Walisongo Journal of Information Technology
Vol 8 No 1 (2026): 85-102. DOI: 10.21580/wjit.2026.8.2.22821
ISSN 2715-0143 (online) | 2714-9048 (printed)

Pengembangan Sistem Absensi Karyawan Berbasis Pengenalan Wajah Menggunakan Convolutional Neural Network (CNN)

Abednego Maranatha [1]
[1]Universitas Nasional
Corresponding Author : ericabendego201196@gmail.com

Abstract: *Employee attendance systems require an effective mechanism for recording attendance to support employee attendance management in companies. Face recognition using a Convolutional Neural Network (CNN) is one of the technologies that can be applied to identify faces from digital images. This study aims to develop an employee attendance system based on face recognition using the CNN algorithm. The research data consist of employee facial images collected manually. System development includes CNN model training and the implementation of several features, including clock-in, clock-out, leave requests, permission requests, and attendance history accessible to administrators. Model training was conducted for 50 epochs using Google Colab, while the application was evaluated through manual testing. The results indicate that the model achieved accuracy values of 98.50% and 99.00% at epoch 50, as reported in the training results. The developed system also provides features for managing employee attendance records and viewing attendance history. Therefore, the system has the potential to support the digitalization of employee attendance recording in companies. However, the specific accuracy metrics and evaluation data split need to be described in greater detail to support a more precise interpretation of the model's performance.*

Keyword: *Convolutional Neural Network; Deep Learning; Employee Attendance; Face Recognition.*

Copyright ©2026 Walisongo Journal of Information Technology

Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License.

1. Pendahuluan

Perkembangan teknologi informasi dan kecerdasan buatan telah mendorong transformasi proses administrasi di berbagai organisasi, termasuk dalam pengelolaan kehadiran karyawan. Sistem absensi merupakan komponen penting dalam mendukung pencatatan kehadiran, pengawasan kedisiplinan, dan pengelolaan sumber daya manusia. Namun, sistem absensi konvensional yang mengandalkan pencatatan manual memiliki keterbatasan dalam hal efisiensi, ketepatan pencatatan, dan potensi manipulasi data. Oleh karena itu, diperlukan sistem absensi yang mampu melakukan identifikasi pengguna secara otomatis dan menyediakan pencatatan kehadiran secara lebih terstruktur. Salah satu teknologi yang dapat digunakan untuk

mendukung kebutuhan tersebut adalah *face recognition,* yaitu teknologi pengenalan identitas berdasarkan karakteristik wajah melalui pengolahan citra digital (Jannah & Nurhidayat, 2023; Mulyana & Aribatullah, 2025)

Teknologi *face recognition* memungkinkan sistem komputer mengidentifikasi atau memverifikasi seseorang dengan membandingkan karakteristik wajah yang terdeteksi dengan data wajah yang tersimpan dalam basis data. Penerapan teknologi ini dalam sistem absensi telah dikaji melalui berbagai pendekatan, baik menggunakan metode pengolahan citra konvensional maupun metode pembelajaran mendalam. (Muhammad et al., 2015), misalnya, mengimplementasikan metode *Eigenface* untuk pengenalan wajah pada sistem absensi dan menunjukkan bahwa tingkat kecocokan dipengaruhi oleh jumlah data wajah serta kondisi pengambilan gambar. Sementara itu, (Supriana & Pratama, 2017) mengkaji pendekatan pengenalan wajah berbasis kontur gradasi warna dan menunjukkan bahwa variasi pencahayaan dapat memengaruhi keberhasilan pengenalan. Temuan tersebut menunjukkan bahwa kinerja sistem pengenalan wajah tidak hanya ditentukan oleh algoritma yang digunakan, tetapi juga oleh karakteristik citra dan kondisi pengambilan data.

Seiring dengan perkembangan metode kecerdasan buatan, *Convolutional Neural Network* (CNN) menjadi salah satu pendekatan yang banyak digunakan dalam pengolahan citra. CNN memiliki kemampuan mempelajari representasi fitur secara bertingkat melalui operasi konvolusi, fungsi aktivasi, dan *pooling*, sehingga dapat digunakan untuk mengenali pola visual pada citra wajah. (Utomo et al., 2020) membahas penerapan pengenalan wajah pada aplikasi akademik daring, sedangkan (Azamy et al., 2023) mengkaji penerapan teknologi pengenalan wajah pada prototipe sistem absensi. Kedua kajian tersebut memperlihatkan relevansi teknologi pengenalan wajah dalam mendukung proses identifikasi otomatis. Dalam konteks pembelajaran mendalam, (Aldiani et al., 2024) mengimplementasikan CNN pada sistem absensi berbasis pengenalan wajah dan melaporkan akurasi sebesar 91% pada skenario penelitian mereka. Hasil tersebut menunjukkan potensi CNN untuk diterapkan pada sistem absensi, meskipun kinerjanya tetap perlu dievaluasi berdasarkan karakteristik dataset dan rancangan pengujian yang digunakan.

Penelitian selanjutnya mengeksplorasi penggunaan arsitektur CNN yang berbeda untuk meningkatkan kinerja pengenalan wajah. (Insani & Santoso, 2024) membandingkan model *pre-trained* VGG16, ResNet50, dan InceptionV3 pada sistem absensi karyawan. Penelitian tersebut melaporkan bahwa InceptionV3 memperoleh akurasi hingga 99% pada data uji yang digunakan. Di sisi lain, (Subeki & Eliyani, 2024) mengkaji pengenalan setengah wajah menggunakan arsitektur Xception, khususnya pada kondisi ketika sebagian informasi wajah tidak terlihat. Penelitian tersebut menunjukkan bahwa pengenalan wajah perlu mempertimbangkan variasi kondisi visual dan ketersediaan fitur wajah. Perbedaan pendekatan tersebut mengindikasikan bahwa pemilihan arsitektur serta karakteristik data merupakan aspek penting dalam pengembangan sistem pengenalan wajah berbasis CNN.

Penerapan CNN juga telah dikembangkan dalam sistem presensi berbasis web dan perangkat bergerak. (Jannah & Nurhidayat, 2023) mengembangkan sistem presensi karyawan berbasis web dengan CNN untuk mendukung proses identifikasi wajah secara lebih praktis. Selanjutnya, (Isputrawan & Suriyanti, 2023) mengkaji pengembangan aplikasi absensi berbasis web menggunakan teknologi pengenalan wajah. Pada tahun berikutnya, penelitian (Aldiani et al., 2024) memperlihatkan penerapan CNN pada sistem absensi dengan variasi dataset wajah, sedangkan (Mulyana & Aribatullah, 2025) mengembangkan sistem absensi berbasis pengenalan wajah yang terintegrasi dengan geolokasi untuk mendukung pemantauan kehadiran karyawan. Perkembangan tersebut menunjukkan bahwa penelitian pengenalan wajah tidak hanya berfokus pada kemampuan klasifikasi citra, tetapi juga pada integrasi model ke dalam sistem informasi yang dapat digunakan dalam proses administrasi kehadiran.

Penelitian terbaru juga menekankan pentingnya membedakan kinerja model pada data pelatihan, validasi, dan pengujian. (Rochmanullah et al., 2025) mengembangkan sistem presensi berbasis CNN dan melaporkan akurasi pelatihan sebesar 97%, akurasi validasi sebesar 90%, serta akurasi pengujian sebesar 93%. Sementara itu, (Nusantoko & Prapanca, 2025) mengembangkan aplikasi *Human Resource Information System* berbasis perangkat bergerak dengan fitur absensi wajah. Penelitian tersebut menggabungkan proses deteksi dan verifikasi wajah serta melakukan evaluasi sistem melalui pengujian fungsional dan pengukuran kinerja identifikasi. Hasil dari berbagai penelitian tersebut memperlihatkan bahwa evaluasi sistem absensi berbasis pengenalan wajah perlu mencakup kinerja model dan keberfungsian aplikasi. Pelaporan akurasi juga perlu menjelaskan secara tegas jenis data yang digunakan dalam evaluasi agar hasil penelitian dapat ditafsirkan secara tepat.

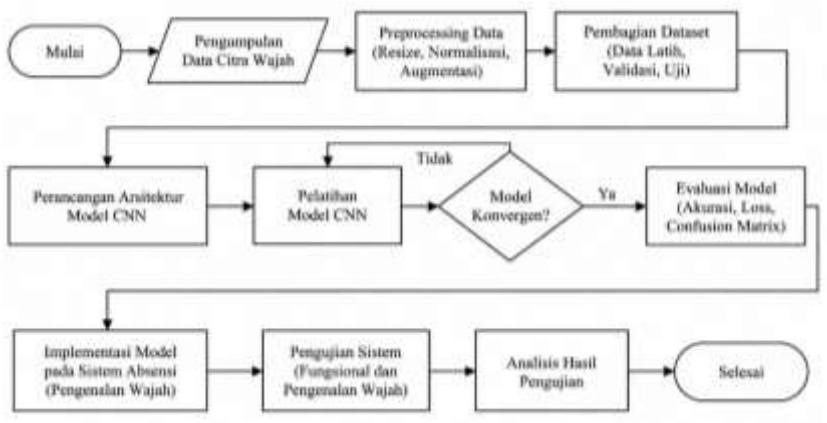
Berdasarkan penelitian terdahulu, pengembangan sistem absensi berbasis pengenalan wajah telah dilakukan melalui berbagai metode, arsitektur CNN, karakteristik dataset, serta bentuk integrasi aplikasi. Meskipun demikian, kinerja model dapat berbeda sesuai dengan jumlah dan variasi data wajah, konfigurasi pelatihan, serta prosedur evaluasi. Oleh karena itu, penerapan CNN pada sistem absensi karyawan tetap perlu disertai penjelasan mengenai proses pelatihan, karakteristik data, dan hasil pengujian yang dilakukan. Penelitian ini berfokus pada pengembangan sistem *face recognition* untuk absensi karyawan menggunakan algoritma CNN. Fokus tersebut diarahkan pada penerapan model pengenalan wajah ke dalam aplikasi absensi yang menyediakan fitur pencatatan kehadiran, pengajuan izin, pengajuan cuti, serta riwayat kehadiran.

Tujuan penelitian ini adalah mengimplementasikan algoritma CNN dalam sistem pengenalan wajah untuk mendukung proses absensi karyawan serta mengevaluasi hasil pelatihan model yang dikembangkan. Model dilatih menggunakan data wajah karyawan yang dikumpulkan untuk kebutuhan penelitian, kemudian diintegrasikan ke dalam aplikasi absensi. Selain fitur pencatatan kehadiran, aplikasi menyediakan fasilitas administrasi yang memungkinkan pengguna mengajukan izin dan cuti serta melihat riwayat kehadiran. Dengan demikian, kontribusi penelitian ini terletak pada penerapan CNN dalam pengembangan sistem absensi karyawan yang mengintegrasikan pengenalan wajah dengan fitur administrasi kehadiran. Evaluasi sistem diharapkan dapat memberikan gambaran mengenai kinerja model dan fungsi aplikasi berdasarkan pengujian yang dilakukan.

2. Metode

Penelitian ini merupakan penelitian pengembangan sistem yang berfokus pada penerapan algoritma *Convolutional Neural Network* (CNN) untuk membangun sistem absensi karyawan berbasis pengenalan wajah (*face recognition*). Objek penelitian adalah sistem absensi karyawan di Carbay Services Indonesia. Penelitian dilaksanakan dengan mempertimbangkan penggunaan sistem di lingkungan dalam dan luar ruangan sebagaimana disebutkan dalam rancangan penelitian.

Gambar 1. Flowchart Tahapan Penelitian



Pendekatan CNN dipilih karena metode ini dapat digunakan untuk mempelajari karakteristik visual citra wajah dan melakukan klasifikasi berdasarkan pola yang diperoleh selama proses pelatihan. Penerapan CNN untuk sistem presensi juga telah dikaji oleh (Syahrul Gunawan Ramdhani & Enny Itje Sela, 2023), yang menggunakan CNN untuk mengklasifikasikan wajah dalam sistem presensi universitas. Sementara itu, (Putra & Imelda, 2022) mengembangkan sistem presensi berbasis pengenalan wajah secara waktu nyata dengan pendekatan *Deep Neural Network*.

Pengumpulan Data

Data penelitian berupa citra wajah karyawan yang dikumpulkan secara manual dari karyawan yang terlibat dalam penelitian. Citra tersebut digunakan sebagai data masukan untuk membangun model pengenalan wajah. Dalam sistem klasifikasi berbasis CNN, setiap citra perlu dikaitkan dengan identitas yang sesuai agar model dapat mempelajari perbedaan karakteristik wajah antarindividu.

(Irawati et al., 2024) menerapkan tahapan pengumpulan dan pengelompokan citra wajah sebelum melakukan pelatihan serta validasi model CNN untuk sistem presensi. Penelitian tersebut menunjukkan pentingnya pengorganisasian data dalam pengembangan model pengenalan wajah. Oleh karena itu, data citra dalam penelitian ini perlu disusun berdasarkan identitas karyawan yang terdaftar pada sistem.

Meskipun demikian, jumlah keseluruhan citra wajah, jumlah identitas karyawan, serta pembagian data untuk pelatihan, validasi, dan pengujian perlu dijelaskan secara terperinci agar proses penelitian dapat direplikasi. Informasi tersebut perlu disesuaikan dengan data dan prosedur yang benar-benar digunakan oleh penulis.

Perancangan Model Convolutional Neural Network

Model pengenalan wajah dikembangkan menggunakan algoritma *Convolutional Neural Network* (CNN). Berdasarkan uraian implementasi pada naskah, citra masukan berukuran 150 × 150 piksel. Arsitektur yang dijelaskan mencakup lapisan konvolusi dengan *kernel* berukuran 3 × 3, *padding* jenis *same*, fungsi aktivasi ReLU, dan *stride* sebesar 1. Tahap berikutnya menggunakan *max pooling* berukuran 2 × 2 dengan *stride* sebesar 2 untuk mereduksi dimensi fitur. Fitur yang diperoleh kemudian diratakan melalui lapisan *flatten* dan diteruskan ke lapisan *dense* dengan fungsi aktivasi softmax untuk menghasilkan klasifikasi.

Secara umum, lapisan konvolusi berfungsi mengekstraksi fitur visual dari citra, sedangkan *pooling* mereduksi dimensi representasi fitur. Lapisan *dense* digunakan untuk memetakan fitur ke kelas keluaran, sementara softmax menghasilkan distribusi probabilitas prediksi pada kelas-kelas yang tersedia. Rancangan CNN untuk pengenalan wajah juga diterapkan (Irawati et al., 2024), yang mengembangkan model CNN menggunakan TensorFlow untuk klasifikasi wajah dalam sistem presensi.

Agar rancangan model dapat direplikasi, penulis perlu menyertakan jumlah lapisan konvolusi, jumlah filter pada setiap lapisan, jumlah neuron pada lapisan *dense*, serta parameter pelatihan yang digunakan. Parameter seperti *optimizer*, *learning rate*, *batch size*, dan jumlah *epoch* juga perlu dicantumkan berdasarkan implementasi sebenarnya.

Pelatihan dan Evaluasi Model

Setelah arsitektur CNN dirancang, model dilatih menggunakan citra wajah yang telah dikumpulkan. Proses pelatihan bertujuan agar model mempelajari karakteristik citra pada setiap kelas identitas sehingga dapat menghasilkan prediksi ketika menerima citra masukan. Naskah penelitian melaporkan proses pelatihan hingga 50 *epoch* serta menampilkan grafik akurasi dan *loss* selama pelatihan dan validasi.

Evaluasi model perlu dilakukan dengan membedakan hasil pada data pelatihan, data validasi, dan data pengujian. Pembedaan tersebut diperlukan agar kinerja model pada data yang telah dipelajari tidak disamakan dengan kemampuannya mengenali citra yang tidak digunakan selama pelatihan. (Putra & Imelda, 2022) melaporkan evaluasi model pengenalan wajah dengan memperhatikan variasi kondisi pengambilan citra, sedangkan (Irawati et al., 2024) menggunakan data validasi serta metrik evaluasi untuk menilai model CNN yang dikembangkan.

Dalam penelitian ini, naskah melaporkan angka akurasi sebesar 98,50% dan 99,00%. Namun, jenis pengukuran yang menghasilkan masing-masing angka tersebut belum dijelaskan secara konsisten. Oleh sebab itu, penulis perlu memastikan apakah kedua nilai tersebut merupakan akurasi pelatihan, validasi, pengujian, atau hasil pengukuran yang berbeda. Nilai tersebut juga perlu disertai penjelasan mengenai jumlah data dan prosedur pengujiannya.

Implementasi dan Pengujian Sistem

Model CNN yang telah dilatih selanjutnya digunakan dalam aplikasi absensi karyawan berbasis pengenalan wajah. Berdasarkan fitur yang dijelaskan dalam naskah, aplikasi menyediakan halaman beranda, absensi, izin, cuti, dan riwayat. Fitur-fitur tersebut mendukung pencatatan kehadiran serta pengelolaan informasi ketidakhadiran karyawan.

Pengujian sistem perlu mencakup dua aspek, yaitu pengujian fungsional aplikasi dan pengujian kinerja pengenalan wajah. Pengujian fungsional dilakukan untuk memeriksa apakah fitur yang tersedia berjalan sesuai dengan tujuan perancangannya. Adapun pengujian pengenalan wajah dilakukan untuk mengetahui kemampuan model mengidentifikasi wajah karyawan berdasarkan citra masukan. Penelitian (Syahrul Gunawan Ramdhani & Enny Itje Sela, 2023) serta (Putra & Imelda, 2022) dapat dijadikan referensi pembanding mengenai penerapan pengenalan wajah dalam sistem presensi.

Agar hasil pengujian dapat dinilai secara objektif, penulis perlu menjelaskan skenario pengujian, jumlah percobaan, kondisi pengambilan citra, dan kriteria keberhasilan identifikasi. Jika pengujian hanya dilakukan secara manual, keterbatasan tersebut perlu disebutkan dan hasilnya tidak boleh langsung digeneralisasi sebagai bukti kinerja sistem pada seluruh kondisi operasional.

3. Hasil dan Pembahasan

Data training

Data yang digunakan dalam penelitian ini berupa citra wajah karyawan yang dikumpulkan secara manual. Citra tersebut digunakan sebagai data pelatihan untuk membangun model *Convolutional Neural Network* (CNN) dalam mengenali identitas karyawan berdasarkan karakteristik visual wajah. Dataset yang digunakan ditampilkan pada Gambar 1, yang memperlihatkan sampel citra wajah sebagai masukan dalam proses pelatihan model.

Gambar 1. Data training



Citra wajah menjadi komponen utama dalam proses pelatihan CNN karena model mempelajari karakteristik visual dari citra masukan untuk membedakan identitas individu. Karakteristik tersebut dapat berupa pola visual yang terbentuk dari bagian-bagian wajah. Kemampuan model dalam mengenali wajah juga dapat dipengaruhi oleh kualitas citra, pencahayaan, posisi wajah, dan jarak pengambilan gambar.

Pada penelitian ini, citra wajah digunakan sebagai masukan untuk proses pembelajaran model CNN. Sampel data pelatihan ditampilkan sebagai representasi data yang digunakan dalam pengembangan sistem pengenalan wajah. Data tersebut selanjutnya diproses melalui tahapan pengolahan citra dan ekstraksi fitur sebelum menghasilkan prediksi identitas.

Perancangan dan Perhitutngan Algoritma CNN

Model CNN dirancang untuk memproses citra wajah melalui beberapa tahapan, yaitu konvolusi, fungsi aktivasi ReLU, *max pooling*, *flatten*, dan lapisan *dense* dengan fungsi aktivasi softmax. Citra masukan menggunakan resolusi 150 × 150 piksel. Pada tahap konvolusi, digunakan *kernel* berukuran 3 × 3, *padding* jenis *same*, dan *stride* sebesar 1. Selanjutnya, operasi *max pooling* menggunakan ukuran 2 × 2 dengan *stride* sebesar 2.

Tahap konvolusi digunakan untuk mengekstraksi fitur visual dari citra masukan. Fungsi aktivasi ReLU diterapkan untuk mengubah nilai negatif menjadi nol, sedangkan operasi *max pooling* mereduksi dimensi fitur dengan mengambil nilai maksimum pada setiap wilayah yang diproses. Hasilnya kemudian diubah menjadi vektor satu dimensi melalui proses *flatten* dan diteruskan ke lapisan *dense* untuk menghasilkan prediksi kelas.

Sebelum proses konvolusi dilakukan, citra wajah dibaca untuk memperoleh nilai piksel penyusunnya. Citra digital terdiri atas sejumlah piksel yang masing-masing memiliki nilai

intensitas warna. Pada citra RGB, setiap piksel direpresentasikan oleh tiga kanal warna, yaitu merah (*red*), hijau (*green*), dan biru (*blue*).

Gambar 2. Citra Masukan untuk Proses Pengolahan Piksel



Nilai piksel diperoleh melalui proses pembacaan citra menggunakan program Python. Hasil pembacaan tersebut berupa array yang merepresentasikan nilai piksel pada setiap kanal warna. Karena jumlah nilai piksel cukup besar, sebagian nilai ditampilkan dalam bentuk potongan array yang terdiri atas empat baris dan empat kolom pertama untuk memudahkan pengamatan.

Gambar 3. Output Nilai Piksel Citra



Program yang digunakan untuk membaca citra menghasilkan representasi numerik berupa array. Nilai tersebut selanjutnya digunakan dalam perhitungan konvolusi untuk menunjukkan proses pengolahan citra pada setiap kanal warna.

Gambar 5. Channel Red, Green, Blue

Channel Red

0	0	0	0	0	0
0	225	226	226	227	0
0	225	225	226	226	0
0	224	225	225	225	0
0	224	224	224	224	0
0	0	0	0	0	0

Channel Green

0	0	0	0	0	0
0	209	210	210	211	0
0	209	209	210	210	0
0	208	209	209	209	0
0	208	208	208	208	0
0	0	0	0	0	0

Channel Blue

0	0	0	0	0	0
0	193	194	194	195	0
0	193	193	194	194	0
0	192	193	193	193	0
0	192	192	192	192	0
0	0	0	0	0	0

Berikut hasil pixel dari gambar yang kita inputkan sebelumnya. Pada tahapan convolutional ini peneliti menggunakan resolusi 150 x 150 dengan kernel 3x3, Padding (same) yang berarti nilai 0 disetiap pixelnya. Activation ReLu, dan Stride bernilai 1. Berikut nilai pada kernel yang digunakan.

1 0 -1

1 0 -1

1 0 -1

Kernel tersebut digeser pada area citra untuk melakukan operasi perkalian elemen demi elemen antara nilai piksel dan nilai kernel. Hasil perkalian pada setiap posisi kemudian dijumlahkan untuk menghasilkan satu nilai pada peta fitur (*feature map*).

Proses konvolusi dilakukan dengan *stride* sebesar 1. Penggunaan *padding* jenis *same* bertujuan mempertahankan dimensi spasial keluaran konvolusi agar tetap sesuai dengan dimensi masukan untuk konfigurasi tersebut.

Perhitungan konvolusi dilakukan pada masing-masing kanal warna RGB. Hasil dari ketiga kanal kemudian digabungkan sesuai dengan operasi yang digunakan dalam implementasi model. Secara konseptual, hasil penggabungan tersebut dapat dituliskan sebagai berikut.

Gambar 6. Channel Red, Green, Blue

Channel Red

-451	-2	-2	452
-676	-3	-2	677
-674	-2	-1	675
-449	-1	0	449

Channel Green

-419	-2	-2	420
-628	-3	-2	629
-626	-2	-1	627
-417	-1	0	417

Channel Blue

-387	-2	-2	388
-580	-3	-2	581
-578	-2	-1	579
-385	-1	0	385

Hasil konvolusi merepresentasikan fitur yang diperoleh dari operasi kernel terhadap nilai piksel. Nilai-nilai tersebut selanjutnya diproses menggunakan fungsi aktivasi ReLU sebelum memasuki tahap *max pooling*.

$$Total = Red + Green + Blue$$

Setelah di jumlahkan maka hasil convolutional yang di dapat seperti di bawah ini

Gambar 1. Hasil Convolutional

-1257	-6	-6	1260
-1884	-9	-6	1887
-1878	-6	-3	1881
-1251	-3	0	1251

Setelah proses konvolusi, hasilnya diproses menggunakan fungsi aktivasi *Rectified Linear Unit* (ReLU). Fungsi ini mengubah nilai negatif menjadi nol, sedangkan nilai positif dipertahankan. Fungsi ReLU dirumuskan sebagai berikut.

$$f(x) = \max(0, x)$$

Gambar 2. Hasil Konvolusi Setelah Aktivasi ReLU

0	0	0	1260
0	0	0	1887
0	0	0	1881
0	0	0	1251

Dengan demikian, apabila nilai hasil konvolusi lebih kecil dari nol, nilai keluarannya menjadi nol. Sebaliknya, apabila nilai hasil konvolusi lebih besar atau sama dengan nol, nilai tersebut dipertahankan. Penerapan ReLU menghasilkan peta fitur yang digunakan pada tahap selanjutnya. Proses ini memberikan representasi fitur nonlinier yang dapat dipelajari oleh model CNN.

Tahap selanjutnya adalah *max pooling*, yang digunakan untuk mereduksi dimensi peta fitur. Penelitian ini menggunakan ukuran *kernel* 2 × 2 dengan *stride* sebesar 2. Pada setiap wilayah berukuran 2 × 2, nilai maksimum dipilih sebagai nilai keluaran.

Gambar 3. Hasil Max Pooling

0	1887
0	1881

Operasi tersebut dilakukan pada setiap wilayah yang diproses sehingga menghasilkan peta fitur dengan dimensi yang lebih kecil. Reduksi dimensi ini mengurangi jumlah nilai yang diteruskan ke tahapan berikutnya.

Setelah tahap *max pooling*, hasil peta fitur diubah menjadi vektor satu dimensi melalui proses *flatten*. Berdasarkan contoh perhitungan yang digunakan dalam penelitian ini, hasilnya direpresentasikan sebagai vektor berukuran 4 × 1.

Vektor tersebut selanjutnya digunakan sebagai masukan pada lapisan *dense*. Pada lapisan ini, setiap nilai masukan dikalikan dengan bobot (*weight*) yang sesuai, kemudian dijumlahkan untuk menghasilkan nilai keluaran neuron. Secara umum, perhitungan neuron dapat dinyatakan sebagai berikut.

$$\sum_{i=1}^{N} Hi * Vij = Ii$$

$$\sum_{i=1}^{N} Ii * Vij = Ji$$

$$\sum_{i=1}^{N} Ji * Vij = Oi$$

Keterangan:

- (z_j) adalah nilai masukan bersih pada neuron ke-(j).
- (x_i) adalah nilai masukan ke-(i).

- (w_{ij}) adalah bobot penghubung dari masukan ke-(i) menuju neuron ke-(j).
- (b_j) adalah nilai bias.
- (N) adalah jumlah masukan yang terhubung ke neuron.

Dalam contoh perhitungan yang disajikan, nilai bias tidak disertakan dan bobot digunakan untuk menggambarkan proses perhitungan pada lapisan *dense*. Hasil perhitungan setiap lapisan diteruskan ke lapisan berikutnya hingga diperoleh nilai keluaran yang digunakan dalam proses klasifikasi.

Untuk lapisan tersembunyi pertama, perhitungan dilakukan menggunakan nilai *flatten* dan bobot yang dicantumkan dalam contoh. Hasilnya adalah sebagai berikut.

I1 = (0*0,1) + (1887 * 0,1) + (0*0,1) + (1881 * 0,1) = 376,8

I2 = (0*0,4) + (1887 * 0,4) + (0*0,4) + (1881 * 0,4) = 1507,2

I3 = (0*0,5) + (1887 * 0,5) + (0*0,5) + (1881 * 0,5) = 1884

I4 = (0*0,3) + (1887 * 0,3) + (0*0,3) + (1881 * 0,3) = 1130,4

Nilai keluaran lapisan pertama kemudian digunakan sebagai masukan pada lapisan kedua. Dengan bobot yang digunakan dalam contoh perhitungan, diperoleh hasil sebagai berikut.

J1 = (376,8*0,3) + (1507,2* 0,3) + (1884*0,3) + (1130,4* 0,3) = 1469,5

J2 = (376,8*0,5) + (1507,2* 0,5) + (1884*0,5) + (1130,4* 0,5) = 2449,2

J3 = (376,8*0,2) + (1507,2* 0,2) + (1884*0,2) + (1130,4* 0,2) = 979,7

J4 = (376,8*0,4) + (1507,2* 0,4) + (1884*0,4) + (1130,4* 0,4) = 1959,4

Nilai keluaran lapisan kedua selanjutnya digunakan untuk menghitung nilai pada lapisan keluaran. Berdasarkan bobot yang digunakan dalam contoh, diperoleh:

O1 = (1469,5*0,3) + (2449,2* 0,3) + (979,7*0,3) + (1959,4* 0,3) = 2057,34

O2 = (1469,5*0,5) + (2449,2* 0,5) + (979,7*0,5) + (1959,4* 0,5) = 3428,9

Nilai (O_1) dan (O_2) merupakan nilai keluaran sebelum fungsi aktivasi softmax. Nilai tersebut kemudian dikonversi menjadi probabilitas untuk setiap kelas keluaran.

Fungsi softmax digunakan untuk mengubah nilai keluaran menjadi distribusi probabilitas pada kelas yang tersedia. Untuk dua nilai keluaran, perhitungannya dirumuskan sebagai berikut.

$$S(O1) = \frac{e^{2057,34}}{e^{2057,34} + e^{3428,9}}$$
$$S(O2) = \frac{e^{3428,9}}{e^{2057,34} + e^{3428,9}}$$

Untuk menghindari nilai eksponensial yang terlalu besar, perhitungan dapat dinormalisasi dengan mengurangi setiap nilai keluaran menggunakan nilai maksimum. Berdasarkan hasil perhitungan sebelumnya, nilai maksimum adalah (O_2=3428{,}88). Dengan demikian:

$$N(o1) = 2057,34 - 3428,9$$

$$N(o2) = 3428{,}9 - 3428{,}9$$

Dan mendapatkan nilai N(o1) = e^(-1371,56) dan N (o2) = e^0, jika di eksponensialkan kedua nilai tersebut adalah e(o1) adalah 0 dan e(o2) adalah 1. Maka nilai softmax adalah.

$$S(O1) = \frac{0}{1} = 0$$

$$S(O2) = \frac{1}{1} = 1$$

Berdasarkan contoh perhitungan tersebut, nilai (O_2) lebih besar daripada (O_1), sehingga kelas kedua menjadi kelas dengan probabilitas prediksi tertinggi. Perhitungan ini menggambarkan mekanisme penentuan kelas berdasarkan keluaran softmax. Hasilnya merupakan ilustrasi matematis menggunakan nilai dan bobot yang dicantumkan dalam contoh, bukan pengukuran akurasi model secara keseluruhan.

Hasil Training Model

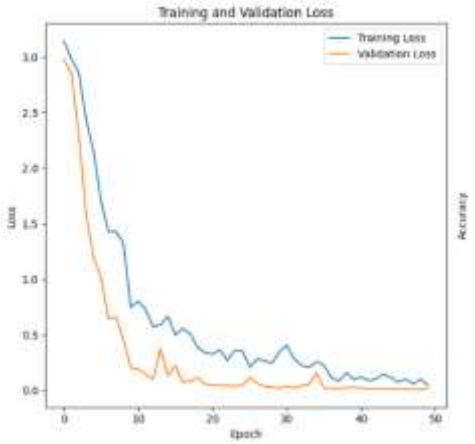
Pelatihan model CNN dilakukan menggunakan Google Colab. Proses pelatihan dijalankan hingga epoch ke-50 untuk mempelajari pola visual pada citra wajah yang digunakan sebagai data pelatihan. Hasil pelatihan ditampilkan pada Gambar 10.

Gambar 10. Hasil Training Model

```
Epoch 1/50
20/20 - 115s - loss: 3.3435 - accuracy: 0.0500 - val_loss: 2.9771 - val_accuracy:
0.0500 - lr: 0.0010 - 115s/epoch - 6s/step
Epoch 2/50
20/20 - 31s - loss: 2.9846 - accuracy: 0.0650 - val_loss: 2.8571 - val_accuracy: 0.1000
- lr: 0.0010 - 31s/epoch - 2s/step
Epoch 3/50
20/20 - 31s - loss: 2.8561 - accuracy: 0.1300 - val_loss: 2.3079 - val_accuracy: 0.3450
- lr: 0.0010 - 31s/epoch - 2s/step
Epoch 4/50
20/20 - 31s - loss: 2.4327 - accuracy: 0.2600 - val_loss: 1.5848 - val_accuracy: 0.6100
- lr: 0.0010 - 31s/epoch - 2s/step
Epoch 5/50
20/20 - 31s - loss: 2.1514 - accuracy: 0.3300 - val_loss: 1.1921 - val_accuracy: 0.6000
- lr: 0.0010 - 31s/epoch - 2s/step
Epoch 6/50
20/20 - 41s - loss: 1.7004 - accuracy: 0.4800 - val_loss: 1.0209 - val_accuracy: 0.7000
- lr: 0.0010 - 41s/epoch - 2s/step
Epoch 7/50
20/20 - 30s - loss: 1.4286 - accuracy: 0.5550 - val_loss: 0.6420 - val_accuracy: 0.7800
- lr: 0.0010 - 30s/epoch - 1s/step
Epoch 8/50
20/20 - 31s - loss: 1.4319 - accuracy: 0.6200 - val_loss: 0.6661 - val_accuracy: 0.8250
- lr: 0.0010 - 31s/epoch - 2s/step
Epoch 9/50
20/20 - 40s - loss: 1.3288 - accuracy: 0.6000 - val_loss: 0.4606 - val_accuracy: 0.8800
- lr: 0.0010 - 40s/epoch - 2s/step
Epoch 10/50
20/20 - 30s - loss: 0.7485 - accuracy: 0.7700 - val_loss: 0.2044 - val_accuracy: 0.9500
- lr: 0.0010 - 30s/epoch - 2s/step
```

Perkembangan kinerja model selama pelatihan diamati melalui grafik *training and validation loss* serta *training and validation accuracy*. Kedua grafik tersebut digunakan untuk menggambarkan perubahan kesalahan prediksi dan tingkat ketepatan klasifikasi selama proses pembelajaran.

Gambar 11. Training and Validation Loss



Grafik *training and validation loss* memperlihatkan kecenderungan penurunan nilai *validation loss* seiring bertambahnya epoch. Penurunan tersebut menunjukkan bahwa kesalahan prediksi pada data validasi cenderung berkurang selama proses pelatihan. Nilai *loss* digunakan untuk mengamati perubahan kesalahan model, sehingga interpretasinya perlu dilihat bersama dengan perkembangan akurasi.

Gambar 12. Training and Validation Accuracy



Grafik *training and validation accuracy* memperlihatkan peningkatan akurasi seiring bertambahnya epoch. Pola tersebut menunjukkan bahwa model semakin mampu mempelajari pola dari data yang digunakan selama pelatihan. Namun, peningkatan akurasi pelatihan saja belum cukup untuk memastikan kemampuan model dalam mengenali citra yang belum pernah digunakan selama pembelajaran. Oleh karena itu, nilai akurasi validasi dan hasil pengujian perlu dipertimbangkan secara terpisah.

Hasil pelatihan dalam naskah melaporkan nilai akurasi sebesar 98,50% dan 99,00% pada epoch ke-50. Kedua nilai tersebut merupakan hasil yang dilaporkan dalam implementasi model. Interpretasi masing-masing nilai bergantung pada jenis pengukuran yang digunakan, seperti akurasi pelatihan, validasi, atau pengujian. Oleh karena itu, pelaporan hasil perlu

menghubungkan setiap nilai akurasi dengan metrik yang bersesuaian pada keluaran eksperimen.

Secara umum, grafik pelatihan menunjukkan perkembangan proses pembelajaran model CNN. Meskipun demikian, keberhasilan model dalam mengenali identitas karyawan pada kondisi penggunaan sebenarnya perlu dinilai berdasarkan hasil pengujian yang terpisah dari data pelatihan.

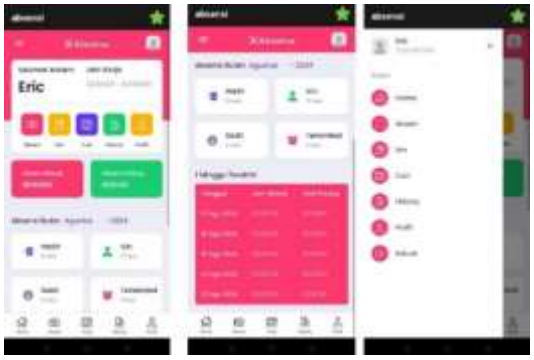
Implementasi Sistem Absensi Karyawan

Model CNN yang dikembangkan diintegrasikan ke dalam aplikasi absensi karyawan. Aplikasi ini menyediakan beberapa fitur utama, yaitu halaman *Home*, absensi masuk dan pulang, pengajuan izin, pengajuan cuti, serta riwayat kehadiran. Implementasi antarmuka tersebut ditampilkan pada Gambar 13 hingga Gambar 17.

1. Tampilan Home

Halaman *Home* merupakan halaman awal yang ditampilkan ketika pengguna mengakses aplikasi. Halaman ini menyediakan akses ke fitur-fitur utama yang tersedia pada sistem absensi karyawan.

Gambar 13. Tampilan Home



2. Tampilan Absensi

Halaman absensi digunakan untuk melakukan pencatatan kehadiran karyawan. Pengguna melakukan pemindaian wajah sebagai bagian dari proses identifikasi sebelum melakukan absensi masuk atau pulang.

Gambar 14. Absen Masuk dan Absen Pulang

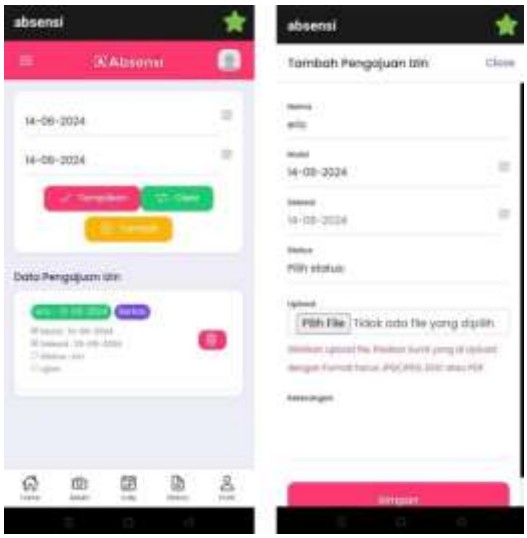


Integrasi pengenalan wajah pada fitur absensi dirancang untuk mendukung pencatatan kehadiran berdasarkan identitas pengguna. Hasil pencatatan yang tersimpan kemudian dapat digunakan sebagai bagian dari riwayat kehadiran karyawan.

3. Halaman Pengajuan Izin

Situs web ini memungkinkan pengguna untuk mengajukan permohonan izin dan memberikan bukti dalam bentuk foto dan informasi. Halaman pengajuan izin menyediakan fasilitas bagi pengguna untuk menyampaikan permohonan izin. Pengguna dapat memasukkan informasi yang diperlukan serta melampirkan bukti pendukung berupa foto sesuai dengan fasilitas yang tersedia pada aplikasi.

Gambar 15. Pengajuan Izin

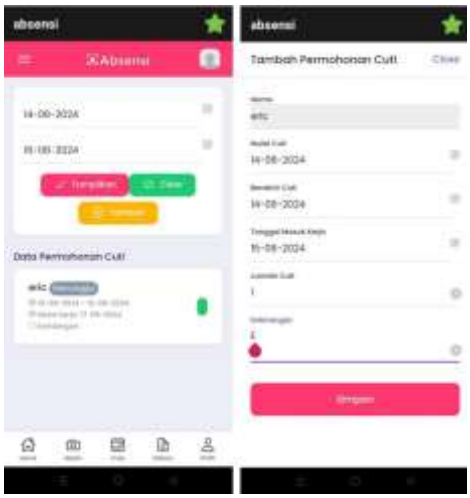


Fitur ini melengkapi fungsi absensi dengan menyediakan sarana pengelolaan informasi ketidakhadiran karyawan. Data pengajuan izin dapat digunakan sebagai bagian dari administrasi kehadiran.

4. Halaman Pengajuan Cuti

Halaman pengajuan cuti digunakan untuk memasukkan informasi permohonan cuti, termasuk tanggal mulai, tanggal berakhir, tanggal masuk kembali jika diperlukan, dan deskripsi pengajuan.

Gambar 16. Pengajuan Cuti

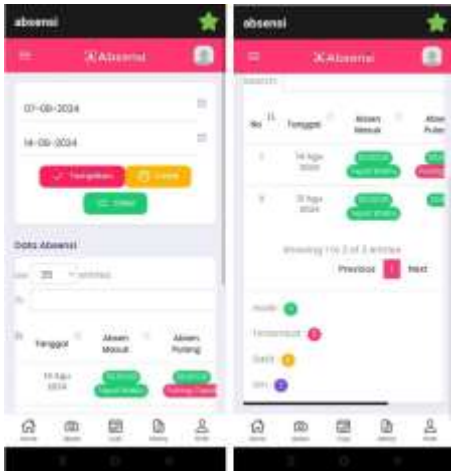


Fitur pengajuan cuti mendukung pencatatan permohonan ketidakhadiran dalam sistem. Dengan adanya fitur ini, aplikasi menyediakan fungsi administrasi yang melengkapi proses pencatatan kehadiran karyawan.

5. Halaman Riwayat Kehadiran

Halaman riwayat digunakan untuk menampilkan informasi kehadiran pengguna. Informasi yang disajikan meliputi jumlah kehadiran serta catatan terkait keterlambatan, sakit, dan izin.

Gambar 17. History



Halaman riwayat memberikan akses kepada pengguna untuk melihat catatan kehadiran yang tersimpan dalam aplikasi. Pada sisi administrasi, fitur riwayat juga mendukung pemantauan data absensi pengguna sesuai dengan hak akses yang tersedia pada sistem.

Pembahasan

Penelitian ini menerapkan algoritma CNN untuk mengembangkan sistem absensi karyawan berbasis pengenalan wajah. Tahapan implementasi mencakup pembacaan citra, pengolahan nilai piksel, konvolusi, aktivasi ReLU, *max pooling*, *flatten*, dan klasifikasi menggunakan fungsi aktivasi softmax. Model kemudian dilatih hingga epoch ke-50 dan diintegrasikan ke dalam aplikasi absensi karyawan.

Grafik pelatihan memperlihatkan kecenderungan peningkatan akurasi dan penurunan *validation loss* seiring bertambahnya epoch. Pola tersebut menunjukkan adanya perkembangan pembelajaran model selama proses pelatihan. Hasil implementasi juga melaporkan nilai akurasi sebesar 98,50% dan 99,00%. Kedua nilai ini perlu diinterpretasikan sesuai dengan jenis metrik yang dihasilkan selama eksperimen agar tidak disamakan dengan akurasi pengujian apabila pengukuran tersebut berasal dari data pelatihan atau validasi.

Dari sisi aplikasi, sistem menyediakan fitur absensi masuk dan pulang, pengajuan izin,pengajuan cuti, serta riwayat kehadiran. Fitur-fitur tersebut menunjukkan integrasi model pengenalan wajah dengan fungsi administrasi kehadiran dalam satu aplikasi. Dengan demikian, sistem yang dikembangkan mencakup pemrosesan citra wajah sekaligus penyediaan antarmuka untuk mendukung pencatatan kehadiran karyawan.

Meskipun hasil pelatihan menunjukkan perkembangan kinerja model, kemampuan pengenalan wajah pada kondisi operasional perlu dipertimbangkan secara terpisah. Perbedaan pencahayaan, posisi wajah, jarak kamera, dan kualitas citra dapat memengaruhi hasil pengenalan. Oleh karena itu, hasil pengujian pada kondisi penggunaan yang berbeda akan memberikan gambaran yang lebih menyeluruh mengenai kemampuan model.

Secara keseluruhan, penelitian ini menghasilkan implementasi sistem absensi karyawan berbasis CNN yang mengintegrasikan pengenalan wajah dengan fitur administrasi kehadiran. Hasil yang diperoleh meliputi proses pelatihan model, visualisasi perkembangan akurasi dan *loss*, serta implementasi fitur aplikasi. Evaluasi lebih lanjut menggunakan skenario pengujian yang terukur dapat memberikan bukti tambahan mengenai keandalan sistem dalam penggunaan operasional.

4. Kesimpulan

Penelitian ini menghasilkan sistem absensi karyawan berbasis *face recognition* dengan menerapkan algoritma *Convolutional Neural Network* (CNN). Sistem dikembangkan untuk mendukung proses pencatatan kehadiran karyawan melalui pengenalan wajah serta menyediakan fitur pengelolaan data kehadiran, pengajuan izin, pengajuan cuti, dan riwayat absensi yang dapat diakses oleh admin. Hasil pelatihan model hingga epoch ke-50 menunjukkan nilai akurasi sebesar 98,50% dan 99,00%, sebagaimana dilaporkan dalam hasil penelitian. Pengujian sistem secara manual juga dilakukan untuk memeriksa fungsionalitas aplikasi. Berdasarkan hasil tersebut, sistem yang dikembangkan menunjukkan potensi untuk diterapkan dalam mendukung proses administrasi kehadiran karyawan di lingkungan perusahaan.

5. References

Aldiani, D., Dwilestari, G., Susana, H., Hamonangan, R., & Pratama, D. (2024). Implementasi Algoritma CNN dalam Sistem Absensi Berbasis Pengenalan Wajah. *Jurnal Informatika Polinema*, *10*(2). https://doi.org/10.33795/jip.v10i2.4852

Azamy, M., Ariwibowo, A. B., & Mardianto, I. (2023). Face Recognition Implementation with MTCNN on Attendance System Prototype at Trisakti University. *Indonesian Journal of Banking and Financial Technology (FINTECH)*, *1*(1). https://doi.org/https://doi.org/10.55927/fintech.v1i1.2812

Insani, M. K., & Santoso, D. B. (2024). Perbandingan Kinerja Model Pre-Trained CNN (VGG16, RESNET, dan INCEPTIONV3) untuk Aplikasi Pengenalan Wajah pada Sistem Absensi Karyawan. *Jurnal Indonesia : Manajemen Informatika Dan Komunikasi*, *5*(3). https://doi.org/10.35870/jimik.v5i3.925

Irawati, A. R., Kurniawan, D., Utami, Y. T., & Taufik, R. (2024). An Exploration of TensorFlow-Enabled Convolutional Neural Network Model Development for Facial Recognition: Advancements in Student Attendance System. *Scientific Journal of Informatics*, *11*(2). https://doi.org/10.15294/sji.v11i2.3585

Isputrawan, M. F., & Suriyanti, S. (2023). PENGEMBANGAN APLIKASI ABSENSI BERBASIS WEB MENGGUNAKAN FACE RECOGNITION. *Jurnal Teknoinfo*, *17*(1). https://doi.org/10.33365/jti.v17i1.2243

Jannah, R., & Nurhidayat, A. I. (2023). Implementasi Web Presensi Karyawan Industri Kertas Jaya Mengunakan Metode Convolutional Neural Network. *Ejournal.Unesa.Ac.Id*.

Muhammad,], Muliawan, R., Irawan, B., Brianorman, Y., Jurusan,], Komputer, S., Mipa, F., Tanjungpura, U., Prof, J., & Nawawi, H. H. (2015). IMPLEMENTASI PENGENALAN WAJAH DENGAN METODE EIGENFACE PADA SISTEM ABSENSI. *Coding Jurnal Komputer Dan Aplikasi*, *3*(1).

Mulyana, D. I., & Aribatullah. (2025). Klasifikasi Absensi Face Geo-Location Menggunakan Metode CNN pada PT Indomarco Prismatama. *Jurnal Indonesia : Manajemen Informatika Dan Komunikasi*, *6*(1). https://doi.org/10.35870/jimik.v6i1.1193

Nusantoko, Y. R., & Prapanca, A. (2025). Pengembangan Aplikasi Human Resource Information System Berbasis Mobile Dengan Absensi Wajah Menggunakan Metode CNN Pada BMT Bahtera Pekalongan. *Journal of Informatics and Computer Science*, *06*(4).

Putra, Y. A., & Imelda, I. (2022). Real-Time Face Recognition Civil Servant Presence System Using DNN Algorithm. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, *16*(4). https://doi.org/10.22146/ijccs.77026

Rochmanullah, M. A., Vendyansyah, N., & Wahyuni, F. S. (2025). Implementasi Convolutional Neural Network (CNN) untuk Face Recognition pada Sistem Presensi Kehadiran. *Indonesian Journal of Applied Informatics*, *9*(2). https://doi.org/10.20961/ijai.v9i2.95563

Subeki, F., & Eliyani, E. (2024). Pengenalan Setengah Wajah menggunakan Arsitektur Xception pada Metode Convolutional Neural Network. *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*, *10*(2). https://doi.org/10.26418/jp.v10i2.73447

Supriana, I., & Pratama, Y. (2017). Face recognition new approach based on gradation contour of face color. *International Journal on Electrical Engineering and Informatics*, *9*(1). https://doi.org/10.15676/ijeei.2017.9.1.8

Syahrul Gunawan Ramdhani, & Enny Itje Sela. (2023). Implementasi Face Recognition Untuk Sistem Presensi Universitas Menggunakan Convolutional Neural Network. *Indonesian Journal of Computer Science*, *12*(6). https://doi.org/10.33022/ijcs.v12i6.3498

Utomo, B. T., Fitri, I., & Mardiani, E. (2020). Penerapan Face Recognition Pada Aplikasi Akademik Online. *Informatik : Jurnal Ilmu Komputer*, *16*(3). https://doi.org/10.52958/iftk.v16i3.2259