data, pelatihan model CNN, serta evaluasi menggunakan *confusion matrix*, *accuracy*, *precision*, *recall*, dan *F1-score*. Model CNN yang dikembangkan diberi nama FACENET V5 dan dirancang menggunakan TensorFlow dengan tiga blok *convolutional layer*, *batch normalization*, *max pooling*, *dropout*, serta *softmax classifier*. Pengujian dilakukan menggunakan variasi ukuran citra 100×100, 200×200, 300×300, dan 400×400 piksel dengan beberapa skenario pembagian dataset. Hasil penelitian menunjukkan bahwa ukuran citra 100×100 dengan pembagian data 90:10 menghasilkan performa terbaik dengan akurasi validasi sebesar 98,28% dan *loss* sebesar 0,1127. Selain itu, model FACENET V5 dibandingkan dengan ResNet50V2, MobileNetV2, dan VGG16. Hasil komparasi menunjukkan bahwa FACENET V5 memiliki performa paling optimal dalam mengenali wajah mahasiswa secara simultan. Penelitian ini membuktikan bahwa CNN mampu diimplementasikan secara efektif sebagai sistem presensi otomatis berbasis pengenalan wajah di lingkungan akademik.

Kata Kunci: Identifikasi Wajah; Convolutional Neural Network; FACENET V5; Presensi Otomatis; Biometrik

Abstract—Manual student attendance systems still present several limitations, including the potential for data manipulation, human error, and low efficiency in large classroom environments. This study aims to implement the Convolutional Neural Network (CNN) method to simultaneously identify students' faces within a classroom setting. The dataset consisted of 1,740 facial images collected from 58 students using a 2K Full HD webcam under varying capture angles and lighting conditions. The research stages included data collection, image preprocessing, data augmentation, CNN model training, and evaluation using a confusion matrix, accuracy, precision, recall, and F1-score metrics. The developed CNN model, named FACENET V5, was designed using TensorFlow with three convolutional blocks, batch normalization, max pooling, dropout, and a softmax classifier. Experiments were conducted using image sizes of 100×100, 200×200, 300×300, and 400×400 pixels with several dataset split scenarios. The results demonstrated that the 100×100 image size with a 90:10 data split achieved the best performance, obtaining a validation accuracy of 98.28% and a loss value of 0.1127. Furthermore, FACENET V5 was compared with ResNet50V2, MobileNetV2, and VGG16. Comparative results indicated that FACENET V5 provided the most optimal performance in simultaneous student face recognition. This study confirms that CNN can be effectively implemented as an automated face recognition-based attendance system in academic environments.

Keywords: Face Identification; Convolutional Neural Network; FACENET V5; Automated Attendance; Biometrics

1. PENDAHULUAN

Sistem presensi mahasiswa merupakan salah satu komponen penting dalam administrasi akademik perguruan tinggi karena berkaitan langsung dengan validitas partisipasi mahasiswa selama proses pembelajaran berlangsung [1], [2]. Kehadiran mahasiswa tidak hanya digunakan sebagai syarat administratif untuk mengikuti ujian, tetapi juga menjadi indikator kedisiplinan dan keterlibatan mahasiswa dalam proses perkuliahan [1]. Di Universitas Muhammadiyah Gorontalo, proses presensi pada sebagian besar kelas masih dilakukan secara manual menggunakan lembar tanda tangan atau paraf. Metode tersebut memiliki beberapa kelemahan, seperti potensi manipulasi data melalui praktik titip absen, rendahnya efisiensi pada kelas dengan jumlah mahasiswa besar, serta tingginya risiko kehilangan maupun kerusakan dokumen presensi fisik [1], [3]. Selain itu, proses rekapitulasi data kehadiran secara manual membutuhkan waktu relatif lama dan rentan terhadap *human error* [2]. Oleh karena itu, modernisasi sistem presensi melalui penerapan teknologi biometrik berbasis pengenalan wajah menjadi solusi yang relevan untuk meningkatkan akurasi dan efisiensi administrasi akademik [4], [3].

Perkembangan teknologi biometrik memberikan peluang untuk mengatasi berbagai keterbatasan tersebut melalui sistem presensi otomatis. Salah satu teknologi biometrik yang banyak dikembangkan adalah pengenalan wajah (*face recognition*). Teknologi ini dinilai lebih praktis dibandingkan metode biometrik lain, seperti *fingerprint* atau kartu RFID, karena proses identifikasi dapat dilakukan tanpa kontak fisik dan mampu mengenali banyak individu secara simultan dalam satu area pengamatan. Dalam konteks ruang perkuliahan, metode pengenalan wajah memungkinkan mahasiswa melakukan presensi secara otomatis tanpa harus mengantre di depan alat pemindai sehingga proses pembelajaran menjadi lebih efisien dan terstruktur [5], [6].

Dalam bidang *computer vision*, metode *Convolutional Neural Network* (CNN) menjadi salah satu pendekatan yang banyak digunakan untuk klasifikasi citra dan identifikasi wajah [7], [8]. CNN memiliki kemampuan untuk mengekstraksi fitur visual secara otomatis melalui proses konvolusi bertingkat sehingga mampu mengenali pola wajah dengan tingkat akurasi yang tinggi [9]. Lapisan awal CNN umumnya mengekstraksi fitur sederhana seperti garis dan tepi, sedangkan

lapisan yang lebih dalam mampu mengenali fitur kompleks berupa struktur wajah manusia [7], [10]. Kemampuan tersebut membuat CNN banyak diterapkan pada berbagai penelitian pengenalan wajah berbasis *deep learning* [8], [9].

Beberapa penelitian sebelumnya telah mengimplementasikan CNN untuk sistem presensi otomatis berbasis pengenalan wajah [11], [12]. Penelitian oleh [11] menggunakan arsitektur *FaceNet* untuk membangun sistem absensi mahasiswa dan menghasilkan proses identifikasi yang cukup responsif. Penelitian lain menerapkan model *pre-trained* seperti VGG16, MobileNetV2, dan ResNet50V2 karena model tersebut memiliki performa yang baik dalam klasifikasi citra skala besar [12], [13]. Selain itu, beberapa studi juga memanfaatkan teknik *transfer learning* untuk mempercepat proses pelatihan model serta meningkatkan performa klasifikasi wajah [14].

Meskipun demikian, sebagian besar penelitian terdahulu masih menggunakan dataset publik dengan kondisi pencahayaan dan posisi wajah yang relatif homogen [15], [16]. Kondisi tersebut menyebabkan model sering mengalami penurunan performa ketika diterapkan pada lingkungan nyata, khususnya di dalam ruang kelas yang memiliki variasi pencahayaan, sudut pengambilan citra, serta pergerakan mahasiswa yang dinamis. Selain itu, penggunaan model *deep learning* berukuran besar seperti ResNet50V2 dan VGG16 membutuhkan sumber daya komputasi yang tinggi sehingga kurang efisien apabila diimplementasikan pada perangkat keras standar di lingkungan kampus [17], [18].

Berdasarkan permasalahan tersebut, terdapat *research gap* pada penelitian sebelumnya, yaitu belum optimalnya model pengenalan wajah yang mampu bekerja secara akurat pada kondisi ruang kelas nyata dengan kebutuhan komputasi yang lebih ringan [19], [20]. Sebagian penelitian lebih berfokus pada peningkatan akurasi menggunakan model *pre-trained* yang kompleks, namun belum banyak penelitian yang mengembangkan arsitektur CNN kustom dengan jumlah parameter lebih efisien dan tetap mampu mempertahankan performa klasifikasi yang tinggi [21]. Selain itu, masih terbatas penelitian yang menggunakan dataset primer mahasiswa secara langsung dengan variasi kondisi nyata di lingkungan akademik [19], [21].

Kebaruhan (*novelty*) penelitian ini terletak pada pengembangan model CNN kustom bernama FACENET V5 yang dirancang khusus untuk identifikasi wajah mahasiswa pada kondisi ruang kelas nyata [22], [23]. Model ini dikembangkan dengan struktur yang lebih ringan dibandingkan model *pre-trained* sehingga dapat diimplementasikan pada perangkat keras standar tanpa mengurangi performa klasifikasi [24]. Selain itu, penelitian menggunakan dataset primer yang diperoleh langsung dari lingkungan Universitas Muhammadiyah Gorontalo dengan variasi pencahayaan, posisi wajah, dan sudut pengambilan citra yang beragam sehingga model diharapkan memiliki kemampuan generalisasi yang lebih baik terhadap kondisi operasional sebenarnya [22], [25].

Model FACENET V5 dirancang menggunakan beberapa *convolution layer* yang dikombinasikan dengan *Batch Normalization*, *Max Pooling*, dan *Dropout* guna meningkatkan stabilitas pelatihan sekaligus mengurangi risiko *overfitting* [26], [27]. Penelitian ini juga menganalisis pengaruh *hyperparameter*, seperti *optimizer*, resolusi citra, dan skema pembagian dataset terhadap performa model [27]. Dataset penelitian terdiri dari 1.740 citra wajah yang diperoleh dari 58 mahasiswa menggunakan webcam 2K Full HD dengan variasi sudut pengambilan dan pencahayaan alami [28]. Seluruh citra diproses melalui tahap prapemrosesan dan augmentasi data untuk meningkatkan kemampuan generalisasi model terhadap kondisi nyata di ruang kelas [26], [4].

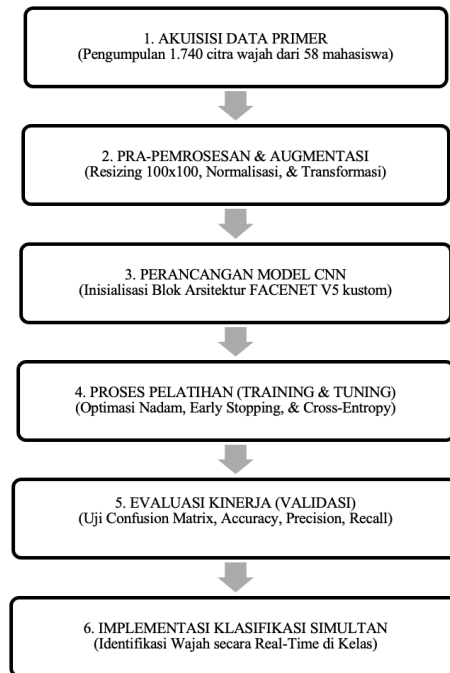
Sebagai metode pembandingan, penelitian ini juga mengimplementasikan model ResNet50V2, MobileNetV2, dan VGG16 untuk mengevaluasi efektivitas model FACENET V5 yang diusulkan [29], [30]. Pengujian dilakukan menggunakan beberapa ukuran citra, yaitu 100×100, 200×200, 300×300, dan 400×400 piksel dengan beberapa skenario pembagian data latih dan data validasi [31]. Evaluasi performa dilakukan menggunakan *confusion matrix* dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score* guna mengukur kemampuan model dalam mengklasifikasikan identitas mahasiswa secara objektif [32], [33].

Berdasarkan uraian tersebut, tujuan penelitian ini adalah mengembangkan dan mengevaluasi model CNN kustom FACENET V5 untuk sistem identifikasi wajah mahasiswa berbasis *deep learning* yang mampu bekerja secara akurat, efisien, dan stabil pada kondisi ruang perkuliahan nyata. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem presensi otomatis berbasis kecerdasan buatan serta mendukung transformasi digital di lingkungan Universitas Muhammadiyah Gorontalo [14], [15].

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui enam tahapan utama yang disusun secara sistematis mulai dari proses pengumpulan data hingga implementasi klasifikasi wajah mahasiswa. Seluruh proses pengembangan sistem dilakukan menggunakan bahasa pemrograman Python dengan bantuan pustaka TensorFlow dan Keras pada lingkungan Visual Studio Code yang memanfaatkan akselerasi GPU [4], [12]. Tahapan penelitian secara umum ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alur

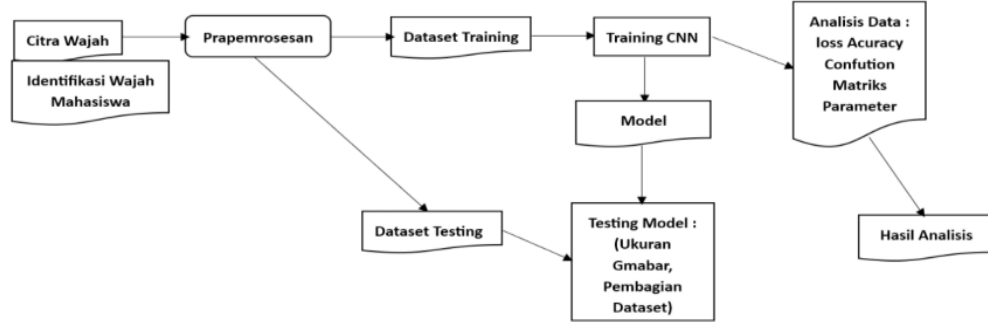
Tahapan penelitian yang ditunjukkan pada Gambar 1 diawali dengan akuisisi data primer berupa pengumpulan 1.740 citra wajah dari 58 mahasiswa Universitas Muhammadiyah Gorontalo menggunakan webcam 2K Full HD dengan variasi posisi wajah, ekspresi, dan pencahayaan [3], [28]. Tahap berikutnya adalah pra-pemrosesan dan augmentasi data yang meliputi *resizing* citra menjadi 100×100 piksel, normalisasi nilai piksel ke rentang $[0,1]$, serta transformasi berupa *rotation* dan *horizontal flip* untuk meningkatkan variasi data pelatihan [13], [26]. Setelah data siap digunakan, dilakukan perancangan model CNN kustom FACENET V5 menggunakan beberapa lapisan *Convolutional 2D*, *Max Pooling*, *Batch Normalization*, dan *Dropout* untuk mengekstraksi fitur wajah secara optimal dengan kompleksitas komputasi yang lebih ringan [10], [30].

Tahap selanjutnya adalah proses pelatihan model (*training* dan *tuning*) menggunakan optimizer Nadam dan fungsi *loss categorical cross-entropy*, serta penerapan *Early Stopping* untuk mencegah *overfitting* dan menjaga stabilitas pelatihan [17], [27]. Model yang telah dilatih kemudian dievaluasi menggunakan *confusion matrix* dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengukur kemampuan klasifikasi identitas mahasiswa [19], [33]. Tahap terakhir adalah implementasi klasifikasi simultan secara *real-time* di dalam kelas untuk mengidentifikasi wajah mahasiswa secara otomatis berdasarkan hasil prediksi model FACENET V5 [5], [15].

2.2 Pengumpulan Dan Prapemrosesan Data

Data yang digunakan dalam penelitian ini merupakan dataset primer yang diperoleh secara langsung di lingkungan Universitas Muhammadiyah Gorontalo menggunakan webcam 2K Full HD [3], [28]. Total dataset terdiri dari 1.740 citra wajah yang berasal dari 58 mahasiswa, dengan setiap individu direpresentasikan oleh 30 citra untuk menangkap variasi ekspresi, sudut pengambilan, serta kondisi pencahayaan yang berbeda. Seluruh data disimpan dalam format JPG dengan kualitas resolusi tinggi sebelum dilakukan proses pengolahan lebih lanjut. Tahap prapemrosesan dilakukan untuk menyeragamkan karakteristik data agar sesuai dengan kebutuhan model pembelajaran mendalam. Proses ini meliputi perubahan ukuran citra menjadi 100×100 piksel serta normalisasi nilai piksel ke rentang $[0,1]$ sehingga proses komputasi menjadi lebih stabil dan efisien [12], [33]. Selanjutnya, teknik augmentasi data diterapkan melalui transformasi rotasi dan *horizontal flipping* untuk memperkaya variasi data pelatihan serta meningkatkan kemampuan generalisasi model terhadap kondisi nyata di lapangan [13], [33].

Setelah melalui tahap tersebut, dataset dibagi menjadi data latih dan data validasi dengan rasio 90:10 guna memastikan keseimbangan antara proses pembelajaran dan evaluasi model. Pembagian ini bertujuan untuk mengukur kemampuan model dalam mengenali data baru yang belum pernah dipelajari sebelumnya sehingga performa sistem dapat dievaluasi secara objektif [17], [27]. Alur keseluruhan proses pengumpulan dan prapemrosesan data ditunjukkan pada Gambar 2.

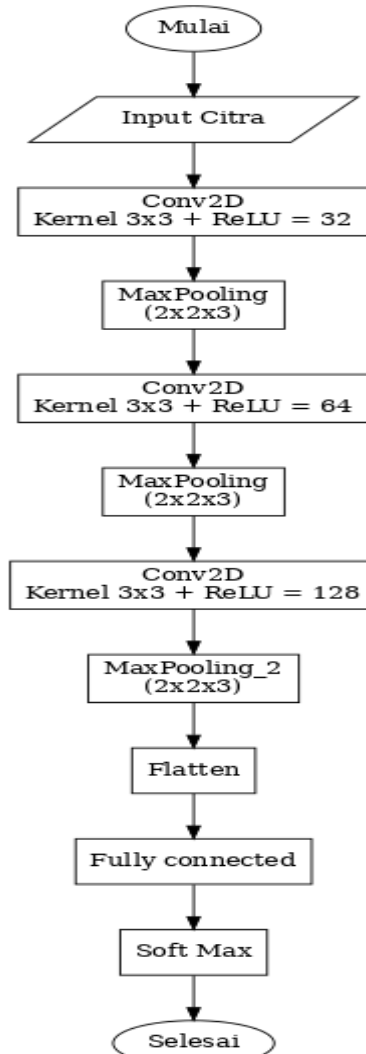


Gambar 2. Diagram Proses Prapemrosesan

2.3 Kajian Metode Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu metode deep learning yang banyak digunakan dalam pengolahan citra digital dan pengenalan wajah. CNN bekerja dengan mengekstraksi fitur citra secara bertingkat melalui proses konvolusi sehingga mampu mengenali pola visual secara otomatis [8], [9]. Pada penelitian ini digunakan model CNN kustom bernama FACENET V5. Arsitektur model terdiri dari beberapa lapisan Convolutional 2D dengan fungsi aktivasi Rectified Linear Unit (ReLU), Max Pooling, Batch Normalization, dan Dropout. Lapisan konvolusi digunakan untuk mengekstraksi fitur wajah, sedangkan Max Pooling berfungsi untuk mereduksi dimensi fitur. Batch Normalization digunakan untuk menjaga stabilitas pelatihan model, sementara Dropout digunakan untuk mengurangi risiko overfitting [26], [27].

Pada lapisan akhir digunakan fungsi aktivasi Softmax dengan 58 neuron output yang merepresentasikan jumlah kelas mahasiswa. Proses optimasi model dilakukan menggunakan optimizer Nadam dengan fungsi loss categorical cross-entropy. Ilustrasi lengkap mengenai struktur dan alur pelatihan model FACENET V5 disajikan pada Gambar 3.



Gambar 3. Arsitektur Model CNN

2.4 Pelatihan Dan Evaluasi Model

Proses pelatihan model FACENET V5 dilakukan menggunakan optimizer Nadam dengan learning rate sebesar 0,001 dan batch size 32. Optimizer Nadam dipilih karena mampu melakukan pembaruan bobot model secara adaptif sehingga proses konvergensi menjadi lebih stabil dan cepat selama pelatihan. Fungsi loss yang digunakan adalah categorical cross-entropy karena penelitian ini termasuk dalam klasifikasi multikelas dengan 58 label identitas mahasiswa [28]. Untuk mengurangi risiko overfitting diterapkan mekanisme Early Stopping yang berfungsi menghentikan proses pelatihan secara otomatis apabila tidak terjadi peningkatan performa model pada data validasi dalam sejumlah epoch tertentu. Seluruh proses pelatihan dilakukan pada lingkungan Visual Studio Code dengan dukungan akselerasi GPU untuk mempercepat proses komputasi [26], [27].

Evaluasi performa model dilakukan menggunakan confusion matrix dan beberapa metrik pengujian, yaitu accuracy, precision, recall, dan F1-score. Accuracy digunakan untuk mengukur tingkat ketepatan prediksi model secara keseluruhan, precision digunakan untuk mengetahui tingkat ketepatan identifikasi pada setiap kelas, recall digunakan untuk mengukur kemampuan model dalam mengenali seluruh data wajah yang seharusnya terdeteksi, sedangkan F1-score digunakan untuk menilai keseimbangan antara precision dan recall. Pengujian ini dilakukan untuk mengetahui kemampuan model FACENET V5 dalam mengklasifikasikan identitas wajah mahasiswa secara tepat dan konsisten pada berbagai kondisi citra [32], [33].

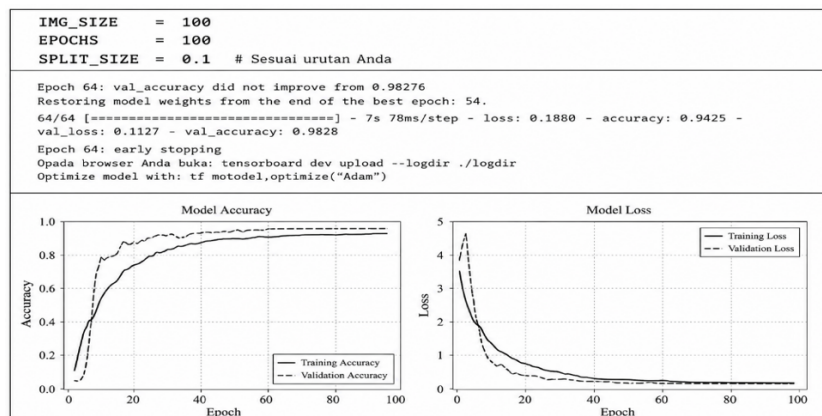
3. HASIL DAN PEMBAHASAN

3.1 Hasil Eksperimen

Penelitian ini bertujuan untuk mengevaluasi kemampuan model Convolutional Neural Network (CNN) kustom FACENET V5 dalam melakukan identifikasi wajah mahasiswa secara otomatis pada sistem presensi berbasis computer vision. Proses identifikasi dimulai ketika citra wajah mahasiswa dimasukkan ke dalam model dengan ukuran input 100×100 piksel. Citra tersebut kemudian diproses melalui beberapa lapisan convolutional untuk mengekstraksi fitur biometrik wajah seperti pola mata, bentuk hidung, kontur wajah, dan tekstur wajah. Setiap lapisan convolutional menggunakan kernel 3×3 dan fungsi aktivasi Rectified Linear Unit (ReLU) untuk menghasilkan representasi fitur non-linear yang lebih kompleks.

Fitur yang dihasilkan kemudian diproses menggunakan lapisan max pooling untuk mereduksi dimensi data sekaligus mempertahankan fitur penting hasil ekstraksi. Proses batch normalization diterapkan untuk menjaga stabilitas distribusi aktivasi selama pelatihan model, sedangkan dropout digunakan untuk mengurangi risiko overfitting. Setelah seluruh fitur berhasil diekstraksi, data diteruskan menuju lapisan flatten dan fully connected layer sebelum dilakukan proses klasifikasi menggunakan fungsi aktivasi Softmax. Fungsi Softmax menghasilkan probabilitas terhadap 58 kelas mahasiswa sehingga sistem dapat menentukan identitas mahasiswa berdasarkan nilai probabilitas tertinggi. Untuk mengukur efektivitas model yang diusulkan, FACENET V5 dibandingkan dengan beberapa model CNN populer, yaitu ResNet50V2, MobileNetV2, dan VGG16 menggunakan parameter pelatihan yang sama. Seluruh model dilatih menggunakan optimizer Nadam dengan learning rate 0,001 serta pembagian dataset sebesar 90:10 antara data latih dan data validasi. Proses pelatihan dilakukan pada lingkungan Google Colab menggunakan akselerasi GPU dengan batas maksimum 100 epoch dan mekanisme early stopping untuk menghentikan pelatihan secara otomatis ketika performa validasi tidak mengalami peningkatan signifikan.

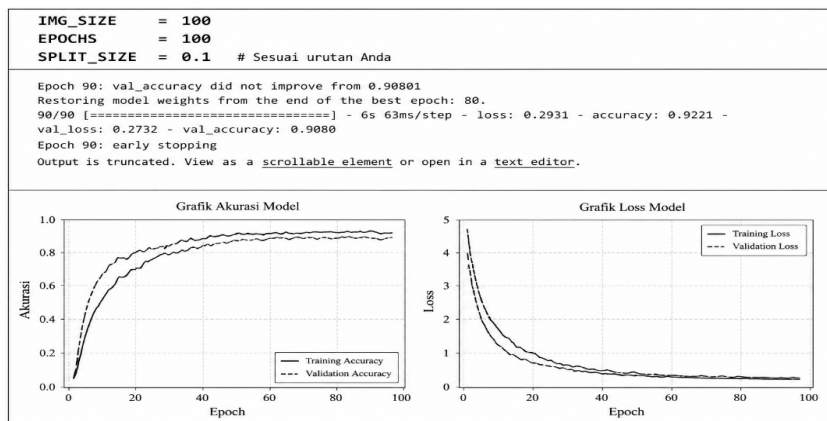
Hasil pelatihan model FACENET V5 ditunjukkan pada Gambar 5. Berdasarkan grafik accuracy dan loss, model FACENET V5 menunjukkan proses pembelajaran yang stabil selama pelatihan berlangsung. Kurva akurasi pelatihan dan validasi mengalami peningkatan secara bertahap sejak epoch awal hingga mencapai titik konvergensi pada epoch ke-64. Pada saat yang sama, nilai loss pelatihan dan validation loss mengalami penurunan secara konsisten tanpa fluktuasi yang signifikan.



Gambar 4. Model buatan Sendiri (FACENET V5)

Model FACENET V5 berhasil memperoleh akurasi pelatihan sebesar 94,25% dan akurasi validasi sebesar 98,28%. Nilai loss pelatihan tercatat sebesar 0,1880 dan validation loss sebesar 0,1127. Perbedaan yang relatif kecil antara performa data latih dan data validasi menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami overfitting secara signifikan. Stabilitas performa ini dipengaruhi oleh kombinasi Batch Normalization dan Dropout yang membantu menjaga distribusi aktivasi neuron selama proses pembelajaran.

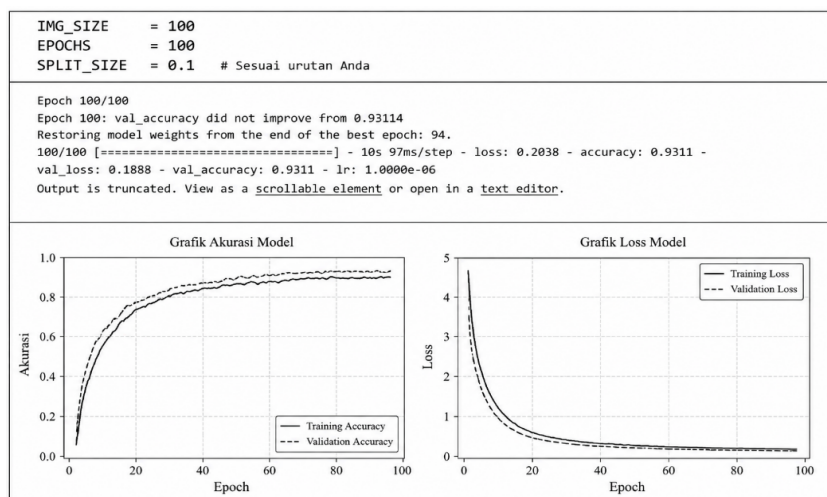
Selain itu, penggunaan resolusi citra 100×100 piksel memberikan keseimbangan antara detail fitur wajah dan efisiensi komputasi. Resolusi tersebut dinilai cukup untuk menangkap karakteristik biometrik mahasiswa tanpa meningkatkan kompleksitas pemrosesan secara berlebihan. Teknik augmentasi data berupa rotation dan horizontal flip juga berkontribusi dalam meningkatkan kemampuan model mengenali variasi sudut wajah dan pencahayaan pada kondisi nyata di lingkungan kampus. Sebagai model pembanding pertama, penelitian ini mengimplementasikan ResNet50V2. Model ini dipilih karena memiliki kemampuan menangani permasalahan vanishing gradient pada jaringan yang dalam melalui residual connection. Hasil pelatihan model ResNet50V2 ditunjukkan pada Gambar 5.



Gambar 5. Model ResNet50V2

Berdasarkan hasil pelatihan, model ResNet50V2 memperoleh akurasi pelatihan sebesar 92,21% dan akurasi validasi sebesar 90,80% dengan validation loss sebesar 0,2732. Proses pelatihan berhenti pada epoch ke-90 melalui mekanisme early stopping. Dibandingkan FACENET V5, model ini membutuhkan jumlah epoch yang lebih banyak untuk mencapai kondisi stabil. Hal tersebut menunjukkan bahwa arsitektur yang lebih dalam memerlukan proses pembelajaran yang lebih kompleks untuk menyesuaikan parameter terhadap dataset primer yang digunakan. Meskipun ResNet50V2 memiliki kemampuan ekstraksi fitur yang baik, jumlah parameter yang besar menyebabkan proses pelatihan menjadi lebih berat dan membutuhkan waktu komputasi yang lebih lama. Pada beberapa epoch awal terlihat adanya fluktuasi pada kurva validasi yang menunjukkan bahwa model memerlukan adaptasi lebih lama terhadap karakteristik dataset lokal. Kondisi ini mengindikasikan bahwa model dengan kompleksitas tinggi tidak selalu memberikan performa optimal pada dataset dengan jumlah sampel yang terbatas.

Penelitian ini juga mengimplementasikan MobileNetV2 sebagai model pembanding kedua. MobileNetV2 dikenal sebagai arsitektur CNN ringan yang dirancang untuk perangkat dengan sumber daya terbatas melalui penggunaan inverted residuals dan linear bottlenecks. Hasil pelatihan MobileNetV2 ditunjukkan pada Gambar 6.

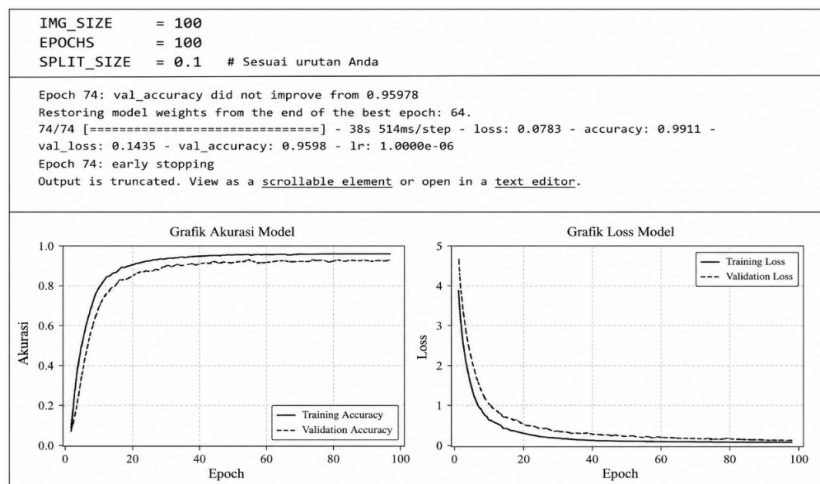


Gambar 6. Model MobileNetV2

Berdasarkan hasil eksperimen, MobileNetV2 menunjukkan performa yang cukup stabil dengan pola konvergensi yang relatif baik. Model ini memiliki penggunaan parameter yang lebih ringan dibandingkan ResNet50V2 dan VGG16

sehingga proses komputasi menjadi lebih efisien. Namun demikian, akurasi validasi yang diperoleh masih berada di bawah FACENET V5. Kondisi tersebut menunjukkan bahwa meskipun MobileNetV2 unggul dalam efisiensi komputasi, model ini masih mengalami kesulitan dalam membedakan fitur biometrik yang memiliki kemiripan tinggi antar mahasiswa. Dataset penelitian yang terdiri dari 58 kelas identitas menyebabkan model harus mengenali karakteristik wajah yang sangat spesifik sehingga dibutuhkan kemampuan ekstraksi fitur yang lebih sesuai dengan kondisi dataset lokal.

Sebagai pembanding terakhir, penelitian ini mengimplementasikan arsitektur VGG16. Model ini menggunakan susunan convolutional layer yang dalam dengan filter berukuran kecil 3x3 secara konsisten untuk mengekstraksi fitur visual secara detail. Hasil pelatihan model VGG16 ditunjukkan pada Gambar 7.



Gambar 7. Model VGG16

Berdasarkan hasil eksperimen, VGG16 memperoleh akurasi pelatihan sebesar 99,11% dan akurasi validasi sebesar 95,98% dengan validation loss sebesar 0,1476. Meskipun menghasilkan akurasi yang tinggi, model ini memiliki jumlah parameter yang jauh lebih besar dibandingkan FACENET V5 sehingga membutuhkan beban komputasi yang lebih tinggi selama pelatihan. Selain itu, terlihat adanya perbedaan yang lebih besar antara akurasi pelatihan dan validasi dibandingkan FACENET V5. Kondisi tersebut menunjukkan bahwa model VGG16 memiliki kecenderungan mengalami overfitting ringan akibat kompleksitas model yang tinggi dibandingkan jumlah dataset yang digunakan. Hal ini menunjukkan bahwa model dengan struktur sangat dalam memerlukan dataset yang jauh lebih besar agar kemampuan generalisasi dapat bekerja secara optimal.

Secara keseluruhan, hasil eksperimen menunjukkan bahwa FACENET V5 mampu memberikan keseimbangan yang baik antara akurasi, stabilitas pelatihan, dan efisiensi komputasi. Model ini mampu mencapai performa validasi tertinggi dengan jumlah parameter yang lebih rendah dibandingkan model pembanding lainnya. Temuan tersebut menunjukkan bahwa arsitektur CNN kustom yang dirancang sesuai karakteristik dataset lokal dapat memberikan performa yang lebih optimal dibandingkan penggunaan model pre-trained generik.

3.2 Analisis Akurasi Dan Loss

Tabel 1. Hasil Pelatihan dan Validasi Tiap Model CNN

Kriteria	FACENET V5	ResNet50V2	MobileNetV2	VGG16
Total Parameter	4,827,898	24,645,690	2,945,658	17,106,298
Akurasi	0.9425	0.9221	0.9234	0.9911
Loss	0.1880	0.2691	0.2539	0.0524
Validasi Akurasi	0.9828	0.9080	0.9080	0.9598
Validasi Loss	0.1127	0.2732	0.4538	0.1476

Berdasarkan Tabel 1, model FACENET V5 menunjukkan performa validasi terbaik dengan nilai validation accuracy sebesar 98,28% dan validation loss sebesar 0,1127. Hasil tersebut menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data wajah yang belum pernah dilihat sebelumnya. Meskipun VGG16 memperoleh akurasi pelatihan tertinggi, model tersebut memiliki jumlah parameter yang jauh lebih besar sehingga memerlukan sumber daya komputasi yang lebih tinggi.

Perbandingan ini menunjukkan bahwa peningkatan jumlah parameter tidak selalu menghasilkan performa validasi yang lebih baik. FACENET V5 dengan jumlah parameter yang lebih ringan mampu menghasilkan performa lebih optimal karena arsitekturnya dirancang sesuai dengan karakteristik dataset penelitian. Penggunaan convolutional layer yang lebih sederhana namun efektif membantu model fokus pada fitur-fitur biometrik penting tanpa meningkatkan kompleksitas jaringan secara berlebihan. Selain itu, validation loss FACENET V5 yang lebih rendah menunjukkan bahwa model mampu mempertahankan stabilitas pembelajaran selama proses pelatihan. Hal ini dipengaruhi oleh penerapan Batch

Normalization dan Dropout yang membantu mencegah overfitting. Dengan demikian, model FACENET V5 dinilai lebih sesuai untuk diterapkan pada sistem presensi otomatis berbasis pengenalan wajah di lingkungan akademik.

3.3 Evaluasi Model dan Confusion Matrix

Evaluasi lebih lanjut dilakukan menggunakan confusion matrix serta metrik precision, recall, dan F1-score untuk mengetahui kemampuan model dalam mengidentifikasi setiap mahasiswa secara spesifik. Hasil evaluasi ditunjukkan pada Tabel 2.

Tabel 2. Confusion Matrix

Label Kelas	Precision	Recall	F1-score
Mahasiswa 1 - 15	1.00	1.00	1.00
Mahasiswa 16	0.75	1.00	0.86
Mahasiswa 17 - 24	1.00	1.00	1.00
Mahasiswa 25	0.75	1.00	0.86
Mahasiswa 26	1.00	0.67	0.80
Mahasiswa 27 - 41	1.00	1.00	1.00
Mahasiswa 42	0.75	1.00	0.86
Mahasiswa 43 - 48	1.00	1.00	1.00
Mahasiswa 49	1.00	0.67	0.80
Mahasiswa 50 - 53	1.00	1.00	1.00
Mahasiswa 54	1.00	0.67	0.80
Mahasiswa 55 - 58	1.00	1.00	1.00
Rata-rata (Macro Avg)	0.98	0.97	0.97

Berdasarkan Tabel 2, sebagian besar kelas mahasiswa memperoleh nilai precision, recall, dan F1-score sebesar 1,00. Hasil tersebut menunjukkan bahwa model mampu mengenali identitas wajah mahasiswa secara tepat tanpa kesalahan klasifikasi yang signifikan. Nilai rata-rata F1-score sebesar 0,97 menunjukkan keseimbangan yang baik antara precision dan recall sehingga model memiliki performa klasifikasi yang stabil. Beberapa kelas seperti Mahasiswa 16, 25, 42, 26, 49, dan 54 menunjukkan penurunan nilai precision atau recall.

Kondisi tersebut mengindikasikan bahwa model masih mengalami kesulitan dalam membedakan beberapa wajah dengan karakteristik biometrik yang mirip atau akibat variasi sudut pengambilan citra yang ekstrem. Namun demikian, jumlah kesalahan klasifikasi yang terjadi relatif kecil dibandingkan total keseluruhan kelas. Hasil confusion matrix juga menunjukkan bahwa sebagian besar prediksi berada pada diagonal utama matriks, yang menandakan bahwa model berhasil memetakan citra wajah ke label identitas yang benar. Hal ini membuktikan bahwa arsitektur FACENET V5 memiliki kemampuan diskriminasi fitur yang baik dalam membedakan karakteristik wajah antar mahasiswa.

3.4 Pembahasan Dan Implikasi

Berdasarkan seluruh rangkaian eksperimen, model CNN kustom FACENET V5 menunjukkan performa yang paling stabil dan efisien untuk sistem identifikasi wajah mahasiswa. Keberhasilan model ini dipengaruhi oleh desain arsitektur yang lebih ringan namun tetap mampu mengekstraksi fitur biometrik secara efektif. Penggunaan tiga convolutional layer bertingkat memungkinkan model mempelajari pola wajah secara bertahap mulai dari fitur sederhana hingga fitur kompleks. Tahap prapemrosesan dan augmentasi data juga memberikan kontribusi penting terhadap peningkatan performa model. Proses resizing membantu menyeragamkan dimensi citra sehingga proses pembelajaran menjadi lebih stabil, sedangkan augmentasi data meningkatkan kemampuan generalisasi model terhadap variasi pencahayaan dan sudut wajah mahasiswa.

Hasil penelitian ini menunjukkan bahwa model CNN kustom yang dirancang sesuai karakteristik dataset lokal mampu memberikan performa lebih baik dibandingkan model pre-trained generik yang memiliki kompleksitas lebih tinggi. Selain menghasilkan akurasi validasi tertinggi, FACENET V5 juga memiliki waktu konvergensi yang lebih cepat dan kebutuhan komputasi yang lebih ringan. Secara praktis, hasil penelitian ini menunjukkan bahwa FACENET V5 memiliki potensi untuk diterapkan sebagai sistem presensi otomatis berbasis pengenalan wajah di lingkungan Universitas Muhammadiyah Gorontalo. Model yang ringan memungkinkan implementasi pada perangkat dengan spesifikasi menengah tanpa membutuhkan perangkat keras berbiaya tinggi. Meskipun demikian, penelitian ini masih memiliki keterbatasan pada jumlah dataset dan kondisi pengambilan citra yang sebagian besar dilakukan di lingkungan dalam ruangan. Penelitian selanjutnya dapat dilakukan dengan menambah jumlah subjek, variasi kondisi pencahayaan ekstrem, serta penggunaan arsitektur CNN yang lebih adaptif untuk meningkatkan kemampuan identifikasi wajah pada kondisi real-time yang lebih kompleks.

4. KESIMPULAN

Penelitian ini telah berhasil mengembangkan dan menguji efektivitas model Convolutional Neural Network (CNN) kustom yang diberi nama FACENET V5 sebagai solusi inovatif untuk sistem identifikasi wajah otomatis 58 mahasiswa di Universitas Muhammadiyah Gorontalo. Berdasarkan serangkaian eksperimen yang dilakukan, arsitektur yang

diusulkan menunjukkan performa yang sangat impresif dengan capaian akurasi validasi sebesar 98,28%, yang secara signifikan melampaui kinerja model state-of-the-art lainnya seperti VGG16 yang mencatatkan akurasi 95,98% dan ResNet50V2 dengan 90,80%. Keunggulan ini divalidasi lebih lanjut melalui analisis confusion matrix yang menunjukkan nilai rata-rata F1-score sebesar 0,97, membuktikan bahwa model memiliki ketangguhan tinggi dalam mengekstraksi fitur biometrik wajah secara presisi meskipun dihadapkan pada tantangan visual seperti variasi ekspresi wajah, sudut kemiringan kepala, hingga penggunaan hijab pada mahasiswi. Keberhasilan teknis ini didorong oleh integrasi desain arsitektur yang efisien, penggunaan optimizer Nadam yang mempercepat pembaruan bobot, serta implementasi strategi augmentasi data yang optimal, sehingga model mampu mencapai titik konvergensi stabil pada epoch ke-64 tanpa menunjukkan indikasi overfitting. Secara praktis, FACENET V5 menawarkan kontribusi nyata bagi institusi akademik melalui penyediaan sistem presensi otomatis yang tidak hanya akurat, tetapi juga hemat sumber daya komputasi dan responsif untuk penggunaan real-time. Penelitian ini menyimpulkan bahwa adaptasi model CNN yang dirancang khusus sesuai karakteristik dataset lokal mampu memberikan hasil yang lebih optimal dibandingkan model generik. Sebagai langkah pengembangan ke depan, integrasi attention mechanism dan perluasan dataset pada kondisi lingkungan luar ruangan yang ekstrem menjadi peluang strategis untuk meningkatkan skalabilitas dan reliabilitas sistem dalam menghadapi kompleksitas kebutuhan administrasi kampus di masa depan.

REFERENCES

- [1] Abdul Muis Mappalotteng, Al Imran, and Mahdaniar, "Pengembangan Sistem Presensi Berbasis Android Pada Mahasiswa Program Studi Pendidikan Teknologi dan Kejuruan Program Pascasarjana UNM," *Inf. Technol. Educ. J.*, vol. 2, no. 2, pp. 13–20, 2023, doi: 10.59562/intec.v2i2.271.
- [2] A. D. Pratama, N. Ariati, and H. Di Kesuma, "Sistem Informasi E-Presensi Mahasiswa Menggunakan QR Code," *J. Sist. Teknol. Inf. Komun.*, vol. 7, no. 1, pp. 15–20, 2023, [Online]. Available: <https://doi.org/10.32524/jusitik.v7i1.1041>
- [3] Muhammad Fauzan Yasykur and Wahyu Andi Saputra, "Implementasi Face Recognition Pada Sistem Presensi Mahasiswa Menggunakan Metode Ssd Dan Lbph," *J. Pendidik. Teknol. Inf. (JUKANTI)*, no. 7, pp. 63–74, 2024, [Online]. Available: <https://doi.org/10.37792/jukanti.v7i1.1207>
- [4] Syahrul Gunawan Ramdhani and Enny Itje Sela, "Implementasi Face Recognition Untuk Sistem Presensi Universitas Menggunakan Convolutional Neural Network," *Indones. J. Comput. Sci.*, vol. 12, no. 6, pp. 4098–4108, 2023, doi: 10.33022/ijcs.v12i6.3498.
- [5] D. A. Menggunakan, F. Satria, D. Hamdhana, and L. Rosnita, "Sistem Presensi Mahasiswa Berbasis Pengenalan Wajah Real-Time dengan," vol. 13, no. 1, pp. 441–450, 2026, doi: 10.30865/jurikom.v13i1.9502.
- [6] T. Widodo, "Penerapan Algoritma Convolutional Neural Network (CNN) pada Aplikasi Presensi Siswa Berbasis Pengenalan Wajah," vol. 7, pp. 459–469, 2025, doi: 10.30865/json.v7i2.9303.
- [7] T. Sarawan, "Klasifikasi Pengenalan Wajah Siswa Pada Sistem Kehadiran Dengan Menggunakan Metode Convolutional Neural Network (CNN)," vol. 6, no. 1, pp. 49–60, 2025, doi: 10.46576/djtechno.
- [8] P. Wajah, F. Yusuf, I. Lesmana, H. P. Bagja, F. I. Komputer, and U. Kuningan, "Implementasi Convolutional Neural Network (CNN) untuk Sistem Presensi Mahasiswa Berbasis Pengenalan Wajah," vol. 11, no. April, pp. 47–56, 2025, [Online]. Available: <https://doi.org/10.25134/buffer.v11i1.367>
- [9] R. A. Saputra, E. Ryansyah, F. M. Setiawan, and C. Rozikin, "Pendeteksi Bahasa Isyarat Menggunakan TensorFlow dengan Metode Convolutional Neural Network," *J. Inform. Dan Rekayasa Komputer(JAKAKOM)*, vol. 5, no. 2, pp. 1723–1731, 2025, doi: 10.33998/jakakom.2025.5.2.2386.
- [10] D. Angeline, E. Jochsen, D. E. Herwindiati, and J. Hendryli, "Performa Metode Convolutional Neural Network Pada Face Landmark Untuk Virtual Make Up Try On," *J. Media Inform. Budidarma*, vol. 7, no. 4, p. 2097, 2023, doi: 10.30865/mib.v7i4.6619.
- [11] R. D. Geralda, A. Irsyad, M. L. Jundillah, S. Informasi, U. Mulawarman, and K. Samarinda, "Implementasi Sistem Presensi Berbasis Face Recognition Menggunakan Model Pra-Latih Facenet Dan Cosine Similarity Dengan Pendekatan Waterfall Pada Website Praktikum Sistem Informasi," vol. 10, no. 2, pp. 2878–2886, 2026, [Online]. Available: <https://doi.org/10.36040/jati.v10i2.17828>
- [12] N. M. K. K. Handayani, E. Y. Hidayat, M. Naufal, and P. L. W. E. Putra, "Pengenalan Ekspresi Wajah Menggunakan Transfer Learning MobileNetV2 dan EfficientNet-B0 dalam Memprediksi Perkelahian," *J. Media Inform. Budidarma*, vol. 8, no. 1, p. 106, 2024, doi: 10.30865/mib.v8i1.7048.
- [13] M. S. Azzahra, S. S. Maesaroh, and R. G. Guntara, "Penggunaan Convolutional Neural Network dan Transfer Learning untuk Rekomendasi Gaya Rambut Pria," *J. Algoritma.*, vol. 21, no. 2, pp. 173–183, 2024, doi: 10.33364/algoritma/v.21-2.2134.
- [14] N. El Furqani, "Penerapan Teknologi Deep Learning Dalam Pengenalan Wajah Untuk Sistem Keamanan," *Tugas Mhs. Progr. Stud. Inform.*, vol. 1, no. 1, pp. 29–37, 2024, [Online]. Available: <https://ejournal.samudrailmu.com/index.php/jfi/article/view/21>
- [15] A. P. Sari and B. Hendrik, "Analisis Komparatif Algoritma Deep Learning untuk Pengenalan Wajah: CNN, FaceNet, dan ArcFace," *J. Educ. Res.*, vol. 6, no. 4, pp. 1029–1036, 2025, doi: 10.37985/jer.v6i4.2178.
- [16] A. S. W. Hidayat, A. Setyanto, and A. Yaqin, "Evaluasi Pengenalan Wajah Menggunakan Facenet Pada Pegawai Dinas Komunikasi Dan Informatika Kota Samarinda," *Inf. Syst. J.*, vol. 8, no. 01, pp. 1–9, 2025, doi: 10.24076/infosjournal.2025v8i01.2015.
- [17] I. Rafi Alfandi, M. Rizki Fadhil, and R. Samsinar, "Analisis Performa Convolutional Neural Network (CNN) dan Naive Bayes dalam Face Recognition: Akurasi dan Kompleksitas," *Semin. Nas. Call Pap. Hubisintek*, pp. 284–294, 2024, [Online]. Available: <https://www.ojs.uib.ac.id/HUBISINTEK/article/view/4758>
- [18] S. A. S. Mola, B. O. D. K. Wadu, A. N. Kenlopo, and V. C. K. Tungga, "Perbandingan Arsitektur ResNet50V2, InceptionV3, dan DenseNet121 dalam Klasifikasi Pengenalan Ekspresi Wajah," *JIKO (Jurnal Inform. dan Komputer)*, vol. 9, no. 2, p. 285, 2025, doi: 10.26798/jiko.v9i2.1584.
- [19] E. Febiyani, Z. Hanni Pradana, and I. Permatasari, "[15] Analisis Sistem Monitoring Presensi Menggunakan Face Recognition

- Berbasis CNN dengan Arsitektur MobileNetV1,” *J. SINTA Sist. Inf. dan Teknol. Komputasi*, vol. 2, no. 3, pp. 95–102, 2025, [Online]. Available: <https://doi.org/10.61124/sinta.v2i3.83>
- [20] L. H. Romadhoni and F. Ardiani, “Perancangan Sistem Face Recognition Berbasis Deep Learning Menggunakan Pre-Trained Model Arcface,” *J. Inf. Syst. Manag.*, vol. 7, no. 2, pp. 186–191, 2026, doi: 10.24076/joism.2026v7i2.2415.
- [21] S. K. Nisa, R. R. Mardi, and B. H. Prasetyo, “Sistem Monitoring Kondisi Emosi pada Sesi Konseling Menggunakan Face Recognition Berbasis Landmark dan Multi Layer Perceptron (MLP),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 11, pp. 2548–964, 2025, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/15646>
- [22] K. Anwar, “Sistem Deteksi Wajah Berbasis Deep Learning Menggunakan Convolutional Neural Network (CNN),” *J. Comput. Sci. Inf. Technol.*, vol. 1, no. 2, pp. 46–52, 2025, doi: 10.70716/jocsit.v1i2.258.
- [23] S. Nanda, D. Aditya, and T. Informatika, “Sistem Presensi Mahasiswa Berbasis Pengenalan Wajah Parsial Menggunakan Metode CNN Pada Kondisi Penggunaan Masker,” vol. 5, pp. 405–410, 2026, [Online]. Available: <https://doi.org/10.29407/pegppe71>
- [24] T. Raharjo *et al.*, “Analisis Forensik Deepfake Berbasis Convolutional Neural Network (Cnn) Untuk Deteksi Inkonsistensi Tekstur Dan Pola Pada Citra Wajah,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 2, pp. 2731–2738, 2025, doi: 10.36040/jati.v9i2.13058.
- [25] M. Chaska, P. Sofyan, and J. Aryanto, “Bulletin Of Computer Science Research Penggunaan Model Inceptionv3 Berbasis Transfer Learning untuk Mendeteksi Masker Wajah Secara Real-Time,” vol. 6, no. 1, pp. 268–274, 2025, doi: 10.47065/bulletincsr.v6i1.865.
- [26] G. I. Fiyoriirly *et al.*, “Standarisasi Terhadap Akurasi Model Cnn Pada Klasifikasi,” vol. 06, no. 02, pp. 1–11, 2025, doi: 10.32485/jcsai.dalam.
- [27] K. Ratna Mutu Manikam, L. Joni Erawati Dewi, K. Yota Ernanda Aryanto, K. Agus Seputra, and P. Varnakovida, “Analisis Hyperparameter Pada Klasifikasi Jenis Tanaman Menggunakan Algoritma Resnet50 Dan Mobilenetv2,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 6, pp. 9921–9928, 2025, doi: 10.36040/jati.v9i6.15832.
- [28] L. Susanti, N. K. Daulay, and B. Intan, “Sistem Absensi Mahasiswa Berbasis Pengenalan Wajah Menggunakan Algoritma YOLOv5,” *JURIKOM (Jurnal Ris. Komputer)*, vol. 10, no. 2, p. 640, Apr. 2023, doi: 10.30865/jurikom.v10i2.6032.
- [29] T. S. Winanto, C. Rozikin, and A. Jamaludin, “Analisa Performa Arsitektur Transfer Learning Untuk Mengidentifikasi Penyakit Daun Pada Tanaman Pangan,” *J. Appl. Informatics Comput.*, vol. 7, no. 1, pp. 68–81, 2023, doi: 10.30871/jaic.v7i1.5991.
- [30] M. Khatama Insani and D. Budi Santoso, “Perbandingan Kinerja Model Pre-Trained CNN (VGG16, RESNET, dan INCEPTIONV3) untuk Aplikasi Pengenalan Wajah pada Sistem Absensi Karyawan,” *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 2612–2622, 2024, [Online]. Available: <https://journal.stmiki.ac.id>
- [31] G. E. P. Purba, S. Hadi Wijoyo, and N. Y. Setiawan, “Pengaruh Transfer Learning ResNet dan DenseNet Terhadap Performa Klasifikasi Ekspresi Wajah Menggunakan Dataset FER-2013,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 7, pp. 1–9, 2024, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/13931>
- [32] A. Info, “Sentiment Analysis On The Face Recognition Feature At PT KAI,” vol. 8, no. 1, pp. 170–187, 2026.
- [33] N. P. Sari, “Analisis Performa Algoritma CNN dalam Klasifikasi Citra Medis Berbasis Deep Learning,” *J. Komput.*, vol. 2, no. 2, pp. 87–92, 2024, doi: 10.70963/jk.v2i2.113.