

**IMPLEMENTASI SISTEM ABSENSI BERBASIS
PENGENALAN WAJAH MENGGUNAKAN METODE CNN
DAN MODEL *FACENET***

LAPORAN TUGAS AKHIR

Laporan Ini Disusun Guna Memenuhi Salah Satu Syarat Memperoleh Gelar
Sarjana Strata (S1) Pada Program Studi Teknik Informatika Fakultas Teknologi
Industri Universitas Islam Sultan Agung



Disusun Oleh:

Nama : Anggara Putra Meldyantono
NIM : 32602100029
Program Studi : Teknik Informatika

**FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM SULTAN AGUNG
SEMARANG
2025**

FINAL PROJECT
IMPLEMENTATION OF FACE RECOGNITION-BASED
ATTENDANCE SYSTEM USING CNN METHOD AND
FACENET MODEL

Proposed to complete the requirement to obtain a bachelor's degree (S1) At
Informatics Engineering Departement of Industrial Technology Faculty Sultan
Agung Islamic University.



Arranged By:

Nama : Anggara Putra Meldyantono
NIM : 32602100029

MAJORING OF INFORMATICS ENGINEERING
INSUDTRIAL TECHNOLOGY FACULTY
SULTAN AGUNG ISLAMIC UNIVERSITY
SEMARANG
2025

**LEMBAR PENGESAHAN
TUGAS AKHIR**


**IMPLEMENTASI SISTEM ABSENSI BERBASIS PENGENALAN WAJAH
MENGUNAKAN METODE CNN DAN MODEL FACENET**

**ANGGARA PUTRA MELDYANTONO
NIM 32602100029**

Telah dipertahankan di depan tim penguji ujian sarjana tugas akhir
Program Studi Teknik Informatika
Universitas Islam Sultan Agung
Pada tanggal : 18-Februari 2025

TIM PENGUJI SEMINAR TUGAS AKHIR:


Dedy Kurniadi, ST, M.Kom
NIK. 210615048
(Ketua Penguji)

 24-02-2025

Andi Riansyah, ST, M.Kom
NIK. 210616053
(Anggota Penguji)

 24-02-2025

Bagus SWP, S.Kom, M.Cs
NIK. 210616051
(Pembimbing)

 24-02-2025

Semarang, 25-Februari-2025

Mengetahui,

Kaprodik Teknik Informatika
Universitas Islam Sultan Agung


Moch. Taufik, ST, MIT
NIK. 210604034

SURAT PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan dibawah ini :

Nama : Anggara Putra Meldyantono

NIM : 32602100029

Judul Tugas Akhir : Implementasi Sistem Absensi Berbasis Pengenalan Wajah Menggunakan Metode CNN dan Model *FaceNet*.

Dengan bahwa ini saya menyatakan bahwa judul dan isi Tugas Akhir yang saya buat dalam rangka menyelesaikan Pendidikan Strata Satu (S1) Teknik Informatika tersebut adalah asli dan belum pernah diangkat, ditulis ataupun dipublikasikan oleh siapapun baik keseluruhan maupun sebagian, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka, dan apabila di kemudian hari ternyata terbukti bahwa judul Tugas Akhir tersebut pernah diangkat, ditulis ataupun dipublikasikan, maka saya bersedia dikenakan sanksi akademis. Demikian surat pernyataan ini saya buat dengan sadar dan penuh tanggung jawab.

Semarang, 25 Februari 2025

Yang Menyatakan,



Anggara Putra Meldyantono

PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH

Saya yang bertanda tangan dibawah ini :

Nama : Anggara Putra Meldyantonono

NIM : 32602100029

Program Studi : Teknik Informatika

Fakultas : Teknologi industri

Alamat Asal : Bandung, Jawa Barat

Dengan ini menyatakan Karya Ilmiah berupa Tugas akhir dengan Judul :

Implementasi Sistem Absensi Berbasis Pengenalan Wajah Menggunakan Metode CNN dan Model FaceNet.

Menyetujui menjadi hak milik Universitas Islam Sultan Agung serta memberikan Hak bebas Royalti Non-Eksklusif untuk disimpan, dialihmediakan, dikelola dan pangkalan data dan dipublikasikan diinternet dan media lain untuk kepentingan akademis selama tetap menyantumkan nama penulis sebagai pemilik hak cipta. Pernyataan ini saya buat dengan sungguh-sungguh. Apabila dikemudian hari terbukti ada pelanggaran Hak Cipta/Plagiarisme dalam karya ilmiah ini, maka segala bentuk tuntutan hukum yang timbul akan saya tanggung secara pribadi tanpa melibatkan Universitas Islam Sultan agung.

Semarang, 25-Februari-2025

Yang menyatakan,



Anggara Putra Meldyantonono


KATA PENGANTAR

Dengan mengucapkan rasa syukur alhamdulillah atas kehadiran Allah SWT yang telah memberikan Rahmat dan karunianya kepada penulis, sehingga dapat menyelesaikan Laporan Tugas Akhir dengan judul “Implementasi Sistem Absensi Berbasis Pengenalan Wajah Menggunakan Metode CNN dan Model *FaceNet*” ini untuk memenuhi salah satu syarat menyelesaikan studi serta dalam rangka memperoleh gelar sarjana (S-1) pada program Studi Teknik Informatika Fakultas Teknologi Industri Universitas Islam Sultan Agung.

Laporan Tugas Akhir ini disusun dan dibuat dengan adanya bantuan dari berbagai pihak, materi maupun teknis, oleh karena itu saya selaku penulis mengucapkan terima kasih kepada:

1. Rektor UNISSULA Bapak Prof. Dr. H. Gunarto, S.H., M.H yang mengizinkan penulis menimba ilmu dikampus ini.
2. Dekan Fakultas Teknologi Industri Ibu Dr. Ir. Novi Marlyana, S.T., M.T., IPU., ASEAN. Eng
3. Dosen Pembimbing I penulis Bapak Bagus Satrio WP, S.Kom.M.Cs yang memberikan banyak nasehat dan saran.
4. Saya ingin mengucapkan terima kasih yang sebesar-besarnya kepada papah dan mamah, yang selalu melimpahkan kasih sayang yang tulus, doa yang tiada henti-hentinya, serta dukungan yang begitu besar dalam kehidupan penulis.
5. Untuk Alfina Nurusa’adah yang selalu memberikan semangat bahkan nasehat sampai akhirnya penulis mampu bangkit kembali menyelesaikan tugas akhir.
6. Para sahabat, teman-teman yang telah memberikan begitu banyak bantuan, semangat, inspirasi, pengambilan data dan diskusi progress penyusunan Tugas Akhir.

Semarang, 16 Januari 2025


Anggara Putra Meldyantono

DAFTAR ISI

COVER	i
LEMBAR PENGESAHAN TUGAS AKHIR.....	iii
SURAT PERNYATAAN KEASLIAN TUGAS AKHIR.....	iii
PERNYATAAN PERSETUJUAN PUBLIKASI KAYA ILMIAH	v
KATA PENGANTAR.....	vi
DAFTAR ISI	vii
DAFTAR GAMBAR	ix
DAFTAR TABEL.....	xi
ABSTRAK	xii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah.....	2
1.3 Pembatasan Masalah	2
1.4 Tujuan Tugas Akhir	3
1.5 Manfaat.....	3
1.6 Sistematika Penulisan.....	4
BAB II TINJAUAN PUSTAKA DAN DASAR TEORI	5
2.1 Tinjauan Pustaka.....	5
2.2 Dasar Teori	8
2.2.1 Sistem Absensi Berbasis Biometrik	8
2.2.2 <i>Face Recognition</i>	9
2.2.3 <i>Convolutional Neural Network (CNN)</i>	10
2.2.4 <i>FaceNet</i>	16
2.2.5 <i>Algoritma Local Binary Patterns Histogram (LBPH)</i>	18
2.2.6 <i>Library OpenCV</i>	23
2.2.7 <i>Python</i>	24
BAB III METODE PENELITIAN.....	26
3.1 Deskripsi Sistem.....	26
3.2 Studi Literatur.....	29

3.3Metode Penelitian.....	29
3.4Perancangan Sistem.....	31
3.4.1 Flowchart Sistem.....	31
3.5Perancangan Model	32
3.5.1 Pengumpulan Data (<i>Input data</i>).....	32
3.5.2 <i>Preprocessing</i>	32
3.5.3 Ekstraksi Fitur	33
3.5.4 Training Data.....	33
3.5.5 Pengenalan Wajah	33
3.5.6 Absensi	34
3.6Evaluasi Model.....	34
BAB IV HASIL DAN ANALISIS PENELITIAN.....	36
4.1Hasil Pembuatan Sistem.....	36
4.1.1 Halaman Dashboard	36
4.1.2 Tampilan Daftar Hadir	39
4.1.3 Analisis dan Pengujian.....	39
4.1.4 Pengambilan Data Wajah	41
4.1.5 Training	46
4.1.6 Analisis Akurasi	47
4.1.7 Pengujian Performa Sistem	54
4.1.8 Pengujian Pengenalan Wajah Berdasarkan Jarak	58
4.2Analisa Sistem.....	60
BAB V KESIMPULAN DAN SARAN.....	62
5.1Kesimpulan.....	62
5.2Saran	62
DAFTAR PUSTAKA	64

DAFTAR GAMBAR

Gambar 2. 1 Contoh arsitektur convolutional neural network (Satwikayana dkk., 2021)	11
Gambar 2. 2 Proses Convolution Layer	13
Gambar 2. 3 Proses Pooling Layer Metode Max Polling.....	14
Gambar 2. 4 Ekstraksi fitur Facenet.....	17
Gambar 2. 5 Triplet Loss.....	17
Gambar 2. 6 Arsitektur Facenet.	17
Gambar 2. 7 Ilustrasi LBP (https://towardsdatascience.com/).....	19
Gambar 2. 8 Contoh Hasil LBPH, (a) Citra Asli, (b) Citra Hasil Operator LBP, (c) Pembagian Daerah Pada Citra LBP, (d) Histogram Tiap Daerah, (e) Gabungan dari Histogram Tiap Daerah	21
Gambar 2. 9 Logo OpenCV	24
Gambar 2. 10 Logo python	24
 Gambar 3. 1 Diagram Blok Sistem	26
Gambar 3. 2 Alur Sistem.....	29
Gambar 3. 3 Flowchart Metode	30
Gambar 3. 4 Flowchart Sistem.....	31
Gambar 3. 5 Flowchart Preprocessing	32
 Gambar 4. 1 Tampilan Dashboard.....	36
Gambar 4. 2 Proses Absensi Menganalisis Wajah	37
Gambar 4. 3 Form untuk pengisian data pembelajaran	37
Gambar 4. 4 Setelah Proses Pengisian Data.....	38
Gambar 4. 5 Proses Penyimpanan Data	38
Gambar 4. 6 Tampilan Daftar Hadir.....	39
Gambar 4. 7 Hasil Pelatihan LBPH, CNN dan Facenet.....	46
Gambar 4. 8 Grafik perbandingan antara model KNN (rata-rata) dan CNN	48

Gambar 4. 9 Perbandingan Metrik Performa Model.....	48
Gambar 4. 10 Confusion Matrix K=1	49
Gambar 4. 11 Confusion Matrix K=3	49
Gambar 4. 12 Confusion Matrix K=5	50
Gambar 4. 13 Confusion Matrix K=7	50
Gambar 4. 14 Confusion Matrix K=9	51
Gambar 4. 15 Confusion Matrix CNN.....	51
Gambar 4. 16 Hasil Pengenalan Wajah.....	57
Gambar 4. 17 Hasil Pengenalan Wajah.....	57
Gambar 4. 18 Hasil Pengenalan Wajah.....	57
Gambar 4. 19 Hasil Pengenalan Wajah.....	58
Gambar 4. 20 Hasil Pengenalan Wajah.....	58
Gambar 4. 21 Tampilan Daftar Hadir.....	60



DAFTAR TABEL

Tabel 4. 1 Pengujian Sistem	39
Tabel 4. 2 Pengambilan Data Wajah	41
Tabel 4. 3 Hasil Akurasi	47
Tabel 4. 4 Confusion Matrix tiap kelas facenet dengan knn	52
Tabel 4. 5 Skor Precision, recal, dan F1-score	53
Tabel 4. 6 Perhitungan manual	53
Tabel 4. 7 Pengujian intensitas cahaya	54
Tabel 4. 8 Pengujian pengenalan wajah berdasarkan jarak	59



ABSTRAK

Sistem absensi berbasis biometrik, khususnya pengenalan wajah, telah menjadi solusi yang efektif dalam mengatasi kelemahan absensi tradisional seperti kecurangan dan ketidakakuratan pencatatan. Penelitian ini mengembangkan sistem absensi menggunakan metode Convolutional Neural Networks (CNN), *FaceNet*, dan *Local Binary Patterns Histogram* (LBPH) untuk meningkatkan akurasi dan efisiensi pengenalan wajah. CNN digunakan untuk mendeteksi pola kompleks pada wajah, sementara *FaceNet* menghasilkan representasi vektor unik dari setiap wajah, memungkinkan identifikasi individu secara akurat. Metode LBPH dipilih karena ringan secara komputasi, memungkinkan sistem berjalan efisien pada perangkat dengan spesifikasi terbatas. Penelitian ini juga memfokuskan pada pengujian performa sistem dalam berbagai kondisi pencahayaan dan sudut pengambilan wajah. Hasil penelitian menunjukkan bahwa kombinasi metode ini mampu memberikan solusi absensi yang lebih canggih, akurat, dan dapat diimplementasikan secara luas, bahkan di lingkungan dengan sumber daya komputasi terbatas.

Kata Kunci: Pengenalan Wajah, CNN, *FaceNet*, LBPH, Absensi Biometrik.

ABSTRACT

Biometric-based attendance systems, especially face recognition, have become an effective solution in overcoming the weaknesses of traditional attendance such as fraud and inaccurate recording. This research develops an attendance system using Convolutional Neural Networks (CNN), FaceNet, and Local Binary Patterns Histogram (LBPH) methods to improve face recognition accuracy and efficiency. CNN is used to detect complex patterns on faces, while FaceNet generates a unique vector representation of each face, enabling accurate identification of individuals. The LBPH method was chosen because it is computationally lightweight, allowing the system to run efficiently on devices with limited specifications. This research also focuses on testing the system's performance under various lighting conditions and face capture angles. The results show that this combination of methods is able to provide a more sophisticated, accurate, and widely implementable attendance solution, even in environments with limited computing resources.

Keywords: Face Recognition, CNN, FaceNet, LBPH, Biometric Time Attendance.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Dalam manajemen kehadiran, sistem absensi berbasis *biometrik*, terutama pengenalan wajah, telah terbukti sebagai solusi inovatif yang mengatasi kelemahan sistem absensi tradisional. Metode absensi manual, seperti tanda tangan atau penggunaan kartu identitas, sering kali mengalami kendala seperti kecurangan dan ketidakakuratan dalam pencatatan (Zahra dkk., 2022). Teknologi pengenalan wajah tidak hanya menghadirkan tingkat akurasi yang lebih tinggi, tetapi juga meningkatkan efisiensi dan keamanan dalam proses absensi.

Berbagai penelitian telah mengeksplorasi penggunaan metode *Convolutional Neural Network* (CNN) dan FaceNet untuk pengenalan wajah. CNN dikenal memiliki kemampuan yang kuat dalam mendeteksi pola kompleks pada citra wajah, sementara *FaceNet* menghasilkan representasi vektor wajah yang unik, memungkinkan sistem untuk membedakan individu dengan akurasi tinggi (Evelyn dkk., 2022). Namun, penelitian yang ada masih memiliki kelemahan, terutama dalam hal performa di perangkat dengan spesifikasi terbatas, serta tantangan dalam kondisi lingkungan yang tidak ideal, seperti pencahayaan yang buruk (Zahra dkk., 2022).

Keunggulan penelitian ini dibandingkan dengan yang lain terletak pada penggabungan metode CNN, *FaceNet*, dan LBPH (*Local Binary Patterns Histogram*). LBPH merupakan metode yang lebih ringan secara komputasi dan mampu bekerja efisien pada perangkat dengan spesifikasi menengah ke bawah (Saied dan Syafii, 2023). Dengan menggabungkan LBPH, penelitian ini menawarkan solusi yang lebih *fleksibel*, dapat diimplementasikan pada berbagai perangkat, termasuk yang memiliki keterbatasan sumber daya komputasi. Hal ini membuat sistem yang dikembangkan lebih *inklusif* dan dapat diadopsi secara lebih luas oleh institusi yang mungkin tidak memiliki akses ke perangkat keras canggih.

Meskipun terdapat keterbatasan dalam hal pencahayaan dan pengenalan wajah yang tertutup sebagian, sistem ini dirancang untuk mengoptimalkan kinerja dalam kondisi yang lebih bervariasi. Dalam penelitian (Zahra dkk., 2022), performa pengenalan wajah menurun dalam pencahayaan buruk. Penelitian ini berusaha mengurangi dampak tersebut dengan menyesuaikan parameter pencahayaan dan meningkatkan deteksi melalui kombinasi algoritma yang lebih adaptif.

Dengan fokus pada implementasi sistem absensi berbasis pengenalan wajah dan verifikasi lokasi, sistem ini tidak hanya memberikan akurasi yang lebih baik, tetapi juga menawarkan solusi yang lebih efisien dan dapat diandalkan untuk lingkungan yang berbeda-beda. Selain itu, fitur verifikasi lokasi memungkinkan sistem untuk memastikan bahwa pengguna benar-benar hadir di lokasi yang diharuskan, menambahkan lapisan keamanan yang lebih baik dibandingkan dengan penelitian sebelumnya (Saied dan Syafii, 2023).

Dalam penelitian ini, menggunakan metode CNN dan model *FaceNet* untuk sistem absensi berbasis pengenalan wajah. CNN mengenali pola kompleks pada citra wajah, sementara *FaceNet* menghasilkan representasi vektor wajah yang unik. Kombinasi ini memungkinkan pengenalan wajah yang handal meski ada variasi pencahayaan, pose, dan ekspresi wajah, sehingga cocok untuk diterapkan secara *real-time*.

1.2 Perumusan Masalah

Bagaimana merancang dan membuat sistem absensi berbasis web yang mengintegrasikan pengenalan wajah menggunakan metode CNN dan model *FaceNet* untuk mencatat kehadiran mahasiswa dengan akurat.

1.3 Pembatasan Masalah

Batasan masalah dalam proposal ini dapat dirumuskan sebagai berikut:

1. Keterbatasan dalam mengenali wajah yang tertutup sebagian. Sistem mungkin tidak mampu mengenali wajah yang tertutup oleh masker,

kacamata besar, atau aksesori lain yang menutupi sebagian besar fitur wajah.

2. Dalam presensi mahasiswa, proses pengenalan wajah yaitu menggunakan citra statis, bukan video.
3. Validasi presensi yang dilakukan sistem hanya didasarkan pada kecocokan wajah.
4. Tingkat pencahayaan pada saat pengenalan harus sesuai dengan pencahayaan ketika dataset diambil.

1.4 Tujuan Tugas Akhir

Tugas akhir ini bertujuan untuk mengenali wajah mahasiswa dengan akurasi tinggi secara *real-time* dan memastikan identitas mereka terekam dalam sistem secara otomatis.

1.5 Manfaat

Manfaat dari tugas akhir ini terletak pada kontribusinya terhadap pengembangan sistem absensi yang berbasis pengenalan wajah. Dengan menerapkan metode *Convolutional Neural Networks* (CNN), sistem ini mampu mendeteksi pola wajah dengan tingkat akurasi yang lebih tinggi, sehingga dapat meminimalkan kesalahan dalam proses pencatatan kehadiran. Ditambah dengan *FaceNet*, sistem ini dapat menghasilkan representasi vektor unik dari setiap wajah, memungkinkan pengenalan yang lebih presisi dan membedakan individu dengan baik. Sementara itu, *Local Binary Patterns Histogram* (LBPH) memberikan keuntungan berupa efisiensi komputasi yang lebih tinggi, sehingga sistem tetap dapat berjalan optimal bahkan pada perangkat dengan spesifikasi terbatas. Hal ini memungkinkan solusi absensi yang lebih fleksibel dan inklusif untuk berbagai institusi, tanpa harus mengorbankan akurasi dan kecepatan proses. Dengan memadukan ketiga metode ini, sistem absensi yang dihasilkan lebih tangguh dalam berbagai kondisi pencahayaan dan sudut wajah, serta menawarkan keamanan yang

lebih baik, menjadikannya pilihan yang unggul dibandingkan metode absensi tradisional.

1.6 Sistematika Penulisan

Sistematika penulisan laporan tugas akhir yang digunakan oleh penulis disusun sebagai berikut :

- BAB 1 : Bab ini menjelaskan latar belakang pemilihan judul, perumusan masalah, batasan masalah, tujuan penelitian, metode penelitian, serta sistematika penulisan laporan
- BAB 2 : Berisi kajian penelitian sebelumnya dan landasan teori yang relevan untuk membantu penulis memahami konsep-konsep yang berkaitan dengan algoritma Convolutional Neural Network dalam penelitian ini
- BAB 3 : Menguraikan tahapan-tahapan penelitian, dimulai dari pengumpulan data hingga proses pengolahan data yang dilakukan
- BAB 4 : Menyajikan hasil penelitian yang diperoleh, termasuk analisis terhadap hasil tersebut
- BAB 5 : Memuat kesimpulan dari keseluruhan proses penelitian, mulai dari tahap awal hingga akhir, serta memberikan rekomendasi untuk penelitian selanjutnya

BAB II

TINJAUAN PUSTAKA DAN DASAR TEORI

2.1 Tinjauan Pustaka

Bagian ini akan mengulas berbagai literatur dan penelitian terdahulu yang berkaitan dengan penerapan sistem absensi berbasis pengenalan wajah menggunakan metode *Convolutional Neural Network* (CNN) dan model *FaceNet*. Penelitian-penelitian tersebut akan memberikan landasan teori serta gambaran mengenai efektivitas metode ini dalam pengembangan sistem pengenalan wajah untuk keperluan absensi. Penelusuran literatur sangat penting untuk memberikan landasan teori yang kuat serta menghindari duplikasi penelitian.

Penelitian Terdahulu

Beberapa penelitian sebelumnya telah mengkaji serta mengembangkan teknologi absensi menggunakan berbagai metode dan teknologi, di antaranya: Teknologi Pengenalan Wajah: Penelitian sebelumnya telah menunjukkan berbagai metode absensi menggunakan teknologi *biometrik* seperti pengenalan wajah dan *fingerprint*. Bradski dan Kaehler (2008) menjelaskan penggunaan *OpenCV* dalam pengenalan wajah yang dapat diterapkan dalam berbagai aplikasi termasuk sistem absensi. Vincenty (1975) menggambarkan metode geodesik untuk verifikasi lokasi yang dapat digunakan bersama teknologi seperti *Geopy* (Bradski dan Kaehler, 2008).

Convolutional Neural Network (CNN) untuk Pengenalan Wajah: Penelitian yang dilakukan oleh Zahrah dkk. menunjukkan bahwa CNN dapat digunakan secara efektif untuk sistem absensi berbasis pengenalan wajah di lingkungan pendidikan. Sistem ini mampu mendeteksi hingga 80% wajah mahasiswa yang diuji, meskipun akurasi masih dipengaruhi oleh faktor pencahayaan dan sudut kamera (Zahra dkk., 2022)

FaceNet untuk Sistem Absensi Mobile: Evelyn dkk. mengembangkan sistem presensi mahasiswa berbasis Android menggunakan FaceNet. Sistem ini menunjukkan bahwa Cosine Similarity dengan *threshold* optimal dapat

memberikan hasil terbaik dengan akurasi hingga 77,16%. *FaceNet* dipilih karena kemampuannya dalam pengenalan wajah yang presisi dan fleksibilitas *platform* yang didukung oleh *TensorFlow* (Evelyn dkk., 2022) .

Teknologi *Fingerprint* dan RFID: Selain pengenalan wajah, teknologi *fingerprint* dan RFID juga banyak digunakan dalam sistem absensi. Sidik jari manusia merupakan objek biometrik yang unik dan mudah dipindai. Sistem absensi berbasis RFID memanfaatkan gelombang radio untuk identifikasi, yang sering digunakan di lingkungan kerja dan pendidikan (Bathinko dkk., 2024). *SMS Gateway*: Beberapa penelitian juga telah mengimplementasikan sistem absensi yang mengirim notifikasi melalui *SMS Gateway*. Sistem ini memudahkan dalam pelaporan absensi secara real-time dan dapat diintegrasikan dengan database absensi untuk pemantauan yang lebih efektif (Muharman dkk., 2023).

Algoritma dan Pembelajaran Mesin: Berbagai algoritma pembelajaran mesin seperti jaringan syaraf tiruan (*Neural Networks*) dan *vector quantization* telah diterapkan untuk meningkatkan akurasi dan kecepatan dalam sistem absensi berbasis *biometrik* (Saied dan Syafii, 2023).

Efisiensi Metode LBPH dalam Pengenalan Wajah: *Local Binary Patterns Histogram* (LBPH) adalah salah satu metode yang banyak diterapkan dalam pengenalan wajah karena kesederhanaannya dan efektivitasnya, khususnya pada perangkat dengan kapasitas komputasi yang terbatas. LBPH dikenal mampu mengenali pola tekstur lokal dari citra wajah, memberikan kinerja yang cepat tanpa memerlukan daya pemrosesan yang besar. Oleh karena itu, LBPH sering menjadi pilihan dalam aplikasi *real-time*, seperti absensi berbasis wajah yang membutuhkan respon cepat (Pribadi, 2023).

Modified Region CNN dan PCA untuk Pengenalan Wajah: Menurut Talumepa dkk., penggunaan *Modified Region CNN* (MR-CNN) dan PCA dalam pengenalan wajah memberikan akurasi tinggi mencapai 96,1%. Teknik ini menunjukkan potensi yang baik untuk aplikasi di institusi pendidikan

dengan efisiensi waktu dan ketepatan yang tinggi dalam mengenali wajah siswa (Talumepa dkk., 2024).

Pengenalan Wajah Menggunakan Model *FaceNet* untuk Presensi Pegawai: Menurut Ferry Cahyono, penggunaan model *FaceNet* dalam sistem presensi berbasis pengenalan wajah memberikan akurasi tinggi mencapai 100%. Metode ini melibatkan preprocessing gambar, ekstraksi fitur wajah ke dalam vektor 128 dimensi, dan klasifikasi menggunakan *Support Vector Machine* (SVM). Hasil penelitian menunjukkan bahwa model *FaceNet* lebih unggul dibandingkan *OpenFace*, dengan akurasi yang lebih rendah sebesar 93,3%. Teknik ini cocok untuk implementasi sistem presensi *real-time* dengan keandalan tinggi (Cahyono, 2020).

Pengembangan Sistem Presensi Karyawan dengan *Face Recognition* Menggunakan Model *FaceNet*: Menurut Anjeli Puteri Anggreini, penggunaan *FaceNet* dalam sistem presensi karyawan memungkinkan validasi kehadiran secara akurat melalui pengolahan citra wajah. Sistem ini memanfaatkan kamera perangkat secara *real-time* untuk mendeteksi wajah menggunakan algoritma SSD, kemudian mencocokkan fitur wajah dengan data referensi melalui perhitungan jarak *Euclidean*. Pengujian menunjukkan tingkat keberhasilan 98,7% dalam kondisi pencahayaan terang dan 92% pada pencahayaan redup. Sistem ini dirancang untuk memastikan keaslian presensi karyawan secara efisien (Anggreini, 2024).

Convolutional Neural Network (CNN) untuk Deteksi Penyakit Batu Ginjal: Penelitian yang dilakukan oleh Poetro dkk. menunjukkan bahwa CNN dengan arsitektur *DenseNet-121* dapat digunakan secara efektif untuk klasifikasi penyakit batu ginjal menggunakan citra *CT Scan*. Sistem ini mampu mencapai akurasi hingga 98,18% dengan precision sebesar 96,36% dan *recall* 100%, meskipun performa model sangat bergantung pada kualitas data yang digunakan, termasuk *preprocessing* dan augmentasi gambar (Poetro dkk., 2024).

Pengembangan Sistem Klasifikasi Kanker Kulit Menggunakan CNN dan *ResNet50* dengan Segmentasi U-Net: Menurut (Murdiyanto dkk., 2024),

penerapan CNN dalam sistem klasifikasi kanker kulit menunjukkan kinerja yang cukup baik meskipun terhambat oleh masalah *overfitting*. Sistem ini menggunakan U-Net untuk segmentasi gambar lesi kulit, yang meningkatkan kualitas data input sebelum proses klasifikasi. Meskipun CNN menunjukkan keseimbangan dalam kinerja antar kelas, dengan akurasi 47% pada *F1-score* tertimbang, sistem ini mengalami kesulitan dalam klasifikasi beberapa jenis kanker kulit, seperti actinic keratosis dan basal *cell carcinoma*. Penelitian ini menyarankan penggunaan teknik lanjutan seperti augmentasi data dan regularisasi untuk mengatasi masalah *overfitting* dan meningkatkan kinerja model dalam aplikasi klinis (Murdiyanto dkk., 2024).

Berdasarkan penelitian yang telah dilakukan terhadap kerentanannya sistem absensi berbasis *fingerprint*, seperti yang dijelaskan dalam jurnal '*Evaluation of direct attacks to fingerprint verification systems*' (Galbally dkk., 2022), terdapat celah yang memungkinkan terjadinya kecurangan, seperti penggunaan salinan sidik jari dan serangan langsung. Oleh karena itu, implementasi sistem absensi berbasis pengenalan wajah menggunakan metode CNN dan model *FaceNet* yang diusulkan dalam tugas akhir ini dapat menjadi solusi untuk mengurangi tingkat kecurangan absensi. Dengan menggantikan sistem *fingerprint* dengan pengenalan wajah yang lebih aman dan sulit dipalsukan, sistem ini menawarkan keamanan yang lebih tinggi dalam mencatat kehadiran, serta meminimalisir potensi manipulasi data kehadiran yang sebelumnya terjadi pada sistem *fingerprint*.

2.2 Dasar Teori

2.2.1 Sistem Absensi Berbasis Biometrik

Sistem absensi berbasis biometrik adalah solusi modern yang menggunakan ciri-ciri unik individu, seperti sidik jari dan pengenalan wajah, untuk mencatat kehadiran karyawan dengan tingkat akurasi yang tinggi. Teknologi ini menggantikan metode absensi tradisional yang masih banyak bergantung pada pencatatan manual, yang rentan terhadap kesalahan manusia, seperti salah memasukkan data atau pemalsuan informasi kehadiran. Dengan absensi *biometrik*, proses pencatatan kehadiran menjadi otomatis,

sehingga waktu yang diperlukan untuk proses absensi dapat dikurangi secara signifikan. Sistem ini juga menawarkan keuntungan lain, seperti mengurangi kebutuhan akan kartu atau lembar absensi fisik, mempercepat proses pencatatan kehadiran, dan memberikan keamanan data yang lebih tinggi. Data kehadiran yang tersimpan dalam sistem *biometrik* sulit untuk dimanipulasi, sehingga meningkatkan keandalan pengelolaan data kehadiran secara keseluruhan. Selain itu, dengan mengintegrasikan teknologi ini, perusahaan dapat mengoptimalkan produktivitas serta mengurangi beban administratif yang sebelumnya banyak menyita waktu. Dengan demikian, absensi *biometrik* tidak hanya meningkatkan efisiensi tetapi juga meningkatkan keamanan dan keandalan dalam pencatatan kehadiran karyawan (Saied dan Syafii, 2023).

2.2.2 Face Recognition

Penggunaan teknologi pengenalan wajah adalah salah satu bentuk biometrik yang mampu mengidentifikasi wajah manusia secara unik dengan menganalisis pola berdasarkan karakteristik wajah. Pendekatan yang digunakan bisa berbasis fitur (*geometris*) atau berbasis template (*fotometrik*). Pendekatan berbasis fitur memanfaatkan bentuk serta posisi wajah, sementara pendekatan berbasis gambar membuat *template* untuk mengenali wajah. Metode yang umum dipakai mencakup “*eigenfaces*” dan “*fisherfaces*”, yang menggunakan analisis komponen utama (PCA) guna mengekstrak fitur wajah. Selain itu, metode lain yang juga sering digunakan adalah *Local Binary Pattern Histogram* (LBPH). Meskipun tidak ada algoritma yang mampu mencapai akurasi sempurna 100%, tingkat akurasi tertinggi saat ini bisa mencapai 90%. Kegagalan akurasi biasanya disebabkan oleh faktor seperti pencahayaan, sudut pengambilan gambar, serta jarak dari kamera, yang memengaruhi kualitas data gambar wajah (Setiono, 2020).

Algoritma *Haar Cascade* dikenal karena kemampuannya dalam mendeteksi objek dengan tingkat akurasi yang tinggi. Selain mendeteksi wajah manusia, algoritma ini terkadang juga mengidentifikasi objek non-wajah, seperti benda atau bagian tubuh lainnya. Proses deteksinya berfokus

pada ciri-ciri wajah yang paling mudah dikenali, seperti alis, mulut, hidung, lubang hidung, dan iris mata. Setelah area wajah terdeteksi, algoritma akan melakukan verifikasi tambahan untuk memastikan bahwa hasil yang ditemukan benar-benar merupakan wajah. Dikembangkan oleh Paul Viola dan Michael Jones, *Haar-cascade Classifier* dilatih menggunakan kumpulan data yang mencakup gambar wajah dan non-wajah. Algoritma ini bekerja dengan menghitung perbedaan nilai piksel antara area persegi panjang berwarna putih dan hitam. Pada tahun 2001, Paul Viola dan Michael Jones memperkenalkan empat komponen utama dalam deteksi objek menggunakan algoritma ini, yaitu "*haar-like features*", gambar integral, pembelajaran Adaboost, dan "*cascade classifier*" (Kenda dan Witanti, 2022).


1. "*Haar-like features*": Fitur ini berbentuk persegi yang digunakan untuk mengidentifikasi karakteristik spesifik dalam sebuah gambar. Deteksi objek dilakukan berdasarkan jumlah piksel di dalam area persegi, bukan pada nilai piksel individu dari objek tersebut. Terdapat tiga jenis utama *haar-like features*, yaitu *Two-rectangular feature*, *Three-rectangular feature*, dan *Four-rectangular feature*.

2.2.3 Convolutional Neural Network (CNN)

Metode *Convolutional Neural Network* (CNN) yang diterapkan dalam penelitian ini memanfaatkan proses konvolusi pada gambar. CNN merupakan algoritma jaringan saraf yang paling umum digunakan untuk analisis visual, berperan sebagai *multilayer perceptron* dengan koneksi antara setiap neuron di satu lapisan dengan neuron di lapisan berikutnya. Kelebihan utama CNN terletak pada kemampuannya untuk menemukan pola berjenjang dalam data dan merangkai informasi kompleks dari piksel yang lebih sederhana. CNN memiliki performa yang sangat baik dalam menangani kompleksitas dan hubungan *piksel* dalam gambar, serta memerlukan sedikit prapemrosesan dibandingkan algoritma klasifikasi gambar lainnya. CNN telah diterapkan secara luas di berbagai bidang, seperti identifikasi gambar, pengenalan video, klasifikasi gambar, sistem rekomendasi, dan pemrosesan bahasa alami. Metode ini pertama kali diperkenalkan oleh Yann LeCun pada tahun 1988,

dan kesuksesan serta penerapan luas CNN menjadi fondasi dalam perkembangan *deep learning* (Rasywir dkk., 2020).

Convolutional Neural Networks (CNN) merupakan salah satu bentuk jaringan saraf tiruan yang paling efektif untuk pengenalan citra. Inti dari CNN terletak pada tahap konvolusi, di mana setiap fitur dalam sebuah citra dianalisis untuk mengekstraksi pola-pola tertentu, sehingga mempermudah proses pengenalan. Pendekatan ini memungkinkan pembelajaran citra menjadi lebih efisien dan praktis untuk diterapkan.



Gambar 2. 1 Contoh arsitektur convolutional neural network (Satwikayana dkk., 2021)


Desain *Convolutional Neural Network* (CNN) yang ditampilkan pada Gambar 2.1 menggambarkan konsep utama CNN yang umumnya terbagi menjadi tiga bagian, yaitu input, pembelajaran fitur, dan klasifikasi. Pada tahap input, citra digital digunakan sebagai data masukan. Kemudian, proses pembelajaran fitur dilakukan untuk memproses citra tersebut dengan memanfaatkan model konvolusi yang bertugas mengambil matriks dari citra. Aktivasi dilakukan menggunakan fungsi ReLU. Setelah tahap konvolusi dan aktivasi ReLU, proses pooling dilaksanakan untuk mengumpulkan data, di mana nilai tertinggi dari setiap bagian citra diambil dan semua vektor digabungkan menjadi satu. CNN terdiri dari beberapa lapisan yang berfungsi sebagai tahapan penyaringan dalam proses pelatihan citra digital.

Convolutional Neural Network (CNN) mengintegrasikan tiga arsitektur utama, yaitu *local receptive fields*, *shared weights* yang direpresentasikan sebagai filter, dan *spatial subsampling* yang dikenal sebagai *pooling*. Operasi konvolusi dilakukan menggunakan matriks yang berfungsi sebagai *filter* untuk mengekstraksi fitur dari data input (Kusumaningrum, 2018).

Convolutional Neural Network (CNN) adalah salah satu metode deep learning yang banyak digunakan dalam berbagai tugas pemrosesan citra. CNN terdiri dari tiga jenis lapisan utama: *convolutional layer*, *pooling layer*, dan *fully connected layer*. *Convolutional layer* berfungsi untuk mengekstraksi fitur dari citra input melalui operasi konvolusi, yang memungkinkan CNN untuk mengenali pola-pola tertentu dalam citra. Selanjutnya, *pooling layer* berfungsi mengurangi dimensi citra dengan mempertahankan informasi penting dari fitur yang telah diekstraksi sebelumnya, sering menggunakan metode *max pooling* untuk menyusun matriks citra yang lebih kecil. Terakhir, *fully connected layer* berperan dalam proses klasifikasi dengan memproses data menjadi satu dimensi, sehingga jaringan saraf dapat mengasosiasikan fitur-fitur yang telah diekstraksi dengan kelas atau label tertentu, memungkinkan sistem untuk mengklasifikasikan objek dalam citra secara efektif (Nurona dkk., 2021)

1. *Convolution Layer*

Lapisan pertama dalam jaringan saraf konvolusional adalah lapisan konvolusi. Lapisan ini melakukan operasi konvolusi terhadap output dari lapisan sebelumnya dan merupakan elemen kunci dalam proses jaringan saraf konvolusional. Konvolusi adalah istilah yang digunakan dalam pengolahan citra, yang mengacu pada penerapan kernel (sebuah matriks berbentuk kotak berwarna kuning) di seluruh area citra pada berbagai posisi, seperti yang ditunjukkan dalam Gambar 2.2 Area yang lebih luas yang berwarna hijau akan menjadi subjek konvolusi. *Kernel* (kotak kuning) bergerak mulai dari sudut kiri atas dan berlanjut hingga mencapai sudut kanan bawah. Hasil dari operasi ini dapat dilihat di gambar di sebelah kanan. Contoh proses dalam lapisan konvolusi dapat dilihat pada Gambar 2.2.

Gambar 2. 2 Proses *Convolution Layer*

Tujuan utama dari konvolusi pada data citra adalah mengekstraksi fitur-fitur penting dari citra yang diberikan. Proses ini menghasilkan transformasi linier dari data masukan sesuai dengan informasi spasial yang terkandung. Bobot pada lapisan konvolusi menentukan kernel yang digunakan, dan *kernel* ini dapat dilatih berdasarkan data input yang diproses dalam jaringan saraf konvolusional (CNN) (Kusumaningrum, 2018).

Rumus *Convolution*:

Proses Konvolusi dilakukan dengan menggunakan rumus berikut:

$$W_{out} = \left(\frac{W_{in} - N + 2P}{S} \right) + 1 \quad (1)$$

Keterangan:


- W_{out} = Ukuran *Output* setelah konvolusi.
- W_{in} = Ukuran *input* (misalnya lebar atau tinggi citra)
- N = Ukuran *filter pooling* (misalnya 3x3)
- P = *Padding*, yang dapat digunakan untuk mempertahankan dimensi input atau memberikan ruang di sekitar gambar.
- S = *Stride* (jarak pergeseran filter, biasanya 1)

Rumus ini digunakan untuk menghitung dimensi output dari gambar setelah melewati filter konvolusi, dan akan menghasilkan *feature map* (peta fitur).

2. *Pooling Layer*

Selanjutnya, terdapat pooling layer, yang merupakan lapisan dalam *Convolutional Neural Network* (CNN) yang menerima *feature map*

sebagai masukan dan memprosesnya menggunakan operasi statistik tertentu berdasarkan nilai *piksel* terdekat. Dalam arsitektur CNN, lapisan ini biasanya ditempatkan secara berkala setelah beberapa lapisan konvolusi. Dengan menambahkan lapisan ini secara berurutan di antara lapisan konvolusi, proses ini dapat secara bertahap mengurangi dimensi *volume output* dari *feature map*. Hal ini berpengaruh pada pengurangan jumlah *parameter* dan perhitungan dalam jaringan, serta membantu mengatasi masalah *overfitting*. Metode yang digunakan dalam *pooling layer* mencakup *average pooling* dan *max pooling*, namun *max pooling* adalah metode yang paling umum digunakan. Dalam *max pooling*, *output* dari lapisan konvolusi dibagi menjadi *grid* kecil, dan nilai maksimum dari *grid* tersebut diambil untuk membentuk matriks citra baru yang telah direduksi, seperti yang ditunjukkan dalam Gambar 2.3 dibawah ini.



Gambar 2. 3 Proses *Pooling Layer* Metode *Max Polling*

Kotak merah, hijau, kuning, dan biru di sisi kiri merepresentasikan kelompok area yang akan diambil nilai maksimumnya. Hasil dari proses ini terlihat pada kumpulan kotak di sisi kanan. Proses ini memastikan bahwa fitur yang diekstraksi tetap konsisten meskipun terjadi translasi (pergeseran) pada objek dalam citra. Fungsi *pooling layer* dalam CNN adalah untuk mengurangi dimensi citra, memungkinkan ukuran citra diperkecil sehingga lebih efisien tanpa kehilangan fitur penting. Proses ini juga dapat digantikan oleh *convolution layer* dengan *stride* yang sama. *Stride* adalah parameter yang menentukan jumlah pergeseran filter dalam proses konvolusi. Jika *stride* bernilai satu, filter akan bergeser satu piksel baik secara horizontal maupun vertikal. Semakin kecil nilai *stride* yang

digunakan, semakin detail informasi yang dapat diekstraksi dari input. Namun, ini juga meningkatkan kebutuhan komputasi dibandingkan penggunaan *stride* yang lebih besar (Kusumaningrum, 2018).

Rumus *Pooling* (*Max Pooling*):

Untuk max pooling, rumus yang digunakan untuk menghitung ukuran output pooling adalah:

$$W_{out} = \left(\frac{W_{in} - N}{S} \right) + 1 \quad (2)$$

Keterangan:

- W_{out} = Ukuran Output setelah konvolusi.
- W_{in} = Ukuran input (misalnya lebar atau tinggi citra)
- N = Ukuran filter pooling (misalnya 2x2 atau 3x3)
- S = Stride (jarak pergeseran filter, biasanya 1)

Proses ini memastikan bahwa fitur yang dihasilkan tetap stabil meskipun terjadi translasi (pergeseran) pada objek dalam citra. *Pooling layer* dalam CNN berfungsi untuk mengurangi dimensi citra, sehingga ukuran citra dapat diperkecil. Fungsi ini juga dapat digantikan oleh *convolution layer* dengan *stride* yang sama.

3. *Fully Connected Layer*

Lapisan terakhir adalah *Fully Connected Layer*. Pada lapisan ini, setiap neuron aktivasi dari lapisan sebelumnya terhubung secara penuh dengan semua neuron di lapisan berikutnya. *Fully Connected Layer* sering digunakan dalam penerapan *Multi Layer Perceptron* (MLP) dengan tujuan mentransformasi dimensi data sehingga dapat diklasifikasikan secara linear. Perbedaan utama antara *Fully Connected Layer* dan *Convolution Layer* terletak pada pola koneksi neuron. Pada *Convolution Layer*, neuron hanya terhubung dengan area tertentu dari input, sedangkan pada *Fully Connected Layer*, semua neuron saling terhubung secara keseluruhan. Meski demikian, keduanya tetap melakukan operasi *dot product*, sehingga fungsinya tidak sepenuhnya berbeda (Kusumaningrum, 2018).

Rumus *Fully Connected Layer (Dense)* pada CNN ekstraksi fitur:

Untuk menghitung output dari fully connected layer, rumus yang digunakan adalah:

$$y = C \times K + C \quad (3)$$


Keterangan

- y = Output dari layer
- C = Bobot dari koneksi antar neuron (Total Kelas)
- K = Jumlah neuron di layer *Dense* (Jumlah Kernel)
- C = Bias yang ditambahkan pada *output*

Dengan penambahan *rumus* tersebut, bagian teori menjadi lebih lengkap dalam menjelaskan setiap tahapan dalam Convolutional Neural Network (CNN). Rumus-rumus ini menggambarkan proses *konvolusi*, *pooling*, dan *fully connected layer* secara matematis, yang membantu memperjelas cara kerja CNN dalam model pengolahan citra.


2.2.4 FaceNet

FaceNet adalah sistem pengenalan wajah yang dikembangkan oleh para peneliti di Google. Sistem ini menggunakan arsitektur *deep Convolutional Neural Network* (deep CNN) untuk mengekstraksi fitur wajah menjadi vektor. *FaceNet* menerima input berupa foto wajah dan menghasilkan output berupa vektor 128 nilai yang dikenal sebagai *embedding*. Idealnya, *embedding* dari wajah yang sama akan memiliki vektor yang mirip. *Embedding* ini digunakan untuk mengukur kemiripan wajah dengan menghitung jarak dalam *embedding space*; wajah yang serupa memiliki jarak yang mendekati nol, sedangkan wajah yang berbeda memiliki jarak yang lebih jauh. Arsitektur *Deep CNN* yang digunakan oleh *FaceNet* dapat berupa ZF-Net atau Inception. Dalam penelitian ini, *FaceNet* digunakan pada tahap pembelajaran fitur, menghasilkan vektor 128 elemen atau *face embedding*. Vektor ini kemudian diklasifikasikan menggunakan SVM untuk menentukan identitas wajah berdasarkan *embedding* tersebut (Mantara Sakti dkk., 2022).



Gambar 2. 4 Ekstraksi fitur Facenet

Triplet Loss beroperasi berdasarkan tingkat kesamaan dan perbedaan



Gambar 2. 5 Triplet Loss

FaceNet menerima input berupa gambar berwarna berukuran 160x160 piksel dan menghasilkan *output* berupa *vektor* wajah berdimensi 128, sebagaimana ditunjukkan pada Gambar 2.6.

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	(None, 160, 160, 3)	0
Conv2d_1a_3x3 (Conv2D)	(None, 79, 79, 32)	864
Conv2d_1a_3x3_BatchNorm (BatchN	(None, 79, 79, 32)	96
Dropout (Dropout)	(None, 1792)	0
Bottleneck (Dense)	(None, 128)	229376
Bottleneck_BatchNorm (BatchNorm	(None, 128)	384
Total params: 22,808,144		
Trainable params: 22,779,312		
Non-trainable params: 28,832		

Gambar 2. 6 Arsitektur *Facenet*.

Pada Gambar 2.6 Menggambarkan Sebuah *Output* dari Arsitektur pada *Facenet*.

Rumus FaceNet menggunakan embedding wajah:

$$\text{Embedding Face} = \mathcal{F}(\mathcal{W}, \mathcal{X}) \quad (4)$$

Keterangan

- X adalah citra wajah yang di-input-kan ke dalam model.
- W adalah parameter atau bobot dari model *FaceNet* yang dipelajari selama proses pelatihan.
- $\mathcal{F}(W, X)$ adalah fungsi yang digunakan untuk menghasilkan *embedding* dari citra wajah X .

Embedding ini digunakan untuk membandingkan wajah menggunakan jarak *Euclidean* dengan wajah lain di database.

2.2.5 Algoritma Local Binary Patterns Histogram (LBPH)

Local Binary Patterns Histogram (LBPH) adalah salah satu algoritma yang populer dalam bidang pengenalan pola, terutama pada pengenalan wajah. Algoritma ini mengandalkan analisis pola tekstur lokal pada citra wajah untuk mengenali dan membedakan satu wajah dengan wajah lainnya. LBPH bekerja dengan memecah citra wajah menjadi beberapa blok kecil, kemudian menghitung nilai biner berdasarkan intensitas *piksel* di sekitar *piksel* tengah dalam setiap blok tersebut. Hasil perhitungan *biner* ini dikonversi menjadi nilai desimal, yang kemudian digunakan untuk membentuk *histogram*.


Setiap wajah memiliki pola *histogram* yang unik, dan inilah yang digunakan sebagai basis untuk mengenali wajah dalam citra. Algoritma LBPH dianggap sederhana namun efektif karena mampu menangkap variasi pola tekstur kecil yang sering kali merupakan ciri khas dari wajah. Selain itu, LBPH cukup efisien secara komputasi dan dapat bekerja dengan baik dalam kondisi pencahayaan yang berubah-ubah. Hal ini membuatnya menjadi pilihan yang populer, terutama untuk aplikasi pengenalan wajah dalam kondisi lingkungan yang tidak selalu ideal, seperti di luar ruangan atau pada kondisi pencahayaan rendah.

LBPH memiliki beberapa parameter utama yang menentukan kualitas pengenalan wajah, di antaranya radius, jumlah titik sampel, dan *grid* atau ukuran *blok*. Parameter ini memungkinkan LBPH untuk menyesuaikan

sensitivitas dan ketelitian pengenalan wajah, sehingga dapat memberikan performa yang lebih optimal sesuai dengan kebutuhan aplikasi. Walaupun tergolong sederhana dibandingkan dengan metode berbasis jaringan saraf seperti CNN, LBPH tetap menjadi pilihan yang efektif untuk aplikasi yang membutuhkan kecepatan dan efisiensi, seperti dalam sistem absensi berbasis wajah.

1. *Proses Local Binary Pattern (LBP)*

Langkah awal dalam menerapkan perhitungan LBPH adalah dengan membuat citra antara yang merepresentasikan citra asli dan memperjelas *detail* wajah. Proses ini dilakukan dengan menggunakan konsep *sliding window*, yang bergantung pada parameter radius dan kedekatan *piksel* sekitarnya.



Gambar 2. 7 Ilustrasi LBP (<https://towardsdatascience.com/>)

Pada Gambar 2.7, langkah awal dari metode *Local Binary Pattern* (LBP) adalah mengambil setiap piksel dalam sebuah citra dan membandingkannya dengan piksel-piksel di sekitarnya. Sebagai ilustrasi, misalkan dipilih sebuah piksel dengan nilai 90, seperti yang ditunjukkan pada gambar. Piksel ini kemudian dibandingkan dengan piksel tetangganya yang berada dari $f(x-1,y-1)$ hingga $f(x+1,y+1)$, dengan $f(x,y)$ digunakan sebagai nilai ambang batas. Jika nilai piksel tetangga lebih besar dari ambang batas, maka nilai tersebut diubah menjadi biner 1; sebaliknya, jika lebih kecil, diubah menjadi biner 0. Setelah seluruh piksel tetangga dibandingkan, dihasilkan susunan nilai biner yang dikonversi menjadi angka desimal. Nilai desimal ini kemudian menjadi nilai baru untuk piksel yang diproses, yaitu $f(x,y)$. Dalam contoh yang ditunjukkan pada gambar, nilai piksel 90 berubah menjadi 141 setelah melalui proses

ini. Langkah ini diterapkan secara menyeluruh pada semua piksel dalam citra (Harisdias Bustomi dan Hariyanto, 2020).

Rumus Ekstraksi Fitur pada LBPH:

Untuk menghitung nilai *Local Binary Pattern* dari sebuah piksel $f(x,y)$, rumusnya adalah sebagai berikut:


$$LBP(x, y) = \sum_{i=0}^{P-1} 2^i \cdot \delta(\mathcal{F}(x, y), \mathcal{F}(x_i, y_i)) \quad (5)$$

Keterangan:

- P = Jumlah titik sampel disekitar piksel $\mathcal{F}(x, y)$
- $\mathcal{F}(x, y)$ = Nilai piksel pusat
- $\mathcal{F}(x_i, y_i)$ = Nilai piksel tetangga (di sekitar $\mathcal{F}(x, y)$)
- $\delta(a,b)$ = Fungsi yang menghasilkan 1 jika $a \geq b$, dan 0 jika $a < b$.

2. Ekstrak ke Histogram

Setelah menghitung histogram LBP untuk setiap blok, langkah berikutnya adalah menggabungkan histogram dari masing-masing blok sesuai pola *grid* yang telah ditentukan berdasarkan parameter x dan y . Sebagai contoh, jika parameter *grid* x dan y masing-masing bernilai 3, citra akan dibagi menjadi 9 blok yang berukuran sama, dengan tiga blok di setiap baris dan kolom. Histogram dari tiap blok kemudian digabungkan berdasarkan posisi masing-masing dalam *grid*. Sebagai ilustrasi, histogram blok pertama pada baris dan kolom pertama digabungkan dengan *histogram* blok kedua pada baris yang sama, dan proses ini dilanjutkan hingga seluruh histogram dalam *grid* tersusun menjadi satu kesatuan. Hasil akhirnya adalah *histogram* gabungan yang merepresentasikan pola tekstur dari seluruh citra. *Histogram* ini dapat dimanfaatkan untuk mendeteksi atau mengenali objek, termasuk wajah, dalam citra, seperti yang diilustrasikan pada Gambar 2.8.



Gambar 2. 8 Contoh Hasil LBPH, (a) Citra Asli, (b) Citra Hasil Operator LBP, (c) Pembagian Daerah Pada Citra LBP, (d) Histogram Tiap Daerah, (e) Gabungan dari Histogram Tiap Daerah

Gambar 2.8 menunjukkan pengaruh *histogram* terhadap hasil citra. Karena *histogram* merupakan representasi dari kumpulan intensitas *piksel* yang berkisar antara 0 hingga 255, citra yang gelap akan memiliki *histogram* yang cenderung ke kiri, sedangkan citra yang terang akan menunjukkan *histogram* yang condong ke kanan. *Histogram* individual dari setiap blok kemudian digabungkan untuk membentuk sebuah *histogram* akhir yang lebih besar. Sebagai contoh, jika citra dibagi menjadi grid berukuran 8 x 8, maka *histogram* akhir akan terdiri dari $8 \times 8 \times 256 = 16.384$ nilai. *Histogram* ini merepresentasikan karakteristik tekstur dari citra asli secara keseluruhan (Harisdias Bustomi dan Hariyanto, 2020).

Rumus *Histogram*:

Untuk menghitung *histogram* LBP untuk seluruh citra, kita dapat menggunakan rumus berikut:

$$H = \sum_{i=0}^N \text{count}(LBP_i) \quad (6)$$

Keterangan:

- H = Histogram hasil gabungan LBP untuk seluruh citra.
- $\text{count}(LBP_i)$ = Jumlah kemunculan nilai LBP_i di seluruh citra.
- N = Jumlah nilai LBP yang mungkin (misalnya, 256 untuk 8-bit LBP).

3. Normalisasi *Histogram*

Setelah *histogram* selesai dibentuk, langkah berikutnya dalam metode LBPH adalah melakukan normalisasi terhadap nilai-nilai dalam *histogram*. Normalisasi bertujuan untuk meningkatkan kinerja LBPH dalam mengatasi perbedaan pencahayaan atau kontras pada citra. Salah satu metode yang dapat digunakan adalah dengan menghitung nilai rata-rata dan standar deviasi dari *histogram*, kemudian menormalkan setiap nilai dalam *histogram* dengan cara mengurangi rata-rata dan membaginya dengan standar deviasi. Proses ini memastikan bahwa *histogram* menjadi lebih robust terhadap variasi dalam pencahayaan atau kontras.

Rumus Normalisasi *Histogram*:

Untuk normalisasi *histogram*, rumus yang digunakan adalah:

$$H_{norm} = \frac{H - \mu}{\sigma} \quad (7)$$

Keterangan:

- H_{norm} = *Histogram* yang telah dinormalisasi
- H = *Histogram* asli
- μ = Rata-rata dari *histogram*
- σ = Standar deviasi dari *histogram*.

4. Pengenalan Wajah

Kemudian setelah proses normalisasi *histogram* selesai, nilai-nilai *histogram* tersebut dapat dimanfaatkan sebagai fitur untuk mengidentifikasi wajah atau objek dalam citra. LBPH mampu membandingkan *histogram* dari citra yang diuji dengan *histogram* dari citra referensi, serta memberikan nilai kesamaan antara keduanya. Semakin besar kesamaan nilai *histogram* antara citra referensi dan citra uji, maka semakin tinggi kemungkinan bahwa citra uji tersebut adalah identik dengan citra referensi. Oleh karena itu, untuk menemukan gambar yang sesuai dengan gambar *input*, langkah yang perlu diambil adalah membandingkan kedua *histogram* dan mengembalikan gambar yang

memiliki *histogram* paling mirip. Dalam konteks ini, jarak *Euclidean* digunakan sebagai metode perbandingan pada *histogram*.

Rumus Perbandingan *Histogram*:

Untuk membandingkan dua *histogram*, digunakan jarak *Euclidean*, yang dihitung dengan rumus berikut:

$$D = \sqrt{\sum_{i=1}^n (hist1_i - hist2_i)^2} \quad (8)$$

Keterangan:

- D = Jarak antara dua *histogram*
- $hist1_i$ = Nilai *histogram* pada bin ke- i untuk *histogram* 1
- $hist2_i$ = Nilai *histogram* pada bin ke- i untuk *histogram* 2
- N = Jumlah bin pada *histogram*

Algoritma ini menghasilkan identifikasi citra berdasarkan *histogram* yang memiliki kemiripan tertinggi. Selain itu, algoritma juga harus memberikan nilai jarak yang dihitung sebagai ukuran tingkat kesamaan antara citra yang diuji dan kumpulan data yang tersedia. Berdasarkan tingkat kesamaan ini, ditentukan ambang batas minimum untuk mengenali wajah, misalnya lebih dari 50%. Dengan demikian, jika terdapat wajah baru yang tingkat kemiripannya tidak mencapai ambang batas 50%, wajah tersebut akan dianggap sebagai wajah asing yang belum terdaftar.

2.2.6 Library *OpenCV*

Open Source Computer Vision Library (OpenCV) adalah pustaka perangkat lunak yang dirancang untuk pemrosesan gambar secara dinamis dan real-time. Awalnya dikembangkan oleh Intel, *OpenCV* kini didukung oleh Willow Garage dan Itseez. Pustaka ini dirilis di bawah lisensi BSD yang permisif, memungkinkan pengguna untuk menggunakannya dalam proyek komersial tanpa kewajiban membagikan kode sumber, berbeda dengan lisensi GPL. Selain itu, *OpenCV* mendukung bahasa pemrograman Python dan dapat dijalankan di sistem operasi Windows. Dalam penelitian ini, beberapa fungsi *OpenCV* yang digunakan antara lain *cv2.imread()*, *cv2.show()*, dan

`cv2.waitKey()`. Pustaka ini memiliki komunitas *global* yang luas dengan lebih dari 47.000 pengguna dan lebih dari 7 juta unduhan secara *global* (Martunus, 2020)..



Gambar 2. 9 Logo *OpenCV*

OpenCV memiliki lebih dari 2500 algoritma yang telah dioptimalkan. Beberapa fungsi yang disediakan oleh *OpenCV* meliputi: deteksi wajah, pengenalan wajah, pengenalan objek, klasifikasi fitur objek, ekstraksi model objek, serta berbagai algoritma sederhana lainnya yang berhubungan dengan *API* tingkat rendah dalam visi komputer.

2.2.7 *Python*

Python adalah bahasa pemrograman tingkat tinggi yang terkenal karena sintaksnya yang sederhana dan mudah dipahami, sehingga memudahkan pengguna untuk menulis dan memahami kode. Dikembangkan oleh Guido van Rossum dan dirilis pertama kali pada tahun 1991, *Python* mendukung berbagai paradigma pemrograman, termasuk pemrograman berorientasi objek, pemrograman fungsional, dan pemrograman terstruktur. *Python* banyak digunakan di berbagai bidang seperti pengembangan web, data sains, pembelajaran mesin, otomatisasi skrip, dan analisis data.



Gambar 2. 10 Logo *python*

Salah satu keunggulan *Python* adalah ketersediaan pustaka yang luas dan kuat, yang memungkinkan pengguna untuk menangani berbagai macam

tugas secara efisien. Beberapa pustaka terkenal meliputi *NumPy* dan *Pandas* untuk manipulasi data, *Matplotlib* dan *Seaborn* untuk visualisasi data, serta *TensorFlow* dan *Keras* untuk pembelajaran mesin dan kecerdasan buatan. *Python* juga memiliki ekosistem yang mendukung pengembangan aplikasi yang bersifat *multi-platform*, sehingga dapat digunakan di berbagai sistem operasi, seperti *Windows*, *macOS*, dan *Linux*.


Python sangat populer di kalangan pemula maupun profesional karena kemudahan dalam belajar dan penggunaannya yang *fleksibel*. Dengan komunitas yang luas dan dokumentasi yang baik, *Python* terus berkembang menjadi salah satu bahasa pemrograman yang paling berpengaruh dalam dunia teknologi saat ini.



BAB III

METODE PENELITIAN

3.1 Deskripsi Sistem



Gambar 3. 1 Diagram Blok Sistem

Diagram blok sistem pada Gambar 3.1 menggambarkan alur pengumpulan data gambar *user*. Data gambar tersebut kemudian digunakan untuk mendeteksi citra wajah, yang dilanjutkan dengan pemrosesan menggunakan LBPH, CNN dan *Facenet*. Proses ini mencakup tahap preprocessing, ekstraksi fitur, dan klasifikasi. Hasil akhir dari pengolahan CNN adalah mencocokkan wajah individu yang terdeteksi kamera dengan data yang terdapat dalam basis data

Sistem absensi berbasis pengenalan wajah ini dirancang untuk menggantikan metode absensi tradisional dengan teknologi biometrik yang lebih akurat, cepat, dan aman. Sistem menggunakan kamera untuk menangkap citra wajah pengguna saat absensi, yang kemudian diproses dengan metode *Convolutional Neural Networks* (CNN), *FaceNet*, dan *Local Binary Patterns Histogram* (LBPH). Setiap metode tersebut memiliki fungsi spesifik dalam proses pengenalan, sehingga dapat memastikan tingkat akurasi tinggi dan efisiensi sistem pada perangkat dengan spesifikasi terbatas.

Komponen Utama Sistem:

1. **Kamera Pemindai Wajah:** Kamera ini berfungsi sebagai alat input untuk menangkap gambar wajah pengguna saat proses absensi dimulai. Kamera dapat berupa perangkat terintegrasi atau eksternal, tergantung pada jenis perangkat keras yang digunakan institusi.
2. **Modul Pengenalan Wajah:**
 - **CNN (*Convolutional Neural Networks*):** Modul CNN bertugas mendeteksi dan menganalisis pola-pola kompleks pada gambar wajah, seperti struktur wajah, mata, hidung, dan mulut. CNN membantu sistem membedakan setiap wajah berdasarkan karakteristik uniknya.
 - **FaceNet:** FaceNet digunakan untuk menghasilkan representasi vektor unik dari wajah yang terdeteksi, yang memungkinkan sistem untuk mengenali dan membedakan individu secara akurat. Model ini juga membantu dalam memverifikasi identitas pengguna dengan membandingkan vektor wajah yang sudah terdaftar di basis data.
 - **LBPH (*Local Binary Patterns Histogram*):** LBPH adalah metode yang lebih ringan secara komputasi dan berfungsi mendukung performa pengenalan wajah pada perangkat dengan spesifikasi komputasi terbatas. LBPH bekerja dengan menganalisis pola tekstur pada wajah, yang memungkinkan sistem untuk berjalan optimal tanpa membutuhkan perangkat keras canggih.
3. **Database Wajah:** Semua data wajah pengguna yang terdaftar disimpan dalam basis data. Database ini menyimpan vektor representasi wajah setiap individu untuk memungkinkan proses autentikasi cepat dan akurat ketika pengguna melakukan absensi.
4. **Pengaturan Privasi dan Keamanan Data:** Sistem ini mengutamakan keamanan data pengguna dengan menerapkan *enkripsi* data wajah dan protokol autentikasi yang ketat untuk melindungi data biometrik dari


akses yang tidak sah. Sistem juga menyediakan pengaturan privasi untuk memastikan bahwa data hanya dapat diakses oleh pihak yang berwenang.

5. **Antarmuka Pengguna (*User Interface*):** Antarmuka ini memungkinkan pengguna untuk melakukan absensi, memantau kehadiran, dan melihat informasi terkait. **Antarmuka** juga dirancang sederhana dan mudah digunakan agar pengguna dapat dengan mudah melakukan absensi dengan sekali klik atau secara otomatis ketika berada di area verifikasi lokasi.

Alur Kerja Sistem:

1. Pengguna mendekati kamera yang sudah terpasang untuk memulai proses absensi.
2. Kamera menangkap gambar wajah pengguna, yang kemudian dikirim ke modul pengenalan wajah untuk dianalisis.
3. CNN dan *FaceNet* bekerja untuk mendeteksi pola wajah dan menghasilkan vektor wajah yang unik, sementara LBPH memberikan dukungan efisiensi pada perangkat spesifikasi rendah.
4. Sistem membandingkan vektor wajah yang baru saja diambil dengan data di basis data untuk memverifikasi identitas pengguna.
5. Setelah identitas terverifikasi, sistem mencatat kehadiran pengguna di database, yang dapat diakses oleh pihak manajemen untuk keperluan pelaporan kehadiran.

Dengan pendekatan yang menggabungkan teknologi pengenalan wajah dengan verifikasi lokasi, sistem ini menawarkan solusi absensi yang aman, efisien, dan dapat diterapkan secara luas, terutama pada institusi yang memerlukan tingkat akurasi dan keamanan tinggi dalam manajemen kehadiran.



Gambar 3. 2 Alur Penelitian

Gambar 3.2 menunjukkan alur penelitian yang digunakan untuk pengenalan wajah dalam sistem absensi.


3.2 Studi Literatur

Penulis akan melakukan tinjauan terhadap berbagai e-book, artikel, jurnal, dan hasil penelitian sebelumnya yang berkaitan dengan identifikasi wajah, metode *CNN*, *FaceNet*, serta *Local Binary Pattern Histogram (LBPH)*. Referensi-referensi tersebut akan digunakan sebagai landasan dalam merumuskan masalah sekaligus mencari solusi untuk menyelesaikan permasalahan yang diangkat.

3.3 Metode Penelitian

Dalam penelitian ini, metode yang diterapkan untuk pengenalan wajah adalah *Convolutional Neural Networks (CNN)* dan *Local Binary Pattern Histogram (LBPH)*. *CNN* digunakan untuk mengekstraksi fitur wajah dari citra dengan cara yang lebih kompleks dan mendalam, sedangkan *LBPH*


digunakan untuk mendeskripsikan pola tekstur wajah dengan *histogram* lokal, yang lebih sederhana namun tetap efektif dalam pengenalan wajah pada banyak kasus. *FaceNet* digunakan untuk membandingkan wajah dengan *embedding* yang dihasilkan oleh CNN, dan LBPH digunakan sebagai pendekatan tambahan untuk ekstraksi fitur.



Gambar 3.3 menunjukkan alur metode yang dimulai dengan proses pertama yaitu memasukkan citra sebagai input. Setelah citra dimasukkan, tahap berikutnya adalah preprocessing, di mana citra akan melalui proses cropping berdasarkan ROI wajah untuk memperoleh area citra wajah. Kemudian, citra akan masuk ke tahap ekstraksi fitur, di mana fitur atau ciri-ciri dari citra diambil dan diubah menjadi nilai matriks. Langkah terakhir adalah klasifikasi, yang dalam hal ini menggunakan metode *Convolutional Neural Networks* untuk mengenali wajah.

3.4 Perancangan Sistem

3.4.1 Flowchart Sistem



Gambar 3. 4 *Flowchart* Sistem

Gambar 3.4 merupakan Flowchart Sistem, yang terdiri dari beberapa langkah utama sebagai berikut:

1. Mengaktifkan webcam untuk melakukan deteksi wajah. Faktor-faktor penting yang harus diperhatikan antara lain kondisi pencahayaan, jarak wajah dari kamera, serta sudut wajah terhadap kamera.
2. Pengenalan Wajah: Sistem menggunakan CNN dan FaceNet untuk mengekstraksi fitur wajah dan membandingkannya dengan data wajah yang ada dalam database.
3. Tanda dengan kotak hijau menandakan wajah yang terdeteksi.
4. Absensi: Jika wajah yang terdeteksi sesuai dengan wajah yang sudah terdaftar, data absensi akan disimpan dalam database.

3.5 Perancangan Model


3.5.1 Pengumpulan Data (*Input data*)

Sampel wajah diambil menggunakan webcam per individu. Proses pengambilan gambar dilakukan dengan memperhatikan beberapa faktor seperti resolusi kamera, pencahayaan, jarak, dan sudut pengambilan citra.

3.5.2 *Preprocessing*

Setelah pengambilan gambar, langkah selanjutnya adalah preprocessing citra untuk mempersiapkan data agar siap diproses oleh model. Proses ini termasuk:

- Grayscale: Mengubah gambar menjadi grayscale untuk mengurangi kompleksitas warna.
- Resize: Menyesuaikan ukuran citra agar konsisten dengan input model (misalnya, 64x64 untuk CNN)..
- Normalisasi: Gambar dinormalisasi ke rentang nilai $[0, 1]$ agar lebih mudah diproses oleh model.



Gambar 3. 5 Flowchart Preprocessing

Pada Gambar 3.5 menunjukkan tahapan *Preprocessing*. Proses pengolahan citra wajah dimulai dengan *input* citra wajah, di mana gambar wajah diperoleh baik melalui kamera atau diambil dari file. Setelah itu, gambar yang diperoleh dikoversi ke *grayscale* menggunakan fungsi seperti `cv2.cvtColor()` dari *OpenCV*, yang penting untuk memudahkan proses deteksi wajah karena mengurangi kompleksitas warna. Langkah berikutnya adalah deteksi wajah, yang umumnya dilakukan dengan algoritma seperti *Haar Cascade* atau *MTCNN*, untuk menemukan lokasi wajah dalam gambar. Setelah wajah terdeteksi, langkah pemotongan wajah dilakukan dengan memotong bagian gambar yang berisi wajah, menggunakan koordinat yang diperoleh dari deteksi sebelumnya. Kemudian, gambar wajah yang telah dipotong diubah ukurannya menjadi ukuran yang lebih kecil, seperti 64x64 piksel, agar sesuai dengan model yang akan digunakan dalam proses selanjutnya. Gambar yang telah diproses ini kemudian disimpan untuk

digunakan dalam tahap ekstraksi fitur atau pelatihan model. Setelah tahap pemrosesan selesai, gambar yang telah dipotong dan diubah ukurannya siap digunakan dalam proses ekstraksi fitur, di mana teknik seperti *Local Binary Patterns Histogram* (LBPH), *Convolutional Neural Networks* (CNN), atau *FaceNet* dapat diterapkan untuk menganalisis dan mengenali fitur wajah yang relevan.

3.5.3 Ekstraksi Fitur

Tahap selanjutnya setelah preprocessing selesai adalah ekstraksi fitur dengan metode *Local Binary Pattern Histogram* (LBPH), CNN dan FaceNet.

1. LBPH adalah metode yang digunakan untuk menggali pola tekstur pada citra wajah. LBPH bekerja dengan cara menganalisis pola lokal di sekitar piksel pusat citra wajah dan membandingkan nilai intensitas piksel dengan tetangganya. Proses ini menghasilkan histogram dari pola biner lokal yang menggambarkan tekstur wajah.
2. CNN akan digunakan untuk mengekstraksi fitur dari citra wajah yang kemudian digunakan untuk mengenali pola tekstur wajah yang unik.
3. FaceNet menggunakan pendekatan embedding untuk mengubah wajah menjadi vektor numerik yang dapat dibandingkan menggunakan jarak Euclidean.

3.5.4 Training Data

Dataset gambar wajah yang telah diproses dan diekstraksi fitur (menggunakan LBPH, CNN, dan FaceNet) akan digunakan untuk melatih model. Dataset CNN dibagi menjadi dua bagian: training set dan testing set (80% pelatihan dan 20% pengujian). Sementara itu, *FaceNet* menghasilkan *embedding* wajah yang digunakan untuk membandingkan kemiripan wajah dalam database.

3.5.5 Pengenalan Wajah

Pada tahap ini, sistem akan mengenali wajah dengan cara membandingkan citra wajah yang diuji dengan *embedding* wajah dalam *FaceNet*. Jika ada kemiripan yang cukup, wajah tersebut dikenali dan identitasnya dicatat sebagai absen.

3.5.6 Absensi

Setelah wajah dikenali, sistem akan mencatat kehadiran individu ke dalam database menggunakan data yang diterima dari hasil pengenalan wajah.

3.6 Evaluasi Model

Evaluasi dilakukan untuk mengukur akurasi dan kinerja sistem. *Confusion matrix* digunakan untuk menghitung beberapa metrik berikut:

1. *Accuracy*, yaitu seberapa dekat nilai prediksi dan nilai sebenarnya

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

2. *Precision* (presisi): proporsi elemen-elemen terkait yang dipilih dibandingkan dengan jumlah total item yang dipilih, menggambarkan hubungan antara permintaan informasi dan respons yang diberikan terhadap permintaan tersebut.

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

3. *Recall* (recall): perbandingan antara jumlah elemen relevan yang tersedia secara keseluruhan dengan jumlah elemen relevan yang dipilih.

$$Recall = \frac{TP}{TP + FN} \quad (11)$$

4. *F1-Score* (harmonisasi precision dan recall): persamaan harmoni antara nilai recall dan presisi.

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (12)$$

Di mana:

- *True Positives* (TP): Data yang benar-benar positif dan terdeteksi positif.
- *True Negatives* (TN): Data yang benar-benar negatif dan terdeteksi negatif.

- *False Positives* (FP): Data yang salah terdeteksi positif.
- *False Negatives* (FN): Data yang salah terdeteksi negatif.




BAB IV

HASIL DAN ANALISIS PENELITIAN

4.1 Hasil Pembuatan Sistem

Tahap implementasi adalah langkah yang dilakukan setelah proses perancangan selesai, di mana aplikasi dijalankan untuk memastikan apakah tujuan yang diharapkan telah tercapai. Tahap ini dibuat setelah hasil perancangan yang dibuat pada bab sebelumnya,


4.1.1 Halaman Dashboard



Gambar 4. 1 Tampilan *Dashboard*

Pada Fitur ini memungkinkan sistem untuk mendeteksi data wajah mahasiswa yang tersimpan dalam dataset. Tampilan Halaman *Dashboard*: Halaman ini dirancang menggunakan *framework Flask* dengan elemen antarmuka yang intuitif. Komponen utama meliputi:

- Grafik kehadiran: Menampilkan data statistik dalam bentuk visual.
- Navigasi menu: Menghubungkan pengguna ke fitur lain, seperti daftar hadir dan pelatihan model.




Gambar 4. 2 Proses Absensi Menganalisis Wajah

Gambar 4.2 adalah proses pemindaian wajah mahasiswa, Informasi tentang kuliah yang berlangsung dan mahasiswa yang hadir termasuk dalam bagian informasi presensi. Di sini, nama mahasiswa akan ditampilkan jika wajah terdeteksi. Apabila terlihat kotak hijau, itu menandakan bahwa wajah telah terdeteksi dan siap untuk diproses.

Gambar 4. 3 Form untuk pengisian data pembelajaran

Gambar 4.3 adalah proses pengisian data yang mana mahasiswa setelah berhasil terdeteksi wajahnya akan melanjutkan ke proses pengisian form seperti di gambar. Mahasiswa di minta untuk mengisi No, Mata Kuliah, Nama Dosen, Lokasi, Ruangan, Keterangan



Face Attendance - Smart Absensi

Face ID:

Nama:

Capture

Train Model

Mark Attendance

Stop Attendance


© 2025 Smart Absensi. All rights reserved.

For...

No:	Anggara Putra
Mata Kuliah:	Sistem Biomedis
Nama Dosen:	Pak Sri
Lokasi:	FTI
Ruangan:	303
Keterangan:	Hadir
Submit	

Gambar 4. 4 Setelah Proses Pengisian Data

Gambar 4.4 adalah proses setelah melakukan pengisian data yang mana mahasiswa akan di minta untuk mengklik tombol submit untuk menyimpan data yang telah diisikan.



Face Attendance - Smart Absensi

Face ID:

Nama:

Sukses

Data telah berhasil disimpan!

OK

Mark Attendance

Stop Attendance

© 2025 Smart Absensi. All rights reserved.

For...


No:	Anggara Putra
Mata Kuliah:	Sistem Biomedis
Nama Dosen:	Pak Sri
Lokasi:	FTI
Ruangan:	303
Keterangan:	Hadir
Submit	

Gambar 4. 5 Proses Penyimpanan Data

Gambar 4.5 adalah proses Dimana data mahasiswa yang terdeteksi telah berhasil disimpan dan akan tercatat di file *excel* berserta *id NIM* mahasiwa yang tercatat.

4.1.2 Tampilan Daftar Hadir

Tampilan ini digunakan sebagai bentuk validasi untuk meminimalisir manipulasi terhadap absensi.



Gambar 4. 6 Tampilan Daftar Hadir

Gambar 4.6 Sistem akan memprediksi hasil berdasarkan input dari database. Jika terdapat kecocokan, sistem akan menampilkan informasi berikut: nama mahasiswa, waktu, nomor induk mahasiswa, mata kuliah, nama dosen, lokasi, ruangan, keterangan, dan status.

Fitur Utama Tampilan Daftar Hadir:

- Pencarian: Memungkinkan pengguna mencari data berdasarkan nama atau tanggal.
- *Export*: Data dapat diekspor dalam format Excel untuk keperluan administrasi lebih lanjut.

4.1.3 Analisis dan Pengujian

Pada tahap ini, kinerja sistem diuji menggunakan metode pengujian *blackbox* testing. *Blackbox* testing bertujuan untuk mengevaluasi cara kerja sistem tanpa perlu mengetahui kode program yang mendasarinya.

Tabel 4. 1 Pengujian Sistem

Kelas Uji	Kasus Pengujian	Hasil Pengujian	Kesimpulan
-----------	-----------------	-----------------	------------

Dashboard	Mengecek Navigasi menu capture mengarahkan ke halaman yang sesuai	Setiap tombol navigasi berhasil diarahkan ke halaman terkait tanpa error.	Berhasil
	Mengecek Navigasi menu Train Model mengarahkan ke halaman yang sesuai	Setiap tombol navigasi berhasil diarahkan ke halaman terkait tanpa error.	Berhasil
	Mengecek Navigasi menu Mark Attendance mengarahkan ke halaman yang sesuai	Setiap tombol navigasi berhasil diarahkan ke halaman terkait tanpa error.	Berhasil
	Mengecek Navigasi menu Stop Attendance mengarahkan ke halaman yang sesuai	Setiap tombol navigasi berhasil diarahkan ke halaman terkait tanpa error.	Berhasil
Form Input Kehadiran	Mengecek Form GUI muncul saat wajah dikenali.	Saat wajah dikenali, form GUI otomatis muncul untuk input data kehadiran.	Berhasil

	Semua kolom form wajib diisi sebelum tombol submit bisa ditekan.	Validasi kolom form bekerja, form tidak bisa disubmit jika ada kolom kosong.	Berhasil
	Data dari form GUI tersimpan dalam file Excel.	Data kehadiran berhasil dicatat dan langsung ditambahkan ke file attendance.xlsx	Berhasil


4.1.4 Pengambilan Data Wajah

Pada tahap pengumpulan data, penelitian ini melibatkan 20 responden mahasiswa, dengan pengambilan gambar dilakukan hanya dari satu sudut, yaitu tampak depan. Proses perekaman wajah berlangsung lebih dari 3 detik untuk memastikan kehadiran. Data yang telah dikumpulkan kemudian dimasukkan ke dalam sistem.

Tabel 4. 2 Pengambilan Data Wajah

ID	Nama	Citra Wajah
1	Anggara Putra	

2	Alfina	
3	Aufa	
4	Alfiansyah	
5	Arizal	
6	Naila	

7	Farel	
8	Adella	
9	Ananta Nely	
10	Muhammad Paiq	
11	Reza	

12	Tubagus	
13	Yasin	
14	Wahyu	
15	Rais	
16	Victor	


17	Dimas Wirastama	
18	Anam	
19	Ainul Irsyad	
20	Ananda Feri	

proses pengambilan data wajah dilakukan dengan mengaktifkan kamera untuk menangkap wajah secara *real-time* menggunakan deteksi berbasis *Haar Cascade*, di mana wajah yang terdeteksi disimpan dalam folder *training_data* sebagai file gambar berformat (.jpg), dan fitur wajah diekstraksi menggunakan model *FaceNet* untuk menghasilkan *embedding* yang disimpan sebagai file (.pt) sehingga setiap individu dapat memiliki hingga 100 gambar wajah yang nantinya digunakan untuk melatih model LBPH, CNN, dan KNN

guna mendukung pengenalan wajah berbasis *ensemble decision* yang menggabungkan hasil prediksi dari ketiga model tersebut.

4.1.5 Training

proses pelatihan dilakukan dengan memanfaatkan data yang telah dikumpulkan pada tahap sebelumnya. Model LBPH dilatih menggunakan data gambar *grayscale* untuk mengenali pola tekstur lokal pada wajah dengan mengimplementasikan algoritma *Local Binary Patterns Histogram*. Model CNN dilatih menggunakan gambar yang telah melalui proses normalisasi dan perubahan ukuran menjadi 64x64 piksel untuk melakukan klasifikasi berdasarkan fitur wajah, sedangkan model FaceNet digunakan untuk mengekstraksi *embedding* wajah yang kemudian dilatih menggunakan algoritma *K-Nearest Neighbors* (KNN) untuk klasifikasi berdasarkan jarak kosinus. Ketiga model ini diterapkan secara bersamaan dalam metode *ensemble decision* untuk memastikan akurasi pengenalan wajah, di mana keputusan akhir diambil berdasarkan mayoritas prediksi dari ketiga model tersebut. Hasil pelatihan disimpan ke dalam file model masing-masing, yaitu *s_model.yml* untuk LBPH, *cnn_model.h5* untuk CNN, dan *facenet_knn_model.pkl* untuk FaceNet-KNN, sehingga dapat digunakan dalam tahap pengujian dan implementasi sistem.



Gambar 4. 7 Hasil Pelatihan LBPH, CNN dan Facenet

Gambar 4.7 menunjukkan Hasil pelatihan disimpan ke dalam file model masing-masing.

4.1.6 Analisis Akurasi

Dalam penelitian ini, sistem absensi berbasis pengenalan wajah diuji untuk menilai seberapa baik model dapat mengidentifikasi wajah dengan akurasi yang tinggi. Model yang digunakan adalah metode CNN (*Convolutional Neural Network*) untuk ekstraksi fitur dan *FaceNet* untuk representasi vektor embedding wajah. Selain itu, algoritma *K-Nearest Neighbors* (KNN) digunakan sebagai model klasifikasi untuk memetakan embedding ke identitas individu. Untuk mengukur kinerja, metrik akurasi dihitung menggunakan fungsi *accuracy_score* dari pustaka *Scikit-learn*. Selain itu, evaluasi metrik lainnya, seperti presisi, *recall*, dan *F1-score*, dilakukan untuk memberikan gambaran performa yang lebih komprehensif.

Prosedur Pengujian


Data pelatihan terdiri dari 1.000 citra wajah dari 10 individu, di mana setiap individu memiliki 100 data wajah. Data tersebut dipecah menjadi data latih dan data uji dengan rasio 80:20. Ekstraksi fitur dilakukan menggunakan *FaceNet*, di mana setiap wajah direpresentasikan sebagai vektor embedding berdimensi 128. Model KNN diuji dengan berbagai nilai parameter k (1, 3, 5, 7, dan 9), sementara model CNN dievaluasi berdasarkan akurasi klasifikasinya.

Tabel 4. 3 Hasil Akurasi facenet dengan knn dan CNN.

Nilai K	Hasil Akurasi
$k = 1$	100.00%
$k = 3$	100.00%
$k = 5$	100.00%
$k = 7$	99.89%
$k = 9$	99.89%
CNN	100.00%


Pada Tabel 4.3 hasil terbaik diperoleh dengan nilai $k=1$, dengan akurasi mencapai 100.00%. Namun, nilai k yang lebih besar ($k=7$ dan $k=9$)

menunjukkan kestabilan terhadap noise, meskipun akurasi sedikit menurun. Dan untuk CNN memperoleh akurasi mencapai 100,000%.



Gambar 4. 8 Grafik perbandingan antara model KNN (rata-rata) dan CNN


Pada Gambar 4.8 menunjukkan perbandingan performa antara model KNN (rata-rata) dan CNN pada empat metrik: *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Kedua model menunjukkan hasil yang serupa, dengan sedikit perbedaan di setiap metrik. Grafik ini menggambarkan kemampuan kedua model dalam klasifikasi data dengan evaluasi yang seimbang.




Gambar 4. 9 Perbandingan Metrik Performa Model

Gambar 4.9 membandingkan performa model KNN dengan berbagai nilai K (K=1, K=3, K=5, K=7, K=9) dan model CNN pada empat metrik:


Accuracy, Precision, Recall, dan F1-Score. Setiap metrik ditampilkan dengan warna berbeda, menunjukkan perbandingan kinerja antara model KNN dan CNN.




Gambar 4. 10 Confusion Matrix K=1




Gambar 4. 11 Confusion Matrix K=3




Gambar 4. 12 Confusion Matrix K=5



Gambar 4. 13 Confusion Matrix K=7



Gambar 4. 14 Confusion Matrix K=9



Gambar 4. 15 Confusion Matrix CNN

Pada Gambar 4.10 – 4.15 adalah hasil akurasi dan evaluasi model dengan confusion matrix yang memiliki 5 kategori yaitu K=1, K=3, K=5, K=7, dan K=9.

- Nilai K Kecil ($K=1$): Pada $K=1$, model mencapai akurasi sempurna sebesar 100% dengan nilai Precision, Recall, dan F1-Score yang juga mencapai 1.0. Hal ini menunjukkan bahwa model sangat akurat dalam memetakan data pelatihan ke data prediksi, tetapi cenderung overfitting dan sensitif terhadap noise atau outlier.
- Nilai K Menengah ($K=3$ dan $K=5$): Pada $K=3$ dan $K=5$, model tetap mempertahankan akurasi sebesar 100% dengan metrik evaluasi lainnya (Precision, Recall, dan F1-Score) masing-masing sebesar 1.0. Hal ini mengindikasikan bahwa model dapat menjaga keseimbangan antara sensitivitas terhadap noise dan generalisasi prediksi.
- Nilai K Besar ($K=7$ dan $K=9$): Pada $K=7$ dan $K=9$, akurasi model sedikit menurun menjadi 99.89%, dengan nilai Precision, Recall, dan F1-Score masing-masing sebesar 0.9989. Meskipun model menjadi lebih stabil terhadap noise, terdapat sedikit pengorbanan dalam detail prediksi, terutama dalam menangkap pola dari data pelatihan secara spesifik.

Menggunakan confusion matrix dengan berbagai nilai K membantu menganalisis kinerja model dan memilih nilai K yang optimal, berdasarkan trade-off antara overfitting dan underfitting. Tabel 4.4 menampilkan hasil *Precision*, *Accuracy*, *Recall*, dan *F1-score* untuk setiap kelas, yang dihitung berdasarkan nilai *True Positive* (TP), *False Positive* (FP), *False Negative* (FN), dan *True Negative* (TN).

Tabel 4. 4 *Confusion Matrix* tiap kelas facenet dengan knn dan cnn

Nilai K	TP	FP	FN	TN
K=1	1988	0	0	1988
K=3	1988	0	0	1988
K=5	1988	0	0	1988
K=7	1986	2	2	1988
K=9	1986	2	2	1988
CNN	399	0	0	399

Tabel 4.5 Hasil dari masing-masing kelas yang diuji dengan optimasi, termasuk *Precision*, *recal*, dan *F1-score*.

Tabel 4. 5 Skor *Precision*, *recal*, dan *F1-score* facenet dengan knn dan cnn.

Nilai K	<i>Precision</i>	<i>Recal</i>	<i>F1-Score</i>
K=1	1	1	1
K=3	1	1	1
K=5	1	1	1
K=7	0.998999	0.998994	0.9989
K=9	0.998999	0.998994	0.9989
CNN	1	1	1

Tabel 4.6 Menggambarkan perhitungan *Precision*, *recal*, dan *F1-score* untuk setiap kelas berdasarkan nilai TP,FP dan FN.

Tabel 4. 6 Perhitungan manual facenet dengan knn dan cnn.

Kelas	Perhitungan	Hasil
	$Precision = \frac{TP}{TP + FN}$	
K=1	$Precision = \frac{1988}{1988 + 0} = \frac{1988}{1988} = 1$	1
K=3	$Precision = \frac{1988}{1988 + 0} = \frac{1988}{1988} = 1$	1
K=5	$Precision = \frac{1988}{1988 + 0} = \frac{1988}{1988} = 1$	1
K=7	$Precision = \frac{1986}{1986 + 2} = \frac{1986}{1988} = 0.9989$	0,9989
K=9	$Precision = \frac{1986}{1986 + 2} = \frac{1986}{1988} = 0.9989$	0,9989
CNN	$Precision = \frac{399}{399 + 0} = \frac{399}{399} = 1$	1
	$Recall = \frac{TP}{TP + FN}$	
K=1	$Recall = \frac{1988}{1988 + 0} = \frac{1988}{1988} = 1$	1
K=3	$Recall = \frac{1988}{1988 + 0} = \frac{1988}{1988} = 1$	1
K=5	$Recall = \frac{1988}{1988 + 0} = \frac{1988}{1988} = 1$	1

K=7	$Recall = \frac{1986}{1986 + 2} = \frac{1986}{1988} = 0.9989$	0,9989
K=9	$Recall = \frac{1986}{1986 + 2} = \frac{1986}{1988} = 0.9989$	0,9989
CNN	$Recall = \frac{399}{399 + 0} = \frac{399}{399} = 1$	1
	$F1 - Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$	
K=1	$F1 - Score = 2 \cdot \frac{1 \cdot 1}{1 + 1} = 2 \times \frac{1}{2} = 1$	1
K=3	$F1 - Score = 2 \cdot \frac{1 \cdot 1}{1 + 1} = 2 \times \frac{1}{2} = 1$	1
K=5	$F1 - Score = 2 \cdot \frac{1 \cdot 1}{1 + 1} = 2 \times \frac{1}{2} = 1$	1
K=7	$F1 - Score = 2 \cdot \frac{0,998999 \cdot 0,998994}{0,998999 + 0,998994}$ $= 2 \times \frac{0,99799401}{1,997993} = 0.9989$	0,9989
K=9	$F1 - Score = 2 \cdot \frac{0,998999 \cdot 0,998994}{0,998999 + 0,998994}$ $= 2 \times \frac{0,99799401}{1,997993} = 0.9989$	0,9989
CNN	$F1 - Score = 2 \cdot \frac{1 \cdot 1}{1 + 1} = 2 \times \frac{1}{1} = 1$	1

4.1.7 Pengujian Performa Sistem

Pada tahap ini, dilakukan pengujian pencocokan wajah yang disajikan dalam bentuk tabel. Tabel 4.7 berikut menunjukkan hasil pencocokan wajah berdasarkan berbagai skenario yang diuji, untuk menentukan cocok atau tidaknya wajah tersebut. Pengujian intensitas cahaya dilakukan dengan mengukur tingkat cahaya yang mengenai wajah menggunakan alat pengukur yang disebut luxmeter. Perhitungan luxmeter ini dilakukan melalui aplikasi smartphone "luxmeter".


Tabel 4. 7 Pengujian intensitas cahaya

No	Gambar	Skenario Uji Lux	Hasil	Keterangan
----	--------	---------------------	-------	------------


1		2 lux	Tidak Terdeteksi	Citra wajah tidak teridentifikasi pada intensitas cahaya 2 lux meter.
2		17 lux	Tidak Terdeteksi	Citra wajah tidak teridentifikasi pada intensitas cahaya 2 lux meter.
3		24 lux	Terdeteksi	Citra wajah teridentifikasi pada intensitas cahaya 24 lux meter.
4		43 lux	Terdeteksi	Citra wajah teridentifikasi pada intensitas cahaya 43 lux meter.

5		70 lux	Terdeteksi	Citra wajah teridentifikasi pada intensitas cahaya 70 lux meter.
6		200 lux	Terdeteksi	Citra wajah teridentifikasi pada intensitas cahaya 200 lux meter.
7		1200 lux	Terdeteksi	Citra wajah teridentifikasi pada intensitas cahaya 1200 lux meter.
8		3500 lux	Terdeteksi	Citra wajah teridentifikasi pada intensitas cahaya 3500 lux meter.

A. Pengujian menggunakan website




Gambar 4. 16 Hasil Pengenalan Wajah




Gambar 4. 17 Hasil Pengenalan Wajah



Gambar 4. 18 Hasil Pengenalan Wajah



Gambar 4. 19 Hasil Pengenalan Wajah



Gambar 4. 20 Hasil Pengenalan Wajah

Pada Uji coba presensi, di mana sistem menjalankan *loop* tanpa batas untuk membaca frame kamera untuk mempermudah identifikasi wajah, seperti yang ditunjukkan pada Gambar 4.16–4.20, berhasil menampilkan wajah dan NIM yang sesuai dengan data pelatihan.

4.1.8 Pengujian Pengenalan Wajah Berdasarkan Jarak

Pengujian ini mengharuskan pengguna untuk mengarahkan wajah mereka ke kamera pada jarak 20, 50, dan 100 cm. Tujuan dari uji coba ini adalah untuk menilai sejauh mana sistem dapat mendeteksi wajah berdasarkan jarak antara kamera dan wajah. Pengukuran jarak menggunakan aplikasi smartphone “*Distance meter*”. Selama proses pengujian, sistem diberi waktu lima detik untuk mengenali dan mendeteksi wajah dengan tepat. Tabel 4.8 menunjukkan hasil pengujian.

Tabel 4. 8 Pengujian pengenalan wajah berdasarkan jarak

No	User ID	Pengujian	Hasil Analisa	
			Dikenali	Tidak Dikenali
1	User1	20cm	5	-
		50cm	5	-
		100cm	5	-
2	User2	20cm	5	-
		50cm	5	-
		100cm	5	-
3	User3	20cm	5	-
		50cm	5	-
		100cm	5	-
4	User4	20cm	5	-
		50cm	5	-
		500cm	4	-
5	User5	20cm	5	-
		50cm	5	-
		500cm	4	-

Uji coba jarak ditunjukkan pada tabel 4.8 pengujian pertama, kedua, ketiga, keempat dan kelima dengan nilai centimeter 20, 50, 100 dan 500 centimeter, citra wajah tetap dapat diidentifikasi dengan baik pada jarak 500 cm. Penyelidikan lebih lanjut diperlukan untuk mengetahui mengapa pengguna tidak dapat mengidentifikasi wajah diatas jarak pengujian yang telah disebutkan. Oleh karena itu, penulis menilai hasil pengujian serta faktor-faktor yang berkontribusi pada kegagalan.

1. Setiap wajah pengguna diambil dari jarak 20 cm hingga 100 cm dari kamera, sehingga tidak ada data yang dikumpulkan dari jarak lebih dari 100 cm.

2. Kondisi pencahayaan perlu diperhatikan selama pengujian agar fitur wajah, seperti mata, dapat terlihat dengan jelas tanpa terhalang. Proses pengenalan wajah memerlukan pencahayaan yang cukup untuk mencapai hasil yang optimal. Selain itu, pencahayaan selama pengujian harus sebanding dengan kondisi saat pengambilan dataset.
3. Perubahan posisi atau gerakan wajah dapat menyulitkan sistem mengenali wajah. Untuk hasil terbaik, wajah harus tegak dan stabil di depan kamera.

A	B	C	D	E	F	G	H	I
No	Waktu	Label	Mata Kuliah	Nama Dosen	Lokasi	Ruangan	Keterangan	Status
Anam	16/01/2025 01:16	30302300070	Hukum Fisika	Pak Doni	FH	301	Hadir	Diketahui
Anggara Putra	16/01/2025 01:30	32602100009	Sistem Biomedis	Pak Sri	FTI	301	Hadir	Diketahui
Alfina	16/01/2025 02:06	30702100024	Psikologi Klinis	Bu Ratna	Psikologi	401	Hadir	Diketahui
Aufa	17/01/2025 15:06	21402300002	Pengolahan Citra	Pak Bagus	FTI	301	Hadir	Diketahui
Victor	17/01/2025 15:06	32602300060	Pengolahan Citra	Pak Bagus	FTI	301	Hadir	Diketahui

Gambar 4. 21 Tampilan Daftar Hadir

Seperti yang ditunjukkan pada Gambar 4.21. Semua data yang telah dikenali dan diuji telah dicatat dalam database file *Excel*. Sistem ini dibuat untuk membuat pelacakan kehadiran lebih mudah dan memberikan informasi absensi yang akurat dan rinci untuk setiap orang. Hasil pemrosesan menunjukkan semua siswa yang hadir, seperti yang ditunjukkan pada gambar. Informasi penting seperti nama siswa, mata kuliah, dosen, lokasi, ruangan, keterangan, dan waktu absensi disimpan.

4.2 Analisa Sistem

Pada tahap analisis sistem, dilakukan pemeriksaan terhadap input, proses, dan output yang diperlukan untuk melaksanakan tugas deteksi wajah, di mana gambar wajah yang diambil melalui kamera diproses untuk mengenali identitas pengguna, sementara data mahasiswa yang meliputi nama, mata kuliah, dosen, lokasi, ruangan, dan keterangan diinput melalui form yang muncul setelah wajah terdeteksi, untuk mencatat absensi berdasarkan pengenalan wajah tersebut. Sistem ini memerlukan sejumlah prosedur untuk dapat berfungsi dengan baik, antara lain:

1. Deteksi Wajah

Sistem memanfaatkan algoritma deteksi wajah MTCNN untuk mendeteksi wajah dalam setiap frame video yang diambil dari kamera. Wajah yang berhasil terdeteksi akan diberi tanda kotak hijau, sementara wajah yang tidak terdeteksi akan ditandai dengan kotak merah.

2. Pengambilan Citra Wajah

Sistem akan mengambil gambar wajah pengguna menggunakan kamera. Gambar ini digunakan untuk proses pengenalan wajah.

3. Pengenalan Wajah

Pada tahap pengenalan wajah, digunakan beberapa metode untuk mengenali wajah pengguna, di antaranya LBPH (*Local Binary Patterns Histograms*) untuk ekstraksi fitur tekstur wajah, KNN (*K-Nearest Neighbors*) untuk meningkatkan akurasi dan efisiensi pengenalan wajah menggunakan embedding dari model FaceNet, serta CNN (*Convolutional Neural Network*) yang dilatih khusus untuk klasifikasi wajah.

4. Absensi

Setelah wajah terdeteksi dan dikenali, informasi absensi dicatat dengan menginput data seperti nama mahasiswa, mata kuliah, dosen, lokasi, dan ruangan. Sistem secara otomatis mencatat waktu kehadiran, status (terdeteksi atau tidak), serta keterangan lainnya.

5. Klasifikasi

Proses klasifikasi dilakukan menggunakan tiga model, yaitu LBPH yang digunakan untuk mengklasifikasikan wajah pada jarak dekat, KNN yang mengklasifikasikan wajah berdasarkan embedding dari model FaceNet, lebih efektif untuk jarak jauh, dan CNN yang digunakan untuk meningkatkan akurasi klasifikasi baik pada jarak dekat maupun jauh.

6. Menampilkan Hasil Klasifikasi

Fungsi terakhir adalah menampilkan hasil klasifikasi, di mana sistem akan menampilkan NIM mahasiswa yang sesuai dengan identitas wajah yang terklasifikasi.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan penelitian berjudul Implementasi Sistem Absensi Berbasis Pengenalan Wajah Menggunakan Metode CNN dan Model *FaceNet*, dapat disimpulkan bahwa sistem ini menunjukkan kinerja sangat baik dengan akurasi mencapai 100% pada nilai k yang rendah ($k=1$, $k=3$, $k=5$), sedikit menurun pada nilai k yang lebih besar ($k=7$, $k=9$). Faktor-faktor seperti jumlah dataset yang cukup, pencahayaan memadai (24–3500 lux), jarak kamera 20–100 cm, serta posisi wajah yang stabil mendukung keberhasilan sistem. Penggunaan metode *ensemble decision* dari LBPH, CNN, dan KNN meningkatkan akurasi dan stabilitas pengenalan wajah terhadap noise. Sistem ini juga dapat menyimpan data kehadiran secara otomatis dalam format *Excel* menggunakan teknologi deteksi wajah berbasis MTCNN dan *embedding* dari *FaceNet*, sehingga mempermudah administrasi absensi.


5.2 Saran

Hasil penelitian ini memberikan beberapa rekomendasi untuk pengembangan dan peningkatan sistem di masa mendatang, yaitu:

1. Peningkatan Algoritma Pencahayaan: Untuk mengatasi kendala pada kondisi pencahayaan buruk, disarankan untuk menambahkan algoritma penyesuaian otomatis untuk pencahayaan. Hal ini dapat membantu meningkatkan akurasi pengenalan wajah dalam situasi dengan pencahayaan tidak ideal.
2. Optimasi untuk Perangkat Spesifikasi Rendah: Meski sistem sudah mendukung perangkat dengan spesifikasi terbatas, optimasi lebih lanjut pada proses komputasi dapat dilakukan agar sistem berjalan lebih ringan tanpa mengorbankan akurasi.

3. Pengembangan Filter Wajah Terhalang: Menerapkan teknik deteksi objek tambahan untuk mengidentifikasi area wajah yang tertutup, seperti masker atau kacamata besar, akan meningkatkan ketahanan sistem dalam mengenali wajah yang sebagian tertutup.
4. Uji Lapangan di Berbagai Lingkungan: Untuk memastikan performa sistem di berbagai kondisi nyata, diperlukan uji lapangan yang lebih luas pada lingkungan yang beragam, termasuk di luar ruangan dan area dengan variasi pencahayaan tinggi.
5. Stabilitas Deteksi Wajah: Mengembangkan sistem agar lebih toleran terhadap variasi posisi, ekspresi, dan gerakan wajah sehingga dapat digunakan secara lebih fleksibel di kondisi nyata.

Dengan pengembangan lebih lanjut, diharapkan sistem absensi ini dapat menjadi solusi yang semakin andal dan inklusif bagi berbagai institusi, menyediakan teknologi absensi yang lebih canggih namun tetap terjangkau.



DAFTAR PUSTAKA

- Anggreini, A. (2024). Pengembangan Sistem Presensi Karyawan dengan Face Recognition menggunakan Model Facenet. Dalam *Universitas Islam Indonesia*.
<https://dspace.uui.ac.id/bitstream/handle/123456789/51600/20523151.pdf?sequence=1&isAllowed=y>
- Bathinko, D., Putra Kelana, G., & Meimaharani, R. (2024). Perancangan Sistem Absensi Karyawan Berbasis Web Dengan Metode Waterfall. Dalam *Bina Informatika dan Komputer (BINER) DOI: ...* (Vol. 2, Nomor 1).
- Bradski, G. R., & Kaehler, Adrian. (2008). *Learning OpenCV: computer vision with the OpenCV library*. O'Reilly.
- Cahyono, F. (2020). *Pengenalan Wajah Menggunakan Model Facenet Untuk Presensi Pegawai*. https://repository.its.ac.id/76660/2/07111850067013-Master_Thesis.pdf
- Evelyn, Adipranata, R., & Gunadi, K. (2022). Sistem Presensi Mahasiswa Menggunakan Face Recognition Dengan Metode Facenet Pada Android. *Jurnal Infra*, 10(2), 56–62.
- Galbally, J., Fierrez, • J, Alonso-Fernandez, • F, & Martinez-Diaz, • M. (2022). Evaluation of direct attacks to fingerprint verification systems. *Cornell University*. <http://atvs.ii.uam.es>.
- Harisdias Bustomi, R., & Hariyanto, T. (2020). *Sistem Absensi Berbasis Pengenalan Wajah dengan Metode LBPH Menggunakan Raspberry Pi*. <https://towardsdatascience.com/>
- Kenda, P., & Witanti, A. (2022). *Sistem Presensi Berbasis Wajah Dengan Metode Haar Cascade*.
- Kusumaningrum, T. (f). (2018). Tutut Furi Kusumaningrum_14611135_FMIPA_Statistika Implementasi Convolution Neural Network (Cnn) Untuk Klasifikasi Jamur Konsumsi Di Indonesia Menggunakan Keras. *Implementasi Convolution Neural Network (Cnn) Untuk Klasifikasi Jamur Konsumsi Di Indonesia Menggunakan Keras*.
- Mantara Sakti, D., Sudoro Murti, W., Kurniasari, A., & Rosid, J. (2022). Face recognition dengan metode Haar Cascade dan Facenet. *Indonesian Journal of Data and Science (IJODAS)*, 3(1), 30–34.
- MARTUNUS, F. (2020). *Implementasi Face Recognition Dengan Opencv Pada "Smart Cctv" Untuk Keamanan Brankas Berbasis Iot*.

- Muharman, A., Frinaldi, A., Magriasti, L., & Vena Anisa, F. (2023). *Implementasi Kebijakan Sistem Absensi Online Dalam Meningkatkan Kinerja Asn Di Bappeda Kota Sungai Penuh* (Vol. 10). <https://siabon.sungaipenuhkota.go.id>
- Murdiyanto, A. W., Zulfikar, D. H., Waluyo Poetro, B. S., & Siregar, A. C. (2024). Performance Comparison of CNN and ResNet50 for Skin Cancer Classification Using U-Net Segmented Images. *Indonesian Journal of Data and Science*, 5(3), 198–205. <https://doi.org/10.56705/ijodas.v5i3.200>
- Nurona Cahya, F., Hardi, N., Riana, D., & Hadiani, S. (2021). SISTEMASI: Jurnal Sistem Informasi Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN). *Jurnal Sistem Informasi*, 10(3), 618–626. <http://sistemasi.ftik.unisi.ac.id>
- Poetro, B. S. W., Mulyono, S., & Pramesti, V. A. (2024). Prediksi Penyakit Batu Ginjal dengan Menerapkan Convolutional Neural Network. *Jurnal Buana Informatika*, 15(2), 153–162.
- Pribadi, O. (2023). Aplikasi Pengenalan Wajah Menggunakan Algoritma Haar Cascade Classifier Dan Local Binary Pattern Histogram. *Jurnal TIMES*, 12(1), 40–47.
- Rasywir, E., Sinaga, R., Pratama, Y., Dinamika, U., & Jambi, B. (2020). *Analisis dan Implementasi Diagnosis Penyakit Sawit dengan Metode Convolutional Neural Network (CNN)*. 22(2). <https://doi.org/10.31294/p.v2i1i2>
- Saied, M., & Syafii, A. (2023a). Perancangan dan Implementasi Sistem Absensi Berbasis Teknologi Terkini Untuk Meningkatkan Efisiensi Pengelolaan Kehadiran Karyawan dalam Perusahaan. *Jurnal Teknik Indonesia*, 2(3), 87–92. <https://doi.org/10.58860/jti.v2i3.21>
- Satwikayana, S., Wibowo, S. A., & Vendyansyah, N. (2021). Sistem Presensi Mahasiswa Otomatis Pada Zoom Meeting Menggunakan Face Recognition Dengan Metode Convolutional Neural Network Berbasis Web. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 5(2), 785–793.
- Setiono, P. R. (2020). Prince Richard Setiono *jm_informatika,+_Jurnal+Penelitian+Prince+R+Setiono. Aplikasi Pengenalan Wajah Untuk Sistem Absensi Kelas Berbasis Raspberry Pi.*
- Talumepa, R. V., Putra, D. A., & Soetanto, H. (2024). Sistem Presensi Pendeteksi Wajah menggunakan Metode Modified Region Convolutional Neural Network dan PCA. *Edumatic: Jurnal Pendidikan Informatika*, 8(1), 46–55. <https://doi.org/10.29408/edumatic.v8i1.25207>

Zahra, S., Azhar, & Musta'inul, A. (2022). Syifa2022 Sistem Deteksi Wajah Untuk Pencatatan Kehadiran Mahasiswa Di Kls Menggunakan Metode CNN. *ournal of Artificial Intelligence and Software Engineering*, 2(1), 24–28.

