

# KOMPARASI ALGORITMA CNN DAN TRANSFER LEARNING UNTUK IDENTIFIKASI EKSPRESI WAJAH POTENSI KEJAHATAN

Afrizal Najwa Syaqui<sup>1\*</sup>, Bambang Agus Herlambang<sup>2</sup>, Khoiriya Latifah<sup>3</sup>

<sup>1,2,3</sup> Program Studi Teknik Informatika, Universitas PGRI Semarang

email: afrizal20670117@upgris.ac.id<sup>1\*</sup>, bambangherlambang@upgris.ac.id<sup>2</sup>, khoiriyalatifah@upgris.ac.id<sup>3</sup>

**Abstract:** *This study aims to develop and implement a Convolutional Neural Network (CNN) algorithm to detect suspicious facial expressions in order to prevent crime in public facilities. Facing the challenge of detecting criminal behavior quickly and accurately, this study designs a facial expression prediction system to support security officers in preventing crime, spreading the effectiveness of deep learning models on CCTV footage, and implementing cybersecurity measures to protect the system from unauthorized access. This study also compares traditional CNN models with transfer learning methods such as ResNet50, MobileNetV2, and VGG16. The results show that traditional CNN not only has high accuracy in detecting suspicious facial expressions, but is also more stable and effective in avoiding overfitting compared to transfer learning models. In addition, the implemented cybersecurity measures are proven to be effective in protecting the system from external threats. This study makes a significant contribution to improving public security through advanced and secure facial expression detection technology.*

**Keywords:** *CNN, Facial Expression Detection, Public Security, CCTV, Cyber Security.*

**Abstrak:** Penelitian ini bertujuan untuk mengembangkan dan menerapkan algoritma Convolutional Neural Network (CNN) guna mendeteksi ekspresi wajah mencurigakan dalam rangka pencegahan tindak kejahatan di fasilitas publik. Menghadapi tantangan dalam mendeteksi perilaku kriminal secara cepat dan akurat, penelitian ini merancang sistem prediksi ekspresi wajah untuk mendukung petugas keamanan dalam mencegah kejahatan, mengevaluasi efektivitas model deep learning pada rekaman CCTV, serta menerapkan langkah-langkah keamanan siber untuk melindungi sistem dari akses yang tidak sah. Penelitian ini juga melakukan komparasi antara model CNN tradisional dengan metode transfer learning seperti ResNet50, MobileNetV2, dan VGG16. Hasil penelitian menunjukkan bahwa CNN tradisional tidak hanya memiliki akurasi tinggi dalam mendeteksi ekspresi wajah mencurigakan, tetapi juga lebih stabil dan efektif dalam menghindari overfitting dibandingkan dengan model-model transfer learning. Selain itu, langkah-langkah keamanan siber yang diterapkan terbukti efektif dalam melindungi sistem dari ancaman eksternal. Penelitian ini memberikan kontribusi signifikan dalam meningkatkan keamanan publik melalui teknologi deteksi ekspresi wajah yang canggih dan aman.

**Kata Kunci:** *CNN, Deteksi Ekspresi Wajah, Keamanan Publik, CCTV, Keamanan Siber.*

## Pendahuluan

Keamanan di fasilitas publik merupakan prioritas utama dalam menjaga ketertiban dan keselamatan masyarakat. Salah satu teknologi yang telah banyak digunakan untuk tujuan ini adalah sistem pengawasan berbasis CCTV. Namun, meskipun keberadaannya telah membantu dalam memonitor aktivitas di ruang publik, efektivitas sistem ini sangat bergantung pada kemampuan manusia untuk terus memantau rekaman video secara berkelanjutan (Shah et al., 2021). Faktor kelelahan dan keterbatasan waktu membuat sistem ini tidak sepenuhnya dapat diandalkan dalam mendeteksi perilaku mencurigakan secara real-time (Jamhari et al., 2020). Seiring dengan kemajuan dalam bidang kecerdasan buatan, teknologi pengenalan ekspresi wajah berbasis deep learning muncul sebagai solusi potensial untuk mengatasi keterbatasan ini. *Convolutional Neural Network (CNN)* (Arsal et al., 2020) telah menjadi salah satu algoritma yang paling populer dalam pengenalan citra, termasuk deteksi dan klasifikasi ekspresi wajah. Namun, dengan berkembangnya model-model transfer learning seperti ResNet50, MobileNetV2, dan VGG16, muncul pertanyaan mengenai model mana yang paling efektif dalam aplikasi keamanan publik, terutama dalam konteks deteksi ekspresi wajah yang mencurigakan. Selain akurasi berbagai model deep learning dalam mendeteksi ekspresi wajah, tetapi penulis juga menekankan pada kemampuan model dalam menghindari overfitting, sebuah masalah umum yang dihadapi dalam implementasi model deep learning pada data dunia nyata. CNN tradisional, meskipun sering dianggap sebagai model dasar, dipilih sebagai solusi akhir dalam penelitian ini karena

menunjukkan keseimbangan yang lebih baik antara akurasi dan kemampuan generalisasi dibandingkan dengan model-model transfer learning yang lebih kompleks seperti VGG16. Keunikan lain dari penelitian ini adalah fokus pada aplikasi langsung dalam sistem pengawasan CCTV, memberikan wawasan praktis yang dapat diterapkan di lapangan.

Berbagai penelitian telah dilakukan terkait dengan pengenalan ekspresi wajah menggunakan teknologi deep learning. (Mollahosseini et al., 2016) menunjukkan bahwa deep neural networks dapat secara efektif mengklasifikasikan ekspresi wajah, namun mereka juga mencatat bahwa model cenderung overfit pada dataset yang terbatas. (Corneanu et al., 2016) menyoroti bahwa penggunaan data multimodal, seperti RGB dan citra termal, dapat meningkatkan akurasi deteksi ekspresi, namun hal ini memerlukan sumber daya komputasi yang besar. Sementara itu, penelitian yang dilakukan oleh (Fadlil et al., 2022) menggunakan CNN tradisional untuk deteksi wajah pada sistem keamanan ruangan dan mencapai akurasi yang signifikan tanpa memerlukan model yang sangat kompleks. Temuan ini mendukung gagasan bahwa model yang lebih sederhana dapat lebih stabil dalam aplikasi dunia nyata, terutama ketika berhadapan dengan variabilitas tinggi dalam data. Jurnal-jurnal terkait menunjukkan bahwa meskipun model-model transfer learning seperti VGG16 memiliki keunggulan dalam hal akurasi, mereka juga sering kali rentan terhadap overfitting, terutama ketika diterapkan pada dataset yang tidak besar atau tidak cukup bervariasi. (Andi Agustinus et al., 2023) dan (Nathasya & Ginting, 2023) dalam penelitian mereka menyarankan bahwa CNN tradisional mungkin lebih efektif dalam skenario dunia nyata, di mana generalisasi model lebih penting daripada sekadar mencapai akurasi tertinggi pada data pelatihan.

Meskipun penelitian sebelumnya telah banyak mengeksplorasi penggunaan CNN dan transfer learning untuk pengenalan ekspresi wajah (Hermawan, 2021), ada kekurangan literatur yang membahas perbandingan komprehensif antara model CNN tradisional dan model transfer learning dalam hal kemampuan mereka menghindari overfitting. Penelitian ini mengisi celah tersebut dengan memberikan analisis tentang performa berbagai model, tidak hanya dari segi akurasi tetapi juga dari segi stabilitas dan generalisasi, yang merupakan faktor kritis dalam aplikasi keamanan publik.

Tujuan utama dari penulisan artikel ini adalah untuk menyajikan temuan komparatif antara CNN tradisional dan model transfer learning (ResNet50 (Purba et al., 2017), MobileNetV2, dan VGG16) dalam konteks deteksi ekspresi wajah yang mencurigakan, dengan fokus khusus pada kemampuan model untuk menghindari overfitting. Artikel ini juga bertujuan untuk merekomendasikan model yang paling efektif dan stabil untuk diimplementasikan dalam sistem pengawasan berbasis CCTV di fasilitas publik.

## **Metode**

### **Pendekatan Penelitian**

Penelitian ini menggunakan pendekatan kuantitatif (Yam & Taufik, 2021) dengan metode eksperimen. Pendekatan ini dipilih untuk mengukur kinerja dan efektivitas model deep learning dalam mendeteksi ekspresi wajah yang mencurigakan. Penelitian ini melibatkan pengujian dan komparasi antara model CNN tradisional dan model transfer learning (ResNet50, MobileNetV2, dan VGG16) dalam konteks sistem pengawasan berbasis CCTV.

### **Lokasi Penelitian**

Penelitian ini dilakukan secara virtual, dengan menggunakan dataset publik FER-2013 yang diperoleh dari Kaggle (Rahmat et al., 2023). Pengolahan data dan pelatihan model dilakukan pada pycharm, yang memaksimalkan penggunaan GPU pada komputer untuk mempercepat proses pelatihan model.

### **Subjek Penelitian**

Subjek penelitian dalam studi ini adalah model-model deep learning yang diterapkan untuk mendeteksi ekspresi wajah. Dataset FER-2013 (Purba et al., 2017) digunakan sebagai sumber data, yang terdiri dari gambar wajah dengan tujuh jenis ekspresi: marah, jijik, takut, senang, netral, sedih, dan terkejut.

## Variabel Penelitian

1. Variabel Bebas (Independen): Arsitektur model deep learning (CNN tradisional, ResNet50, MobileNetV2, VGG16).
2. Variabel Terikat (Dependen): Akurasi deteksi ekspresi wajah, tingkat overfitting, dan kemampuan generalisasi model.
3. Variabel Kontrol: Resolusi gambar (48x48 piksel), ukuran batch (32), jumlah epoch (100), serta teknik augmentasi data yang digunakan.

## Teknik Pengumpulan Data

Data dikumpulkan dari dataset FER-2013, yang terdiri dari 35.887 gambar grayscale (Alamsyah & Pratama, 2020) berukuran 48x48 piksel yang sudah dilabeli sesuai dengan kategori ekspresi wajah. Dataset ini dibagi menjadi data latih dan data uji dengan rasio 80:20. Teknik augmentasi data seperti rotasi, flipping, dan zooming digunakan untuk meningkatkan variabilitas data latih.

## Teknik Pengolahan Data

Data diolah dengan menggunakan model CNN tradisional serta model-model transfer learning (ResNet50, MobileNetV2, VGG16). Setiap model dilatih menggunakan data latih yang telah di-augmentasi, dan performa model diukur menggunakan data uji. Metrik evaluasi yang digunakan meliputi akurasi, presisi, recall, F1-score, dan AUC-ROC.

## Instrumen Pelatihan

Instrumen utama yang digunakan dalam penelitian ini adalah:

1. Pycharm: Digunakan untuk pelatihan model dan eksperimen, dengan dukungan GPU (Hu et al., 2018).
2. TensorFlow dan Keras: Framework yang digunakan untuk membangun dan melatih model deep learning (Muharram et al., 2022).
3. Python: Bahasa pemrograman utama yang digunakan untuk pengolahan data, pelatihan model, dan analisis hasil (Sanner, 1999).

## Teknik Analisis Data

Hasil pelatihan dan pengujian model dianalisis menggunakan metrik-metrik evaluasi seperti akurasi, loss, presisi, recall, dan F1-score. Selain itu, analisis overfitting dilakukan dengan membandingkan performa model pada data latih dan data uji. Perbandingan ini memberikan wawasan mengenai kemampuan model untuk generalisasi pada data yang belum pernah dilihat sebelumnya. Data visualisasi seperti confusion matrix, grafik loss dan akurasi, serta AUC-ROC curve digunakan untuk mendukung analisis ini. Berikut Alur analisisnya sebagai berikut:

1. Preprocessing Data: Meliputi normalisasi gambar dan augmentasi data untuk meningkatkan variabilitas data latih.
2. Training Model: Melibatkan pelatihan CNN tradisional dan model-model transfer learning menggunakan dataset yang telah diproses.
3. Evaluation: Setiap model dievaluasi berdasarkan performanya pada data uji, dengan fokus khusus pada tingkat akurasi dan overfitting.
4. Comparison: Kinerja model-model dibandingkan untuk menentukan model yang paling efektif dan stabil dalam mendeteksi ekspresi wajah yang mencurigakan.

## Hasil dan Pembahasan

### Hasil Penelitian

Penelitian ini melakukan komparasi antara performa beberapa model deep learning, termasuk ResNet50, MobileNetV2, VGG16, dan CNN tradisional, dalam mendeteksi ekspresi wajah yang mencurigakan. Salah satu fokus utama dari penelitian ini adalah untuk mengukur tingkat overfitting pada setiap model, yang dinilai berdasarkan perbedaan performa antara data latih dan data uji. Overfitting terjadi ketika model menunjukkan performa yang sangat baik pada data latih, namun gagal mempertahankan kinerja tersebut pada data uji.

ResNet50, sebagai salah satu model yang diuji, menunjukkan peningkatan akurasi pada data latih dari epoch pertama ke epoch kedua. Namun, hasil ini tidak diikuti oleh perbaikan yang signifikan pada data validasi. Pada epoch kedua, data validasi bahkan tidak tersedia, yang menyulitkan penilaian lebih lanjut mengenai kemampuan generalisasi model ini. Temuan ini menunjukkan bahwa ResNet50

mengalami kesulitan dalam menggeneralisasi pola dari data latih ke data validasi, mengindikasikan potensi overfitting.

**Tabel 1.** Hasil Train Menggunakan ResNet50

No	Epoch	Accuracy (Acc)	Validation Accuracy (Val acc)	Loss	Validation Loss (Val loss)
1.0	1.0	0.3967	0.202	2.2649	2.7236
2.0	2.0	0.4125	nan	2.0847	nan

MobileNetV2 juga diuji dan menunjukkan peningkatan bertahap dalam akurasi validasi dari epoch pertama hingga epoch keempat. Meskipun demikian, model ini menunjukkan fluktuasi dalam akurasi pelatihan, terutama pada epoch kelima, di mana pelatihan harus dihentikan karena akurasi yang sangat rendah. Fluktuasi ini menunjukkan ketidakstabilan selama proses pelatihan dan menandakan bahwa MobileNetV2 mungkin belum mencapai stabilitas yang diperlukan untuk menghindari overfitting.

**Tabel 2** Hasil Train Menggunakan MobileNetV2

No	Epoch	Accuracy		Loss	
		Acc	Val acc	Loss	Val loss
1	Epoch 1	0.2672	0.2685	2.9112	2.6320
2	Epoch 2	0.2578	0.3211	2.8022	2.5379
3	Epoch 3	0.2685	0.3346	2.6865	2.4709
4	Epoch 4	0.2747	0.3486	2.6094	2.4262
5	Epoch 5	accuracy: 0.2155 Accuracy -- Stop Training			

VGG16, yang dikenal sebagai model yang kuat untuk tugas klasifikasi gambar, menunjukkan akurasi pelatihan yang sangat tinggi, pada tabel 3, performa meningkat dari 89.47% pada epoch pertama menjadi 99.53% pada epoch ke-21. Namun, peningkatan ini disertai dengan tanda-tanda overfitting, di mana loss validasi mulai meningkat setelah epoch ke-11 meskipun akurasi validasi tetap tinggi. Ini mengindikasikan bahwa model VGG16, meskipun kuat, terlalu menyesuaikan diri dengan data latih sehingga tidak dapat sepenuhnya mengatasi data baru.

**Tabel 3** Hasil Train Menggunakan VGG16

No	Epoch	Accuracy (Acc)	Validation Accuracy (Val_acc)	Loss	Validation Loss (Val_loss)
1	1.0	0.8947	0.5177	0.233	0.8534
2	2.0	0.8862	0.5599	0.2553	0.7811
3	3.0	0.9024	0.7108	0.2278	0.5705
4	4.0	0.9178	0.6676	0.1994	0.7051
5	5.0	0.918	0.6651	0.2079	0.6713
6	6.0	0.9181	0.6917	0.199	0.6613
7	7.0	0.9306	0.6984	0.177	0.6554
8	8.0	0.9371	0.7239	0.1647	0.5746
9	9.0	0.9434	0.7569	0.1483	0.5711
10	10.0	0.9567	0.7548	0.1182	0.6442
11	11.0	0.9638	0.7831	0.1037	0.5573
12	12.0	0.9678	0.7758	0.0902	0.6246
13	13.0	0.9732	0.7774	0.0792	0.6913
14	14.0	0.9786	0.7778	0.063	0.7135
15	15.0	0.9832	0.7857	0.0535	0.7545
16	16.0	0.9878	0.7823	0.0381	0.8247
17	17.0	0.9884	0.7888	0.036	0.8922
18	18.0	0.9902	0.7947	0.0301	0.8701
19	19.0	0.9927	0.7955	0.0248	0.9686

20	20.0	0.9936	0.797	0.0196	0.9841
21	21.0	0.9953	0.7935	0.0143	1.0422

Berbeda dengan model-model di atas, CNN tradisional menunjukkan performa yang lebih stabil dan minim overfitting. Dengan peningkatan akurasi pelatihan dari 86.57% pada epoch pertama menjadi 97.42% pada epoch ke-100, dan peningkatan akurasi validasi dari 45.19% menjadi 81.64%, CNN tradisional berhasil menunjukkan kemampuan generalisasi yang lebih baik. Tidak ada tanda-tanda overfitting yang signifikan pada model ini, menjadikannya lebih dapat diandalkan untuk aplikasi di dunia nyata.

**Tabel 4** Hasil Train Menggunakan CNN Tradisional

No	Epoch	Accuracy (Acc)	Validation Accuracy (Val_acc)	Loss	Validation Loss (Val_loss)
75.	75.0	0.9589	0.7995	0.1042	0.4701
76.	76.0	0.9624	0.7976	0.0915	0.4686
77.	77.0	0.9632	0.8037	0.0944	0.4509
78.	78.0	0.965	0.7881	0.0914	0.502
79.	79.0	0.9611	0.7977	0.0978	0.4752
80.	80.0	0.9639	0.8008	0.0914	0.4794
81.	81.0	0.9649	0.7981	0.0902	0.4848
82.	82.0	0.9667	0.8104	0.0868	0.4565
83.	83.0	0.9649	0.8004	0.0875	0.4644
84.	84.0	0.9653	0.7843	0.0882	0.5013
85.	85.0	0.9644	0.8031	0.0922	0.4882
86.	86.0	0.9671	0.7842	0.0842	0.5137
87.	87.0	0.9665	0.8037	0.0859	0.4687
88.	88.0	0.9685	0.8121	0.0822	0.4649
89.	89.0	0.9671	0.8111	0.0861	0.4561
90.	90.0	0.9702	0.7901	0.0807	0.5185
91.	91.0	0.9636	0.788	0.0907	0.4929
92.	92.0	0.9654	0.8062	0.0876	0.4613
93.	93.0	0.9693	0.7892	0.0801	0.5094
94.	94.0	0.9654	0.8018	0.0885	0.4828
95.	95.0	0.9695	0.8079	0.0784	0.4792
96.	96.0	0.9684	0.8026	0.0809	0.4775
97.	97.0	0.9678	0.8082	0.0799	0.4754
98.	98.0	0.9708	0.8048	0.0759	0.4797
99.	99.0	0.9718	0.8149	0.0716	0.4751
100.	100.0	0.9742	0.8064	0.0698	0.4774

### Pengembangan Wireframe dan Website

Setelah menyelesaikan pelatihan dan evaluasi model (Siswidiyanto et al., 2020), langkah selanjutnya adalah mengintegrasikan model terbaik, yaitu CNN tradisional, ke dalam sebuah aplikasi berbasis web. Pengembangan dimulai dengan pembuatan wireframe, Wireframe ini dirancang untuk memastikan bahwa antarmuka pengguna (UI) akan intuitif dan mudah digunakan oleh petugas keamanan yang akan memantau ekspresi wajah yang mencurigakan melalui sistem CCTV.



Gambar 1. Homepage

Wireframe ini mencakup beberapa elemen kunci, seperti layar utama yang menampilkan streaming video dari kamera CCTV, serta panel yang menampilkan hasil deteksi ekspresi wajah secara real-time. Terdapat juga fitur untuk mengakses database sistem.

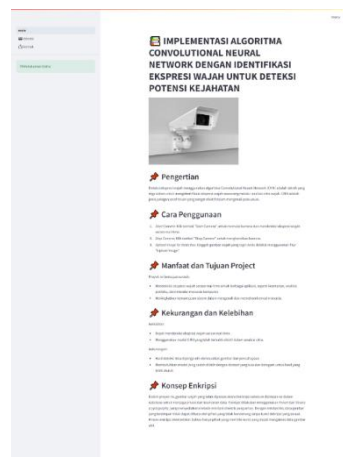


a. (Detection Page)

b. (Dete Contact Page)

Gambar 2 Fitur

Sistem ini dirancang agar dapat menerima input dari kamera CCTV secara real-time, memproses gambar menggunakan model yang sudah dilatih, dan menampilkan hasil deteksi di antarmuka pengguna. Kemudian, selanjutnya adalah halaman kontak, agar sewaktu waktu apabila dibutuhkan developer bisa langsung membantu petugas. Setelah melalui beberapa evaluasi dari user, berikut adalah hasil akhir halaman home, halaman ini menyediakan informasi tentang pengertian proyek, cara penggunaan, manfaat dan tujuan proyek, serta kekurangan dan kelebihan. Selain itu, halaman ini juga menjelaskan konsep enkripsi fernet(Ardiyanti, 2016) yang digunakan untuk menjaga privasi dan keamanan data gambar yang diproses. Dengan antarmuka yang intuitif dan informatif, halaman ini memudahkan pengguna memahami dan memanfaatkan sistem deteksi ekspresi wajah yang telah dikembangkan.



Gambar 3. Hasil Akhir dari Homepage

Pada halaman detection, pengguna dapat mengakses fitur untuk memulai dan menghentikan kamera, yang memungkinkan deteksi ekspresi wajah secara real-time. Pengguna juga memiliki opsi untuk mengunggah gambar melalui fitur "Upload Image" untuk analisis deteksi ekspresi. Instruksi

penggunaan dijelaskan dengan jelas di bawah bagian "Cara Penggunaan", mencakup langkah-langkah untuk memulai kamera, menghentikan kamera, dan mengunggah gambar untuk deteksi. Halaman ini dirancang untuk memberikan pengalaman pengguna yang intuitif dan memudahkan dalam menjalankan dan memahami fungsi deteksi ekspresi wajah dalam proyek ini.

### Hasil Pengujian Sistem dan Model

Setelah website selesai dikembangkan, tahap pengujian dilakukan untuk memastikan bahwa sistem berfungsi sesuai dengan yang diharapkan. Pengujian dilakukan dalam beberapa tahapan, meliputi pengujian fungsionalitas (black box), pengujian internal kode dan logika (white box), serta pengujian terhadap pengalaman pengguna melalui System Usability Scale (SUS).

Pengujian black box difokuskan pada validasi fungsi-fungsi yang ada di dalam website, tanpa memperhatikan implementasi internal dari sistem (Parlika et al., 2020). Pengujian ini melibatkan simulasi pengguna untuk memastikan bahwa setiap fitur, seperti pemrosesan streaming video dari CCTV, deteksi ekspresi wajah secara real-time, dan akses terhadap laporan hasil deteksi, berfungsi dengan baik. Berdasarkan hasil pengujian *black box* yang sudah dilakukan dari 11 *Test Case website* yang sudah dibuat di ujikan kepada 3 dosen informatika berikut adalah hasilnya:

**Tabel 5.** Form Black Box

Nama Pengujian	Test Case	Hasil yang Diharapkan	Hasil yang Didapatkan	Kesimpulan		
				Diterima	Perbaikan	
Halaman Home	User dapat melakukan gulir atau scroll ke bawah	User dapat melihat semua fitur yang ada pada halaman home (page prediksi, form upload)	Website akan menampilkan semua fitur yang ada pada halaman home	√	√	√
Koneksi ke Basis Data	Aplikasi dapat terhubung ke basis data	Koneksi berhasil tanpa error	Aplikasi berhasil terhubung ke basis data	√	√	√
Membuat Tabel di Basis Data	Tabel `emotion_data` dibuat di basis data	Tabel `emotion_data` ada di basis data	Tabel berhasil dibuat di basis data	√	√	√
Menghasilkan Kunci Enkripsi	Kunci enkripsi dihasilkan	Kunci enkripsi dihasilkan tanpa error	Kunci enkripsi berhasil dihasilkan	√	√	√
Mengenkripsi Gambar	Gambar dienkripsi dengan benar	Gambar berhasil dienkripsi	Gambar berhasil dienkripsi tanpa error	√	√	√
Prediksi Ekspresi Wajah	Sistem dapat memprediksi ekspresi wajah	Ekspresi wajah berhasil diprediksi dan ditampilkan	Ekspresi wajah berhasil diprediksi	√	√	√
Menyimpan Hasil Deteksi ke Basis Data	Hasil deteksi disimpan di basis data	Hasil deteksi disimpan tanpa error	Hasil deteksi berhasil disimpan di basis data	√	√	√
Menampilkan Gambar yang Diunggah	Gambar yang diunggah ditampilkan di halaman web	Gambar ditampilkan tanpa error	Gambar berhasil ditampilkan di halaman web	√	√	√

Memulai Kamera untuk Deteksi Real-time	Kamera mulai dan menampilkan video secara real-time	Video real-time ditampilkan tanpa error	Kamera berhasil menampilkan video real-time	√	√	√
Mengunggah Gambar untuk Deteksi	Gambar diterima dan diproses untuk deteksi	Gambar diterima dan diproses tanpa error	Gambar berhasil diproses untuk deteksi	√	√	√
Menampilkan Hasil Deteksi	Hasil deteksi ditampilkan di halaman web	Hasil deteksi ditampilkan tanpa error	Hasil deteksi berhasil ditampilkan	√	√	√

Hasil pengujian sebagai berikut:

Pengujian pertama:

$$\text{Tercapai} : \frac{11}{11} \times 100 \% = 100 \%$$

$$\text{Gagal} : \frac{0}{11} \times 100 \% = 0 \%$$

Pengujian kedua:

$$\text{Tercapai} : \frac{11}{11} \times 100 \% = 100 \%$$

$$\text{Gagal} : \frac{0}{11} \times 100 \% = 0 \%$$

Pengujian ketiga:

$$\text{Tercapai} : \frac{11}{11} \times 100 \% = 100 \%$$

$$\text{Gagal} : \frac{0}{11} \times 100 \% = 0 \%$$

$$\text{Jumlah presentase rata-rata tercapai} = \frac{300\%}{3} = 100\%$$

$$\text{Jumlah presentase rata-rata gagal} = \frac{0\%}{3} = 0\%$$

Kemudian, pengujian white box dilakukan dengan menganalisis kode dan logika yang menggerakkan website, termasuk integrasi model CNN tradisional dengan sistem backend yang dibangun menggunakan Streamlit dan SQLite. Pengujian ini bertujuan untuk memastikan bahwa semua bagian dari kode berfungsi seperti yang diharapkan (Pratala et al., 2020), tanpa kesalahan atau bug yang dapat mempengaruhi performa sistem.

**Tabel 6** White Box Testing

Node	Code	Pengertian
1.	conn = connect_database()	Menghubungkan ke basis data SQLite
2.	key = generate_key()	Menghasilkan kunci enkripsi menggunakan Fernet
3.	encrypted_image = encrypt_image(image_blob, key)	Mengenkripsi gambar menggunakan kunci yang dihasilkan
4.	label = predict_emotion(face_image, emotion_model)	Memprediksi ekspresi wajah menggunakan model CNN
5.	save_to_database(face, label, conn, key)	Menyimpan gambar hasil deteksi yang telah dienkripsi ke dalam basis data
6.	cap = cv2.VideoCapture(0)	Memulai kamera untuk mendeteksi ekspresi wajah secara real-time
7.	st.file_uploader("Upload Gambar untuk Deteksi Disini")	Form untuk mengunggah gambar untuk deteksi ekspresi wajah
8.	st.image(image, channels="BGR")	Menampilkan gambar yang diunggah pada halaman Streamlit
9.	st.write("Detected expression: {result_text}")	Menampilkan hasil deteksi ekspresi wajah pada halaman Streamlit

Pengujian SUS dilakukan dengan melibatkan beberapa pengguna, yang sebagian besar adalah petugas keamanan yang akan menggunakan sistem ini dalam tugas sehari-hari (Galuh Sembodo et al., 2021). Hasil dari SUS menunjukkan skor rata-rata yang tinggi, mengindikasikan bahwa website ini dianggap sangat mudah digunakan dan efisien dalam mendukung pekerjaan mereka. Pengguna melaporkan bahwa antarmuka yang intuitif dan responsif sangat membantu dalam memantau ekspresi wajah yang mencurigakan secara real-time.

**Tabel 7** Hasil Pengujian System Usability Scale

Pertanyaan	Hasil Pengujian				
	R1	R2	R3	R4	R5
1	4	5	5	5	5
2	2	2	1	2	2
3	5	5	5	5	5
4	2	1	1	1	3
5	5	5	4	5	5
6	1	1	1	1	1
7	5	4	4	5	5
8	1	3	1	1	1
9	5	5	4	5	5
10	1	3	1	4	2
Jumlah Skor SUS	92.5	85	92.5	90	90
Nilai Rata-rata	90				

## Simpulan

Berdasarkan penelitian yang telah dilakukan, model Convolutional Neural Network (CNN) yang dilatih menggunakan dataset FER-2013 dengan 28.709 data pelatihan dan 7.178 data pengujian menunjukkan hasil yang sangat memuaskan. Model ini mampu mencapai akurasi pelatihan sebesar 97.42% dan validation accuracy sebesar 80.64%, menunjukkan bahwa CNN mampu mendeteksi berbagai ekspresi wajah seperti marah, jijik, takut, bahagia, netral, sedih, dan terkejut dengan baik. Keberhasilan ini menunjukkan bahwa CNN dapat diandalkan untuk mendeteksi ekspresi mencurigakan dan tidak mencurigakan, yang sangat penting dalam aplikasi keamanan untuk mencegah potensi kejahatan. Selain itu, penelitian ini juga mencakup tahapan pengujian yang komprehensif, termasuk pengujian black box, white box, dan system usability scale (SUS). Pengujian black box menunjukkan tingkat keberhasilan 100%, di mana semua skenario pengujian berhasil tanpa ada kegagalan. Pengujian white box juga mencapai keberhasilan 100%, memastikan bahwa seluruh alur logika dan fungsionalitas kode berfungsi dengan baik. Pengujian SUS dengan 5 responden menunjukkan hasil yang sangat baik dengan skor rata-rata 90, yang mengindikasikan tingkat kepuasan pengguna yang tinggi terhadap kinerja dan fungsionalitas aplikasi. Setelah melakukan komparasi dengan metode transfer learning menggunakan model ResNet50, MobileNetV2, dan VGG16, penelitian ini memutuskan untuk menggunakan arsitektur CNN tradisional sebagai pendekatan utama. Hal ini disebabkan oleh keefektifan dan stabilitas yang lebih tinggi dari CNN tradisional dalam mendeteksi ekspresi wajah yang mencurigakan dibandingkan dengan model-model transfer learning tersebut.

## Daftar Pustaka

- Alamsyah, D., & Pratama, D. (2020). Implementasi Convolutional Neural Networks (Cnn) Untuk Klasifikasi Ekspresi Citra Wajah Pada Fer-2013 Dataset. *Jurnal Teknologi Informasi*, 4(2).
- Andi Agustinus, Rudi Kurniawan, & Harma Oktafia Lingga Wijaya. (2023). *Klasifikasi Emosi Melalui Ekspresi Wajah Menggunakan Algoritma Deep Learning* (Vol. 2). Built Environment Research Unit, University of Wolverhampton.
- Ardiyanti, H. (2016). *Cyber-Security Dan Tantangan Pengembangannya Di Indonesia*. <http://kominformasi.go.id/index.php/content/detail/3980/>
- Arsal, M., Agus Wardijono, B., & Anggraini, D. (2020). Face Recognition Untuk Akses Pegawai Bank Menggunakan Deep Learning Dengan Metode CNN. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 6(1), 55–63. <https://doi.org/10.25077/teknosi.v6i1.2020.55-63>

- Corneanu, C. A., Simón, M. O., Cohn, J. F., & Guerrero, S. E. (2016). Survey on RGB, 3D, Thermal, and Multimodal Approaches for Facial Expression Recognition: History, Trends, and Affect-Related Applications. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(8), 1548–1568. <https://doi.org/10.1109/TPAMI.2016.2515606>
- Fadlil, A., Prayogi, D., Dahlan, A., & Penulis Korespondensi, Y. (2022). Sistem Pengenalan Wajah pada Keamanan Ruangan Berbasis Convolutional Neural Network. In *Jurnal Sains Komputer & Informatika (J-SAKTI)* (Vol. 6, Issue 2).
- Galuh Sembodo, F., Fadila Fitriana, G., & Prasetyo, N. A. (2021). Evaluasi Usability Website Shopee Menggunakan System Usability Scale (SUS). In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 5, Issue 2). <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Hermawan, E. (2021). *Klasifikasi Pengenalan Wajah Menggunakan Masker atau Tidak Dengan Mengimplementasikan Metode CNN ( Convolutional Neural Network )*.
- Hu, Q., Ma, L., & Zhao, J. (2018). DeepGraph: A PyCharm Tool for Visualizing and Understanding Deep Learning Models. *Proceedings - Asia-Pacific Software Engineering Conference, APSEC, 2018-December*, 628–632. <https://doi.org/10.1109/APSEC.2018.00079>
- Jamhari, A., Mukti Wibowo, F., & Andi Saputra, W. (2020). *Perancangan Sistem Pengenalan Wajah Secara Real-Time pada CCTV dengan Metode Eigenface*. 2(2), 20–032. <https://doi.org/10.20895/INISTA.V2I2>
- Mollahosseini, A., Chan, D., & Mahoor, M. H. (2016). *Going Deeper in Facial Expression Recognition using Deep Neural Networks*.
- Muharram, R. F., Suryadi, A., Raya, J., No, T., Gedong, K., Rebo, P., & Timur, J. (2022). Implementasi Artificial Intelligence Untuk Deteksi Masker Secara Realtime Dengan Tensorflow Dan Ssdmobilenet Berbasis Python. *Jurnal Widya*, 3(2), 281–290. <https://jurnal.amikwidyaloka.ac.id/index.php/awl>
- Nathasya, Y., & Ginting, B. (2023). *Deteksi Emosi Anak Dari Ekspresi Wajah Dengan Deep Learning Untuk Menilai Kesehatan Mental*.
- Parlika, R., Ardhan Nisaa', T., Ningrum, S. M., & Haque, B. A. (2020). Studi Literatur Kekurangan dan Kelebihan Pengujian Black Box. *TEKNOMATIKA*, 10(02), 1–5.
- Pratala, C. T., Asyer, E. M., Prayudi, I., & Saifudin, A. (2020). Pengujian White Box pada Aplikasi Cash Flow Berbasis Android Menggunakan Teknik Basis Path. *Jurnal Informatika Universitas Pamulang*, 5(2), 111. <https://doi.org/10.32493/informatika.v5i2.4713>
- Purba, G. E. P., Hadi Wijoyo, S., & Setiawan, N. Y. (2017). *Pengaruh Transfer Learning Resnet Dan Densenet Terhadap Performa Klasifikasi Ekspresi Wajah Menggunakan Dataset Fer-2013* (Vol. 1, Issue 1). <http://j-ptiik.ub.ac.id>
- Rahmat, A., Syafiih, M., & Faid, M. (2023). Implementasi Klasifikasi Potensi Penyakit Jantung Dengan Menggunakan Metode C4.5 Berbasis Website ( Studi Kasus Kaggle.Com ). *INFOTECH Journal*, 9(2), 393–400. <https://doi.org/10.31949/infotech.v9i2.6295>
- Sanner, M. F. (1999). *Python: A Programming Language For Software Integration And Development*. <http://www.python.org/doc/Comparisons.html>
- Shah, N., Bhagat, N., & Shah, M. (2021). Crime forecasting: a machine learning and computer vision approach to crime prediction and prevention. In *Visual Computing for Industry, Biomedicine, and Art* (Vol. 4, Issue 1). Springer. <https://doi.org/10.1186/s42492-021-00075-z>
- Siswidiyanto, S., Munif, A., Wijayanti, D., & Haryadi, E. (2020). Sistem Informasi Penyewaan Rumah Kontrakan Berbasis Web Dengan Menggunakan Metode Prototype. *Jurnal Interkom: Jurnal Publikasi Ilmiah Bidang Teknologi Informasi Dan Komunikasi*, 15(1), 18–25. <https://doi.org/10.35969/interkom.v15i1.64>
- Yam, J. H., & Taufik, R. (2021). *Hipotesis Penelitian Kuantitatif*. 3(2).