

## **Klasifikasi Rentang Usia Berdasarkan Citra Wajah Menggunakan Convolutional Neural Network**

**Fazila Nazifa Edilia<sup>1</sup>, Tiara Amanda Lestari<sup>2</sup>, M. Rifqi Arrafi<sup>3</sup>, Fauhan Alfarizi Saragih<sup>4</sup>,**

**Adli Rahman Harun Harahap<sup>5</sup>, Mhd. Furqan<sup>6</sup>**

<sup>1,2,3,4,5,6</sup> Ilmu Komputer, Universitas Negeri Sumatera Utara

Email: <sup>1</sup>fazilanazifaedilia@gmail.com, <sup>2</sup>tiaraamanda7888@gmail.com, <sup>3</sup>rifqyarrafi697@gmail.com, <sup>4</sup>alfarizisiantar2017@gmail.com,

<sup>5</sup>adliharahap1123@gmail.com, <sup>6</sup>mfurqan@uinsu.ac.id

Email Penulis Korespondensi: fazilanazifaedilia@gmail.com

### **Abstrak**

Klasifikasi usia berbasis citra wajah memegang peran krusial dalam berbagai bidang, mulai dari sistem keamanan hingga analisis pasar digital. Dalam studi ini, dikembangkan pendekatan klasifikasi menggunakan Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2 untuk mengkategorikan usia ke dalam empat kelompok: anak, remaja, dewasa, dan lansia. Sebanyak 3.250 citra wajah dari platform Kaggle diproses melalui tahap normalisasi dan augmentasi guna meningkatkan variasi dan mengurangi overfitting. Hasil pengujian menunjukkan bahwa model yang dibangun dengan teknik transfer learning ini mencapai akurasi 84% pada data validasi, dengan performa terbaik di kelas dewasa. Namun demikian, kelas dengan data lebih sedikit menunjukkan kinerja lebih rendah, mengisyaratkan perlunya penanganan khusus untuk ketidakseimbangan data. Temuan ini memperkuat potensi CNN untuk klasifikasi usia, sekaligus menyoroti pentingnya strategi data yang lebih berimbang.

**Kata Kunci:** Klasifikasi Usia, Citra Wajah, Convolutional Neural Network, MobileNetV2, Transfer Learning.

### **Abstract**

Facial image-based age classification holds a crucial role across various fields, ranging from security systems to digital market analysis. In this study, a classification approach was developed using a Convolutional Neural Network (CNN) with the MobileNetV2 architecture to categorize age into four groups: children, adolescents, adults, and the elderly. A total of 3,250 facial images from the Kaggle platform were processed through normalization and augmentation stages to increase data variation and reduce overfitting. Testing results demonstrate that the model, built using transfer learning techniques, achieved 84% accuracy on validation data, with its best performance in the adult class. However, classes with fewer data samples exhibited lower performance, indicating the need for specialized handling of data imbalance. These findings reinforce the potential of CNNs for age classification while highlighting the importance of a more balanced data strategy.

**Keywords:** Age Classification, Facial Images, Convolutional Neural Network, MobileNetV2, Transfer Learning.

## **1. PENDAHULUAN**

Pengenalan ekspresi wajah merupakan kemampuan esensial untuk hubungan interpersonal yang baik, dan merupakan sebuah subjek dalam studi pada bidang perkembangan manusia (human development), kesehatan psikologis (psychological well-being), dan penyesuaian social (social adjustment) [1].

Wajah merupakan bagian tubuh manusia yang paling mudah dikenali dan paling sering menjadi perhatian orang lain. Selain itu, wajah berperan penting sebagai media untuk berkomunikasi serta menampilkan berbagai ekspresi emosi [2]. Seiring dengan pesatnya perkembangan teknologi, berbagai inovasi semakin canggih dan banyak dimanfaatkan dalam kehidupan sehari-hari. Salah satu bentuk pemanfaatannya adalah sistem pengolahan citra, termasuk teknologi pengenalan wajah [3]. Wajah merupakan salah satu karakteristik yang merupakan bagian dari identitas seseorang. Selain sebagai identitas, wajah juga merupakan alat pendukung dalam bersosialisasi secara langsung [4].

Citra sangat dibutuhkan dalam melakukan klasifikasi wajah salah satunya adalah informasi tentang jenis kelamin, usia, ras, dan ekspresi. Klasifikasi wajah menjadi tantangan sendiri mengingat ragamnya bentuk wajah manusia. Tingkat akurasi dalam klasifikasi menjadi tolak ukur terhadap kesuksesan dalam identifikasi wajah [5].

Meskipun fitur wajah dapat mengindikasikan usia, klasifikasinya melalui citra merupakan tantangan kompleks akibat keragaman karakteristik individu seperti tekstur kulit, kerutan, dan perubahan struktur wajah [6]. Di sisi lain, kemajuan AI dalam menganalisis pola kompleks ini ironisnya juga memicu munculnya deepfake yang berpotensi menyebarkan misinformasi dan pencurian identitas [7].

Oleh karena itu, pengembangan model yang cakap tidak hanya dalam klasifikasi usia tetapi juga deteksi manipulasi menjadi kebutuhan mendesak [8]. Dalam konteks ini, Convolutional Neural Network (CNN) menawarkan solusi potensial. Kemampuannya mengekstraksi fitur visual seperti kontur dan tekstur secara optimal, yang telah terbukti dalam identifikasi wajah dan pengenalan ekspresi, menjadikannya kandidat ideal untuk estimasi usia, terlebih ketika dipadukan dengan teknik deteksi wajah yang akurat [9].

Convolutional Neural Network merupakan jenis dari Deep Neural Network yang didesain untuk mengolah data dua dimensi dengan kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra [10]. Dalam proyek pemrosesan gambar terdapat algoritma yang dipakai Convolutional Neural Network (CNN) [11]. Keandalan ini membuatnya sangat cocok untuk estimasi usia yang mengandalkan detail tekstur dan struktur wajah [12].

Deep learning terus meningkatkan performa pengenalan wajah melalui arsitektur CNN yang dapat menghasilkan representasi fitur yang stabil meskipun terdapat variasi. Tantangan utama tetap pada optimalisasi model, yang bergantung pada kualitas data, augmentasi, dan pemilihan arsitektur untuk memastikan konsistensi di kondisi nyata. Implementasi CNN yang tepat diharapkan dapat menghasilkan sistem yang andal dan siap diterapkan [13].

Dengan adanya kemajuan teknologi kecerdasan buatan dan pembelajaran mesin, sistem deteksi wajah mampu mengenali berbagai ekspresi, sudut pandang, dan pencahayaan dengan lebih akurat dan efisien [14].

Selain pengembangan arsitektur CNN, peningkatan kualitas data juga menjadi faktor penting dalam keberhasilan klasifikasi usia berbasis citra wajah. Dataset yang memiliki variasi ekspresi, resolusi, sudut pandang, dan kondisi pencahayaan dapat membantu model belajar mengenali fitur wajah secara lebih menyeluruh. Teknik augmentasi seperti rotasi, flipping, zooming, dan penyesuaian kontras terbukti mampu memperluas keragaman data tanpa harus menambah jumlah sampel secara manual. Dengan data yang lebih bervariasi, model memiliki kemampuan generalisasi yang lebih baik terhadap kondisi nyata [15].

Selain augmentasi, penggunaan teknik transfer learning semakin banyak dimanfaatkan karena mampu mempercepat proses pelatihan dan meningkatkan akurasi. Model pra-latih seperti MobileNetV2, VGG16, atau ResNet telah mempelajari fitur dasar citra dalam skala besar sehingga dapat digunakan kembali pada domain klasifikasi usia. Pendekatan ini sangat membantu terutama ketika jumlah data pelatihan terbatas atau tidak seimbang antar kelas, sehingga performa model tetap stabil meskipun variasi data tidak terlalu besar [16].

Dalam konteks pemodelan CNN untuk klasifikasi usia, perhatian juga diberikan pada pemilihan fungsi aktivasi, ukuran kernel, dan jumlah lapisan convolutional. Parameter-parameter tersebut berpengaruh langsung terhadap kemampuan model dalam mengekstraksi fitur penting seperti garis wajah, tekstur kulit, dan pola kerutan. Peningkatan kedalaman jaringan sering kali mampu meningkatkan akurasi, namun harus diimbangi dengan mekanisme regularisasi untuk mencegah overfitting, seperti dropout dan batch normalization [17].

Beberapa penelitian juga menunjukkan efektivitas penggabungan CNN dengan pendekatan modern seperti attention mechanism, yang memungkinkan model memberikan fokus lebih besar pada area wajah yang relevan untuk penentuan usia. Area seperti sekitar mata, dahi, dan garis senyum merupakan bagian yang sangat dipengaruhi oleh proses penuaan sehingga pemodelan berbasis attention memungkinkan peningkatan presisi dalam klasifikasi. Pendekatan ini memperkuat kinerja CNN terutama pada dataset dengan detail wajah yang beragam [18].

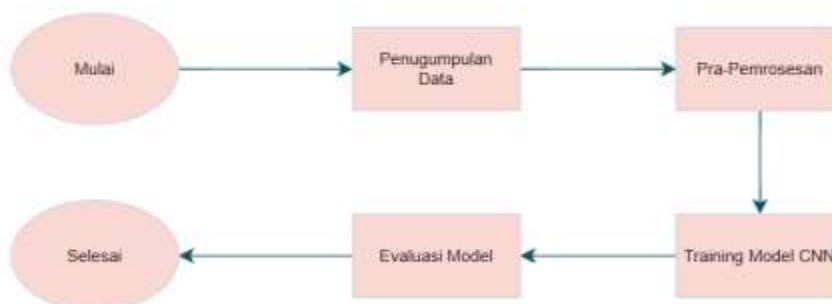
Tidak hanya untuk klasifikasi usia, pendekatan CNN juga telah diterapkan dalam berbagai aplikasi lain seperti deteksi manipulasi wajah, pengenalan identitas, dan analisis ekspresi. Konsistensi performa CNN di berbagai bidang menunjukkan bahwa metode ini memiliki kemampuan representasi fitur visual yang kuat dan fleksibel terhadap berbagai skenario. Oleh karena itu, pemanfaatan CNN pada klasifikasi usia menjadi solusi andal yang dapat diimplementasikan pada sistem berbasis keamanan, monitoring, maupun layanan otomatis berbasis kecerdasan buatan [19].

Dengan semakin berkembangnya teknologi pembelajaran mendalam, arsitektur CNN terus mengalami pembaruan untuk meningkatkan efisiensi dan akurasi. Penggunaan model yang lebih ringan namun tetap akurat seperti MobileNetV2 dan EfficientNet menjadikan implementasi klasifikasi usia dapat diterapkan tidak hanya pada perangkat komputer berkinerja tinggi, tetapi juga pada perangkat bergerak seperti smartphone. Hal ini membuka peluang penerapan klasifikasi usia secara real-time pada aplikasi yang membutuhkan respons cepat dan efisien [20].

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Penelitian ini mengadopsi metode deep learning dengan arsitektur MobileNetV2 guna mengklasifikasikan citra wajah ke dalam empat kelompok usia: Anak, Remaja, Dewasa, dan Lansia. Metodologi disusun secara sistematis, meliputi akuisisi dan penyiapan data, pra-pemrosesan dan augmentasi, pelatihan model, hingga evaluasi akhir. Rancangan ini bertujuan menghasilkan model yang optimal berdasarkan karakteristik dataset yang ada.



Gambar 1. Diagram metodologi penelitian

## 2.2 Pengumpulan Data

Pada tahap akuisisi data, dilakukan penggabungan dataset citra wajah dari dua direktori berbeda, yakni faces dan faces\_02. Dataset gabungan ini kemudian diklasifikasikan secara manual ke dalam empat kelas berdasarkan rentang usia: anak, remaja, dewasa, dan lansia.



Gambar 2. Dataset wajah

## 2.3 Pra-pemrosesan

Setiap citra diubah ukurannya menjadi 224×224 piksel dan dinormalisasi ke rentang [0,1]. Normalisasi dilakukan dengan membagi nilai piksel citra dengan nilai maksimum 255, yang dirumuskan sebagai:

$$x' = \frac{x}{255} \quad (1)$$

Untuk meningkatkan keragaman data dan mencegah *overfitting*, diterapkan augmentasi menggunakan *ImageDataGenerator*, yang meliputi rotasi, *shift*, *zoom*, *horizontal flip*, dan variasi kecerahan. Data dibagi dengan rasio 80:20 untuk pelatihan dan validasi. Guna mengatasi ketidakseimbangan kelas, diterapkan pembobotan (*class weighting*) pada setiap kategori selama pelatihan.

## 2.4 Training Model CNN

Model menggunakan arsitektur MobileNetV2 yang telah dilatih sebelumnya (*pre-trained*) pada dataset ImageNet. Pada tahap awal, lapisan dasar (*base layers*) dibekukan (*freeze*) dan ditambahkan lapisan Global Average Pooling, Dropout, serta Dense dengan 128 neuron sebelum lapisan output softmax.

Fungsi softmax digunakan untuk menghasilkan probabilitas prediksi pada setiap kelas, yang dirumuskan sebagai:

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (2)$$

Dengan  $z_i$  merupakan nilai logit untuk kelas ke- $i$  dan  $K$  adalah jumlah total kelas. Pelatihan dilakukan dalam dua fase, yaitu fase *warm-up* selama 7 epoch dengan *learning rate*  $1e-4$ , kemudian dilanjutkan fase *fine-tuning* selama 10 epoch dengan *learning rate*  $1e-5$ , di mana sebagian lapisan dasar dibuka kembali untuk menyesuaikan bobot model terhadap data pelatihan. Proses pelatihan dimonitor menggunakan *callback* EarlyStopping, ReduceLROnPlateau, dan ModelCheckpoint.

## 2.5 Evaluasi Pembahasan

Kinerja model diuji menggunakan data validasi dengan metrik akurasi, precision, recall, dan F1-score pada setiap kelas. Evaluasi ini bertujuan untuk mengukur kemampuan model dalam melakukan klasifikasi secara tepat dan seimbang pada seluruh kategori. Confusion matrix digunakan untuk menganalisis distribusi hasil prediksi serta mengidentifikasi kesalahan klasifikasi yang terjadi. Nilai precision, recall, dan F1-score dihitung berdasarkan jumlah *true positive* (TP), *false positive* (FP), dan *false negative* (FN), yang dirumuskan sebagai berikut:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4)$$

$$\text{F1-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

Evaluasi dilakukan pada model terbaik yang tersimpan secara otomatis selama proses pelatihan. Hasil evaluasi ini selanjutnya digunakan sebagai landasan analisis pada bab pembahasan.


# 3. Hasil Dan Pembahasan

## 3.1 Hasil Pelatihan Model

Proses pelatihan model CNN berlangsung selama 13 epoch. Pada grafik akurasi, terlihat peningkatan kinerja di fase awal, dengan akurasi validasi mencapai puncak sekitar 0.85 pada epoch ke-7. Setelah titik tersebut, akurasi pelatihan mulai mengalami penurunan, sementara akurasi validasi berfluktuasi dalam kisaran sempit. Pola ini mengisyaratkan

bahwa model telah berhasil menangkap pola dasar dari data, namun menunjukkan gejala overfitting ringan pada fase akhir pelatihan.

Sementara itu, training loss menurun di awal namun meningkat tajam di pertengahan epoch, sedangkan validation loss relatif stabil pada rentang 0.4–0.7. Perbedaan tren antara kedua kurva loss tersebut memperkuat dugaan bahwa model lebih mudah beradaptasi dengan kelas yang dominan dibandingkan dengan kelas yang jumlah sampelnya lebih sedikit.

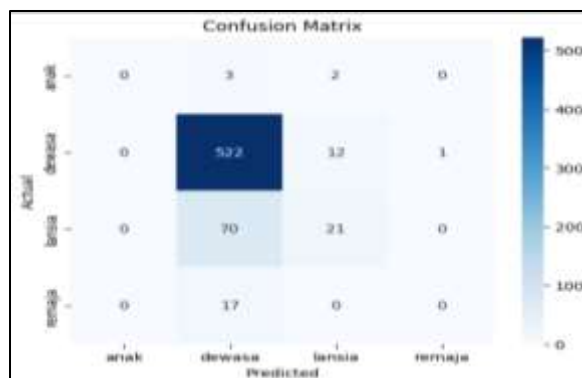


Gambar 3. Grafik akurasi dan loss selama proses pelatihan

## 3.2 Evaluasi Kinerja Model

Evaluasi model dilakukan dengan menganalisis confusion matrix dan classification report. Berdasarkan confusion matrix, model mencatat kinerja terbaik pada kelas dewasa, dengan 522 prediksi yang tepat. Hal ini diduga kuat disebabkan oleh distribusi data kelas dewasa yang lebih banyak dan representatif. Pada kelas lansia, model berhasil mengidentifikasi 21 sampel dengan benar dari total 91 data, menunjukkan performa yang sedang. Di sisi lain, model sama sekali tidak berhasil memprediksi kelas anak dan remaja dengan akurat, di mana tidak ada satu pun prediksi benar yang dihasilkan untuk kedua kelas tersebut.

Classification report memperlihatkan bahwa kelas dewasa meraih precision 0.85, recall 0.98, dan f1-score 0.91, yang merupakan nilai tertinggi di antara semua kelas. Kelas lansia hanya mencapai f1-score 0.33, sementara kelas anak dan remaja mencatat nilai 0.00 untuk semua metrik. Secara agregat, model mencapai akurasi 0.84 dengan weighted average f1-score 0.80. Dengan demikian, dapat disimpulkan bahwa model memiliki performa keseluruhan yang baik, namun distribusi kinerjanya belum merata di semua kelas.



Gambar 4. Confusion matrix

Tabel 1. Hasil Classification Report

Kelas	Precision	Recall	F1-Score	Support
Anak	0.00	0.00	0.00	5
Dewasa	0.85	0.98	0.91	535
Lansia	0.60	0.23	0.33	91
Remaja	0.00	0.00	0.00	17
Accuracy			0.84	648
Macro avg	0.36	0.30	0.31	648
Weighted Avg	0.79	0.84	0.80	648

### 3.3 Pembahasan

Hasil penelitian mengungkapkan adanya bias model CNN terhadap kelas yang memiliki data lebih banyak. Kondisi ini tampak dari performa tinggi pada kelas dewasa, berbanding terbalik dengan kinerja rendah pada kelas anak dan remaja akibat jumlah sampel yang terbatas. Gejala *overfitting* yang ditandai dengan fluktuasi akurasi dan kenaikan training loss di tengah pelatihan turut mengurangi kemampuan generalisasi model, khususnya untuk kelas minoritas. Upaya perbaikan dapat dilakukan melalui penyeimbangan distribusi data, peningkatan variasi augmentasi, atau modifikasi arsitektur model. Meskipun akurasi keseluruhan menunjukkan hasil yang baik, disparitas kinerja antarkelas menegaskan perlunya peningkatan kualitas dan kuantitas data pada kelas minoritas guna menciptakan model yang lebih stabil dan mampu melakukan klasifikasi secara merata.

## 4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan arsitektur MobileNetV2 untuk klasifikasi usia dengan akurasi validasi mencapai 84% melalui teknik *transfer learning*. Namun, meskipun akurasi globalnya tinggi, model ini mengalami masalah bias yang signifikan akibat ketidakseimbangan data (*data imbalance*). Hasil evaluasi menunjukkan bahwa model hanya mampu mengenali kelas dewasa dengan sangat baik karena jumlah datanya yang mendominasi, sementara kelas anak dan remaja gagal terklasifikasi secara akurat. Kondisi ini diperparah dengan munculnya gejala *overfitting* ringan yang menandakan bahwa augmentasi data saat ini belum cukup efektif. Secara keseluruhan, penelitian ini menyimpulkan bahwa meskipun MobileNetV2 memiliki potensi besar, pengembangannya memerlukan strategi khusus untuk menangani distribusi data yang tidak merata agar performa model lebih adil di seluruh kategori usia.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada seluruh pihak yang telah memberikan dukungan teknis dan masukan dalam pengembangan model klasifikasi usia berbasis MobileNetV2 ini. Diskusi yang mendalam mengenai penanganan ketidakseimbangan data (*data imbalance*) dan analisis performa per kelas telah memberikan wawasan berharga dalam penyempurnaan penelitian ini.

## DAFTAR PUSTAKA

- [1] I. Ekawati, F. Nidya, R. Putra, M. Sumadyo, and R. Nugroho, "Deteksi Emosi Menggunakan Convolutional Neural Network Berdasarkan Ekspresi Wajah," vol. 5, no. 1, pp. 73–82, 2025.
- [2] N. Chalista *et al.*, "Identifikasi Pengenalan Wajah Berdasarkan Jenis Kelamin Menggunakan Metode Convolutional Neural Network ( CNN )," vol. 6, no. 1, 2024, doi: 10.37802/joti.v6i1.694.
- [3] A. Zein, "MEMREDIKSI USIA DAN JENIS KELAMIN MENGGUNAKAN," vol. 30, no. 1, pp. 1–7, 2021.
- [4] A. Yusuf, R. C. Wihandika, and C. Dewi, "Klasifikasi Emosi Berdasarkan Ciri Wajah Menggunakan Convolutional Neural Network," vol. 3, no. 11, 2021.
- [5] M. S. Negara, M. Irzan, A. Dia, and F. Bimantoro, "Implementasi Convolutional Neural Network pada Multi -label Classification Wajah Manusia Berdasarkan Usia , Gender , dan Ras," vol. 11, no. 2, pp. 135–145, 2024.
- [6] Niasiska, H. AR., and H. Budiati, "Klasifikasi Usia Berdasarkan Citra Wajah Menggunakan Algoritma You Only Look Once Age Classification Based on Face Image Using You Only Look Once Algorithm," vol. 13, no. 105, pp. 996–1003, 2024.
- [7] J. Mu, M. Adrezo, and A. N. Haikal, "Identifikasi Wajah Asli dan Buatan Deepfake Menggunakan Metode Convolutional Neural Network Identifying Deepfake Generated Faces and Real Faces Using Convolutional Neural Network," vol. 13, no. 1, pp. 45–50, 2024, doi: 10.34148/teknika.v13i1.705.
- [8] D. Jhon, R. Hutauruk, and A. A. Hendharsetiawan, "Pendeteksian Wajah Bermasker Berbasis Android Menggunakan Algoritma Convolutional Neural Network ( CNN )," vol. 3, no. 2, pp. 207–216, 2022.
- [9] N. Dewi and F. Ismawan, "Implementasi Deep Learning Menggunakan Convolutional Neural Network untuk Sistem Pengenalan Wajah," vol. 14, no. 1, pp. 34–43, 2021, doi: 10.30998/faktorexacta.v14i1.8989.
- [10] Sriyati; Arief Setyanto; Emha Taufiq Luthfi, "Literature Review : Pengenalan Wajah Menggunakan Algoritma," vol. 8, no. 2, 2020.
- [11] E. Y. Christin and Y. Wahyuningsih, "IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK PADA PENGENALAN EKSPRESI WAJAH UNTUK ANAK USIA DINI," pp. 1–8.
- [12] M. F. Naufal, S. F. Kusuma, U. Surabaya, P. Korespondensi, and T. Learning, "PENDETEKSI CITRA MASKER WAJAH MENGGUNAKAN CNN DAN TRANSFER," vol. 8, no. 6, 2021, doi: 10.25126/jtiik.202185201.
- [13] D. Aldiani *et al.*, "Implementasi algoritma cnn dalam sistem absensi berbasis pengenalan wajah," pp. 197–202, 2022.
- [14] C. Cahyaningtyas, C. Gudiato, and M. Sari, "Deteksi Ekspresi Wajah Manusia Menggunakan Metode Convolutional Neural Network," vol. 15, no. 1, pp. 138–145, 2025.
- [15] E. S. Akhmad Solikin, *Sistem Cerdas Deteksi Mengantuk pada Pengemudi Ekstraksi Fitur Wajah Menggunakan Deep Learning*. Penerbit Adab, 2020.
- [16] A. Syahputra, R. Riansyah, D. A. Aptanta, and M. Farhan, "Klasifikasi Jenis Bunga Iris Menggunakan Algoritma Klasifikasi Tradisional," vol. 4, 2025.
- [17] A. R. Siregar and M. Furqan, "Journal of Computer Networks , Architecture and High Performance Computing Classification of Scholarships for Students in Schools Using the Naïve Bayes Method Journal of Computer Networks , Architecture and High Performance Computing," vol. 7, no. 1, pp. 278–289, 2025.

- [18] D. Anisa, “JURNAL RISET SISTEM INFORMASI KLASIFIKASI CITRA JENIS KULIT WAJAH DENGAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK ( CNN ) RESNET-50,” vol. 1, no. 3, pp. 2–8, 2024.
- [19] M. Nurkhasanah, “Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network,” vol. 18, no. 2, pp. 183–190, 2021.
- [20] P. Y. Saputra, *Deep Learning: Teori, Algoritma, dan Aplikasi*. banten: PT SADA KURNIA PUSTAKA, 2025.

-