

Implementasi *Convolutional Neural Network* (CNN) untuk *Face Recognition* pada Sistem Presensi Kehadiran

Moch Arif Rochmanullah^{1*}, Nurlaily Vendyansyah¹, Febriana Santi Wahyuni¹

¹Program Studi S1 Teknik Informatika, Fakultas Teknologi Industri, Institut Teknologi Nasional Malang, Indonesia

*Email: 2118100@scholar.itn.ac.id

Info Artikel	Abstrak
Kata Kunci : <i>convolutional neural network, face recognition, sistem presensi, pengenalan wajah, deep learning</i> Keywords : <i>convolutional neural networks, face recognition, presence system, facial recognition, deep learning</i> Tanggal Artikel Dikirim : 27 November 2024 Direvisi : 7 Januari 2025 Diterima : 10 Februari 2025	Sistem presensi merupakan elemen penting dalam memastikan kehadiran, terutama di lingkungan pendidikan dan pekerjaan. Penelitian ini bertujuan mengembangkan sistem presensi berbasis <i>face recognition</i> menggunakan metode <i>Convolutional Neural Network</i> (CNN) untuk mengatasi kelemahan presensi manual yang rentan terhadap kecurangan, seperti di Prodi Teknik Informatika ITN Malang. Model CNN dilatih dengan <i>deep learning</i> menggunakan <i>dataset</i> wajah mahasiswa untuk mengenali pola unik fitur wajah. Hasilnya, model mencapai <i>training accuracy</i> sebesar 97%, <i>validation accuracy</i> sebesar 90%, dan pengujian mencapai <i>accuracy</i> 93%. Sistem ini meningkatkan efisiensi absensi dan akurasi identifikasi hingga 93%, sekaligus mengurangi potensi kecurangan. CNN terbukti andal dalam mendukung presensi berbasis teknologi dengan pengelolaan lebih praktis. Kendati demikian, performa model masih dapat ditingkatkan melalui pengayaan <i>dataset</i> dan optimasi model. Sistem ini berpotensi besar meningkatkan keandalan dan keamanan proses presensi, menjadi solusi inovatif dalam pengelolaan kehadiran di era digital. Abstract <i>The attendance system is a crucial element in ensuring presence, especially in educational and workplace settings. This study aims to develop a face recognition-based attendance system using the Convolutional Neural Network (CNN) method to address the weaknesses of manual attendance prone to fraud, as observed in the Informatics Engineering Study Program at ITN Malang. The CNN model was trained using deep learning techniques with a student face dataset to recognize unique facial features. The results show the model achieved a training accuracy of 97%, validation accuracy of 90%, and testing accuracy of 93%. This system improves attendance efficiency and identification accuracy by 93%, while reducing the potential for fraud. CNN has proven reliable in supporting technology-based attendance with more practical management. However, the model's performance can still be improved through dataset enrichment and optimization. This system holds significant potential to enhance the reliability and security of attendance processes, providing an innovative solution for managing attendance in the digital era.</i>

1. PENDAHULUAN

Sistem absensi merupakan proses pencatatan kehadiran individu yang sangat penting, baik dalam konteks pekerjaan maupun pendidikan, untuk memastikan pemenuhan kewajiban kehadiran. Dalam praktiknya, absensi dapat dilakukan secara manual menggunakan tanda tangan atau melalui sistem digital seperti absensi elektronik, yang kini semakin banyak menggunakan teknologi biometrik. Teknologi biometrik, khususnya pengenalan wajah (*face recognition*), telah menjadi salah satu solusi yang populer karena memungkinkan identifikasi individu secara unik melalui karakteristik wajah tanpa kontak fisik. Teknologi ini unggul dibandingkan metode biometrik lainnya, seperti pengenalan sidik jari atau iris mata, karena kenyamanan dan keandalannya dalam berbagai kondisi. [1] *Face Recognition* bekerja dengan menggunakan perangkat seperti kamera untuk menganalisis fitur unik wajah seseorang, menangkap gambar wajah dan kemudian membandingkannya dengan data pelatihan yang disimpan. [2] Proses ini dapat dimanfaatkan untuk berbagai aplikasi, termasuk autentikasi dan identifikasi, serta telah terbukti efektif dalam sistem presensi mahasiswa. [3] Salah satu teknik paling umum untuk pendekatan ini adalah *Convolutional Neural Network* (CNN), yang merupakan bagian *deep learning* yang dirancang khusus memproses informasi visual.

Convolutional Neural Network (CNN) merupakan pengembangan dari *multilayer perceptron* (MLP) serta jenis jaringan saraf *feedforward* (bukan berulang). CNN di *design* untuk mengolah data dua dimensi seperti gambar, dengan menganalisis pola-pola kompleks secara otomatis tanpa memerlukan pra-pemrosesan manual. CNN sering digunakan dalam aplikasi pengenalan citra karena kemampuannya mengenali fitur unik pada wajah, seperti bentuk, tekstur, dan pola lainnya. CNN juga merupakan bagian dari jaringan saraf tiruan tipe *deep neural network*, yang memiliki struktur jaringan mendalam sehingga mampu mengenali pola kompleks, baik secara langsung maupun tidak langsung. CNN juga memungkinkan untuk mendeteksi serta mengenali objek pada gambar dengan akurasi tinggi berkat kemampuannya dalam mengekstraksi vektor fitur berdimensi tinggi [4]. Tingkat akurasi CNN mencapai 98%, jauh lebih baik dibandingkan metode tradisional seperti *eigenfaces* dan LBPH [3]. CNN memiliki kemampuan untuk mengenali pola yang lebih kompleks dan tahan terhadap variasi pencahayaan, sudut pandang, atau ekspresi wajah, yang sering menjadi kelemahan pada metode tradisional. Hal ini membuat CNN lebih andal dalam aplikasi biometrik berbasis wajah di lingkungan nyata. Namun, metode ini juga memiliki tantangan, termasuk kebutuhan komputasi tinggi dan ketergantungan pada kualitas dataset [4].

Penelitian terdahulu juga telah membuktikan efektivitas CNN dalam berbagai penerapan teknologi *face recognition*. Pernyataan tersebut terbukti dari oleh penelitian [3] berfokus dalam pengembangan sistem presensi dengan *face recognition* menggunakan metode CNN. Penelitian ini menunjukkan akurasi sistem sebesar 92,5% dengan kemampuan mengenali wajah secara real-time. Sementara itu, penelitian [5] yang juga melibatkan *Convolutional Neural Network* (CNN) untuk pengenalan wajah juga menunjukkan bahwa sistem dapat berfungsi dengan baik bahkan dalam kondisi pencahayaan yang gelap. Sistem ini mencapai rata-rata akurasi 88,25% dengan akurasi sebesar 99,25% untuk pengguna asli dan 77,25% untuk bukan pengguna asli. Penelitian lain [6] yang berfokus pada penerapan metode CNN untuk sistem pengenalan wajah dengan menggunakan library *openFace*. Dalam penelitian ini, menggunakan ekstraksi fitur menggunakan CNN serta klasifikasi menggunakan *Support Vector Machine* (SVM) membuktikan bahwa metode ini memiliki akurasi tinggi hingga 99,84%. Hal ini menunjukkan metode CNN efektif untuk digunakan dalam sistem pengenalan wajah. Selanjutnya pada penelitian [7] juga melakukan penelitian *face recognition* dengan implementasi *Convolutional Neural Network* (CNN) untuk sistem presensi mahasiswa pada *zoom meeting*. Penelitian ini melakukan pengujian terhadap 10 relawan mahasiswa dan dari 150 uji coba, sistem berhasil mencatat tingkat akurasi sebesar 92% dalam mengenali wajah. Hasil penelitian menunjukkan bahwa sistem tersebut berfungsi dengan baik. Penelitian [8] mengembangkan sistem monitoring kehadiran mahasiswa berbasis pengenalan wajah menggunakan *Convolutional Neural Networks* (CNN). Sistem ini mampu mencatat kehadiran secara otomatis melalui deteksi wajah menggunakan kamera, dengan tingkat akurasi mencapai 75%. Implementasi ini menunjukkan efisiensi dalam mengurangi waktu dan kesalahan pada pencatatan kehadiran manual.

Dalam implementasinya, penggunaan CNN untuk pengenalan wajah dihadapkan pada beberapa kendala, seperti variasi ekspresi, pencahayaan, dan posisi wajah. Kondisi lingkungan seperti penggunaan aksesoris (masker atau topi) juga dapat memengaruhi performa sistem. Oleh karena itu, diperlukan langkah-langkah seperti peningkatan kualitas *dataset* untuk mencakup variasi tersebut, serta optimasi model menggunakan teknik *fine-tuning* dan *transfer learning*. Teknik-teknik ini memungkinkan penggunaan model pra-latih (*pre-trained model*) untuk mempercepat pelatihan dan meningkatkan akurasi sistem.


Setelah mengkaji beberapa penelitian, penulis memutuskan untuk melakukan penelitian implementasi *Convolutional Neural Network* (CNN) untuk *face recognition* pada sistem presensi kehadiran. Penelitian ini dilakukan di program studi Teknik Informatika ITN Malang. Sistem presensi praktikum pada program studi Teknik Informatika ITN Malang hingga saat ini masih menggunakan metode manual, di mana mahasiswa diharuskan menandatangani daftar hadir secara fisik. Selain memakan waktu, proses ini juga rentan terhadap potensi kecurangan presensi. Dalam konteks ini, dibutuhkan solusi teknologi yang dapat mengatasi masalah tersebut. Sistem presensi berbasis *face recognition* menjadi salah satu alternatif yang dapat di

implementasikan untuk kebutuhan ini. Penelitian ini juga bertujuan untuk mengimplementasikan CNN untuk *face recognition* pada sistem presensi. Berbeda dari penelitian sebelumnya, yang lebih berfokus pada pengembangan algoritma atau peningkatan akurasi secara umum, penelitian ini mengimplementasikan teknologi CNN pada lingkungan pendidikan, khususnya untuk mengatasi tantangan spesifik dalam presensi mahasiswa di program studi Teknik Informatika ITN Malang. Dengan penerapan teknologi ini, di harapkan sistem presensi dapat mengurangi potensi kecurangan, meningkatkan akurasi, dan mempermudah pengelolaan kehadiran mahasiswa. dengan sistem ini, diharapkan proses absensi menjadi lebih cepat, andal, dan sesuai dengan kebutuhan era digital.

2. METODE PENELITIAN

2.1 Tahapan Penelitian

Untuk menyelesaikan penelitian ini sesuai dengan tujuan penelitian, maka peneliti menetapkan langkah penelitian sebagai berikut:



Gambar 1. Tahapan Penelitian

Pada gambar 1 menggambarkan langkah-langkah utama dalam proses penelitian, terutama untuk implementasi metode *Convolutional Neural Network* (CNN) untuk *face recognition* pada presensi kehadiran. Proses ini diawali dengan analisis masalah, lalu dilanjutkan dengan pengumpulan data (akuisisi data), eksplorasi data, pemodelan (*modelling*) untuk membangun sistem, dan diakhiri dengan evaluasi hasil. Setiap tahap saling mendukung guna memastikan penelitian menghasilkan model berakurasi baik, berkinerja tinggi, dan sesuai kebutuhan.

2.1.1 Analisis Masalah

Pada tahap ini merupakan langkah awal penelitian, di mana masalah yang ingin dipecahkan didefinisikan dengan jelas. Setelah menemukan permasalahan maka dilakukan penguraian rumusan masalah dan tujuan dari penelitian. Analisis ini mencakup identifikasi kebutuhan sistem, tantangan teknis, dan justifikasi pemilihan metode CNN.

2.1.2 Akuisisi Data

Tahap untuk melakukan pengumpulan *dataset* wajah yang digunakan dalam melatih dan menguji model. *Dataset* ini berasal dari sumber internal misalnya diambil dari Mahasiswa yang akan menggunakan sistem dan sumber external relevan seperti *dataset public* untuk pengenalan wajah. *Dataset* diharuskan mencakup beberapa variasi seperti pencahayaan, sudut pandang, ekspresi wajah dan hingga penggunaan aksesoris. Kualitas dan kuantitas *dataset* sangat mempengaruhi akurasi model yang akan dibuat.

2.1.3 Eksplorasi Data

Pada tahap ini, *dataset* yang diperoleh dilakukan analisis untuk memahami Kualitas data. eksplorasi dilakukan untuk memahami distribusi data, mendeteksi data yang kurang dan duplikasi. Eksplorasi data mungkin mencakup analisis pola wajah, resolusi gambar, dan *preprocessing*. *Preprocessing* juga bertujuan untuk memperkecil (*resize*) tiap citra yang ada menjadi ukuran tertentu untuk memudahkan proses selanjutnya [9]. *Preprocessing* dilakukan dengan cara cropping bagian wajah, *normalization*, dan *augmentation* untuk meningkatkan kualitas data. *Cropping* dilakukan untuk memusatkan area wajah dengan menghilangkan latar belakang atau elemen tidak relevan, sedangkan *normalization* mengubah nilai piksel gambar menjadi skala tertentu (misalnya 0–1) untuk meningkatkan stabilitas dan efisiensi pelatihan. *Augmentation* mencakup teknik seperti rotasi, *flipping*, translasi, penyesuaian kecerahan, dan penambahan *noise* guna meningkatkan variasi *dataset*. Selain itu, *preprocessing* bertujuan untuk memperkecil (*resize*) tiap citra menjadi ukuran tertentu, seperti 64x64 piksel. Sehingga menghasilkan dataset yang siap untuk digunakan dalam pelatihan model dengan distribusi data yang optimal. Serta digunakan untuk mempercepat proses komputasi [10].

2.1.4 Modelling

Pada tahap ini, proses pengembangan model metode *convolutional neural network* (CNN) dan dilatih menggunakan *dataset* yang sudah disiapkan. Model dirancang agar dapat mengenali pola unik dari wajah secara otomatis. Setelah model dilatih, maka akan dilakukan pengujian menggunakan data validasi untuk menilai performa awal model. Parameter seperti *learning rate*, jumlah *epoch*, dan optimisasi dipertimbangkan agar model dapat mengidentifikasi wajah secara akurat.

2.1.5 Evaluasi

Tahap ini bertujuan untuk mengukur kinerja model agar mendapatkan nilai akurasi model. Pengujian dilakukan menggunakan data uji dan parameter seperti *accuracy*, *precision*, *recall* dan *F1-score* dianalisis. Performa sistem juga diuji pada kondisi pencahayaan dan variasi lain seperti perubahan ekspresi untuk memastikan sistem dapat bekerja dengan baik. Sedangkan untuk melakukan evaluasi performa model menggunakan persamaan berikut:


$$accuracy = \frac{\text{prediksi benar}}{\text{total data}} \times 100 \quad (1)$$

2.2 Face Recognition (Pengenalan Wajah)

Face Recognition merupakan sebuah teknologi yang memungkinkan perangkat komputer dapat mengenali wajah orang. [3] Teknologi ini telah banyak diaplikasikan dalam berbagai bidang, termasuk sistem absensi, keamanan, dan interaksi manusia-komputer. Tujuan dari *face recognition* adalah untuk meminimalkan kemungkinan kesalahan yang terjadi pada sistem ketika dilakukan secara manual. [11]. *Face recognition* adalah salah satu teknologi autentikasi biometrik yang memiliki tingkat kesulitan tinggi untuk ditiru, dikarenakan setiap individu memiliki karakteristik fisik wajah yang khas dan tidak sama. Namun, dalam penerapannya, terdapat sejumlah tantangan pada proses pengenalan wajah, seperti kondisi pencahayaan, variasi ekspresi, penggunaan aksesoris, dan perubahan penampilan wajah yang dapat memengaruhi tingkat akurasi sistem [12]. Dalam konteks aplikasinya, pengenalan wajah biasanya melibatkan perangkat seperti kamera untuk menangkap citra wajah, yang kemudian dibandingkan dengan data wajah yang sebelumnya (*Data Training*) telah tersimpan dalam basis data sistem [2].

2.3 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan jenis jaringan saraf buatan yang dikembangkan berdasarkan inspirasi dari cara kerja jaringan saraf biologis, seperti proses pemrosesan informasi di otak manusia. CNN terdiri dari lapisan konvolusi, lapisan penurunan sampel, dan lapisan *fully connected*. CNN menggabungkan jaringan saraf tiruan dan konvolusi diskrit untuk pemrosesan gambar dan dapat digunakan untuk mengekstrak fitur secara otomatis. [13]. Algoritma CNN pada dasarnya adalah sebuah arsitektur jaringan syaraf tiruan yang dirancang secara efektif untuk tugas klasifikasi citra. Inti dari algoritma CNN terletak pada operasi konvolusi, di mana setiap fitur dalam citra diekstraksi untuk membentuk pola-pola tertentu yang lebih mudah dikenali dan diklasifikasikan. Pendekatan ini memungkinkan proses pembelajaran gambar menjadi lebih sederhana dan lebih efisien untuk diimplementasikan. [14].




Gambar 2. Arsitektur *Convolutional Neural Network* (CNN)

Ditunjukkan pada Gambar 2 menggambarkan arsitektur *Convolutional Neural Network* (CNN) terdiri atas 3 komponen, yaitu input, komponen *feature learning* dan komponen *classification* [15]. Pada arsitektur CNN, proses dimulai dari *layer* input yang menerima data dalam bentuk gambar yang dinyatakan sebagai matriks *pixel* dengan dimensi tertentu misalnya (28, 28, 3) untuk gambar 28x28 *pixel* dengan tiga saluran warna (RGB). Tahap pertama dalam CNN adalah *feature learning* dengan menjalankan serangkaian operasi *convolution*, *relu* dan *pooling*. Operasi tersebut akan mengekstrak fitur penting dari data

masukan (input). Tahap *feature learning* akan menghasilkan representasi fitur yang merangkum pola-pola utama dalam data input, yang nantinya digunakan pada tahap *classification*. *Feature learning* merupakan proses yang digunakan untuk memperoleh informasi penting guna membedakan wajah individu yang berbeda dari citra wajah yang telah disesuaikan [6]. Selanjutnya akan dilanjutkan tahap *classification*, dimana fitur yang dihasilkan pada tahap *feature learning* digunakan untuk mengidentifikasi dan memprediksi kelas data.

2.3.1 Convolution


Lapisan konvolusi (*convolution layer*) pada CNN berfungsi untuk melakukan proses konvolusi pada citra *digital input* menggunakan filter (*kernel*) yang telah ditentukan. Umumnya, ukuran filter yang digunakan adalah 3x3. Proses konvolusi ini juga bergantung pada pergeseran filter yang diterapkan, yang dikenal dengan istilah *stride*, dan biasanya bernilai 1 [10].



Gambar 3. Proses *Convolution*

Gambar 3 menunjukkan cara kerja operasi konvolusi. Filter yang ditandai dengan kotak hijau, bergerak di atas input yang ditunjukkan dengan kotak biru, sementara hasil dari operasi konvolusi disalurkan ke peta fitur yang digambarkan dengan kotak merah.

2.3.2 ReLu




Gambar 4. Fungsi Aktivasi *ReLU* [10]

Gambar 4 menunjukkan proses penerapan fungsi aktivasi *ReLU*. Setelah langkah konvolusi, CNN akan menggunakan fungsi aktivasi *ReLU* (*Rectified Linear Unit*). *ReLU* adalah jenis lapisan yang menerapkan fungsi aktivasi tersebut, yang berfungsi untuk mengambil nilai input dan membatasi hasilnya hanya hingga nol, sehingga nilai negatif akan diubah menjadi nol. Fungsi ini berguna untuk menghilangkan nilai negatif dari *output layer* sebelumnya [10].

2.3.3 Pooling

Selanjutnya, dilakukan *pooling* untuk mengurangi dimensi *feature map* dengan mengambil nilai maksimum dalam area filter tertentu (misalnya 2x2) pada *Max Pooling*. Hal ini menjadikan jaringan lebih efektif dan lebih tahan terhadap perubahan kecil pada gambar, seperti pergeseran atau rotasi. Operasi ini mengurangi ukuran data yang harus diproses, membantu dalam mengurangi risiko *overfitting*. *Pooling layer* adalah filter yang memiliki ukuran dan *stride* tertentu, yang bergerak di atas *feature map*. Lapisan *pooling* yang sering digunakan adalah *max pooling*, yang mencari nilai maksimum pada area tertentu. *Pooling layer* bertujuan untuk mengurangi ukuran *feature map* yang dihasilkan oleh *layer* sebelumnya. [10]. Pada gambar 5 merupakan proses dari *pooling layer* dengan menggunakan filter 2x2 dan *stride* 2.



Gambar 5. *Pooling Layer*

2.3.4 Flatten


Pada tahap *flatten layer* ini mengubah nilai matriks dari hasil *max pooling* menjadi *vector* 1 dimensi. Proses pada *flatten layer* ditunjukkan pada gambar 6. Hasil dari tahap ini akan digunakan sebagai nilai inputan yang akan dimasukkan ke *fully connected layer* untuk menentukan hasil klasifikasi [10].



Gambar 6. Flatten Layer [10]

2.3.5 Fully Connected

Pada lapisan *fully connected* ini, strukturnya identik dengan *Multi-Layer Perceptron*. Setiap *neuron* dihubungkan dengan *neuron-neuron* pada *hidden layer* untuk menghasilkan output berdasarkan nilai bobot dan bias, menggunakan fungsi aktivasi *ReLU* [10]. Ilustrasi *fully connected layer* dapat dilihat pada gambar 7.




Gambar 7. Fully Connected Layer [10]

2.3.6 Softmax

Softmax adalah suatu fungsi yang menghitung probabilitas setiap kategori pada suatu target untuk semua kemungkinan kategori target dan menentukan kategori target berdasarkan masukan. Keuntungan *softmax* adalah ia beroperasi pada rentang probabilitas keluaran 0 hingga 1 [16].


2.4 Flowchart Metode Convolutional Neural Network (CNN)



Gambar 8. Flowchart Metode Convolutional Neural Network (CNN)

Flowchart pada gambar 13 menjelaskan proses dalam implementasi *Convolutional Neural Network* (CNN) ini dimulai dengan tahap *Start*, yang mengarah ke pemuatan *dataset* gambar wajah pada langkah *Load Dataset*. *Dataset* ini akan menjadi input utama untuk pelatihan model. Selanjutnya, gambar wajah yang dimuat mengalami proses *pre-processing*, yang terdiri dari beberapa langkah. Langkah pertama adalah *cropping wajah*, yaitu memotong gambar agar hanya menyisakan area wajah saja. Setelah itu, gambar di-*resize* atau diubah ukurannya agar memiliki dimensi yang seragam untuk input CNN. Proses *augmentasi data* kemudian dilakukan untuk menambahkan dataset dengan variasi gambar, seperti rotasi atau perubahan pencahayaan, agar model lebih tangguh terhadap variasi kondisi. Setelah *pre-processing* selesai, proses berlanjut ke tahap *feature learning* atau pembelajaran fitur, yang bertujuan untuk mengekstrak fitur penting dari citra wajah. Langkah ini dimulai dengan *Convolution 1 + relu*, di mana operasi konvolusi pertama dilakukan untuk mengenali pola dasar pada gambar, menghasilkan fitur awal. Kemudian, *Pooling 1* dilakukan untuk mengurangi ukuran fitur dan mempertahankan informasi utama melalui proses *downsampling*. Selanjutnya, dilakukan *Convolution 2 + relu* untuk mendeteksi fitur yang lebih kompleks, diikuti dengan *Pooling 2* untuk kembali mengurangi ukuran data hasil konvolusi. Pada *feature learning*, parameter seperti jumlah *epoch* dan *learning rate* dipilih secara hati-hati untuk memastikan efisiensi dan konvergensi model. Berdasarkan implementasi dalam kode, model menggunakan *optimizer Adam* yang secara otomatis menyesuaikan *learning rate* untuk mempercepat konvergensi. Jumlah *epoch* ditetapkan sebanyak 20 epoch, cukup untuk model mencapai performa optimal pada dataset tanpa *overfitting*, dengan mekanisme *early stopping* yang dapat menghentikan pelatihan lebih awal jika performa validasi tidak membaik. *Batch size* ditetapkan sebesar 32, yang seimbang untuk memanfaatkan sumber daya komputasi sekaligus menjaga stabilitas pelatihan. Parameter ini diuji dan disesuaikan selama eksperimen awal untuk memastikan model mampu belajar secara efektif dari dataset yang diberikan. Tahap *feature learning* ini memungkinkan model mempelajari ciri-ciri wajah yang lebih detail dari setiap gambar input. Pada tahap akhir, yaitu klasifikasi, hasil *feature learning* diubah menjadi vektor satu dimensi melalui proses *Flatten*, yang mempersiapkan data untuk diproses pada lapisan *Fully Connected*. Lapisan ini menghubungkan seluruh *neuron* pada hasil *flatten* dengan *neuron-neuron* dalam jaringan untuk menyatukan fitur yang telah dipelajari. Terakhir, fungsi *Softmax* pada lapisan output mengubah hasilnya menjadi probabilitas, sehingga model dapat mengidentifikasi kelas wajah yang dikenali. Proses ini berakhir di langkah *End*, di mana model menghasilkan *output* berupa hasil klasifikasi wajah berdasarkan kelas/identitas.

2.5 Flowchart Proses Presensi




Gambar 9. Flowchart proses presensi

Pada Gambar 14 menunjukkan alur dari proses prensensi, proses dimulai dengan inisialisasi camera, dilanjutkan dengan pengambilan *frame* dari camera oleh sistem. Setelah itu melakukan *capture frame*, kemudian sistem akan mendeteksi wajah dan melakukan proses identifikasi wajah praktikan. Setelah identifikasi selesai, jika label terdeteksi maka akan menampilkan identitas mahasiswa dan jika tidak maka akan kembali ke proses pengambilan frame. Setelah menampilkan identitas mahasiswa maka sistem akan melakukan proses prensensi. Dan proses akan berakhir pada langkah selesai.

3. HASIL DAN PEMBAHASAN

3.1 Evaluasi Pelatihan Model

Evaluasi yang berkelanjutan sangat penting untuk mengembangkan model yang optimal. Dalam penelitian ini, evaluasi dilakukan dengan memantau perubahan pada nilai *training loss*, *validation loss*, *training accuracy*, dan *validation accuracy*. Proses evaluasi ini menggunakan fungsi *loss categorical_crossentropy* dan *optimizer Adam*, serta matriks akurasi untuk menilai kinerja model. Hasil evaluasi dapat dilihat pada Gambar 21, yang menunjukkan jumlah *epoch* 20 dengan nilai *training accuracy* terakhir sebesar 0.9786, *training loss* 0.0739, *validation accuracy* 0.9059, dan *validation loss* 0.5318. Hasil ini mengindikasikan bahwa model memiliki performa yang baik dalam mengenali wajah, dengan *validation accuracy* mencapai 90.59%. Jika dibandingkan, penelitian [3] menunjukkan akurasi 92.5% dengan kemampuan mengenali wajah secara *real-time*, sedikit lebih tinggi dari model ini. Di sisi lain, penelitian [8] yang berfokus pada sistem monitoring kehadiran mahasiswa hanya mencapai akurasi 75%, menjadikan model ini lebih unggul dalam akurasi validasi. Perbandingan ini menunjukkan bahwa model yang dikembangkan cukup kompetitif untuk aplikasi pengenalan wajah.



Gambar 10 Evaluasi Pelatihan Model

3.2 Pengujian Model

Pengujian dilakukan terhadap 10 mahasiswa yang data wajahnya telah digunakan untuk melatih model. Hasil dari pengujian model yang telah dirancang dapat dilihat pada Tabel 1.

Tabel 1. Pengujian Model

NIM	Benar	Salah	Total	Precision	Recall	F1-Score
2118100	20	0	20	100%	100%	100%
2118101	20	0	20	95%	100%	98%
2118036	19	1	20	95%	95%	95%
2118035	20	0	20	95%	100%	98%
2118126	19	1	20	83%	95%	88%
2118108	17	3	20	89%	85%	87%
2118117	17	3	20	100%	85%	92%
2118120	18	2	20	82%	90%	86%
2118131	18	2	20	90%	90%	90%
2118112	18	2	20	95%	90%	92%
Total	186	14	200			
Akurasi	93%	7%	100%			

Ditunjukkan pada Tabel 1 kemungkinan paling banyak prediksi benar di tunjukkan pada NIM 2118100, 2118101, 2118035 dan 2118126. Dan prediksi salah paling banyak ditunjukkan pada NIM 2118108 dan 2118117. Prediksi salah pada proses identifikasi memiliki nilai akurasi 7% dikarenakan beberapa dataset yang memiliki jumlah sedikit, variasi ekspresi wajah dan kondisi pencahayaan yang berbeda. Sehingga dari hasil diatas dapat disimpulkan semakin banyaknya *dataset* saat pelatihan akan meningkatkan prediksi benar. Dalam 200 pengujian terdapat 166 prediksi benar dan 14 prediksi salah. Dengan nilai akurasi prediksi benar 93% dan prediksi salah 7% sehingga dapat disimpulkan model untuk *face recognition* tersebut memiliki tingkat akurasi yang baik.

4. KESIMPULAN

Penelitian implementasi *Convolutional Neural Network* (CNN) menghasilkan model CNN yang cukup baik dengan nilai *training accuracy* 97%, *training loss* 7%, *validation accuracy* 90% dan *validation loss* 53%. Dan pada pengujian model memiliki nilai *accuracy* 93%. Sistem ini memberikan alternatif praktis untuk pengelolaan presensi berbasis teknologi dengan tingkat akurasi tinggi. Namun, model ini masih membutuhkan data latih yang cukup kompleks dalam variasi data agar model memiliki hasil yang maksimal dengan tingkat *accuracy* lebih tinggi. Saran untuk penelitian selanjutnya adalah dapat menambahkan dataset yang cukup dan proposional pada setiap label/identitas. Serta dapat melakukan pengembangan model dengan output *embedding* agar pada saat melakukan penambahan *dataset* maka tidak melakukan pelatihan ulang pada model yang sudah dikembangkan. Selain itu, pengujian sistem dengan *dataset* yang lebih besar dan beragam juga disarankan untuk mengukur performa model pada kondisi nyata yang lebih kompleks.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Ibu Nurlaily Vendyansyah, ST., MT. dan Ibu Febriana Santi Wahyuni, S.Kom., M.Kom. atas bimbingan dan arahan yang diberikan. Terima kasih juga kepada pihak lain yang ikut mendukung dalam proses penyelesaian penelitian ini. Semoga penelitian ini bermanfaat dalam pengembangan teknologi face recognition pada dunia pendidikan, serta memberikan kontribusi untuk penelitian selanjutnya.

DAFTAR PUSTAKA

- [1] M. F. Isputrawan, "Pengembangan Aplikasi Absensi Berbasis Web Menggunakan Face Recognition," vol. 17, pp. 55–65, 2023.
- [2] R. A. Pratama, S. Achmadi, and K. Auliasari, "Penerapan Metode Convolutional Neural Network Pada Aplikasi Deteksi Wajah Pengunjung Perpustakaan," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 6, no. 1, pp. 253–258, 2022, doi: 10.36040/jati.v6i1.4517.
- [3] J. E. Wijaya, Axell Marvelino Samodra, "Sistem Presensi Pegawai dengan Face Recognition Menggunakan Deep Learning CNN," pp. 163–168, 2023.
- [4] P. A. Nugroho, I. Fenriana, and R. Arijanto, "Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia," *Algor*, vol. 2, no. 1, pp. 12–21, 2020.
- [5] S. Abdullah, Fahmi Fauzi Agustin, "Penerapan Biometric Face Recognition Menggunakan Metode Convolutional Neural Network Pada Aplikasi Berbasis Android," *INDEXIA Inform. Comput. Intell. J.*, vol. 6, 2024.
- [6] 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.
- [7] S. Satwikayana, S. Adi Wibowo, and N. Vendyansyah, "Sistem Presensi Mahasiswa Otomatis Pada Zoom Meeting Menggunakan Face Recognition Dengan Metode Convolutional Neural Network Berbasis Web," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 5, no. 2, pp. 785–793, 2021, doi: 10.36040/jati.v5i2.3762.
- [8] H. Chi and M. City, "Svitlana G. Antoshchuk 2)," vol. 3, no. 3, pp. 179–190, 2020.
- [9] I. Suhardin, A. Patombongi, and A. M. Islah, "Mengidentifikasi Jenis Tanaman Berdasarkan Citra Daun Menggunakan Algoritma Convolutional Neural Network," *Simtek J. Sist. Inf. dan Tek. Komput.*, vol. 6, no. 2, pp. 100–108, 2021, doi: 10.51876/simtek.v6i2.101.
- [10] A. Agustyawan, "Pengolahan Citra untuk Membedakan Ikan Segar dan Tidak Segar Menggunakan Convolution Neural Network," p. 6, 2015.
- [11] M. Hartomo, Brian Dwi, Hendrayudi, "Penerapan Computer Vision untuk Absensi Wajah Berbasis Algoritma CNN pada Guru SMK Excellent 1 Tangerang," *JTIM*, vol. 4, pp. 69–72, 2021.
- [12] N. M. Saraswati, R. Cipta, S. Hariyono, and D. Chandra, "Face Recognition Menggunakan Metode Haar Cascade Classifier Face Recognition Using The Method Haar Cascade Classifier And Local Binary Pattern Histogram," vol. 20,

- no. 3, pp. 1–6, 2023.
- [13] L. Faizal, Y. Yuyun, and H. Hazriani, “Identifikasi Sampah Plastik Menggunakan Algoritma Deep Learning,” *J. Ilm. Sist. Inf. dan Tek. Inform.*, vol. 6, no. 2, pp. 162–171, 2023, doi: 10.57093/jisti.v6i2.176.
- [14] D. Arsal, Muhammad ; Wardijono, Bheta Agus; Anggraini, “Face Recognition Untuk Akses Pegawai Bank Menggunakan Deep Learning,” *J. Nas. Teknol. dan Sist. Inf.*, vol. 6, pp. 55–63, 2020.
- [15] C. Widi Wiguna, J. Dedy Irawan, and M. Orisa, “Penerapan Metode Convolutional Neural Network Pada Aplikasi Deteksi Wajah Buronan Berbasis Web,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 6, no. 2, pp. 1051–1058, 2023, doi: 10.36040/jati.v6i2.5438.
- [16] H. Herdianto and D. Nasution, “Implementasi Metode Cnn Untuk Klasifikasi Objek,” *METHOMIKA J. Manaj. Inform. dan Komputerisasi Akunt.*, vol. 7, no. 1, pp. 54–60, 2023, doi: 10.46880/jmika.vol7no1.pp54-60.