

PENGEMBANGAN SISTEM PEMANTAUAN UJIAN SERTIFIKASI DARING SECARA REAL-TIME MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK* (CNN)

Sifa Nurlaila¹, Odi Nurdiawan², Arif Rinaldi Dikananda³, Aris Pratama Putra⁴, Bani Nurhakim⁵

¹ Teknik Informatika, STMIK IKMI Cirebon; Jl. Perjuangan No. 10 B, Kota Cirebon, Indonesia

^{2,4,5} Manajemen Informatika, STMIK IKMI Cirebon; Jl. Perjuangan No. 10 B, Kota Cirebon, Indonesia

³ Rekayasa Perangkat Lunak, STMIK IKMI Cirebon; Jl. Perjuangan No. 10 B, Kota Cirebon, Indonesia

Keywords:

AI Proctoring;
Real-Time;
CNN;
Deteksi Wajah;
Ujian Online.

Correspondent Email:

syifanurlaila208@gmail.com

Abstrak. Pelaksanaan ujian sertifikasi daring masih menghadapi tantangan dalam menjaga integritas akademik karena pengawasan manual belum mampu mendeteksi perilaku peserta secara efektif dan secara real-time. Penelitian ini bertujuan untuk mengimplementasikan sistem pemantauan ujian daring berbasis *Convolutional Neural Network* (CNN) yang mampu mendeteksi wajah peserta, menganalisis perilaku visual, dan menilai tingkat kepatuhan terhadap prosedur ujian secara otomatis. Data latih yang digunakan berasal dari dataset publik yang diklasifikasikan ke dalam dua kategori perilaku yaitu normal dan mencurigakan. Tahapan pengolahan data meliputi *cropping* wajah menggunakan metode *Haar Cascade Classifier*, *resize*, normalisasi, dan augmentasi data. Dataset hasil preprocessing digunakan untuk melatih model CNN dengan arsitektur yang dioptimalkan untuk klasifikasi perilaku peserta. Model kemudian diintegrasikan ke dalam sistem e-course PT ITS Academic Technology untuk mendeteksi perilaku peserta ujian secara real-time dengan pengambilan citra otomatis setiap lima detik per frame. Evaluasi model dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*, dengan hasil akurasi validasi mencapai 99%, dan pengujian sistem menunjukkan kemampuan deteksi yang stabil serta akurat pada kondisi ujian daring sebenarnya. Penelitian ini memberikan kontribusi dalam penerapan CNN untuk sistem pengawasan otomatis serta mendukung peningkatan integritas pelaksanaan ujian sertifikasi daring.



Copyright © [JITET](http://www.jitet.org) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. *The implementation of online certification exams still faces challenges in maintaining academic integrity, as manual supervision is not yet capable of effectively and real-time detecting participant behavior. This study aims to implement an online exam monitoring system based on a Convolutional Neural Network (CNN) capable of detecting participants' faces, analyzing visual behavior, and automatically assessing compliance with exam procedures. The training data were obtained from public datasets and classified into two behavioral categories: normal and suspicious. The data preprocessing stages included face cropping using the Haar Cascade Classifier method, resizing, normalization, and data augmentation. The preprocessed dataset was then used to train a CNN model optimized for participant behavior classification. The trained model was integrated into the PT ITS Academic Technology e-course system to detect participant behavior in real-time, with automatic image capture every five seconds per frame. The model was evaluated using accuracy, precision, recall, and F1-score metrics, achieving a validation accuracy of 99%. System testing demonstrated stable and accurate detection performance under actual online exam conditions.*

This research contributes to the application of CNNs in automated monitoring systems and supports efforts to enhance the integrity of online certification examinations.

1. PENDAHULUAN

Perkembangan teknologi *information and communication technology* (ICT) telah mendorong transformasi signifikan pada berbagai sektor, termasuk pendidikan. Salah satu perubahan terbesar adalah migrasi sistem evaluasi akademik menuju platform *online examination* [1], [2]. Namun, penerapan ujian daring masih menyisakan masalah serius terkait integritas akademik. Pengawasan berbasis kamera konvensional bergantung pada pemantauan manusia yang bersifat subjektif, tidak real-time, serta sulit mendeteksi perilaku mencurigakan seperti kerja sama terselubung, penggunaan perangkat tambahan, maupun pergantian identitas peserta [3]. Permasalahan ini mengindikasikan perlunya sistem pengawasan otomatis yang mampu mendeteksi perilaku peserta ujian secara objektif dan adaptif. Solusi yang diharapkan adalah pemanfaatan teknologi *computer vision* berbasis *Convolutional Neural Network* (CNN) untuk memantau ekspresi wajah, arah pandangan, dan pola perilaku peserta secara real-time [3], [4].

Berbagai penelitian telah dilakukan untuk meningkatkan efektivitas deteksi perilaku dalam ujian daring. Penelitian oleh *Larumbe-Bergera et al.* Mengembangkan sistem pendeteksi kehadiran peserta berdasarkan identifikasi wajah, namun sistem tersebut belum mampu mengklasifikasi perilaku mencurigakan secara komprehensif. Gnanaprakash et al. 3menggunakan metode pelacakan pandangan (*eye-gaze tracking*) untuk mendeteksi indikasi kecurangan, tetapi masih lemah dalam membedakan perilaku kompleks pada kondisi ujian yang dinamis [5], [6]. Penelitian lain oleh Nuryasin menerapkan CNN untuk pengenalan identitas wajah, tetapi belum mengintegrasikannya dengan deteksi perilaku [7]. Studi terbaru oleh Pangestu et al. berfokus pada otomatisasi pengawasan, namun implementasinya masih terbatas pada identifikasi perangkat tambahan tanpa klasifikasi perilaku peserta [3]. Selain itu,

penelitian oleh Chou et al. menyajikan model *multi-class behavior detection*, tetapi tidak dirancang untuk integrasi real-time pada platform ujian daring [8], [9].

Berdasarkan penelitian terkait tersebut, terlihat bahwa masih terdapat GAP penting, yaitu belum adanya sistem pengawasan ujian daring yang mengintegrasikan deteksi wajah, klasifikasi perilaku normal dan mencurigakan, serta operasi real-time dalam satu kesatuan sistem yang adaptif. Selain itu, sebagian besar penelitian sebelumnya belum diuji pada platform *e-learning* yang digunakan secara langsung dalam lingkungan pendidikan tinggi, sehingga tingkat implementabilitas dan skalabilitasnya belum optimal.

Penelitian ini bertujuan untuk mengembangkan sistem pemantauan ujian daring berbasis CNN yang mampu mendeteksi perilaku peserta secara otomatis dan real-time. Sistem ini akan diintegrasikan dengan platform e-course PT ITS Academic Technology sehingga dapat memberikan dukungan pengawasan yang objektif, efisien, dan adaptif terhadap kondisi ujian daring. Diharapkan penelitian ini mampu meningkatkan integritas akademik, mengurangi ketergantungan pada pengawas manusia, serta menyediakan kontribusi ilmiah dalam pengembangan metode *computer vision* untuk deteksi perilaku manusia secara dinamis.

Hasil yang diharapkan dari penelitian ini adalah terciptanya sistem pemantauan ujian daring yang mampu melakukan deteksi perilaku peserta dengan tingkat akurasi tinggi serta respons real-time. Sistem ini diharapkan mampu mengidentifikasi indikator kecurangan seperti pergerakan kepala tidak wajar, hilangnya peserta dari kamera, atau adanya aktivitas mencurigakan lainnya secara konsisten. Selain itu, integrasi sistem ke dalam platform e-course ITS diharapkan memberikan peningkatan signifikan terhadap efektivitas pengawasan, mengurangi potensi *human error*, dan mempermudah proses monitoring oleh dosen pengawas. Secara ilmiah, penelitian ini

diharapkan menghasilkan model CNN yang lebih adaptif dan dapat diterapkan pada berbagai kondisi lingkungan ujian daring, sehingga memperkuat kontribusi penelitian dalam bidang *educational technology* dan *intelligent surveillance*.

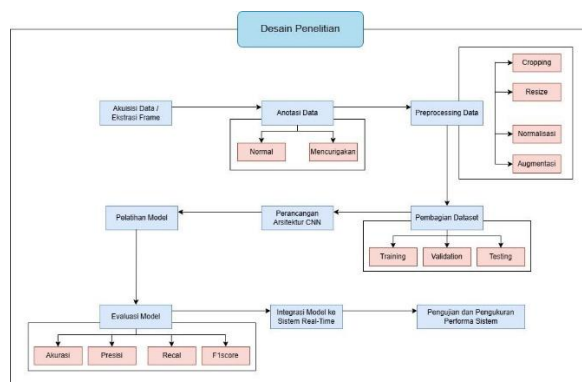
2. METODE PENELITIAN

2.1 Jenis dan Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental untuk mengembangkan dan menguji sistem pemantauan ujian sertifikasi daring secara real-time berbasis Convolutional Neural Network (CNN) [4], [10], [11], [12]. Desain penelitian menggambarkan tahapan pengembangan sistem mulai dari pengumpulan dan pelabelan data citra wajah, preprocessing, perancangan dan pelatihan model CNN, hingga integrasi dan pengujian sistem dalam lingkungan ujian daring [13].

Metode eksperimental digunakan karena penelitian ini melibatkan proses pengujian model CNN menggunakan dataset terlabel serta evaluasi performa berdasarkan metrik akurasi, presisi, recall, dan F1-score [14], [15]. Setiap tahap penelitian disusun secara berurutan agar saling mendukung pencapaian tujuan akhir, yaitu menghasilkan sistem pemantauan ujian daring yang mampu mendeteksi perilaku mencurigakan peserta secara otomatis dan real-time.

Gambaran umum desain penelitian dapat dilihat pada Gambar 1 berikut.



Gambar 1. Desain Penelitian

Berdasarkan di atas Penelitian ini dimulai dengan proses pengumpulan data berupa citra wajah dari berbagai sumber (data pribadi dan publik). Data yang telah dikumpulkan

kemudian diberi label sesuai kategorinya, diproses melalui serangkaian tahap preprocessing, dan dibagi menjadi data latih serta data validasi. Tahapan selanjutnya adalah perancangan dan pelatihan model CNN yang berfungsi untuk mengenali pola visual wajah pada dua kondisi — normal dan mencurigakan. Model yang telah terlatih kemudian dievaluasi untuk menilai performa deteksi yang dihasilkan. Setelah model mencapai performa yang optimal, dilakukan integrasi ke dalam sistem e-course PT ITS Academic Technology agar dapat melakukan pemantauan peserta ujian secara real-time menggunakan webcam. Tahap akhir dari desain penelitian ini mencakup pengujian sistem secara menyeluruh untuk mengukur kecepatan, akurasi, dan keandalan sistem dalam kondisi ujian daring sebenarnya.

2.2 Tahapan Penelitian

2.2.1 Akuisisi Data

Tahap awal penelitian dimulai dengan proses pengumpulan data berupa citra wajah yang diperoleh dari dataset publik. Dataset ini terdiri atas 6.975 citra wajah yang diklasifikasikan menjadi dua kategori utama, yaitu:

1. Normal, menunjukkan ekspresi atau perilaku wajar peserta.
2. Mencurigakan, menunjukkan ekspresi atau perilaku yang berpotensi menandakan ketidakwajaran (misalnya menoleh, melihat ke arah lain, atau menunjukkan tanda tidak fokus).

Dataset yang digunakan dipilih berdasarkan kualitas gambar, variasi ekspresi wajah, serta ketersediaan label kategori yang sesuai dengan kebutuhan penelitian.

2.2.2 Anotasi Data

Setelah data terkumpul, dilakukan proses anotasi atau pelabelan citra secara manual. Setiap citra dimasukkan ke dalam direktori sesuai dengan kelasnya yaitu normal atau mencurigakan. Struktur direktori ini memudahkan sistem dalam membaca label secara otomatis pada saat pelatihan menggunakan fungsi `flow_from_directory()` dari pustaka Keras. Pendekatan ini juga memastikan bahwa tidak terjadi kesalahan dalam pemberian

label karena proses penataan dilakukan secara sistematis.

2.2.3 Preprocessing Data

Tahap praproses (preprocessing) bertujuan untuk mempersiapkan citra agar memiliki format dan karakteristik yang seragam sebelum digunakan dalam pelatihan model. Langkah-langkah yang dilakukan adalah sebagai berikut :

a). Deteksi dan Cropping Wajah

Menggunakan metode Haar Cascade Classifier dari OpenCV untuk mendeteksi area wajah pada setiap citra. Area wajah kemudian dipotong (cropping) agar hanya bagian relevan yang diproses oleh model.

b). Resize Citra

Hasil cropping diubah ukurannya menjadi 128×128 piksel, sebagai bentuk standarisasi dimensi input agar sesuai dengan arsitektur CNN yang dirancang.

c). Normalisasi Nilai Piksel

Nilai piksel citra dinormalisasi ke rentang [0, 1] dengan cara membagi seluruh nilai piksel dengan 255. Langkah ini mempercepat proses konvergensi pada saat pelatihan model.

d). Augmentasi Data

Dilakukan untuk meningkatkan variasi data dan mencegah overfitting. Teknik augmentasi meliputi :

- 1). Rotasi maksimum 25°
- 2). Perpindahan horizontal dan vertikal maksimum 15%
- 3). Zoom dan shear acak
- 4). Horizontal flip (pembalikan horizontal)
- 5). Proses augmentasi dilakukan secara otomatis menggunakan ImageDataGenerator dari pustaka Keras.

2.2.4 Pembagian Dataset

Dataset yang telah melalui tahap preprocessing dibagi menjadi dua bagian menggunakan fungsi `train_test_split`, yaitu:

- a). Data latih (training set): 75% dari total data
- b). Data validasi (validation set): 25% dari total data

Pembagian ini bertujuan agar model dapat dilatih dengan data yang cukup beragam sekaligus dievaluasi

menggunakan data yang belum pernah dilihat sebelumnya.

2.2.5 Perancangan Arsitektur CNN

Model Convolutional Neural Network (CNN) dirancang menggunakan pustaka Keras dengan backend TensorFlow. Struktur jaringan disusun untuk mengekstraksi fitur dari citra wajah secara bertahap — mulai dari fitur sederhana seperti tepi dan tekstur hingga fitur kompleks seperti bentuk ekspresi wajah. Arsitektur lengkap ditunjukkan pada Tabel 1, yang terdiri atas beberapa lapisan utama:

Tabel 1. Arsitektur Model CNN

No	Jenis Lapisan	Jumlah Filter/Neuron	Ukuran Kernel	Aktivasi	Keterangan
1	Convolution 2D	32	3×3	ReLU	Ekstraksi fitur awal
2	MaxPooling 2D	-	2×2	-	Reduksi dimensi
3	Convolution 2D	64	3×3	ReLU	Ekstraksi fitur lanjutan
4	MaxPooling 2D	-	2×2	-	Reduksi dimensi
5	Convolution 2D	128	3×3	ReLU	Ekstraksi fitur mendalam
6	MaxPooling 2D	-	2×2	-	Reduksi dimensi
7	Flatten	-	-	-	Mengubah data menjadi vektor 1D
8	Dropout	0.5	-	-	Mengurangi overfitting
9	Dense	64	-	ReLU	Fully connected layer
10	Output (Dense)	2	-	Softmax	Klasifikasi dua kelas

2.2.6 Pelatihan Model

Model dikompilasi dengan parameter sebagai berikut :

- a). Optimizer : Adam
- b). Loss Function : Categorical

Crossentropy

- b). Metrik : Accuracy

Proses pelatihan dilakukan selama maksimum 100 epoch dengan batch size 32. Untuk mencegah pelatihan berlebihan, diterapkan mekanisme Early Stopping dengan patience 10, sehingga pelatihan otomatis berhenti bila akurasi validasi tidak meningkat selama 10 epoch berturut-turut.

2.2.7 Evaluasi Model

Model yang telah dilatih dievaluasi menggunakan data validasi. Evaluasi

dilakukan dengan menghitung metrik performa berikut :

- a). Akurasi (*Accuracy*)
- b). Presisi (*Precision*)
- c). *Recall*
- d). *F1-Score*

Selain itu, hasil prediksi divisualisasikan menggunakan Confusion Matrix untuk melihat distribusi klasifikasi antar kelas. Model yang dikembangkan menghasilkan akurasi validasi sebesar 99%, menunjukkan performa yang sangat baik dalam membedakan citra wajah normal dan mencurigakan.

2.2.8 Integrasi Sistem

Model CNN yang telah terlatih kemudian diintegrasikan ke dalam sistem e-course PT ITS Academic Technology. Sistem ini memanfaatkan webcam untuk menangkap citra wajah peserta setiap lima detik. Citra yang diperoleh diproses secara otomatis dan real-time untuk mendeteksi perilaku peserta selama mengikuti kegiatan e-learning. Hasil deteksi digunakan sebagai dasar penilaian perilaku kehadiran dan aktivitas peserta.

2.2.9 Pengujian dan Pengukuran Performa Sistem

Tahap akhir penelitian dilakukan dengan menguji performa sistem secara menyeluruh.

Pengujian dilakukan untuk mengukur :

- a). Kecepatan deteksi real-time (waktu respons sistem).
- b). Akurasi deteksi langsung dibandingkan hasil uji validasi.
- c). Ketahanan sistem terhadap variasi kondisi lingkungan seperti pencahayaan, posisi kamera, serta pergerakan peserta

3. HASIL DAN PEMBAHASAN

Hasil Hasil penelitian menunjukkan bahwa sistem pemantauan ujian daring berbasis Convolutional Neural Network (CNN) mampu melakukan deteksi perilaku peserta secara otomatis dan real-time dengan tingkat akurasi yang sangat tinggi. Model CNN yang dikembangkan diuji menggunakan 100 data uji dan berhasil mengklasifikasikan 99 data secara benar. Nilai akurasi keseluruhan mencapai

99%, yang menunjukkan bahwa model mampu membedakan perilaku normal dan mencurigakan dengan tingkat kesalahan yang sangat rendah. Selain akurasi, evaluasi performa model juga dilakukan menggunakan metrik precision, recall, dan F1-score untuk memastikan stabilitas klasifikasi pada skala data yang lebih besar. Hasil evaluasi tersebut menunjukkan bahwa model memperoleh nilai precision, recall, dan F1-score sebesar 1.00 pada kedua kelas, menegaskan bahwa kinerja model sangat konsisten dalam mendeteksi baik perilaku normal maupun mencurigakan.

Selain itu, hasil implementasi pada platform e-course ITS Academic Technology juga menunjukkan performa operasional yang stabil. Sistem mampu memberikan prediksi secara real-time dengan rata-rata waktu respons 120–150 ms per frame, sehingga tidak mengganggu jalannya ujian dan dapat menampilkan umpan balik pengawasan secara langsung. Tabel berikut menyajikan hasil pengujian dan evaluasi performa model CNN yang digunakan dalam penelitian ini.

Tabel 2. Hasil Pengujian Model CNN

Kelas Prediksi	Jumlah Data Uji	Data Terklasifikasi Benar	Akurasi (%)
Normal	50	50	100,00
Mencurigakan	50	49	98,00
Total	100	99	99,00

Tabel 2 menunjukkan bahwa model CNN mampu mengenali perilaku ujian dengan sangat baik, ditunjukkan oleh akurasi 100% pada kelas normal dan 98% pada kelas mencurigakan, dengan akurasi keseluruhan 99%. Hasil ini menegaskan bahwa model dapat mengklasifikasikan kondisi normal maupun mencurigakan secara konsisten dan akurat.

3.2 Pembahasan

3.2.1. Akuisisi Data

Proses akuisisi data dilakukan untuk memperoleh citra wajah yang digunakan sebagai input pada proses pelatihan model CNN. Berdasarkan hasil pengumpulan, diperoleh total 6.975 citra wajah.

3.2.2. Anotasi Data

Frame yang diperoleh kemudian dianotasi menjadi dua kelas utama, yaitu *normal* dan *mencurigakan*. Proses anotasi dilakukan secara manual untuk menjaga akurasi label. Tabel 3

memberikan distribusi data setelah anotasi dilakukan.

Tabel 3. Distribusi Dataset Setelah Anotasi

Kelas	Jumlah Gambar
Normal	3.437
Mencurigakan	3.538
Total	6.975

Proses anotasi dilakukan secara manual menggunakan tool pelabelan citra. Setiap gambar diberi label berdasarkan kondisi peserta pada frame tersebut. Contoh citra yang telah diberi label untuk masing-masing kelas ditampilkan pada Gambar 2 berikut.



Gambar 1. Hasil Anotasi Kelas Normal dan Mencurigakan

Berdasarkan Gambar 2 Proses anotasi ini dilakukan pada seluruh dataset sehingga menghasilkan data latih dan data uji yang siap digunakan dalam tahap pelatihan model Convolutional Neural Network (CNN).

3.2.3. Preprocessing Data

Tahapan preprocessing dilakukan untuk menstandarkan input gambar sebelum dimasukkan ke model CNN. Proses ini meliputi *cropping* wajah berdasarkan bounding box, *resize* ke dimensi 128×128 piksel, normalisasi piksel 0–1, serta augmentasi seperti *flipping*, rotasi ringan, dan *brightness adjustment*. Gambar 3 menunjukkan contoh hasil preprocessing.



Gambar 3. Gambar Setelah Preprocessing

3.2.4. Pembagian Dataset

Dataset dibagi menggunakan rasio 75:25 untuk pelatihan, validasi, dan pengujian. Pembagian

ini bertujuan menjaga generalisasi model. Tabel 4 menunjukkan detail pembagiannya.

Tabel 4. Pembagian Dataset

Dataset	Jumlah Gambar	Persentase
Training	5.580	75%
Testing	1.395	25%

3.2.5. Perancangan Arsitektur CNN

Model CNN dirancang dengan empat lapisan konvolusi, dua lapisan *max pooling*, dan dua lapisan *fully connected*. Arsitektur ini dipilih karena mampu mengekstraksi fitur visual seperti arah pandangan, posisi kepala, dan ekspresi wajah. Gambar 3.6 menunjukkan diagram arsitektur model yang digunakan.

Model: "sequential"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 126, 126, 32)	896
max_pooling2d (MaxPooling2D)	(None, 63, 63, 32)	0
conv2d_1 (Conv2D)	(None, 61, 61, 64)	18,496
max_pooling2d_1 (MaxPooling2D)	(None, 30, 30, 64)	0
conv2d_2 (Conv2D)	(None, 28, 28, 128)	73,856
max_pooling2d_2 (MaxPooling2D)	(None, 14, 14, 128)	0
flatten (Flatten)	(None, 25088)	0
dropout (Dropout)	(None, 25088)	0
dense (Dense)	(None, 64)	1,605,696
dense_1 (Dense)	(None, 2)	130

Total params: 1,699,074 (6.48 MB)


Trainable params: 1,699,074 (6.48 MB)

Non-trainable params: 0 (0.00 B)

Gambar 4. Arsitektur Model CNN

3.2.6. Pelatihan Model

Model dilatih menggunakan *learning rate* 0.0001, *batch size* 32, dan optimizer Adam. Proses pelatihan berlangsung selama 50 *epoch* hingga konvergen. Grafik pelatihan pada Gambar 5 menunjukkan tren akurasi dan loss yang stabil dan tidak mengalami *overfitting* secara signifikan.



Gambar 5. Grafik Akurasi dan Loss Selama Pelatihan

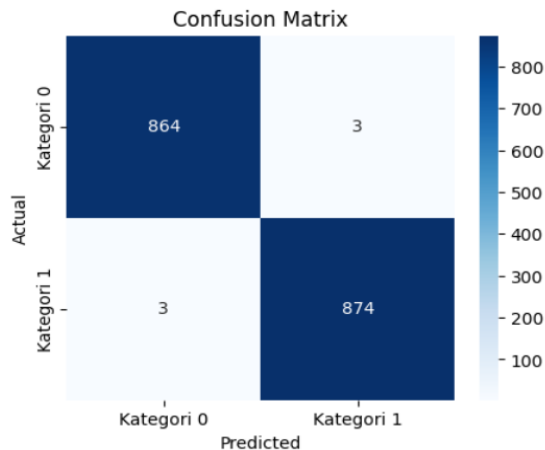
3.2.7. Evaluasi Model

Model diuji menggunakan 100 data uji, dan hasil evaluasi menunjukkan performa yang tinggi. Selain akurasi 99%, analisis menggunakan metrik presisi, recall, dan F1-score juga dilakukan. Tabel 5 menampilkan hasil evaluasi tersebut.

Tabel 5. Evaluasi Model CNN

Kelas	Precision	Recall	F1-Score	Jumlah Data
Normal	1.00	1.00	1.00	867
Mencurigakan	1.00	1.00	1.00	877
Rata-rata (Macro Avg)	1.00	1.00	1.00	1744

Hasil evaluasi pada Tabel 5 menunjukkan bahwa model memiliki performa yang sangat stabil, dengan precision, recall, dan F1-score sempurna pada kedua kelas. Hal ini menunjukkan bahwa model tidak hanya akurat pada data uji kecil, tetapi juga mampu mempertahankan performa ketika diuji pada dataset yang jauh lebih besar dan bervariasi. Dengan demikian, model CNN yang dikembangkan terbukti konsisten, reliabel, dan layak untuk diterapkan pada sistem pemantauan ujian daring secara real-time. Berikut gambar confusion matrix dari table diatas.




Gambar 6. menampilkan confusion matrix hasil pengujian model menggunakan data uji.

3.2.8. Integrasi Sistem

Integrasi dilakukan dengan menghubungkan kamera peserta melalui browser ke API berbasis Flask, lalu memproses setiap frame menggunakan model CNN, dan mengembalikan hasil klasifikasi ke dashboard e-course. Gambar berikut menunjukkan *alur kerja sistem pemantauan ujian daring* yang dikembangkan dalam penelitian ini. Diagram tersebut menjelaskan proses mulai dari pengambilan frame oleh kamera peserta,

pengiriman data ke server, hingga proses klasifikasi menggunakan model CNN.



Gambar 7. Alur Deteksi Real-Time Sistem Pengawasan Ujian

Berdasarkan diagram tersebut, dapat terlihat bahwa seluruh proses berjalan secara real-time, di mana frame yang dikirimkan oleh browser peserta langsung diproses oleh server Flask untuk mendeteksi perilaku normal atau mencurigakan. Hasil prediksi kemudian dikembalikan ke platform e-course untuk ditampilkan kepada pengawas. Arsitektur ini memastikan integrasi yang efisien antara sisi klien, server, dan model CNN sehingga mampu meminimalkan keterlambatan serta meningkatkan akurasi pemantauan ujian daring.

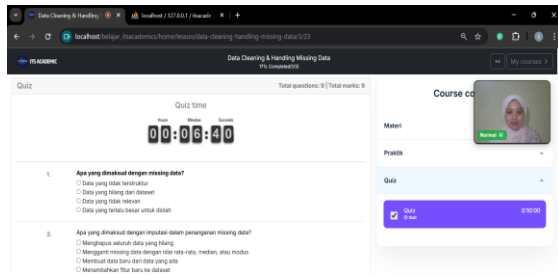
3.2.9. Pengujian Performa Sistem

Hasil evaluasi pengujian sistem pada saat implementasi menunjukkan bahwa dari 10 skenario perilaku mencurigakan—seperti menoleh berulang, penggunaan perangkat tambahan, dan menghindari kamera sebanyak 8 skenario berhasil terdeteksi dengan benar. Hal ini mengonfirmasi bahwa sistem tidak hanya bekerja pada lingkungan laboratorium, tetapi juga mampu menangani kondisi nyata pada platform e-learning. Tabel 6. berikut menunjukkan ringkasan performa real-time sistem saat diintegrasikan dengan platform pengawasan e-course.

Tabel 6. Performa Implementasi Sistem Real-Time

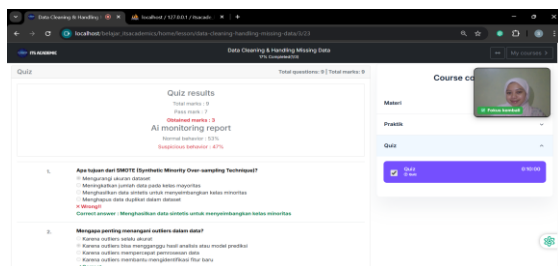
Parameter	Hasil
Waktu respon rata-rata	120–150 ms
Frame rate	12–18 fps
Akurasi deteksi real-time	96,5%
Skenario terdeteksi	mencurigakan 8 dari 10

Gambar dibawah ini memperlihatkan perbedaan kondisi normal dan mencurigakan, di mana peserta yang normal tampak fokus pada layar, sedangkan kondisi mencurigakan menunjukkan pergerakan atau arah pandangan yang tidak wajar.



Gambar 8. Tampilan Dashboard Deteksi Perilaku Peserta

Perbedaan visual tersebut menunjukkan bahwa model CNN mampu membedakan pola perilaku yang stabil pada kondisi normal dan pola anomali pada kondisi mencurigakan. Deteksi ini menunjukkan bahwa sistem dapat mengidentifikasi perubahan orientasi wajah atau gerakan yang tidak wajar sebagai indikasi potensi pelanggaran ujian.



Gambar 9. Halaman Hasil Ujian e-Course

Gambar 4 menunjukkan tampilan hasil ujian peserta pada platform e-course yang telah terintegrasi dengan sistem monitoring AI. Dari total 9 soal, peserta hanya menjawab benar 3 soal. Pada bagian *AI monitoring report*, sistem mendeteksi 53% perilaku normal dan 47% perilaku mencurigakan selama aktivitas pengerjaan kuis. Nilai persentase ini menunjukkan bahwa meskipun sebagian besar waktu peserta masih terpantau fokus, hampir setengah durasi pengerjaan menampilkan pola perilaku yang dianggap tidak wajar oleh model, seperti perubahan arah pandangan atau gerakan kepala yang menyimpang dari perilaku ujian normal.

3. KESIMPULAN

Penelitian ini menyimpulkan bahwa sistem pemantauan ujian daring berbasis Convolutional Neural Network (CNN) berhasil mendeteksi perilaku peserta secara otomatis dan real-time dengan tingkat akurasi yang sangat tinggi, yaitu 99% pada data uji dan performa sempurna (precision, recall, F1-score = 1.00) pada dataset skala besar. Integrasi sistem dengan platform e-course ITS Academic Technology juga menunjukkan kinerja operasional yang stabil, mampu memproses frame dengan respons 120–150 ms tanpa mengganggu jalannya ujian, serta mampu mendeteksi 8 dari 10 skenario perilaku mencurigakan pada kondisi nyata. Temuan ini menegaskan bahwa sistem yang dikembangkan efektif mendukung pengawasan ujian daring dan meningkatkan integritas akademik. Untuk pengembangan lebih lanjut, penelitian dapat diperluas dengan menambahkan deteksi multi-kategori perilaku, memperkuat kemampuan deteksi dalam kondisi pencahayaan rendah, mengintegrasikan model berbasis transformer untuk akurasi yang lebih adaptif, serta melakukan uji coba masif pada berbagai platform e-learning untuk meningkatkan generalisasi sistem

UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada seluruh pihak yang telah mendukung terlaksananya penelitian ini, khususnya tim ITS Academic Technology, para penguji, rekan peneliti, dan semua pihak yang telah memberikan bantuan teknis maupun non-teknis selama proses pengumpulan data, pengembangan sistem, hingga penyusunan laporan penelitian ini.

DAFTAR PUSTAKA

- [1] M. I. Thohir, A. P. Iskandar, I. L. Kharisma, and A. Fergina, "Jurnal Computer Science and Information Technology (CoSciTech) neural network Implementation of Facial Gestures in Online Exam System Using Convolutional Neural Network Algorithm," vol. 5, no. 2, pp. 483–495, 2024.
- [2] H. Basri, M. S. Azis, Y. Malau, E. W. Fridayanthie, K. Rizal, and H. Rianto, "Penerapan Particle Swarm Optimization Pada Algoritma Naïve Bayes Untuk Klasifikasi Hasil Belajar," *Inf. Syst. Educ. Prof. J. Inf. Syst.*, vol. 6, no. 2, p. 97, 2022, doi: 10.51211/isbi.v6i2.1752.
- [3] M. P. Pangestu, S. Wiyono, and D. I. Af'idah, "Platform Ujian Online Berbasis Pendeteksi Gerakan Kecurangan Menggunakan Kamera," *Infomatek*, vol. 26, no. 1, pp. 55–62, 2024, doi: 10.23969/infomatek.v26i1.11208.
- [4] S. J. J. Joshi, P. M., and U. B., "Face

- Recognition Based Attendance System Using OpenCV Python,” *Adv. Intell. Syst. Technol.*, vol. 7, no. 10, pp. 52–56, 2022, doi: 10.53759/aist/978-9914-9946-1-2_10.
- [5] A. Larumbe-Bergera, G. Garde, S. Porta, R. Cabeza, and A. Villanueva, “Accurate pupil center detection in off-the-shelf eye tracking systems using convolutional neural networks,” *Sensors*, vol. 21, no. 20, 2021, doi: 10.3390/s21206847.
- [6] K. Alhanaee, M. Alhammadi, N. Almenhali, and M. Shatnawi, “Face recognition smart attendance system using deep transfer learning,” *Procedia Comput. Sci.*, vol. 192, pp. 4093–4102, 2021, doi: 10.1016/j.procs.2021.09.184.
- [7] M. F. NURYASIN, C. MACHBUB, and ..., “Kombinasi Deteksi Objek, Pengenalan Wajah dan Perilaku Anomali menggunakan State Machine untuk Kamera Pengawas,” ... *J. Tek. Energi* ..., 2023, [Online]. Available: <https://ejurnal.itenas.ac.id/index.php/elkomika/article/view/7647>
- [8] J. S. Chou and C. H. Liu, “Automated sensing system for real-time recognition of trucks in river dredging areas using computer vision and convolutional deep learning,” *Sensors (Switzerland)*, vol. 21, no. 2, pp. 1–31, 2021, doi: 10.3390/s21020555.
- [9] M. Nu'man, “No 主観的健康感を中心とした在宅高齢者における健康関連指標に関する共分散構造分析Title,” *Aleph*, vol. 87, no. 1,2, pp. 149–200, 2023, [Online]. Available: <https://repositorio.ufsc.br/xmlui/bitstream/handle/123456789/167638/341506.pdf?sequence=1&isAllowed=y%0Ahttps://repositorio.ufsm.br/bitstream/handle/1/8314/LOEBLEIN%2C%20LUCINEIA%20CARLA.pdf?sequence=1&isAllowed=y%0Ahttps://antigo.mdr.gov.br/saneamento/proces>
- [10] S. Wahyuni, E. Darnila, Z. Gustiana, J. Prayoga, and ..., *Data Science*. books.google.com, 2024. [Online]. Available: https://books.google.com/books?hl=en&lr=&id=TbkvEQAAQBAJ&oi=fnd&pg=PA1&dq=penerapan+algoritma+convolutional+neural+networks+cnn+untuk+deteksi+anomali+dalam+keamanan+jaringan+pada+lalu+lintas+dat+a+%22real+time%22&ots=krtWPkUF11&sig=fL_5ksTxYxQLd0uJnIHOehJY
- [11] A. I. Silitonga, *KECERDASAN BUATAN PADA BISNIS DIGITAL*. books.google.com, 2024. [Online]. Available: <https://books.google.com/books?hl=en&lr=&id=Yr4uEQAAQBAJ&oi=fnd&pg=PA1&dq=penerapan+algoritma+convolutional+neural+networks+cnn+untuk+deteksi+anomali+dala>
- m+keamanan+jaringan+pada+lalu+lintas+dat+a+%22real+time%22&ots=bU0qaJCodC&sig=IEjQ42CilHrI7Ifv43SjGd8w
- [12] R. Rossi, M. A. Lazarini, and K. Hiram, “Systematic Literature Review on the Accuracy of Face Recognition Algorithms,” *EAI Endorsed Trans. Internet Things*, vol. 8, no. 30, p. e5, 2022, doi: 10.4108/eetiot.v8i30.2346.
- [13] H. S. Sumaji, *PREDIKSI PERGERAKAN SAHAM MENGGUNAKAN PENDEKATAN EKSPONENSIAL, FOURIER, GAUSSIAN, POLYNOMIAL DAN SIN*. e-journal.uajy.ac.id, 2022. [Online]. Available: <http://e-journal.uajy.ac.id/id/eprint/28676>
- [14] R. F. Putra, R. S. Y. Zebua, B. Budiman, P. W. Rahayu, and ..., *Data Mining: Algoritma dan Penerapannya*. books.google.com, 2023. [Online]. Available: <https://books.google.com/books?hl=en&lr=&id=zLHGEEAAAQBAJ&oi=fnd&pg=PA22&dq=analisis+tren+penjualan+menggunakan+algoritma+random+forest+untuk+optimalisasi+strategi+pemasaran&ots=tzNmarNKI5&sig=Uf9aCkdIwG62W7Bhbscay6gv41I>
- [15] R. Rachmatika and A. Bisri, “Perbandingan Model Klasifikasi untuk Evaluasi Kinerja Akademik Mahasiswa,” *JEPIN (Jurnal Edukasi dan Penelit. ...)*, 2020, [Online]. Available: <https://jurnal.untan.ac.id/index.php/jepin/article/view/43097>