

PENERAPAN METODE DEEP LEARNING UNTUK DETEKSI USIA DARI EKSPRESI WAJAH REAL-TIME MENGUNAKAN WEBCAM BERBASIS VISUAL CODE

Yuliy Gusnitasari¹, Yuza Reswan²

1,2) Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Bengkulu, Indonesia

Article Info

Article history:

Received: 27 Januari 2025

Revised: 07 Februari 2025

Accepted: 13 Februari 2025

ABSTRACT

Abstrak

Pengenalan Wajah (*Face Recognition*) adalah teknologi yang memungkinkan sistem komputer mengidentifikasi individu berdasarkan fitur wajah dan banyak digunakan dalam keamanan, verifikasi identitas, serta analisis emosi dan usia. Dalam deteksi usia dan ekspresi wajah secara real-time menggunakan Deep Learning, pengenalan wajah berperan penting dalam mendeteksi wajah secara otomatis melalui webcam untuk dianalisis lebih lanjut. Penelitian ini bertujuan meningkatkan akurasi dan kecepatan deteksi usia serta ekspresi wajah menggunakan *Convolutional Neural Networks (CNN)* meskipun terdapat variasi pencahayaan, sudut pandang, dan ekspresi wajah. Metode penelitian yang digunakan adalah kuasi-eksperimen dengan sampel sebanyak 20 orang yang dipilih menggunakan teknik purposive sampling. Model diuji sebanyak tiga kali untuk mengoptimalkan akurasi deteksi. Hasil pengujian menunjukkan bahwa model yang dikembangkan mampu mencapai akurasi pelatihan 81,53% dan akurasi validasi 76,05%, menunjukkan efektivitas pendekatan yang digunakan. Dengan hasil ini, penelitian dapat disimpulkan telah mencapai tujuan dalam meningkatkan akurasi deteksi usia dan ekspresi wajah secara real-time menggunakan metode Deep Learning berbasis CNN.

Kata Kunci: *Face Recognition, Convolutional Neural Networks (CNN), Deteksi Usia, Ekspresi Wajah, Deep Learning.*

Abstract

Face Recognition is a technology that enables computer systems to identify individuals based on facial features and is widely used in security, identity verification, and emotion and age analysis. In real-time age and facial expression detection using Deep Learning, face recognition plays an important role in automatically detecting faces through webcams for further analysis. This research aims to improve the accuracy and speed of age detection and facial expressions using Convolutional Neural Networks (CNN) despite variations in lighting, viewing angles, and facial expressions. The research method used is quasi-experiment with a sample of 20 people selected using purposive sampling technique. The model was tested three times to optimize detection accuracy. The test results showed that the developed model was able to achieve 81.53% training accuracy and 76.05% validation accuracy, demonstrating the effectiveness of the approach used. With these results, the research can be concluded to have achieved the goal of improving the accuracy of real-time age and facial expression detection using the CNN-based Deep Learning method.

Keywords: *Face Recognition, Convolutional Neural Networks (CNN), Age Detection, Facial Expression, Deep Learning*

Djtechno: Jurnal Teknologi Informasi oleh Universitas Dharmawangsa Artikel ini bersifat open access yang didistribusikan di bawah syarat dan ketentuan dengan Lisensi Internasional Creative Commons Attribution NonCommercial ShareAlike 4.0 ([CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/)).



Corresponding Author:

E-mail : gusnitasariyuli@gmail.com

1. PENDAHULUAN

Pengenalan wajah (Face Recognition) adalah teknologi yang memungkinkan sistem komputer untuk mengidentifikasi individu berdasarkan fitur wajah mereka [1]. Teknologi ini digunakan dalam berbagai aplikasi, seperti keamanan, verifikasi identitas, dan analisis emosi atau usia. Dalam penerapan Deep Learning untuk deteksi usia dan ekspresi wajah secara real-time, Face Recognition sangat penting untuk mendeteksi wajah secara otomatis melalui webcam, yang kemudian dianalisis untuk menilai usia dan ekspresi wajah [2].

Pentingnya Face Recognition terletak pada kemampuannya meningkatkan akurasi deteksi wajah [3]. Tanpa pengenalan wajah yang tepat, analisis usia dan ekspresi tidak akan efektif. Dengan mengisolasi wajah dari latar belakang, model Deep Learning dapat fokus pada elemen wajah yang relevan [4], meskipun ada perubahan posisi atau pencahayaan. Menggunakan webcam, teknologi ini memungkinkan pengenalan wajah secara langsung dan real-time. Face Recognition memastikan wajah yang terdeteksi adalah wajah yang dimaksud, sementara Deep Learning menganalisis usia dan ekspresi secara cepat dan akurat, meningkatkan efisiensi dan hasil dalam berbagai aplikasi [5].

Pada proses Face Recognition data set menentukan kebutuhan keberhasilan tingkat akurasi. Jika data set bervariasi (iluminasi, ukuran, dan tipe file) maka akan sulit mengenali wajah dengan benar karena faktor seperti pencahayaan yang buruk, sudut wajah yang berbeda, ekspresi wajah yang bervariasi, dan lambatnya proses deteksi, sehingga diperlukan cara untuk menormalkan data dan mempercepat pemrosesan agar hasilnya lebih akurat dan cepat [6].

Normalisasi dataset sesuai dengan kebutuhan sistem dapat mempermudah pengenalan pola wajah. Dengan pendekatan ini, deteksi usia dari ekspresi wajah menjadi lebih akurat dan cepat, meskipun ada perbedaan pencahayaan, sudut pandang, atau ekspresi wajah. Normalisasi ini pakai CNN karena kemampuannya dalam secara otomatis mengekstraksi fitur penting dari gambar, seperti wajah, tanpa memerlukan pengolahan manual. CNN juga efektif dalam mengatasi masalah perbedaan kondisi wajah, seperti pencahayaan yang buruk, ekspresi yang bervariasi, dan perbedaan sudut pandang [7].


Dalam penelitian terbaru, CNN telah diterapkan untuk pengenalan ekspresi wajah secara real-time menggunakan OpenCV. Hasil penelitian menunjukkan bahwa model CNN yang diimplementasikan mampu mencapai akurasi yang baik dalam mendeteksi dan mengklasifikasikan ekspresi wajah [8].

2. METODE PENELITIAN

Penelitian ini menerapkan model Convolutional Neural Network (CNN) melalui beberapa tahap. Langkah pertama adalah pengumpulan data, di mana dataset utama yang digunakan dalam penelitian ini berasal dari Karolinska Directed Emotional Faces (KDEF)[9]. KDEF adalah dataset standar yang berisi kumpulan gambar wajah manusia

dengan berbagai ekspresi, termasuk senang, sedih, marah, dan terkejut, yang telah divalidasi secara akademis untuk penelitian psikologi dan pengolahan citra. Penggunaan dataset ini memastikan bahwa ekspresi wajah dalam penelitian memiliki dasar yang sah dan dapat dipercaya.

Setelah pengumpulan data, gambar dalam dataset diproses melalui tahap pre-processing untuk menyesuaikan ukuran, normalisasi piksel, serta augmentasi guna meningkatkan variasi data. Model CNN kemudian dilatih menggunakan dataset KDEP yang telah diproses untuk meningkatkan akurasi klasifikasi ekspresi wajah. Tahap akhir adalah evaluasi model guna menilai performa dan tingkat akurasinya dalam mendeteksi ekspresi wajah secara real-time menggunakan webcam.



Gambar 1. Alur Penelitian

Tahapan penelitian berdasarkan gambar 1 dijelaskan lebih rinci sebagai berikut:

1) Pengumpulan Data:

Dataset Publik adalah untuk usia wajah dan klasifikasi wajah dengan berbagai ekspresi. Webcam atau Kamera Menggunakan OpenCV untuk mengambil gambar wajah secara langsung dari kamera [10]. kumpulan gambar wajah dari berbagai ekspresi dan usia dan posisi wajah. hasilnya terdapat 4 katagori wajah Ekspresi wajah yaitu : senang, sedih, marah, terkejut. hasilnya terdapat 9 katagori usia yaitu: mendeteksi umur terbagi menjadi 7 yaitu 4-6tahun, 8-12tahun, 15-20tahun, 21-24tahun, 25-32tahun, 38-43tahun, 48-53tahun. posisi foto tersebut yaitu menengok keatas, kebawah, kekanan, dan kekiri [11].

2) Pre-processing data :


Pre-processing data merupakan tahap penting dalam mempersiapkan data sebelum digunakan dalam pelatihan model deep learning [12]. Proses ini mencakup beberapa langkah utama untuk meningkatkan kualitas data agar model dapat mengenali pola dengan lebih baik. Langkah pertama adalah menyesuaikan ukuran gambar ke standar tertentu, misalnya 224x224 piksel, guna memastikan kompatibilitas dengan arsitektur model yang digunakan. Selanjutnya, dilakukan normalisasi nilai piksel ke rentang 0-1 untuk mempercepat proses pembelajaran serta menjaga stabilitas

distribusi data. Selain itu, teknik augmentasi data diterapkan untuk meningkatkan variasi dalam dataset [13], seperti rotasi, flipping, perubahan pencahayaan, dan zoom, sehingga model dapat lebih adaptif terhadap perbedaan kondisi lingkungan serta mengurangi risiko overfitting. Untuk meningkatkan akurasi deteksi, dilakukan juga proses reduksi noise dan peningkatan kontras guna menghilangkan elemen yang tidak relevan serta memperjelas fitur wajah [14].


Dalam penelitian ini, proses pre-processing dilakukan sebelum model dilatih dan diuji sebanyak tiga kali guna memperoleh akurasi yang optimal. Setiap pengujian bertujuan menyesuaikan parameter dan metode yang digunakan agar model dapat mengenali pola wajah dengan lebih baik. Hasil dari ketiga pengujian menunjukkan peningkatan akurasi secara bertahap, di mana model akhirnya mampu mencapai tingkat akurasi yang tinggi setelah dilakukan penyesuaian strategi pre-processing.

3) Model CNN:

Convolutional Neural Network (CNN) adalah arsitektur deep learning yang dirancang untuk mengolah data berbentuk grid seperti gambar, dengan kemampuan mengekstraksi fitur penting secara otomatis melalui serangkaian lapisan yang saling terhubung [15]. Proses dimulai dengan lapisan konvolusi, yang menggunakan filter atau kernel untuk mendeteksi pola-pola spesifik seperti tepi, tekstur, atau detail lain dalam gambar, yang menjadi dasar analisis lebih lanjut [16]. Setelah itu, fungsi aktivasi seperti ReLU (Rectified Linear Unit) [17] diterapkan untuk memperkenalkan non-linearitas, memungkinkan jaringan mempelajari pola-pola yang lebih kompleks. Lapisan pooling kemudian digunakan untuk mengurangi dimensi data tanpa kehilangan informasi penting, seperti dengan max pooling yang mengambil nilai maksimum dari area tertentu [18], sehingga mempercepat komputasi dan mengurangi risiko overfitting. Data yang telah melalui tahap ini diproses lebih lanjut oleh lapisan fully connected [19], yang menghubungkan semua neuron untuk menghasilkan prediksi akhir berdasarkan analisis yang dilakukan, seperti klasifikasi usia atau ekspresi wajah. Selain itu, teknik regulasi seperti dropout sering digunakan untuk mengurangi overfitting dengan cara acak mengabaikan sebagian neuron selama pelatihan. Dengan kombinasi proses ini, CNN mampu mengenali pola visual dengan akurasi tinggi dan sangat cocok untuk tugas seperti deteksi usia, analisis ekspresi wajah, dan berbagai aplikasi berbasis pengolahan citra [20].




Dibawah ini adalah proses tahap face recognition :



Gambar 3. Diagram Face Recognition

3. HASIL DAN PEMBAHASAN

Tampilan ini akan menunjukkan expression yang terdiri dari bingung, marah, terkejut, senang, sedih dan menunjukkan prediksi usia terdiri dari 1-6tahun, 8-12tahun, 15-25tahun, 38-43tahun, 48-53tahun.




Gambar 4. Design Face Recognition

Tabel 1: Kriteria Usia dan Jumlah Orang

No.	Kriteria Usia	Jumlah Orang	Ekspresi
1	4-6tahun	20 orang	Bingung (5 orang), Marah (10 orang), Senang (3 orang), Terkejut (2 orang)
2	8-12tahun	20 orang	Marah (12 orang), Senyum (4 orang), Bingung (2 orang), Terkejut (2 orang)
3	15-20tahun	20 orang	Bingung (6 orang), Marah (8 orang), Senang (4 orang), Terkejut (2 orang)
4	21-24tahun	20 orang	Bingung (4 orang), Marah (10 orang), Senyum (3 orang), Terkejut (3 orang)
5	25-32tahun	20 orang	Marah (10 orang), Bingung (5 orang), Senang (3 orang), Terkejut (2 orang)
6	38-43tahun	20 orang	Terkejut (5 orang), Marah (10 orang), Bingung (3 orang), Senang (2 orang)
7	48-53tahun	20 orang	Marah (12 orang), Bingung (4 orang), Senyum (3 orang), Terkejut (1 orang)

Pada Gambar 4 di bawah ditunjukkan beberapa contoh sampel dataset mendeteksi usia dan ekspresi wajah secara real-time digunakan dalam penelitian ini. Dataset terdiri dari empat kategori utama yaitu **senang, sedih, marah, dan terkejut**.





Gambar 4. Sampel dataset Hasil Deteksi usia dari Ekspresi wajah

Dalam penelitian ini bertujuan untuk mendeteksi usia dan ekspresi wajah secara real-time dengan memanfaatkan metode deep learning, khususnya menggunakan model Convolutional Neural Network (CNN). Dataset yang digunakan mencakup variasi usia dan ekspresi wajah. Kriteria usia dalam dataset dibagi menjadi tujuh kelompok, yaitu: 4-6 tahun, 8-12 tahun, 15-20 tahun, 21-24 tahun, 25-32 tahun, 38-43 tahun, dan 48-53 tahun. Selain itu, ekspresi wajah yang dianalisis meliputi empat kategori utama: senang, sedih, marah, dan terkejut.

Penelitian ini melibatkan 20 peserta yang dipilih dengan teknik purposive sampling. Berdasarkan asumsi bahwa setiap peserta memiliki satu gambar untuk setiap kombinasi usia dan ekspresi, terdapat 28 kombinasi unik, hasil dari 7 kelompok usia dikalikan dengan 4 kategori ekspresi ($7 \times 4 = 28$). Oleh karena itu, total gambar dalam dataset diperkirakan mencapai 560 gambar ($20 \text{ peserta} \times 28 \text{ kombinasi} = 560$). Dataset ini dirancang untuk mencakup beragam kondisi, seperti variasi pencahayaan, sudut pandang, dan ekspresi wajah, sehingga dapat meningkatkan akurasi model CNN dalam mengenali pola dan melakukan klasifikasi.

Proses preprocessing dilakukan untuk menormalkan dataset melalui langkah-langkah seperti penyesuaian ukuran gambar, normalisasi piksel, dan augmentasi data. Langkah ini memastikan model menjadi lebih tangguh terhadap overfitting dan mampu mengenali pola meskipun terdapat variasi kondisi pada data.

Pada percobaan pertama, model Convolutional Neural Network (CNN) dilatih dengan membekukan seluruh lapisan dasar dan hanya melatih lapisan tambahan menggunakan learning rate awal sebesar $1e-4$, menghasilkan akurasi pelatihan sebesar 81,09% dan akurasi validasi 70,63% dengan loss masing-masing 0,93 dan 1,11, namun menunjukkan gejala overfitting karena model lebih fokus pada pola dalam data pelatihan dibandingkan pola pada data validasi, sehingga pelatihan dihentikan pada epoch ke-64.

melalui mekanisme early stopping untuk mencegah overfitting lebih lanjut.

Pada percobaan kedua, model CNN dengan arsitektur ResNet-101 tetap menggunakan lapisan dasar yang dibekukan, namun strategi ReduceLRonPlateau diatur lebih agresif untuk menurunkan learning rate lebih cepat saat performa validasi stagnan. Hasilnya, akurasi pelatihan mencapai 76,97% dengan nilai loss 1,22, sementara akurasi validasi tercatat sebesar 69,38% dengan loss 1,33. Meskipun akurasi validasi tidak meningkat signifikan dibanding percobaan pertama, stabilitas hasil validasi lebih baik, menunjukkan bahwa pengaturan ini membantu meningkatkan konsistensi model.

Pada percobaan ketiga, dilakukan fine-tuning pada beberapa lapisan terakhir arsitektur ResNet-101, memungkinkan penyesuaian bobot agar lebih spesifik terhadap dataset, sehingga menghasilkan akurasi pelatihan sebesar 81,53% dengan loss 0,92 dan akurasi validasi tertinggi 76,05% dengan loss 1,35, yang menunjukkan peningkatan kemampuan generalisasi model tanpa mengalami overfitting.

Tabel 2. Perbandingan Hasil Percobaan

Percobaan	Epoch Berhenti	Akurasi Pelatihan (%)	Loss Pelatihan	Akurasi Validasi (%)	Loss Validasi
1	64	81,09	0,93	70,63	1,11
2	48	76,97	1,22	69,38	1,33
3	52	81,53	0,92	76,05	1,35

Dari ketiga percobaan yang dilakukan, dapat disimpulkan bahwa percobaan ketiga, yang menggunakan strategi fine-tuning pada beberapa layer terakhir ResNet-101, memberikan hasil terbaik. Pada percobaan pertama, hanya layer tambahan yang dilatih sementara layer dasar tetap dibekukan, menghasilkan akurasi pelatihan tinggi (81,09%) namun akurasi validasi lebih rendah (70,63%), yang menunjukkan adanya overfitting karena model tidak mampu mengenali pola pada data validasi. Percobaan kedua mencoba mengatasi masalah ini dengan strategi ReduceLRonPlateau untuk menurunkan learning rate lebih cepat ketika performa stagnan, tetapi hasilnya tidak signifikan, dengan akurasi validasi turun menjadi 69,38%, meskipun stabilitasnya sedikit lebih baik.

Berbeda dengan itu, percobaan ketiga menggunakan pendekatan fine-tuning, yang membuka beberapa layer terakhir dari ResNet-101 untuk menyesuaikan bobot dengan pola spesifik dataset. Strategi ini membuat model lebih mampu mengenali variasi data, seperti pencahayaan, sudut pandang, dan ekspresi wajah, menghasilkan akurasi pelatihan sebesar 81,53% dan akurasi validasi tertinggi sebesar 76,05%. Dengan perbedaan kecil antara akurasi pelatihan dan validasi serta loss yang stabil, percobaan ketiga menunjukkan kemampuan generalisasi yang baik tanpa overfitting. Pelatihan juga

dihentikan pada epoch ke-52 menggunakan mekanisme early stopping untuk memastikan hasil optimal.

Secara keseluruhan, percobaan ketiga membuktikan bahwa fine-tuning adalah strategi yang lebih efektif dalam meningkatkan performa model untuk dataset yang kompleks, dibandingkan hanya melatih layer tambahan seperti pada percobaan sebelumnya. Pendekatan ini memungkinkan model menghasilkan hasil terbaik dalam tugas klasifikasi wajah dengan variasi kondisi yang tinggi.


Tabel 3. Hasil Model Terbaik

Percobaan	Epoch	Akurasi	Loss	Akurasi	Loss
	Berhenti	Pelatihan (%)	Pelatihan	Validasi (%)	Validasi
3	52	81,53	0,92	76,05	1,35



Gambar 5. Perbandingan akurasi pelatihan dan validasi model terbaik

Pada Gambar 5 ditampilkan grafik perbandingan akurasi antara data pelatihan dan validasi dari model terbaik yang diperoleh pada percobaan ketiga. Akurasi pelatihan meningkat secara bertahap hingga mencapai nilai tertinggi sebesar 81,53%, sementara akurasi validasi mencapai nilai puncak sebesar 76,05% pada epoch ke-52. Perbedaan kecil antara kedua akurasi ini menunjukkan bahwa model mampu melakukan generalisasi dengan baik pada data validasi tanpa mengalami overfitting. Pelatihan dihentikan menggunakan mekanisme Early Stopping untuk mencegah penurunan performa pada data validasi, sehingga memastikan model berhenti pada titik optimal. Grafik ini mencerminkan bahwa strategi fine-tuning yang diterapkan pada beberapa lapisan terakhir ResNet-101 berperan penting dalam meningkatkan akurasi dan stabilitas model, membuatnya andal dalam mengenali pola pada data baru.



Gambar 6. Hasil

Gambar 6 ini menunjukkan hasil Gambar ini menunjukkan hasil pengujian sistem deteksi usia dan ekspresi wajah secara real-time yang menggunakan metode deep learning berbasis CNN, khususnya dengan penerapan fine-tuning pada model ResNet-101 untuk meningkatkan akurasi. Sistem ini berhasil mendeteksi wajah dengan ditandai oleh kotak hijau dan titik-titik merah yang merepresentasikan landmark di area wajah, seperti mata, hidung, dan mulut, untuk mendukung analisis lebih mendalam.

Berdasarkan deteksi tersebut, sistem mengidentifikasi ekspresi wajah "Marah" dan secara akurat memperkirakan usia individu dalam rentang 21–24 tahun, dengan hasil ini ditampilkan secara visual dalam antarmuka secara real-time. Pengujian ini mencerminkan kemampuan sistem dalam mengelola variasi fitur wajah pada kondisi nyata, seperti pencahayaan atau sudut pandang, serta menunjukkan tingkat akurasi yang tinggi dalam mengenali ekspresi dan usia. Selain itu, implementasi ini menegaskan keberhasilan pendekatan deep learning dalam mendeteksi data secara langsung melalui input webcam, memberikan respons cepat dan hasil yang relevan, sesuai dengan tujuan utama penelitian untuk menciptakan sistem yang handal, responsif, dan akurat dalam klasifikasi ekspresi dan estimasi usia berbasis citra wajah.

4. SIMPULAN

Penelitian ini berhasil mengembangkan sistem deteksi usia dan ekspresi wajah secara real-time menggunakan Convolutional Neural Network (CNN) dengan arsitektur ResNet-101, yang melalui penerapan fine-tuning pada lapisan terakhir mampu menghasilkan akurasi pelatihan 81,53% dan akurasi validasi 76,05%, menunjukkan kemampuan generalisasi yang baik dalam mengenali pola kompleks dari dataset bervariasi, serta mendeteksi wajah secara otomatis melalui webcam untuk memberikan hasil analisis usia dan ekspresi dengan akurasi tinggi yang dapat diaplikasikan pada berbagai bidang seperti keamanan dan teknologi berbasis pengenalan wajah.

REFERENCES

- [1]. T. Susim and C. Darujati, "Pengolahan Citra untuk Pengenalan Wajah (Face Recognition) Menggunakan OpenCV," *J. Syntax Admiration*, vol. 2, no. 3, pp. 534–545, 2021, doi: 10.46799/jsa.v2i3.202.
- [2]. N. Dewi and F. Ismawan, "Implementasi Deep Learning Menggunakan Cnn Untuk Sistem Pengenalan Wajah," *Fakt. Exacta*, vol. 14, no. 1, p. 34, 2021, doi: 10.30998/faktorexacta.v14i1.8989.
- [3]. Z. Gustiana and A. H. Elyas, "Penerapan Deep Learning Pada Face Recognition (Literature Review)," *Djtechno J. Teknol. Inf.*, vol. 5, no. 1, pp. 153–158, 2024, doi: 10.46576/djtechno.v5i1.4541.
- [4]. M. JEFRI, "PENGUKURAN TINGKAT AKURASI DETEKSI WAJAH AUTIS MENGGUNAKAN CNN (CONVOLUTIONAL NEURAL NETWORK) FAKULTAS SAINS DAN TEKNOLOGI UNIVERSITAS ISLAM NEGERI AR-RANIRY BANDA ACEH PENGUKURAN TINGKAT AKURASI DETEKSI WAJAH AUTIS MENGGUNAKAN CNN (CONVOLUTIONAL NEURA," 2024.
- [5]. H. Auza, M. Bagus Arisila Putra, M. Azril Saputra, R. Hartono, and P. Rosyani, "Implementasi Deep Learning untuk Deteksi Wajah dan Ekspresi menggunakan Algoritma Convolutional Neural Network (CNN) dengan OpenCV," *J. Artif. Intel. dan Sist. Penunjang Keputusan*, vol. 1, no. 4, pp. 261–265, 2024, [Online]. Available: <https://jurnalmahasiswa.com/index.php/aidanspk>
- [6]. A.P. Diana, "Pengenalan Wajah Pada Aplikasi Sistem Kehadiran Mahasiswa (Sikemas) Dengan Metode Convolutional Neural Network," *Inform. FTIK-ITS*, vol. Tugas Akhi, p. 26, 2019.
- [7]. B. A. A. S, "Pengenalan Wajah dengan Menggunakan Deep Learning REZA ALBIAN JAWAS, Bakhtiar Alldino A.S., S.Si, M.Cs.," 2021.
- [8]. A. Santoso and G. Ariyanto, "Implementation of Hard-Based Deep Learning for Face Recognition," *Emit. J. Tek. Elektro*, vol. 18, no. 01, pp. 15–21, 2018.
- [9]. A. Faraz, M. Fuzail, A. H. Khan, A. Naeem, N. Aslam, and M. A. Mirza, "Convolutional Approaches in Transfer Learning for Facial Emotion Analysis," vol. 06, no. 02, 2024, [Online]. Available: <https://doi.org/10.56979/602/2024>
- [10]. F. Utami, S. Suhendri, and M. Abdul Mujib, "Implementasi Algoritma Haar Cascade pada Aplikasi Pengenalan Wajah," *J. Inf. Technol.*, vol. 3, no. 1, pp. 33–38, 2021, doi: 10.47292/joint.v3i1.45.
- [11]. S. E. Prastya et al., "Pemodelan Sistem Deteksi Parasit Malaria pada Citra Mikroskopis Sel Darah Menggunakan Metode Deep Learning," vol. 14, no. 2, pp. 409–416, 2024.
- [12]. M. A. Haq, A. Rosadi, and W. Wicaksono, "Sistem Identifikasi Wajah Personal dan Hemat Daya dengan ESP32 dan OV2640 Berbasis Model," vol. 7, no. 02, 2024.
- [13]. F. Rizki, M. P. Kharisma Putra, M. A. Assuja, and F. Ariany, "Implementasi Deep Leraning Lenet Dengan Augmentasi Data Pada Identifikasi Anggrek," *J. Inform. dan Rekayasa Perangkat Lunak*, vol. 4, no. 3, pp. 357–366, 2023, doi: 10.33365/jatika.v4i3.3652.
- [14]. Rohman Dijaya, *Buku Ajar Pengolahan Citra Digital*. 2023.
- [15]. S. Agustini, "PENERAPAN PENGOLAHAN CITRA UNTUK PENGENALAN WAJAH : STUDI LITERATUR," vol. 6, no. 3, pp. 129–136, 2024.

- [16]. AL Sigit Guntoro, Edy Julianto, and Djoko Budiyo, "Pengenalan Ekspresi Wajah Menggunakan Convolutional Neural Network," J. Inform. Atma Jogja, vol. 3, no. 2, pp. 155–160, 2022, doi: 10.24002/jiaj.v3i2.6790.
- [17]. L. O. A. S. Sagala, "Klasifikasi Cats dan Dogs dengan Metode CNN dalam Fungsi Aktivasi Relu , Sigmoid , Softmax , Softplus , Softsign , dan Selu," Pros. Semin. Nas. Inform. Bela Negara di UPN "Veteran" Jawa Timur, vol. 2, no. 1, pp. 1–6, 2023.
- [18]. D. R. R. Putra and R. A. Saputra, "Implementasi Convolutional Neural Network (Cnn) Untuk Mendeteksi Penggunaan Masker Pada Gambar," J. Inform. dan Tek. Elektro Terap., vol. 11, no. 3, pp. 710–714, 2023, doi: 10.23960/jitet.v11i3.3286.
- [19]. F. Paraijun, R. N. Aziza, and D. Kuswardani, "Implementasi Algoritma Convolutional Neural Network Dalam Mengklasifikasi Kesegaran Buah Berdasarkan Citra Buah," Kilat, vol. 11, no. 1, pp. 1–9, 2022, doi: 10.33322/kilat.v10i2.1458.
- [20]. M. I. Maulana and K. Aeni, "PENGENALAN EKSPRESI WAJAH MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) Kata Kunci : Pengenalan Ekspresi Wajah , Machine Learning , Deep Learning , Convolutional Neural Network ,".