

**Rancang Bangun Prototipe Sistem Pengenalan Wajah Berbasis Multi-Task
Cascaded Convolutional Network (MTCNN) untuk Mengoptimalkan
Pengelolaan Data Mahasiswa di Universitas Lampung**

(Skripsi)

Oleh

YUDHA NUGRAHA

2015061001



**PROGRAM STUDI TEKNIK INFORMATIKA
JURUSAN TEKNIK ELEKTRO
FAKULTAS TEKNIK
UNIVERSITAS LAMPUNG
2025**

**Rancang Bangun Prototipe Sistem Pengenalan Wajah Berbasis Multi-Task
Cascaded Convolutional Network (MTCNN) untuk Mengoptimalkan
Pengelolaan Data Mahasiswa di Universitas Lampung**

Oleh:

YUDHA NUGRAHA

2015061001

Skripsi

Sebagai salah satu syarat untuk mencapai gelar

SARJANA TEKNIK

Pada

Program Studi Teknik Informatika

Jurusan Teknik Elektro

Fakultas Teknik Universitas Lampung



**FAKULTAS TEKNIK
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2025

ABSTRAK

Rancang Bangun Prototipe Sistem Pengenalan Wajah Berbasis Multi-Task Cascaded Convolutional Network (MTCNN) untuk Mengoptimalkan Pengelolaan Data Mahasiswa di Universitas Lampung

Oleh:

YUDHA NUGRAHA

Pengelolaan data mahasiswa yang efisien dan akurat merupakan aspek krusial dalam mendukung administrasi pendidikan di perguruan tinggi. Namun, metode pendataan manual yang masih umum digunakan saat ini sering kali menghadapi berbagai kendala, seperti *human error*, kehilangan data, dan manipulasi identitas, yang berdampak negatif pada efektivitas manajemen akademik. Untuk mengatasi tantangan ini, penelitian ini mengusulkan optimalisasi sistem pendataan mahasiswa di Universitas Lampung dengan mengadopsi teknologi pengenalan wajah berbasis algoritma *Multi-task Cascaded Convolutional Networks* (MTCNN). Tujuan penelitian ini adalah untuk membuat sistem yang dapat mengidentifikasi wajah mahasiswa secara otomatis dan real-time, meningkatkan efektifitas dan efisiensi pendataan mahasiswa. Diharapkan sistem ini akan memungkinkan verifikasi identitas yang lebih aman dan cepat dan mengurangi kesalahan pendataan. Hasil pengujian menunjukkan performa algoritma MTCNN dalam mengklasifikasikan citra pendeteksi wajah mahasiswa menunjukkan skor akurasi sistem sebesar 0.8081, *Precision* model menunjukkan angka 0.8129, *Recall* atau sensitivitas model tercatat sebesar 0.7689, *F1 Score* model adalah 0.7643 dan nilai FPS (*Frames Per Second*) yang rendah yaitu 0.53. Sistem pengenalan wajah dapat berjalan secara *real-time* dengan *frame per second (FPS)* bervariasi pada jarak 0,5–2 meter dari kamera. Implementasi sistem ini menjadi tahap awal penerapan teknologi pengenalan wajah untuk berbagai kebutuhan akademik di Universitas Lampung.

Kata Kunci: *Multi-Task Cascaded Convolutional Network* (MTCNN), Pengenalan Wajah, Pendataan Mahasiswa

ABSTRACT

Design And Development Of A Face Recognition System Prototype Based On Multi-Task Cascaded Convolutional Network (Mtcnn) To Optimize Student Data Management At Universitas Lampung

By:

YUDHA NUGRAHA

Efficient and accurate student data management is a critical aspect of supporting educational administration in higher education institutions. However, manual data collection methods, which are still commonly used, often face various challenges such as human error, data loss, and identity manipulation, negatively affecting the effectiveness of academic management. To address these challenges, this research proposes optimizing the student data management system at the University of Lampung by adopting face recognition technology based on the Multi-Task Cascaded Convolutional Networks (MTCNN) algorithm. The goal of this research is to develop a system capable of automatically and in real-time identifying student faces, thereby enhancing the effectiveness and efficiency of student data collection. This system is expected to enable faster and more secure identity verification while reducing data collection errors. Testing results show that the MTCNN algorithm performs well in classifying student face images, achieving a system accuracy score of 0.8081. The model's precision was recorded at 0.8129, recall (sensitivity) at 0.7689, and F1 Score at 0.7643, with a low Frames Per Second (FPS) value of 0.53. The face recognition system operates in real-time with FPS variability at a distance of 0.5–2 meters from the camera. This system implementation marks an initial step in applying face recognition technology for various academic needs at the University of Lampung.

Keywords: Multi-Task Cascaded Convolutional Network (MTCNN), Face Recognition, Student Data Management

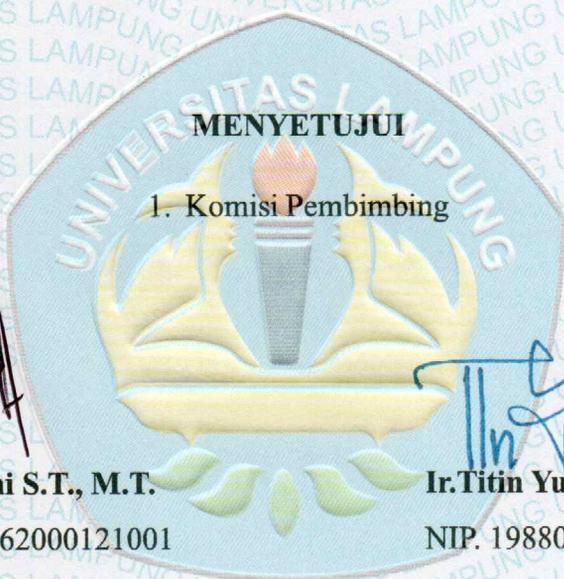
Judul Skripsi : Rancang Bangun Prototipe Sistem
Pengenalan Wajah Berbasis Multi-Task
Cascaded Convolutional Network
(MTCNN) untuk Mengoptimalkan
Pengelolaan Data Mahasiswa di
Universitas Lampung

Nama Mahasiswa : Yudha Nugraha

Nomor Pokok Mahasiswa : 201501001

Program Studi : Teknik Informatika

Fakultas : Teknik



1. Komisi Pembimbing

Yessi Mulyani S.T., M.T.
NIP. 197312262000121001

Ir. Titin Yulianti, S.T., M.Eng.
NIP. 198807092019032015

2. Mengetahui

**Ketua Jurusan
Teknik Elektro**

Herlinawati, S.T., MT.
NIP. 19710314 199903 2 001

**Ketua Program Studi
Teknik Informatika**

Yessi Mulyani S.T., M.T.
NIP. 197312262000121001

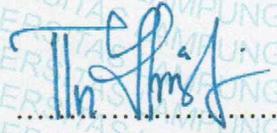
MENGESAHKAN

1. Tim Penguji

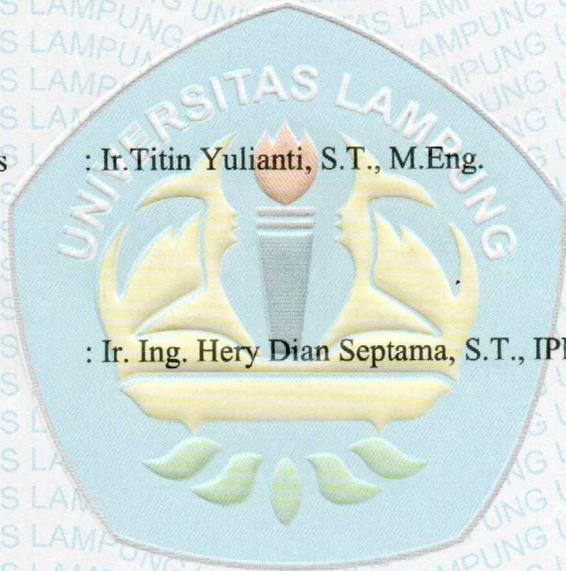
Ketua : Yessi Mulyani S.T., M.T.



Sekretaris : Ir. Titin Yulianti, S.T., M.Eng.



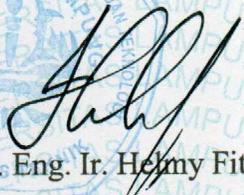
Penguji : Ir. Ing. Hery Dian Septama, S.T., IPM



2. Dekan Fakultas Teknik

Dr. Eng. Ir. Helmy Fitriawan, S.T., M.Sc.

NIP. 19750928 200112 1 002



Tanggal Lulus Ujian Skripsi: 23 Januari 2025

SURAT PERNYATAAN

Dengan ini saya menyatakan bahwa dalam skripsi ini tidak terdapat karya yang pernah dilakukan orang lain dan sepanjang pengetahuan saya tidak terdapat atas diterbitkannya oleh orang lain, kecuali secara tertulis diacu dalam naskah ini sebagaimana yang disebutkan dalam daftar Pustaka. Selain itu, saya menyatakan pula bahwa skripsi ini dibuat oleh saya sendiri.

Apabila pernyataan saya tidak benar, maka saya bersedia dikenai sanksi akademik sesuai dengan hukum yang berlaku.

Bandar Lampung, 23 Januari 2025



Yudha Nugraha
NPM. 2015061001

RIWAYAT HIDUP



Saya lahir di Natar, Lampung Selatan, pada tanggal 08 Maret 2003 sebagai anak bungsu dari 2 bersaudara, anak dari Bapak Rudi dan Ibu Rusmiati. Pendidikan sekolah dasar diselesaikan di SDN 02 Rajabasa pada tahun 2014, sekolah menengah pertama di SMP Negeri 1 Natar diselesaikan pada tahun 2017, dan sekolah menengah atas di SMA Negeri 1 Natar diselesaikan pada tahun 2020. Pada tahun 2020, saya terdaftar sebagai mahasiswa di Program Studi Teknik Informatika, Jurusan Teknik Elektro Fakultas Teknik Universitas Lampung melalui jalur SNMPTN. Saya telah aktif terlibat dalam berbagai kegiatan akademik dan organisasi. Selama dua periode kepengurusan, saya menjabat sebagai Sekretaris Departemen Komunikasi dan Informasi dan Sekertaris Umum di Himpunan Mahasiswa Teknik Elektro (Himatro) Universitas Lampung. Selain itu, saya menjadi ketua komisi V Hubungan Luar Dewan Perwakilan Mahasiswa Universitas Lampung. Sebagai anggota aktif, saya turut aktif di Laboratorium Teknik Digital sebagai asisten selama tahun 2022-2024 dan aktif dalam komunitas Jejak Bermakna.

Pada semester lima, saya mendapatkan kesempatan mengikuti kegiatan Studi Independent dengan mitra Dicoding Indonesia, selain itu juga saya mendapatkan kesempatan kedua untuk mengikuti kegiatan Studi Idependent dengan Program Artificial Intelligence adalah program Studi Independen Bersertifikat yang diselenggarakan oleh Yayasan Bakti Achmad Zaky. Selain itu, saya memiliki pengalaman kerja praktik di UPT Teknologi Informasi Dan Komunikasi Universitas Lampung. Selain itu juga, saya berpartisipasi dalam berbagai proyek dan kegiatan, seperti Rancangan HUD Mobil Listrik UNILA EVU-01 dan menjadi panitia dalam berbagai acara, termasuk seminar nasional dan kompetisi nasional. Pencapaian ini mencerminkan dedikasi pengembangan diri dan berkontribusi pada komunitas akademis dan profesional. Saya berharap dapat terus berkontribusi dalam meningkatkan kualitas dan eksplorasi di dunia teknologi melalui perjalanan akademis dan kegiatan organisasi yang saya jalani.

PERSEMBAHAN



Bismillahirrahmanirrahim

Dengan Ridho Allah SWT
Teriring shalawat kepada Nabi Muhammad SAW
Karya Tulis ini ku persembahkan untuk:

Papa dan Mama Tercinta
Bapak Rudi dan Ibu Rusmiati
Serta Kakaku
M. Ridho Magribi, S.Kom

Terima kasih untuk semua dukungan dan doa selama ini.
Sehingga aku dapat menyelesaikan hasil karyaku ini.





MOTTO

*“Maka sesungguhnya bersama kesulitan ada kemudahan.
Sesungguhnya bersama kesulitan ada kemudahan”*
(QS. Al-Insyirah: 5-6)

“Wahai orang-orang yang beriman, jika kamu menolong
(agama) Allah, niscaya Dia akan menolongmu dan
meneguhkan kedudukanmu”
(QS. Muhammad: 7)

”Dan sebaik-baik manusia adalah yang paling bermanfaat
bagi manusia lainnya”
(HR. Thabrani dalam Al-Mu’jam Al-Awsath, no. 5949.)

”Memaknai sebuah proses, dapat membuatmu mengerti akan
arti dari sebuah hasil”
-Yudha N-



SANWACANA

Alhamdulillah, puji syukur saya panjatkan ke hadirat Allah SWT atas segala rahmat, hidayah, serta inayah-Nya. Dengan segala karunia-Nya, laporan skripsi yang berjudul "Optimalisasi Sistem Pendataan Mahasiswa Universitas Lampung Menggunakan Teknologi Pengenalan Wajah Dengan Algoritma Mtcnn Dan Haarcascade" ini dapat diselesaikan tepat waktu. Laporan ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Teknik di Program Studi Teknik Informatika, Jurusan Teknik Elektro, Fakultas Teknik, Universitas Lampung.

Shalawat serta salam, semoga senantiasa tercurah kepada Nabi Muhammad SAW, keluarga, sahabat, serta para pengikutnya yang istiqomah di jalan Islam hingga akhir zaman.

Selama penyusunan skripsi ini, banyak pihak yang telah memberikan bantuan, baik berupa pemikiran maupun dorongan moril. Oleh karena itu, dengan penuh rasa hormat, saya ingin mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Ibu Prof. Dr.Ir. Lusmeilia Afriani, D.E.A., I.P.M., selaku Rektor Universitas Lampung.
2. Bapak Dr. Eng. Ir. Helmy Fitriawan, S.T., M.Sc., selaku Dekan Fakultas Teknik Universitas Lampung.
3. Ibu Herlinawati, S.T., M.T. selaku Ketua Jurusan Teknik Elektro Fakultas Teknik Universitas Lampung.
4. Ibu Yessi Mulyani S.T., M.T. selaku Ketua Program Studi Teknik Informatika Fakultas Teknik Universitas Lampung dan selaku dosen pembimbing utama bagi penulis.
5. Ibu Titin Yulianti, S.T., M.Eng. selaku pembimbing pendamping tugas akhir, yang telah membantu, membimbing, dan memberi dukungan kepada penulis.
6. Bapak Ir. Ing. Hery Dian Septama, S.T., IPM selaku dosen penguji bagi penulis.
7. Ibu Dr. Eng. Mardiana, S.T.,M.T. sebagai Dosen Pembimbing Akademik, yang telah membantu dalam perjalanan akademik penulis.

8. Seluruh Dosen dan karyawan Jurusan Teknik Elektro Universitas Lampung, berkat ilmu yang telah diajarkan kepada penulis selama penulis menjalani masa studi di perkuliahan.
9. Bapak Rudi dan Ibu Rusmiati selaku orang tua yang senantiasa memberikan dukungan serta do'a kepada penulis.
10. Keluarga rekan-rekan di Laboratorium Teknik Digital, yang selalu memberikan dukungan dalam setiap proses apapun selama menjadi asisten laboratorium teknik digital.
11. Teman Teman Parelemen Pelita Baskala DPM U 2023, (Ahsanul Khotam, M. Nasih Ulwan, Miftahul Arifin, Ahmad Risdan, Nabila Arzeti, Annisa Reswari, Kiki Juwita, Zahrotul Maghfiroh, Aulia Imtitsal, Mutiara Aprilia, Regita Pramesti) yang telah memberikan pengalaman berharga dan warna dalam perjalanan hidup saya.
12. Teman teman Komunitas Jejama, atas kebersamaan dan bantuan yang telah diberikan.
13. Teman teman BC Semen (Addam, Rahmat, Doni , Satria, Thariq, Zaki, Kevin, Bachtiar, Andro, Fathan) yang telah yang telah mendukung saya selama ini
14. Keluarga besar Helios Angkatan 2020, yang telah memberikan banyak motivasi, nilai-nilai sosial, dan bantuan dalam berbagai hal.
15. Keluarga besar Himatro Unila, yang telah menjadi wadah dalam mengembangkan nilai-nilai organisasi bagi penulis.
16. Semua pihak yang tidak dapat disebutkan satu persatu dan terlibat langsung maupun tidak langsung yang telah membantu penulis dalam pembuatan skripsi.

Semoga Allah SWT membalas semua perbuatan dan kebaikan yang telah diberikan kepada Penulis sampai dengan terselesaikannya Skripsi ini. Penulis menyadari bahwa laporan skripsi ini masih memiliki banyak kekurangan, baik dari segi penyusunan maupun pemilihan kata. Maka dari itu penulis terbuka untuk menerima masukan kritik dan saran yang dapat membangun Penulis kedepannya. Semoga penulisan skripsi ini dapat bermanfaat bagi pembaca.

Bandar Lampung, 23 Januari 2025

Penulis,

Yudha Nugraha

Daftar Isi

	Halaman
ABSTRAK	iii
ABSTRACT	iv
Daftar Isi	xiii
Daftar Gambar	xv
Daftar Tabel	xviii
BAB I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	2
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	3
1.5 Batasan Masalah	4
1.6 Sistematika Penulisan	4
BAB II. TINJAUAN PUSTAKA	6
2.1 Artificial Intelligence	6
2.2 Jaringan Syaraf Tiruan	7
2.3 Python	10
2.4 Convolutional Neural Networks (CNN)	11
2.5 MTCNN (Multi-Task Cascaded Convolutional Network)	12
2.6 Penelitian Terdahulu	15
BAB III. METODE PENELITIAN	20
3.1 Waktu dan Tempat Penelitian	20
3.2 Alat Penelitian	21
3.3 Dataset	21

3.4 Tahapan Penelitian	22
3.4.1 Studi Literatur	23
3.4.2 Pengambilan Data	23
3.4.3 Pemahaman Data	23
3.4.4 Preprocessing Data	24
3.4.5 Pemodelan MTCNN	24
3.4.6 Evaluasi	29
3.4.7 Deployment	30
3.5 Metode Analisis Evaluasi Kinerja Model Menggunakan Confusion Matrix dan Metrik Evaluasi	30
BAB IV. HASIL DAN PEMBAHASAN	32
4.1 Hasil Pendeteksi Wajah Menggunakan Algoritma MTCNN	32
4.1.1 Pengambilan Data	32
4.1.2 Pemahaman Data	34
4.1.3 Preprocessing Data	34
4.1.4 Pemodelan	42
4.1.4 Evaluasi	47
4.1.5 Penerapan	53
4.2 Perbandingan Jarak	60
BAB V. KESIMPULAN DAN SARAN	64
5.1 Kesimpulan	64
5.2 Saran	65
Daftar Pustaka	66

Daftar Gambar

	Halaman
Gambar 1. Penggunaan kecerdasan buatan	7
Gambar 2. Struktur Jaringan Syaraf Tiruan	8
Gambar 3. Arsitektur CNN [7].....	11
Gambar 4. Arsitektur P-Net	12
Gambar 5. Arsitektur R-Net.....	13
Gambar 6. Arsitektur O-Net.....	14
Gambar 7. Tahapan Penelitian	22
Gambar 8. Tahapan Persiapan Data	24
Gambar 9. Arsitektur jaringan P-Net	27
Gambar 10. Arsitektur jaringan R-Net.....	28
Gambar 11. Arsitektur jaringan O-Net.....	28
Gambar 12. Dataset yang berasal dari formulir	33
Gambar 13. sampling dataset yang diambil menggunakan platform google form	33
Gambar 14. Dataset yang berasal dari kamera.....	33
Gambar 15. sampling dataset yang diambil menggunakan kamera.....	33
Gambar 16. Dataset Awal	34
Gambar 17. sampling dataset	34
Gambar 18. proses pendeteksian wajah	35
Gambar 19. proses pemotongan (cropping)	35
Gambar 20. proses mengubah ukuran gambar (resize).....	37
Gambar 21. Hasil Augmentasi Gambar	38
Gambar 22. Sampung folder hasil augmentasi data.....	39
Gambar 23. Jumlah File Awal per Folder sebelum augmentasi	39
Gambar 24. Jumlah Augmentasi per File per Folder	40
Gambar 25. image pyramid MTCNN	42
Gambar 26. Hasil dari proses P-Net pada MTCNN.....	43
Gambar 27. Hasil dari proses R-Net pada MTCNN	44

Gambar 28. Hasil dari proses O-Net pada MTCNN	46
Gambar 29. kode perintah training model.....	47
Gambar 30. Confusion Matrix Sistem pendeteksi wajah menggunakan algoritma MTCNN	48
Gambar 31. Grafik Hasil Akurasi MTCNN selama Training	49
Gambar 32. Grafik hasil loss MTCNN selama training.....	49
Gambar 33. Hasil Pembacaan Wajah Tunggal	53
Gambar 34. Hasil Pendeteksi Wajah Banyak	54
Gambar 35. Hasil Uji pengecekan tingkat presisi, tingkat akurasi, sensitifitas dan F1 skor.....	55
Gambar 36. Visualisasi pengecekan CM, tingkat presisi, tingkat akurasi, sensitifitas dan F1 skor.....	55
Gambar 37. Kode Penyimpanan Data secara Real Time	58
Gambar 38. Citra Hasil asil proses pengenalan wajah yang disimpan kedalam CSV	59
Gambar 39. Surat Izin Pengambilan Data Penelitian.....	69
Gambar 40. Tampilan Halaman Pertama Formulir Pengumpulan Dataset.....	70
Gambar 41. Tampilan Halaman Kedua Formulir Pengumpulan Dataset	72
Gambar 42. Tampilan Halaman Kedua Formulir Pengumpulan Dataset	72
Gambar 43. Dataset Penelitian.....	73
Gambar 44. Dataset Mahasiswa Zaki.....	73
Gambar 45. Dataset Mahasiswa Zaki setelah mengalami augmentasi	73
Gambar 46. Dataset Mahasiswa Addam Raihan setelah mengalami augmentasi .	74
Gambar 47. Dataset Mahasiswa Ahmad Riskon setelah mengalami augmentasi .	74
Gambar 48. Dataset Mahasiswa Ahsanul Khotam setelah mengalami augmentasi	74
Gambar 49. Dataset Mahasiswa Annisa Reswari setelah mengalami augmentasi	75
Gambar 50. Dataset Mahasiswa Arlin setelah mengalami augmentasi	75
Gambar 51. Dataset Mahasiswa Diah Riadi Putri setelah mengalami augmentasi	75
Gambar 52. Dataset Mahasiswa Euis Rohimattul Mutmainnah setelah mengalami augmentasi.....	76
Gambar 53. Dataset Mahasiswa Fathan Nur Sudiq setelah mengalami augmentasi	76

Gambar 54.. Dataset Mahasiswa Fauziah setelah mengalami augmentasi	76
Gambar 55. Dataset Mahasiswa Febri Yanti setelah mengalami augmentasi	77
Gambar 56.Dataset Mahasiswa Habibah setelah mengalami augmentasi	77
Gambar 57.Dataset Mahasiswa Hasan Hafidzul setelah mengalami augmentasi .	77
Gambar 58.Dataset Mahasiswa Irza Chairul setelah mengalami augmentasi.....	78
Gambar 59.Dataset Mahasiswa Kiki Juwita setelah mengalami augmentasi	78
Gambar 60. Dataset Mahasiswa Melza Hepyliana setelah mengalami augmentasi	78
Gambar 61. Dataset Mahasiswa Miftahul Arifin setelah mengalami augmentasi	79
Gambar 62. Dataset Mahasiswa Mohd. At Thariq Okadiksi setelah mengalami augmentasi.....	79
Gambar 63. Dataset Mahasiswa Muhammad Bachtiar setelah mengalami augmentasi.....	79
Gambar 64. Dataset Mahasiswa Muhammad Rifqi Majid setelah mengalami augmentasi.....	80
Gambar 65. Dataset Mahasiswa Munfiatun Nairoh setelah mengalami augmentasi	80
Gambar 66. Dataset Mahasiswa Paulus setelah mengalami augmentasi	80
Gambar 67.Dataset Mahasiswa Raffi Hs setelah mengalami augmentasi	81
Gambar 68. Dataset Mahasiswa Rega Saphira setelah mengalami augmentasi ...	81
Gambar 69. Dataset Mahasiswa Reza setelah mengalami augmentasi.....	81
Gambar 70. Dataset Mahasiswa Saepudin setelah mengalami augmentasi	82
Gambar 71.Dataset Mahasiswa Salsabila setelah mengalami augmentasi	82
Gambar 72. Dataset Mahasiswa Satria Berliano Manzi setelah mengalami augmentasi.....	82
Gambar 73. Dataset Mahasiswa Siska Septina setelah mengalami augmentasi ...	83
Gambar 74. Dataset Mahasiswa Wahyu Romadhon setelah mengalami augmentasi.....	83
Gambar 75. Dataset Mahasiswa Yudha Nugraha setelah mengalami augmentasi	83
Gambar 76. Dataset Mahasiswa Zaid Aiman setelah mengalami augmentasi.....	84
Gambar 77. Dataset Mahasiswa Zaki setelah mengalami augmentasi	84

Daftar Tabel

	Halaman
Tabel 1. Penelitian Terdahulu	17
Tabel 2. Timeline Penelitian	20
Tabel 3. Alat Penelitian.....	21
Tabel 4. Data Hasil Augmentasi	41
Tabel 5. Tabel hasil akurasi dan loss pada saat training MTCNN.....	50
Tabel 6. Hasil Evaluasi Matrik Sistem Pendeteksi Wajah menggunakan algoritma MTCNN	51
Tabel 7. Perbandingan Jarak Sistem	60

BAB I. PENDAHULUAN

1.1 Latar Belakang

Tingginya kebutuhan akan efisiensi dan akurasi dalam pengelolaan data mahasiswa telah mendorong berbagai perguruan tinggi untuk mengadopsi teknologi informasi sebagai tulang punggung manajemen akademik. Di universitas, penggunaan teknologi dalam manajemen data akademik telah menjadi kebutuhan yang mendesak. Pengelolaan data mahasiswa yang efisien dan akurat adalah aspek yang sangat penting dalam mendukung administrasi pendidikan, pelaporan akademik, dan pelayanan kepada mahasiswa. Penggunaan metode manual dalam pendataan mahasiswa, seperti pencatatan manual atau penggunaan kartu identitas, sering kali tidak efektif dan rentan terhadap berbagai kesalahan, seperti human error, kehilangan data, dan pemalsuan identitas. Oleh karena itu, penerapan teknologi yang lebih canggih dan otomatis dalam sistem pendataan mahasiswa menjadi sangat penting untuk meningkatkan efisiensi dan keamanan data.

Teknologi pengenalan wajah telah mengalami perkembangan signifikan dalam beberapa dekade terakhir dan telah diadopsi secara luas dalam berbagai aplikasi, mulai dari keamanan, pembayaran digital, hingga sistem kehadiran otomatis. Teknologi ini menawarkan cara yang lebih aman dan efisien dalam mengidentifikasi individu berdasarkan karakteristik wajah mereka. Algoritma pengenalan wajah yang canggih, seperti *Multi-task Cascaded Convolutional Networks (MTCNN)*, telah menunjukkan akurasi yang tinggi dalam mendeteksi dan mengenali wajah manusia. MTCNN, misalnya, menggabungkan beberapa tugas pendeteksian wajah dalam satu jaringan konvolusi, yang membuatnya lebih andal dalam menghadapi variasi pose, pencahayaan, dan ekspresi wajah.

Algoritma MTCNN telah terbukti dapat mendeteksi wajah dengan sangat akurat bahkan dalam berbagai kondisi, seperti pencahayaan yang berbeda atau pose wajah

yang tidak selalu frontal. Untuk proses pengenalan yang lebih lanjut, MTCNN tidak hanya mendeteksi keberadaan wajah tetapi juga memetakan mata, hidung, dan mulut. Namun, kelemahan MTCNN adalah waktu pemrosesan yang lebih lama ketika banyak wajah diproses secara bersamaan dalam satu frame.

Mengintegrasikan teknologi pengenalan wajah berbasis MTCNN ke dalam sistem pendataan mahasiswa di Universitas Lampung dapat menjadi solusi yang optimal. Teknologi ini memungkinkan identifikasi dan verifikasi identitas mahasiswa secara otomatis dan *real-time*, sehingga dapat mengurangi kesalahan manusia, meningkatkan akurasi data, dan mempercepat proses administrasi. Dengan menggunakan MTCNN, sistem dapat lebih adaptif terhadap berbagai kondisi lingkungan, seperti variasi pose dan pencahayaan, yang sering kali menjadi tantangan dalam pendeteksian wajah.

Oleh karena itu penelitian ini hadir untuk mengoptimalkan sistem pengolahan data mahasiswa di Universitas Lampung, Sistem ini dapat meningkatkan kualitas layanan administrasi akademik, meminimalkan risiko penipuan identitas, pendataan pada saat pemilihan raya mahasiswa, presensi mahasiswa pada saat perkuliahan, serta memberikan pengalaman yang lebih baik bagi mahasiswa. Lebih jauh lagi, Sistem ini dapat menjadi model bagi perguruan tinggi lain di Indonesia dalam menerapkan teknologi pengenalan wajah untuk meningkatkan efisiensi dan keamanan data akademik mereka.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, maka rumusan masalah dari penelitian ini ialah sebagai berikut:

1. Bagaimana mengidentifikasi wajah mahasiswa Universitas Lampung secara lebih akurat dan efisien menggunakan algoritma MTCNN?
2. Bagaimana menentukan performa algoritma MTCNN dalam mengklasifikasikan citra pendeteksi wajah mahasiswa, dengan menghitung presisi, sensitivitas, akurasi, F1 skor?

1.3 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah sebagai berikut:

1. Membuat rancang bangun sistem pengenalan wajah mahasiswa Universitas Lampung menggunakan algoritma *Multi-task Cascaded Convolutional Networks (MTCNN)*.
2. Evaluasi performa algoritma MTCNN dalam mengklasifikasikan citra pendeteksi wajah mahasiswa, dengan menghitung presisi, sensitivitas, akurasi, F1 skor.

1.4 Manfaat Penelitian

Adapun Manfaat dari penelitian ini adalah :

1. Memperdalam pengetahuan tentang penggunaan deep learning dengan menggunakan algoritma MTCNN dengan tujuan mengetahui tingkat keakuratan algoritma MTCNN dalam mengklasifikasikan citra wajah Mahasiswa sehingga dapat dijadikan sebagai informasi bagi penelitian selanjutnya.
2. Sebagai tahap awal dalam peningkatan kualitas layanan administrasi akademik, meminimalkan risiko penipuan identitas, pendataan pada saat pemilihan raya mahasiswa, presensi mahasiswa pada saat perkuliahan, serta memberikan pengalaman yang lebih baik bagi mahasiswa.

1.5 Batasan Masalah

Batasan masalah dari penelitian ini adalah :

1. Data yang digunakan pada penelitian ini merupakan data primer yang diperoleh dari sampling mahasiswa Universitas Lampung dari setiap fakultas.
2. Dataset yang digunakan merupakan kumpulan gambar dengan format warna RGB yang memiliki format ekstensi file berupa (.jpg dan .png) yang terdiri dari beberapa citra mahasiswa.
3. Sistem ini menggunakan algoritma MTCNN untuk mendeteksi dan mengidentifikasi wajah mahasiswa di Universitas Lampung. Dalam penelitian ini, algoritma atau teknologi pengenalan wajah lainnya tidak dibahas secara menyeluruh.
4. Pengujian sistem dilakukan dalam lingkungan tertentu, termasuk pencahayaan, pose wajah, dan perangkat keras yang digunakan. Kondisi ekstrim atau variasi lingkungan yang tidak umum tidak termasuk dalam ruang lingkup pengujian.

1.6 Sistematika Penulisan

Adapun sistematika penulisan laporan penelitian ini adalah sebagai berikut.

1. PENDAHULUAN

Penelitian ini menjelaskan mengenai optimalisasi sistem pendataan mahasiswa universitas lampung menggunakan teknologi pengenalan wajah dengan algoritma *Multi-Task Cascaded Convolutional Network* (MTCNN) untuk membuat sistem yang dapat mengidentifikasi wajah siswa secara otomatis dan real-time, meningkatkan efektifitas dan efisiensi pendataan mahasiswa.

2. TINJAUAN PUSTAKA DAN LANDASAN TEORI

Membahas tentang penelitian-penelitian terkait pada tinjauan pustaka dan dasar-dasar teori dari Kecerdasan Buatan, Pengenalan Wajah, *Python*, *Convolutional Neural Networks (CNN)*, *Multi-Task Cascaded Convolutional Network (MTCNN)*.

3. METODE PENELITIAN

Menjelaskan waktu, tempat, alat dan bahan, serta tahapan tentang Pengolahan data, Analisis Kasus Pendataan, Penggunaan *OpenCv* untuk mendeteksi wajah menggunakan metodologi yang memiliki enam tahapan, yaitu studi literatur, pemahaman data, *preprocessing* data, pemodelan *MTCNN*, evaluasi, dan deployment.

4. HASIL DAN PEMBAHASAN

Memaparkan hasil penelitian dan pembahasan dari tahapan penelitian pada hasil Analisis performa pendeteksi (presisi, sensitivitas, akurasi, F1 skor) berdasarkan eksperimen.

5. KESIMPULAN DAN SARAN

Berisi tentang kesimpulan dari hasil penelitian dan saran dari hasil penelitian untuk pengembangan penelitian selanjutnya.

BAB II. TINJAUAN PUSTAKA

2.1 *Artificial Intelligence*

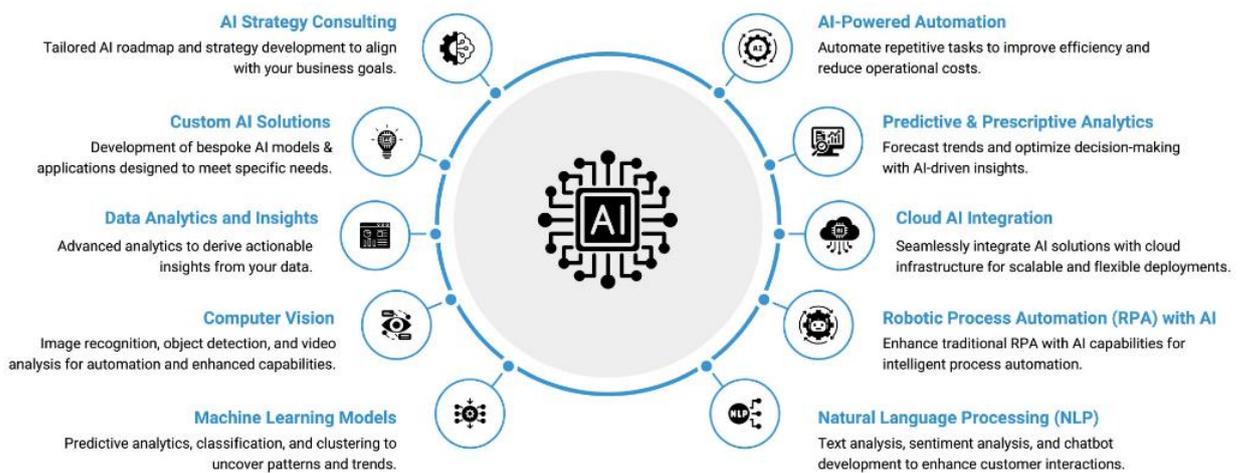
Kecerdasan Buatan (AI) atau *Artificial Intelligence* adalah bidang yang berfokus pada pengembangan teknologi untuk meniru kemampuan berpikir dan menyelesaikan masalah yang dimiliki oleh makhluk hidup maupun benda mati. Tujuan utama dari AI adalah untuk memberikan kemampuan pada komputer agar dapat berpikir dan membuat keputusan dengan cara yang mirip dengan manusia, sehingga dapat beroperasi secara lebih cerdas dan efektif. Berbagai pendekatan AI telah dikembangkan untuk memungkinkan komputer belajar, berpikir, dan mengambil keputusan secara independen [1].

Dalam dunia administrasi publik, AI memiliki beragam aplikasi yang bermanfaat, seperti untuk meningkatkan efisiensi operasional, menyajikan pengalaman yang lebih personal bagi penggunanya, dan mengotomatisasi pencarian informasi. Selain itu, AI juga dapat digunakan untuk menganalisis data pengguna dan mengintegrasikan sistem dengan cara yang lebih canggih, guna menghasilkan keputusan yang lebih akurat dan cepat.

Penerapan kecerdasan buatan di lingkup administrasi publik membantu pemerintah mengelola kebutuhan masyarakat yang berubah akibat penetrasi teknologi, tetapi belum merata di Indonesia karena keterbatasan anggaran untuk infrastruktur teknologi dan kurangnya kesiapan sumber daya manusia di bidang pemerintahan.

Machine Learning (ML) adalah subset dari AI yang mengandalkan data untuk "mengajarkan" komputer cara melakukan tugas tanpa diprogram secara eksplisit. Machine Learning memungkinkan komputer untuk belajar dari data, mendeteksi pola, dan membuat prediksi atau keputusan berdasarkan pengalaman yang diperoleh. Dalam praktiknya, Machine Learning juga digunakan untuk berbagai aplikasi seperti pengenalan gambar, deteksi anomali, dan prediksi tren pasar [2].

Sebagai bagian dari *Machine Learning*, *Computer Vision* merupakan bidang yang memungkinkan komputer untuk "melihat" dan memahami dunia visual, termasuk gambar dan video. Dengan menggunakan model AI, terutama deep learning, komputer dapat menganalisis dan menginterpretasi objek dalam gambar atau video dengan tingkat akurasi yang semakin tinggi. *Computer Vision* digunakan dalam berbagai aplikasi seperti pengenalan wajah, pemantauan lalu lintas, dan deteksi objek dalam citra medis.



Gambar 1. Penggunaan kecerdasan buatan

2.2 Jaringan Syaraf Tiruan

Jaringan saraf tiruan adalah sistem pemrosesan informasi yang dirancang untuk meniru cara otak manusia untuk memecahkan masalah dengan melakukan proses pembelajaran dengan mengubah bobot sinaptik. Jaringan saraf tiruan dapat mengenali tindakan berdasarkan data historis. Data historis dipelajari menggunakan jaringan syaraf tiruan, memberikan kemampuan untuk membuat keputusan berdasarkan data yang belum pernah dipelajari sebelumnya.

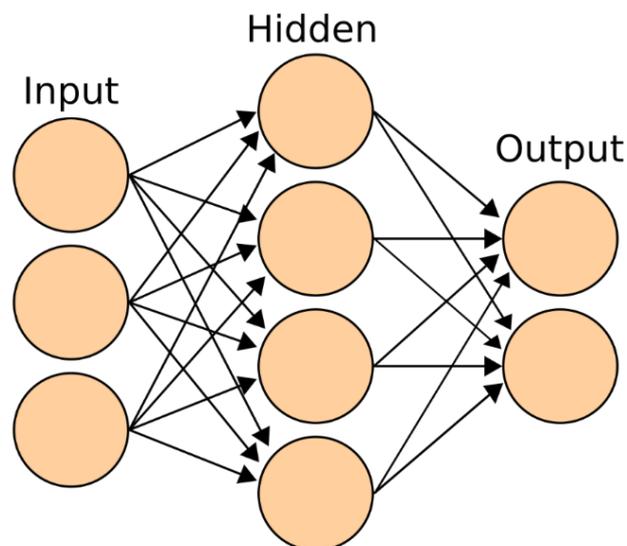
Ada banyak arsitektur jaringan yang digunakan dalam jaringan syaraf tiruan antara lain:

1. Jaringan lapisan tunggal (*single-layer network*) Pada jaringan ini, sekumpulan neuron input dihubungkan langsung ke sekumpulan output. Beberapa model (misalnya *perceptron*) hanya memiliki satu unit neuron keluaran;

2. Jaringan Multilayer (*multi layer network*) merupakan perpanjangan dari satu lapisan. Selain perangkat input dan output, jaringan ini memiliki perangkat lain (disebut layar tersembunyi). Seperti halnya perangkat input dan output, perangkat pada layar yang sama tidak terhubung satu sama lain;

3. Jaringan Berulang Model jaringan berulang mirip dengan jaringan permukaan tunggal atau ganda. Neuron keluaran umum (disebut loop umpan balik) mengirimkan sinyal ke perangkat masukan.

Jaringan saraf tiruan (JST) merupakan suatu model dari sistem syaraf biologis yang disederhanakan sebagai suatu alternatif sistem komputasi. Untuk menggunakan sistem pelatihan jaringan saraf Kohonen untuk pengenalan wajah, diperlukan proses modifikasi yang tepat. Penggunaan piksel langsung dari gambar wajah membuat proses pelatihan menjadi lebih lambat. Jaringan saraf tiruan model pengorganisasian mandiri (SOM), juga dikenal sebagai jaringan Kohonen, telah banyak digunakan dalam pengenalan pola dalam bentuk, suara, penambangan data, deteksi virus komputer, identifikasi objek, sintesis teks, dan lainnya[3].



Gambar 2. Struktur Jaringan Syaraf Tiruan

Sistem jaringan saraf tiruan terdiri dari beberapa unit pemrosesan yang mengumpulkan (menambah) bobot masukan dan menghasilkan keluaran dengan

karakteristik kinerja tertentu. Sifat jaringan ditentukan oleh topologi jaringan, bobot interkoneksi dan fungsi aktivitas.

Fungsi aktivasi merupakan fungsi yang digunakan pada jaringan syaraf untuk mengaktifkan atau tidak mengaktifkan neuron. Sebuah neuron akan mengolah N input (x_1, x_2, \dots, x_N) yang masing-masing memiliki bobot $(w_1, w_2, w_3, \dots, w_N)$ dan bobot bias b , sehingga kalkulasi kombinasi linear antara input dengan bobot dijumlahkan dengan bias dirumuskan dengan persamaan:

$$y_i = \sum_{i=1}^N x_i W_i \tag{1}$$

Keterangan:

- y_i adalah hasil dari penjumlahan berbobot (weighted sum) yang dihitung untuk setiap indeks i
- $\sum_{i=1}^N$ Simbol sigma (Σ) menunjukkan operasi penjumlahan. Penjumlahan ini dilakukan dari indeks i yang dimulai dari 1 hingga N
- x_i adalah nilai data pada indeks i . Ini bisa merujuk pada elemen dari sebuah vektor atau deret data yang diberikan.
- W_i adalah bobot yang diberikan pada x_i Ini bisa merujuk pada elemen dari sebuah vektor bobot yang berkorespondensi dengan data x_i

Fungsi aktivasi memainkan peran yang sangat penting dalam mempelajari model jaringan saraf dan menafsirkan fungsi nonlinier yang kompleks. Fungsi aktivasi menambahkan karakteristik nonlinier ke jaringan saraf. Tanpa fungsi aktivasi, jaringan saraf hanya dapat mewakili satu fungsi linier, tidak peduli berapa banyak lapisan yang dimilikinya.

Fungsi sigmoid adalah fungsi aktivasi yang paling umum digunakan dalam penelitian jaringan saraf *feedforward* awal. Mirip dengan model regresi logistik, fungsi sigmoid dapat digunakan pada lapisan keluaran untuk klasifikasi biner, yang

mudah dihitung dan menghasilkan fungsi monotonik dan kontinu dengan hasil yang kecil. Fitur-fitur ini mendorong integrasi jaringan.

Fungsi Softmax adalah perpanjangan dari fungsi sigmoid dalam kasus multi-dimensi. Ekspresi fungsinya adalah sebagai berikut:

$$\sigma(z)_j = \frac{e^z_j}{\sum_k e^z_k} \quad (2)$$

Keterangan:

- $\sigma(z)_j$ adalah hasil softmax untuk elemen ke-j dari vektor input z
- e adalah bilangan Euler (sekitar 2.718)
- z adalah nilai input ke-j
- $\sum_k e^z_k$ adalah jumlah dari semua eksponensial nilai input dalam vektor z
- K adalah jumlah total kelas

Fungsi softmax dirancang untuk memetakan vektor arbitrer bilangan real dari satu dimensi K ke distribusi probabilitas dimensi K lainnya. Oleh karena itu, fungsi softmax sering digunakan sebagai lapisan keluaran untuk multi-klasifikasi.

2.3 Python

Python merupakan bahasa pemrograman yang dinamis dan tingkat tinggi, Python sendiri merupakan bahasa pemrograman interpreter yakni dapat mengkonversi *source code* menjadi *machine code* secara langsung ketika program di jalankan, Python juga dapat mendukung pendekatan Pemrograman Berorientasi Objek yang membuah mudahnya dalam mengembangkan aplikasi dan mudah dipelajari serta menyediakan banyak struktur data tingkat tinggi[4].

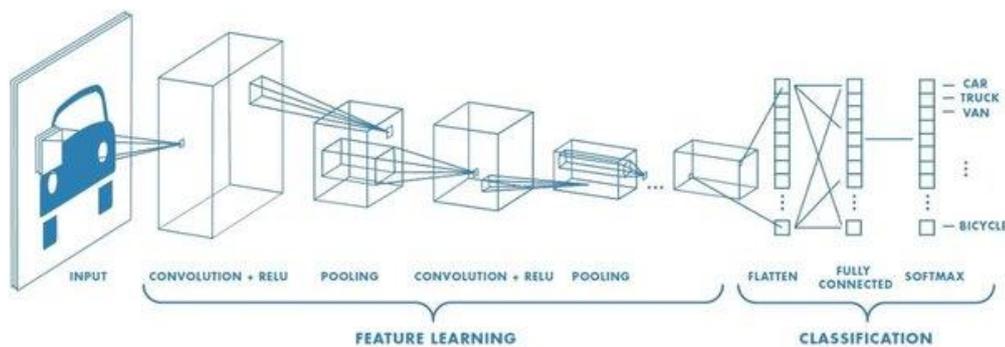
Python banyak digunakan dalam aplikasi web, pengembangan perangkat lunak, ilmu data, dan pembelajaran mesin (ML). Pengembang menggunakan python karena efisien, mudah dipelajari dan berjalan di berbagai platform. Perangkat lunak Python

dapat diunduh secara gratis dan terintegrasi dengan baik dengan berbagai program untuk meningkatkan kecepatan pengembangan..

2.4 Convolutional Neural Networks (CNN)

Convolutional Neural Networks (CNN) adalah dua buah dimensi dari hasil transmisi dari jaringan. Menyebabkan parameter CNN dan oprasi linear dapat menghasilkan hasil yang bebeda[5].

Convolutional Neural Networks (CNN) mirip dengan jaringan Neural pada umumnya, memiliki neuron dengan bobot (weight) dan bias yang dapat dipelajari dan setiap neuronnya menerima beberapa inputam, melakukan proses *do product* dan secara opsional mengikutinya dengan non-lineritras,Dalam arsitektur jaringan saraf *Deep Convolutional*, seluruh jaringan diekspresikan dari piksel gambar mentah (raw image) di satu ujung ke skor kelas (class) di ujung lainnya. Pada lapisan terakhir, mereka memiliki fungsi loss (mis. Softmax) yang terhubung sepenuhnya (fully connected)[6].



Gambar 3. Arsitektur CNN [7]

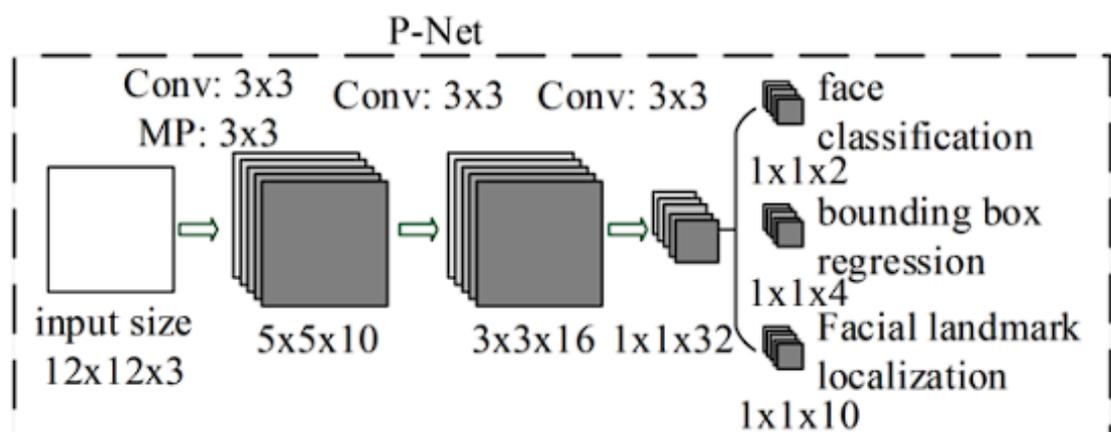
Gambar adalah vektor berdimensi tinggi. Untuk mendefinisikan jaringan saraf tiruan, beberapa variabel harus diperhitungkan. Untuk mengatasi masalah tersebut, diusulkan di CNN untuk mengurangi jumlah variabel input dan mengembangkan arsitektur jaringan saraf. CNN adalah sekumpulan lapisan yang setiap lapisannya menjalankan fungsi berbeda. Dalam CNN, Operasi preprocessing, konvolusi,

pooling, dan klasifikasi akhir dilakukan secara berurutan, seperti yang ditunjukkan pada Gambar 3. Proses forward merupakan proses yang mengaktifkan input. Koefisien antara bobot dan masukan kemudian ditambahkan antar lapisan. Filter memiliki jumlah lapisan yang sama dengan saluran volume masukan, dan volume keluaran memiliki kedalaman yang sama dengan jumlah filter.

2.5 MTCNN (Multi-Task Cascaded Convolutional Network)

MTCNN atau *Multi-Task Cascaded Convolutional Network*, adalah model CNN dengan tiga lapisan (P-Net, R-Net, O-Net) yang menggunakan klasifikasi untuk menyediakan decoding bobot yang efisien dan cepat. Berdasarkan penelitian keunggulan dari MTCNN adalah akurasi dan presisi yang lebih tinggi dibandingkan algoritma Haar-Cascade[8].

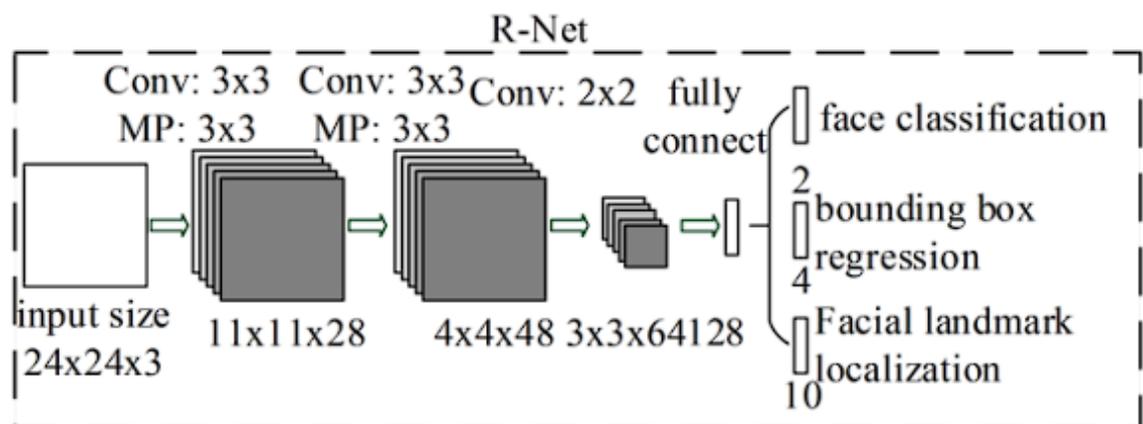
MTCNN adalah alat yang mengintegrasikan data dari berbagai sumber dan data dari CNN menggunakan *multi-task learning*. Ini terdiri dari tiga lapisan: Proposal Network (P-Net), Refine Network (R-Net), dan Output Network (O-Net). P-Net menggunakan kandidat dan koefisien regresinya untuk memprediksi kinerjanya, sementara R-Net memilih mayoritas kandidat dari P-Net dan mengkalibrasi koefisien regresi. O-Net, sebaliknya, mengurutkan kandidat dalam urutan terbalik dan memberi peringkat pada jaringan keluaran[9].



Gambar 4. Arsitektur P-Net

Proposal Network (P-Net) merupakan salah satu jaringan dalam arsitektur *Multi-task Cascaded Convolutional Networks (MTCNN)* yang berfungsi sebagai tahap awal untuk mendeteksi wajah pada citra berukuran kecil. P-Net menerima input berupa citra dengan dimensi $12 \times 12 \times 3$, di mana angka 3 mewakili saluran warna (red, green, blue). Jaringan ini terdiri atas beberapa lapisan konvolusi yang dirancang untuk mengekstraksi fitur penting dari citra masukan.

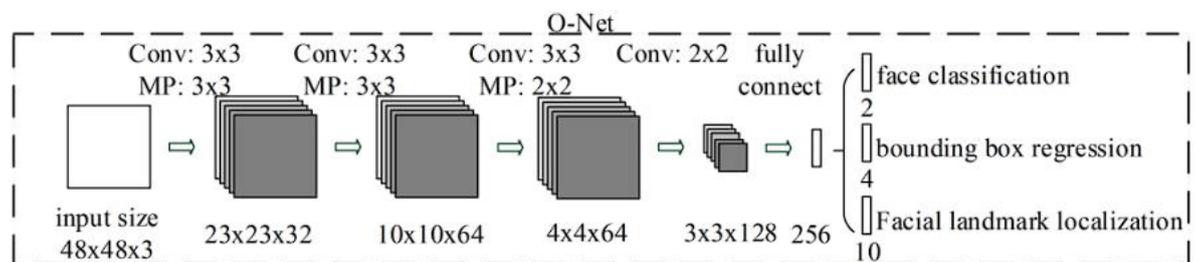
Proses pertama dimulai dengan lapisan konvolusi menggunakan kernel berukuran 3×3 , yang menghasilkan keluaran berupa fitur dengan dimensi $5 \times 5 \times 10$. Keluaran ini kemudian diproses melalui Max Pooling (MP) menggunakan kernel berukuran 3×3 , yang bertujuan untuk mengurangi dimensi data tanpa kehilangan informasi penting. Selanjutnya, lapisan konvolusi kedua, juga menggunakan kernel 3×3 , menghasilkan keluaran berupa fitur dengan dimensi $3 \times 3 \times 16$. Terakhir, lapisan konvolusi ketiga menghasilkan keluaran dengan dimensi $1 \times 1 \times 32$, menghasilkan tiga output yakni Face Classification dengan dimensi $1 \times 1 \times 2$, Bounding Box Regression dengan dimensi $1 \times 1 \times 4$, dan Facial Landmark Localization dengan dimensi $1 \times 1 \times 10$.



Gambar 5. Arsitektur R-Net

Refinement Network (R-Net) memiliki fungsi utama untuk memperbaiki dan menyaring hasil deteksi wajah yang diusulkan oleh P-Net. Proses pada R-Net diawali dengan input berukuran $24 \times 24 \times 3$ dengan lapisan konvolusi pertama yang

menggunakan kernel berukuran 3×3 . Lapisan ini menghasilkan fitur berukuran $11 \times 11 \times 28$. Setelah itu, fitur tersebut diproses lebih lanjut dengan Max Pooling (MP) berukuran 3×3 , yang bertujuan untuk mengurangi dimensi data tanpa kehilangan informasi penting. Proses ini dilanjutkan oleh lapisan konvolusi kedua yang juga menggunakan kernel berukuran 3×3 untuk menghasilkan fitur berukuran $4 \times 4 \times 48$, yang kemudian kembali melewati Max Pooling untuk mengecilkan ukurannya menghasilkan ukuran $3 \times 3 \times 64$. Hasil keluaran ini kemudian diratakan melalui proses flattening dan diteruskan ke lapisan fully connected, menghasilkan tiga output yakni Face Classification dengan keluaran berupa tensor dengan ukuran 2, Bounding Box Regression dengan keluaran berupa tensor dengan ukuran 4, dan Facial Landmark Localization keluaran berupa tensor dengan ukuran 10.



Gambar 6. Arsitektur O-Net

Output Network (O-Net) adalah jaringan neural konvolusional yang digunakan dalam tahap akhir proses deteksi wajah oleh MTCNN. Jaringan ini bertugas untuk secara presisi mengklasifikasikan wajah, memperbaiki posisi kotak pembatas (bounding box), dan menentukan posisi landmark pada wajah.

O-Net menerima input berupa gambar berukuran 48×48 piksel dengan 3 saluran warna (RGB). Input ini adalah hasil dari tahap sebelumnya (R-Net) pada MTCNN. Kemudian, hasilnya diperkecil melalui lapisan max-pooling berukuran 3×3 untuk mengurangi dimensi fitur. Proses ini diulang dengan filter konvolusi kedua berukuran 3×3 untuk menghasilkan 64 fitur (dengan dimensi $10 \times 10 \times 64$), diikuti oleh max-pooling. Lapisan konvolusi terakhir menggunakan filter 2×2 untuk menghasilkan 128 fitur dengan dimensi $3 \times 3 \times 128$. Setelah melewati lapisan konvolusi, fitur yang dihasilkan diubah menjadi vektor berdimensi 256 melalui

lapisan fully connected, menghasilkan tiga output yakni Face Classification dengan keluaran berupa tensor dengan ukuran 2, Bounding Box Regression dengan keluaran berupa tensor dengan ukuran 4, dan Facial Landmark Localization keluaran berupa tensor dengan ukuran 10.

2.6 Penelitian Terdahulu

Untuk memperkuat landasan penelitian ini menggunakan artikel ilmiah dan jurnal yang relevan sebagai sumber referensi. Pemilihan referensi didasarkan pada kesamaan studi kasus dan metode pengembangan sistem. Berikut beberapa artikel dan jurnal ilmiah yang dirujuk dalam penelitian ini:

Penelitian menggunakan metode pengenalan wajah untuk mengembangkan sistem presensi pegawai terkait [10]. Algoritma Facenet dan Openface dipilih dan diimplementasikan untuk menguji performa pengenalan wajah. Validasi model dilakukan menggunakan metode cross validation 5-fold dan 10-fold. Sistem presensi kemudian diuji dengan model yang memiliki akurasi tertinggi untuk mengevaluasi performanya dalam kondisi nyata.. Pengujian sistem presensi Facenet menunjukkan akurasi 100% dengan menggunakan ambang batas probabilitas pengenalan 0,25. Penelitian dari Miftakhurrokhmat yang berjudul “Presensi Kelas Berbasis Pola Wajah dan Tersenyum Menggunakan Deep Learning”[6], menerangkan mengenai rancang bangun sistem presensi kelas berbasis pengenalan pola wajah dan tersenyum. Pengenalan wajah (face recognition) ini diimplementasikan menjadi suatu service IOT, menggunakan metode FaceNet sebagai feature extractor dikombinasikan dengan SVM dan memiliki hasil akurasi yang didapat dari testing model sebesar 92,9%, dan akurasi hasil testing live sebesar 66,7%.

Penelitian lainnya menggunakan algoritma MTCNN, facenet, SVM, sistem pengenalan wajah (face recognition) [6], pada penelitian tersebut diimplementasikan menjadi service yang dipasang pada mini computer atau IoT di tiap kelas, dan terhubung dengan IP CCTV dan jaringan kampus. Hasil akurasi yang didapat dari testing model sebesar 92,9%, dan akurasi hasil testing live sebesar 66,7%.

Penelitian lainnya bertujuan pada pengenalan separuh bagian atas wajah, yang meliputi mata, alis, dan sebagian kecil hidung [11], Penelitian Metode ini diusulkan sebagai alternatif terhadap pengenalan seluruh wajah, dengan tujuan meningkatkan akurasi dan efisiensi. penelitian ini menggunakan menggunakan dua algoritma utama: MTCNN untuk deteksi wajah dan VGGFace untuk ekstraksi landmark wajah. MTCNN bertanggung jawab untuk mendeteksi dan meluruskan wajah dalam gambar, sedangkan VGGFace digunakan untuk mengidentifikasi dan memetakan landmark wajah yang relevan, seperti sudut mata, alis, dan ujung hidung. dari penelitian yang dilakukan didapatkan bahwa metode ini memiliki tingkat akurasi sebesar 95,6%. hasil ini meningkat sekitar 2,3% dibanding menggunakan seluruh wajah.

Penelitian lainnya membahas tentang evaluasi akurasi model Convolutional Neural Network (CNN) dengan arsitektur ResNet50 dan ResNet101 dalam aplikasi pengenalan wajah. Dua model CNN, ResNet50 dan ResNet101 [12], , dilatih menggunakan dataset gambar wajah untuk mempelajari fitur-fitur yang membedakan individu. Akurasi model diukur pada dua tahap: pelatihan dan pengujian. Pada tahap pelatihan, ResNet50 mencapai akurasi tertinggi dengan nilai 96%, menunjukkan kemampuannya dalam mempelajari fitur wajah dengan baik. Di sisi lain, ResNet101 mencapai akurasi terbaik sebesar 85%. Namun, hasil pengujian menunjukkan penurunan performa yang signifikan pada kedua model. Baik ResNet50 maupun ResNet101 hanya memperoleh akurasi sebesar 60% saat diuji pada dataset yang berbeda.

Penelitian lainnya membahas tentang algoritma haar cascade yang dapat melatih suatu sistem komputer agar dapat mendeteksi citra wajah [13], dihasilkan suatu sistem yang dapat mendeteksi wajah menggunakan webcam laptop sebagai sistem pendeteksi, Wajah yang terdeteksi tidak hanya wajah yang menghadap kedepan kamera saja akan tetapi wajah yang menghadap kesamping kanan, kiri, atas dan bawah juga dapat terdeteksi dengan baik dengan hasil pelatihan model menggunakan 20 iterasi dan dengan total data train sebanyak 200 citra menghasilkan hasil train dengan tingkat akurasi sebesar 100%. Setelah itu dengan data test sebanyak 114 dapat menghasilkan akurasi sebesar 95,6% .

Penelitian lainnya membahas tentang pengenalan gestur tangan American Sign Language Alphabet (ASL) [14], menggunakan 3000 gambar, masing-masing berukuran 200×200 piksel, 7000 gambar berukuran 400×400 piksel, dengan menggunakan teknik ensemble menggunakan beberapa CNN dalam yang mendalam berdasarkan LeNet, AlexNet, VGGNet, GoogleNet, dan ResNet memperoleh hasil akurasi sebesar 98,83%.

Penelitian lainnya membahas mengenai penggunaan Discrete Cosine Transform (DCT) sebagai pemrosesan awal dan Penggunaan Jaringan Syaraf Tiruan Self Organizing Map (SOM)/Kohonen dalam proses pelatihannya digunakan sebanyak 10 citra wajah tiap identitas dan menghasilkan dihasilkan Recognition Rate sebesar 80% untuk kemungkinan terbaik, dan 35% untuk kemungkinan teburuk.

Penelitian lainnya membahas mengenai prediksi prestasi mahasiswa [15], menggunakan Tiga metode yaitu regresi logistik (LR), pohon keputusan (DT), dan mesin vektor dukungan (SVM), dengan dataset dari mahasiswa semester 3 Jurusan Pendidikan Sejarah dengan total 106 mahasiswa didapati hasil akurasi 0,96. Skor ini adalah yang tertinggi dibandingkan dengan nilai-nilai lain yang diperoleh oleh LR (0,84) dan SVM (0,62).

Penelitian lainnya membahas mengenai pengenalan wajah dengan model CNN [16], didasarkan pada rata-rata akurasi presisi keseluruhan (mAP) tetapi juga AP sesuai dengan kelas dan ukuran objek, sehingga kekuatan komplementer antara setiap model dapat dimanfaatkan, menggunakan 50 gambar dengan hasil 62% individu diidentifikasi dengan benar.

Tabel 1. Penelitian Terdahulu

No.	Nama Peneliti	Objek	Dataset	Metode	Hasil
1.	Ferry Cahyono (2020)[10]	Wajah	150 gambar dari 15 identitas pegawai	MTCNN, facenet,SVM (Support Vector Machine)	Akurasi 100%
2.	Miftakhurrokhmat (2023)[6]	Pola wajah dan senyuman	700 gambar dari 7 mahasiswa	MTCNN, facenet,SVM	Akurasi 92,9%, akurasi

					<i>live test</i> 66,7%
3.	Hanif Naufal Arif S(2023)[11]	Separuh wajah bagian atas wajah yaitu mata, alis, dan sebagian kecil hidung.	390 gambar dari 15 orang.	MTCNN, VGGFace	Akurasi 95,6%, sensitifitas 96%, Presisi 94%
4.	Ervan Chodry (2024)[12]	Wajah	400 gambar wajah dari 20 mahasiswa	ResNet50, ResNet101	Akurasi 60%
5.	Nugroho F (2023)[13]	Seluruh Wajah	200 citra wajah	Haar Cascade Clasifier	Akurasi test 95,6%
6.	Ma Y (2022)[14]	Gestur tangan	10000 citra gesture tangan	Ensamble Learning	Akurasi 98,83%
7.	Moonlight L (2019) [3]	Wajah	10 citra wajah	Discrete Cosine Transform (DCT) dan Self Organizing Map (SOM)	Akurasi 80%
8.	Nadjamuddin (2024)[15]	Prestasi Mahasiswa	106 mahasiswa	Logistic Regression (LR), Decision Tree (DT), And Support Vector Machine (SVM)	Akurasi 96%
9.	Mulyana D (2023) [17]	Wajah	55 wajah	Haar Cascade	Akurasi 80%-89%
10.	V.K.N Kamlesh Pai (2018)	Wajah	50 wajah	Convolutional Neural Networks	Akurasi 62%

Pada penelitian ini menggabungkan dua algoritma HaarCascade dan MTCNN, dimana dalam algoritma HaarCascade memiliki keunggulan dalam hal kecepatan membaca objek atau model dan memiliki kelemahan dalam akurasi dan presisi model yang belum tinggi, sedangkan untuk algoritma MTCNN memiliki keunggulan berupa tingkat akurasi presisi dari pembacaan modelnya sangat akurat tetapi memiliki kelemahan dibagian kecepatan pembacaan data.

BAB III. METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan pada Juli sampai dengan Desember 2024 yang bertempat di Laboratorium Teknik Digital, Fakultas Teknik, Universitas Lampung. Berikut ialah tabel. 2 yang menunjukkan jadwal kegiatan penelitian yang dilakukan.

Tabel 2. Timeline Penelitian

No.	Aktivitas	Juli 2024		Agustus 2024				September 2024				Oktober 2024				November 2024				Desember 2024			
		Minggu ke -																					
		3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
1	Studi Literatur	■	■	■																			
2	Pengambilan Data				■	■																	
3	Pemahaman Data						■	■	■														
4	Preprocessing Data						■	■	■	■	■												
5	Pemodelan											■	■	■	■								
6	Evaluasi															■	■	■	■				
7	Implementasi																	■	■	■	■		
8	Analisis dan Pembahasan																				■	■	■

3.2 Alat Penelitian

Alat yang digunakan dalam penelitian ini ialah sebagai berikut:

Tabel 3. Alat Penelitian

No.	Nama Alat	Spesifikasi	Deskripsi
1.	Laptop	Processor : AMD Ryzen 7 5700U (8C / 16T, 1.8 / 4.3GHz, 4MB L2 / 8MB L3) Graphics : Integrated AMD Radeon Graphics Chipset : AMD SoC Platform Memory : 4GB Soldered DDR4-3200 + 4GB SO-DIMM DDR4-3200 Storage : 512GB SSD M.2 2280 PCIe 3.0x4 NVMe	Perangkat keras yang digunakan dalam proses pembuatan
3.	PyCharm	Version: 241.18034.82	Perangkat lunak yang digunakan dalam pemrosesan kode
2.	Anaconda 3	Version: 2021.05	Perangkat lunak yang digunakan untuk pengembangan dan pengelolaan ilmu kecerdasan buatan
4.	Python	Version: Python 3.8.8	Bahasa Pemrograman
6.	Webcam	720 Pixel	Kamera

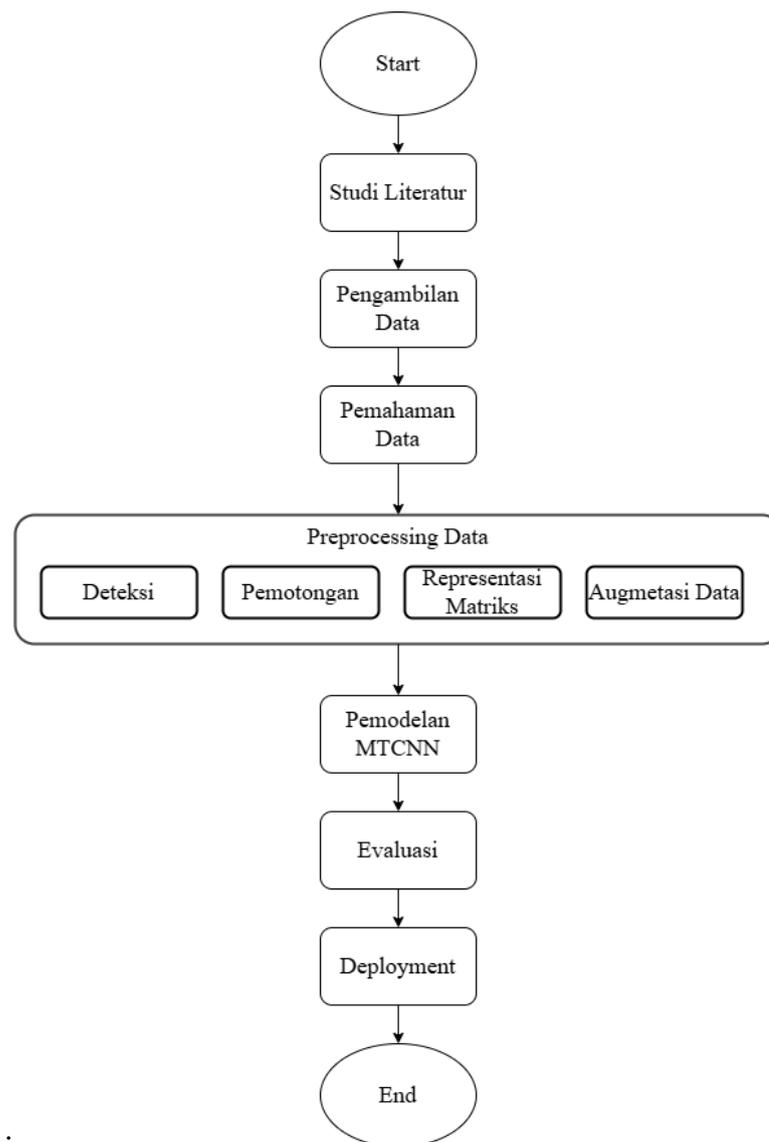
3.3 Dataset

Dataset yang digunakan dalam penelitian ini berupa kumpulan citra wajah mahasiswa Universitas Lampung. Data citra mahasiswa akan dipisahkan menjadi data latih, data validasi, dan data pengujian. Data ini dikumpulkan dari gform dan juga kamera. Dataset terdiri dari 32 wajah mahasiswa yang memiliki total 194 citra

wajah. Dataset digunakan untuk melatih, memvalidasi, dan menguji sistem pengenalan wajah, sehingga dapat mengevaluasi kemampuan sistem dalam mengenali wajah mahasiswa yang sudah terdaftar.

3.4 Tahapan Penelitian

Penelitian ini memiliki enam tahapan, yaitu studi literatur, pemahaman data, *preprocessing* data, pemodelan MTCNN, *evaluasi*, dan *deployment*. Tahapan penelitian disajikan dalam gambar berikut:



Gambar 7. Tahapan Penelitian

3.4.1 Studi Literatur

Pada tahapan ini berfokus pada analisis dan pencarian sumber referensi yang berkaitan dengan *face recognition*, mempelajari tentang Neural Network dan pengimplementasiannya pada *face recognition*. Tahap ini penting untuk menentukan arah dan tujuan analisis data, sehingga model yang dikembangkan relevan dan berfokus pada pemecahan masalah yang tepat.

3.4.2 Pengambilan Data

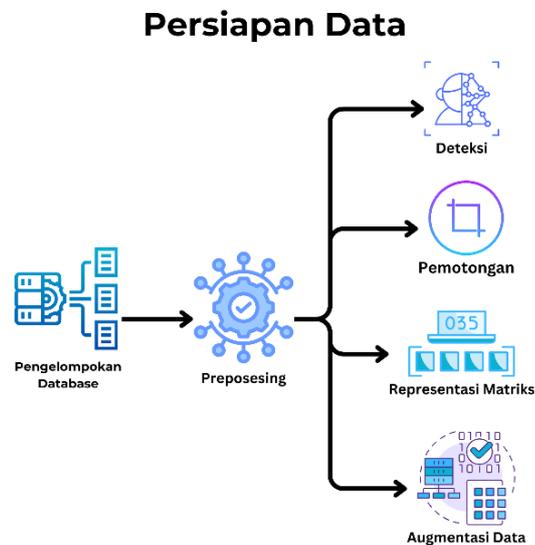
Pada langkah ini, data dikumpulkan melalui berbagai metode untuk memastikan keragaman dan relevansi dataset. Proses pengumpulan data dilakukan dengan memanfaatkan Google Forms sebagai alat pengumpulan data dari responden secara daring, serta menggunakan kamera digital untuk pengambilan gambar secara langsung. Metode ini bertujuan untuk mendapatkan dataset berkualitas tinggi yang mencakup berbagai kondisi pencahayaan, sudut pandang, dan ekspresi wajah, sehingga mendukung keakuratan dan keberagaman analisis pada tahap selanjutnya.

3.4.3 Pemahaman Data

Pada tahapan ini dilakukan pengecekan dan verifikasi data untuk memastikan kualitas dan kelayakannya. Setelah data dikumpulkan, proses ini memberikan pemahaman tentang struktur dan karakteristik data, yang sangat penting untuk menentukan teknik pemrosesan yang sesuai. Dataset terdiri dari 32 wajah mahasiswa yang melihat ke depan. Untuk setiap orang, dengan kriteria tersenyum, miring kanan, miring kiri, serta citra khusus apabila menggunakan kacamata, data yang digunakan meliputi database yang berisi citra dan label mahasiswa yang dikumpulkan melalui Google Form dari 8 mahasiswa dan dari kamera langsung untuk 24 mahasiswa lainnya. Data yang terkumpul ini akan menjadi fondasi dalam membangun model pengenalan.

3.4.4 Preprocessing Data

Pada langkah ini meliputi pengelompokan data berdasarkan label dan preprocessing. Digunakan algoritma seperti MTCNN untuk deteksi wajah, yang merupakan bagian penting dalam pengenalan pola fitur wajah.



Gambar 8. Tahapan Persiapan Data

Data yang dipersiapkan ini kemudian siap digunakan dalam proses pembelajaran dan pemodelan. Dilakukan pengelompokan berdasarkan label dan *pre-processing*, yang melibatkan augmentasi data dengan data dari *Google Form* dan kamera. Pre-processing bertujuan untuk memastikan bahwa data dalam kondisi optimal untuk proses pemodelan, termasuk augmentasi yang bertujuan untuk meningkatkan keragaman data sehingga model dapat lebih robust terhadap variasi.

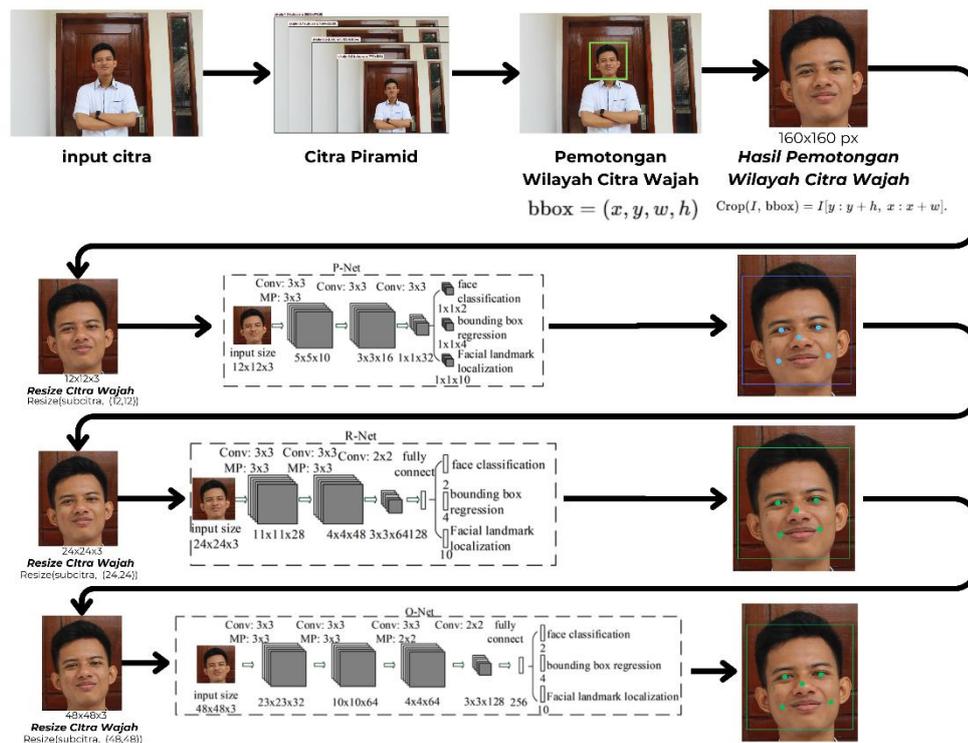
3.4.5 Pemodelan MTCNN

Pada tahapan ini menentukan atribut terbaik dan melanjutkan pengembangan model terkait atribut target dengan memanfaatkan beberapa teknik yang bertujuan untuk menentukan karakteristik yang paling masuk akal bagi model, menggunakan rekayasa fitur.

Pada tahapan ini proses pembuatan dan mempelajari model dilakukan. Program ini menggunakan framework komputasi Machine Learning yaitu, tensorflow.

Tensorflow merupakan sebuah framework Machine Learning milik Google yang memiliki tools dan model untuk membantu proses jaringan saraf tiruan atau *Convolutional Neural Network* (CNN), MTCNN, digunakan untuk membangun model. Algoritma ini berfungsi untuk menghasilkan embedding atau representasi numerik dari fitur wajah, yang kemudian digunakan untuk klasifikasi atau pengenalan identitas.

Algoritma MTCNN melakukan pemotongan gambar, penyesuaian koordinat, dan menyimpan hasil ke folder yang sesuai berdasarkan label, dengan menggunakan arsitektur jaringan P-Net, R-Net, dan O-Net untuk deteksi wajah yang lebih akurat.



Gambar 9. Arsitektur lengkap MTCNN

Gambar 9 menunjukkan arsitektur proses deteksi citra menggunakan MTCNN yang dimulai dari sistem membaca citra input yang menampilkan objek citra mahasiswa, Selanjutnya citra tersebut dibuatkan citra piramid (image pyramid) dengan tujuan sistem mampu mendeteksi wajah dengan berbagai ukuran. Citra tersebut diperkecil ke beberapa resolusi berbeda sehingga MTCNN dapat menangkap wajah besar maupun kecil. Setelah dilakukan citra paramid selanjutnya dilakukan proses pendeteksian bounding box dan pemotongan wilayah citra wajah dengan rumus:

Pendeteksian bounding box:

$$bbox = (x, y, w, h) \quad (3)$$

Keterangan:

- bbox (bounding box) adalah koordinat yang menunjukkan letak wajah di dalam citra tersebut.
- x, y : posisi kiri-atas (*top – left corner*)
- w, h : posisi kiri-atas (*top-left corner*)

Pemotongan wilayah citra wajah:

$$Crop(I, bbox) = I[y: y + h, x: x + w] \quad (4)$$

Keterangan:

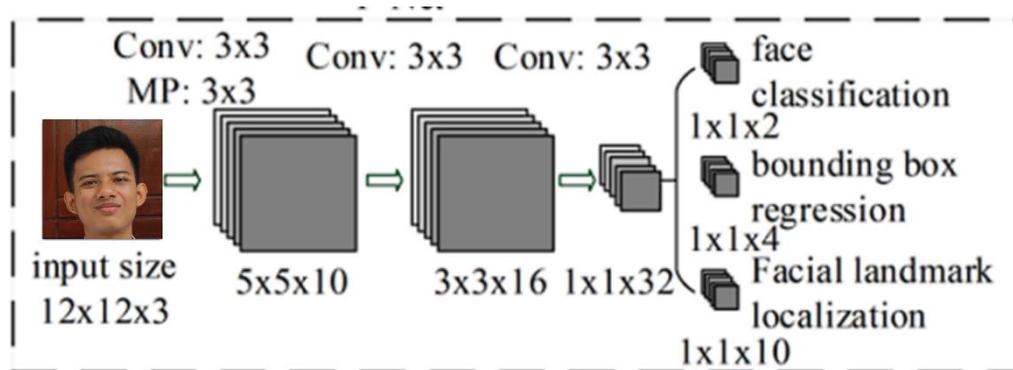
- $0 \leq x < 160$
- $0 \leq y < 160$

Proses selanjutnya ialah melakukan *Resize* citra agar sesuai dengan kebutuhan proses MTCNN dengan rumus sebagai berikut:

$$Resize(subcitra, (12,12)) \quad (5)$$

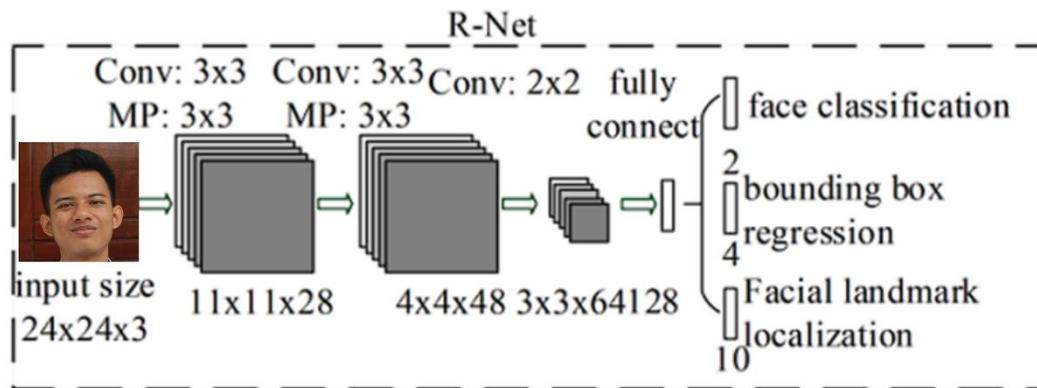
Keterangan:

- Subcitra merupakan hasil dari pemotongan wilayah citra wajah



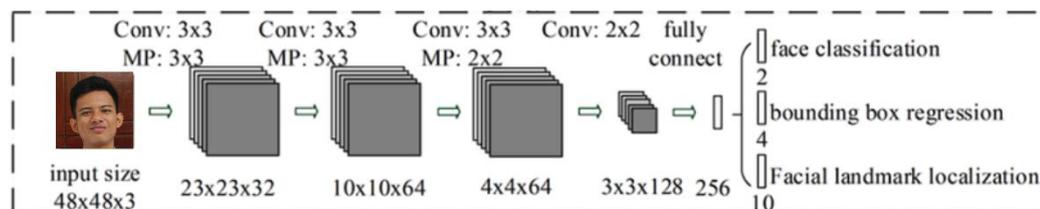
Gambar 10. Arsitektur jaringan P-Net

Gambar 10 menampilkan arsitektur P-Net yang merupakan tahapan awal (*Proposal Network*) dalam rangkaian MTCNN. Proses dimulai dari citra wajah berukuran 12×12 piksel dengan tiga kanal warna (RGB). Lalu, citra tersebut diproses melalui rangkaian lapisan konvolusi (kernel 3×3) dan max pooling (3×3) yang bertujuan mengekstraksi fitur dasar wajah serta mengecilkan dimensi citra. Setiap lapisan konvolusi menggunakan jumlah filter yang meningkat—dari 10, kemudian 16, hingga 32—sehingga peta fitur (*feature maps*) secara bertahap menggambarkan berbagai pola di wajah. Setelah tahap konvolusi terakhir, dimensi peta fitur mengecil menjadi $1 \times 1 \times 32$. Menghasilkan tiga keluaran berbeda (multi-task) yakni *Face Classification* dengan dimensi $1 \times 1 \times 2$ menentukan apakah *patch* gambar 12×12 benar-benar mengandung wajah (*face*) atau tidak (*non-face*), *Bounding Box Regression* dengan dimensi $1 \times 1 \times 4$ memprediksi seberapa jauh posisi kotak deteksi perlu digeser atau diubah ukurannya, yakni melalui empat nilai perbaikan koordinat (Δx , Δy , Δw , Δh), dan *Facial Landmark Localization* dengan dimensi $1 \times 1 \times 10$ memperkirakan lokasi lima titik penting di wajah (dua mata, hidung, dan dua sudut mulut). Masing-masing titik memiliki koordinat (x, y), sehingga totalnya memerlukan 10 nilai..



Gambar 11. Arsitektur jaringan R-Net

Gambar 11 di atas memperlihatkan R-Net (*Refine Network*) dalam rangkaian MTCNN dengan ukuran input 24×24 piksel dan 3 kanal warna (RGB). Mula-mula, citra melalui lapisan konvolusi (kernel 3×3) dan max pooling (3×3) sehingga dimensi peta fitur menyusut dari $24 \times 24 \times 3$ menjadi $11 \times 11 \times 28$. Tahap berikutnya, citra diolah oleh lapisan konvolusi 3×3 dan *max pooling* kedua, yang menghasilkan peta fitur berukuran $4 \times 4 \times 48$. Selanjutnya, lapisan konvolusi 2×2 memperkecil dimensi spasial menjadi $3 \times 3 \times 64$. Hasil peta fitur tersebut kemudian diratakan dan diteruskan ke lapisan *fully connected* (FC) dengan 128 neuron. Dari lapisan FC ini menghasilkan jaringan bercabang ke tiga keluaran (multi-task) yakni *Face Classification* (2 output) Menentukan apakah patch 24×24 benar-benar berisi wajah atau tidak, *Bounding Box Regression* (4 output) Memperbaiki koordinat dan ukuran kotak deteksi wajah (Δx , Δy , Δw , Δh), *Facial Landmark Localization* (10 output): Memperkirakan posisi lima titik penting di wajah (masing-masing titik memiliki koordinat (x, y)).



Gambar 12. Arsitektur jaringan O-Net

Gambar 12 Gambar tersebut menggambarkan O-Net (*Output Network*) dalam rangkaian MTCNN dengan ukuran input $48 \times 48 \times 3$ (RGB). Proses dimulai dengan

lapisan konvolusi 3×3 diikuti max pooling 3×3 , yang mengecilkan dimensi citra menjadi $23 \times 23 \times 32$. Kemudian, citra melewati lapisan konvolusi 3×3 dan max pooling 3×3 kedua hingga menjadi peta fitur $10 \times 10 \times 64$. Selanjutnya, sebuah lapisan konvolusi 3×3 dan *max pooling* 2×2 kembali mengecilkan dimensi menjadi $4 \times 4 \times 64$. Setelah itu, konvolusi 2×2 lebih lanjut menghasilkan $3 \times 3 \times 128$. Peta fitur yang dihasilkan lalu diratakan (*flatten*) dan disambungkan ke lapisan fully connected (FC) berukuran 256 neuron. Dari FC, keluaran terbagi menjadi tiga head (multi-task) yakni Face Classification (2 output): Memastikan patch 48×48 mengandung wajah atau tidak, Bounding Box Regression (4 output): Memperbaiki koordinat dan dimensi bounding box (Δx , Δy , Δw , Δh), Facial Landmark Localization (10 output): Memperkirakan posisi lima titik penting di wajah (masing-masing (x,y)). O-Net ini berperan sebagai tahap akhir (*output network*), yang memberikan deteksi dan prediksi landmark paling akurat setelah melalui saringan di P-Net dan R-Net.

Tahap pemodelan ini sangat penting karena model yang dihasilkan adalah inti dari sistem pengenalan wajah, dan performanya bergantung pada bagaimana data diproses serta arsitektur model yang digunakan.

3.4.6 Evaluasi

Pada tahap ini dilakukan untuk menguji kinerja model dalam mengenali wajah, untuk mengukur kinerja model, meliputi evaluasi tingkat presisi, akurasi, sensitivitas (recall), F1 score. Evaluasi juga mencakup pengukuran FPS (Frame Per Second) untuk menguji seberapa baik model bekerja dalam skenario real-time untuk menilai seberapa baik model dapat mengklasifikasikan data dengan benar. Evaluasi ini juga mencakup uji performa algoritma MTCNN untuk memastikan bahwa model tidak hanya akurat, tetapi juga dapat bekerja dengan efisien dan konsisten dalam kondisi nyata. Hal ini penting untuk memastikan bahwa model tidak hanya akurat, tetapi juga efisien dalam penerapan secara langsung.

3.4.7 Deployment

Dalam tahapan penerapan model yang sudah dievaluasi dan disesuaikan diterapkan dalam konteks nyata. Model yang telah dievaluasi dan dioptimalkan diimplementasikan dalam konteks nyata untuk mengenali wajah mahasiswa secara langsung. Real-time deployment ini memungkinkan sistem untuk mendeteksi dan mengenali wajah secara cepat dan akurat dalam lingkungan kampus. Setiap tahap dari siklus pengembangan ini saling terkait dan mendukung, mulai dari pemahaman bisnis, pengumpulan dan persiapan data, pemodelan, hingga evaluasi dan penerapan, dengan tujuan akhir untuk membangun sistem pengenalan wajah yang efisien, akurat, dan dapat diandalkan. Proses penerapan ini mengkonfirmasi bagaimana sistem yang dikembangkan dapat memberikan solusi yang efektif dan efisien dalam memenuhi tujuan bisnis yang telah ditetapkan.

3.5 Metode Analisis Evaluasi Kinerja Model Menggunakan Confusion Matrix dan Metrik Evaluasi

Hasil yang didapatkan dari tahap-tahap di atas kemudian dianalisis menggunakan metode confusion matrix. Poin-poin yang diperoleh meliputi tingkat akurasi, presisi, sensitivitas (recall), F1 score. Evaluasi ini dilakukan dengan menggunakan tabel matriks confusion yang memiliki beberapa kelas sesuai dengan jumlah individu dalam kumpulan data. Tingkat presisi, akurasi, sensitivitas, F1 score, dan ROC dihitung menggunakan Persamaan (14), (15), (16), (17), dan (18):

$$Accuracy = \frac{TP}{Total\ Test\ Dataset} \quad (6)$$

$$Precision = \frac{TP}{(TP+FP)} \quad (7)$$

$$Sensitivity = \frac{TP}{(TP+FN)} \quad (8)$$

$$F1\ Skor = 2 \times \frac{Presisi \times Sensitivitas}{Presisi + Sensitivitas} \quad (9)$$

Keterangan :

- *True Positive (TP)* adalah suatu kondisi yang diprediksi dengan benar.

- *False Negative (FN)* adalah banyaknya citra seseorang yang teridentifikasi oleh orang lain.
- *False Positive (FP)* adalah jumlah gambar seseorang yang teridentifikasi aneh.
- *True Negative (TN)* adalah gambar bukan wajah yang benar-benar terdeteksi sebagai bukan wajah.

Tingkat presisi diperoleh dengan membagi nilai positif sebenarnya di antara seluruh kumpulan data pengujian. Level yang benar diperoleh dengan membagi hasil positif dengan menjumlahkan hasil positif dan positif palsu. Tingkat sensitivitas kemudian diperoleh dengan membagi positif sebenarnya dengan jumlah positif sebenarnya dan negatif palsu. Hasil tersebut dibandingkan dengan tingkat akurasi, presisi, dan sensitivitas pengenalan wajah menggunakan seluruh aspek tampilan.

BAB V. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Dari penelitian yang dilakukan berupa penelitian pengenalan wajah menggunakan MTCNN dengan menggunakan dataset Mahasiswa Universitas Lampung didapatkan kesimpulan sebagai berikut:

1. Model pengenalan wajah mahasiswa Universitas Lampung yang dibangun menggunakan algoritma MTCNN (Multi-task Cascaded Convolutional Networks) berhasil mencapai tingkat keakuratan yang diharapkan. Algoritma MTCNN terbukti efektif dalam mendeteksi dan mengenali banyak wajah sekaligus. Namun, perlu diperhatikan bahwa meskipun akurasi MTCNN cukup tinggi, algoritma ini memiliki kelemahan dalam hal waktu pemrosesan yang cenderung lebih lama ketika harus membaca banyak wajah secara bersamaan.
2. Hasil Evaluasi performa algoritma MTCNN dalam mengklasifikasikan citra pendeteksi wajah mahasiswa, menghasilkan akurasi sistem tercatat sebesar 0.8081, Precision model menunjukkan angka 0.8129, Recall, atau sensitivitas, model tercatat sebesar 0.7689, F1 Score model adalah 0.7643 dan nilai FPS (Frames Per Second) yang rendah yaitu 0.53.
3. Berdasarkan hasil pengujian sistem pengenalan wajah menggunakan MTCNN menunjukkan kinerja optimal pada jarak (0.5-2 meter) dengan akurasi tinggi. Namun, sistem menjadi kurang efektif pada jarak kurang dari 0,5 meter akibat distorsi fitur wajah yang menghambat proses pengenalan secara akurat. Sistem juga menjadi kurang efektif pada jarak 2.5 - 3 meter terjadi penurunan kinerja yang ditandai dengan menurunnya FPS serta meningkatnya ketidakakuratan dalam deteksi wajah menunjukkan bahwa jarak tersebut kurang optimal untuk pengenalan wajah.

5.2 Saran

Berdasarkan penelitian yang telah dilakukan dalam melakukan tugas akhir mendapatkan beberapa saran untuk pengembangan selanjutnya, sebagai berikut:

1. Disarankan untuk melihat metode optimasi seperti paralelisasi proses atau penggunaan perangkat keras yang lebih kuat seperti GPU yang lebih cepat atau model jaringan saraf yang lebih ringan untuk mempercepat waktu pemrosesan karena algoritma MTCNN membutuhkan waktu yang lebih lama untuk mengenali banyak wajah secara bersamaan dan juga dapat meningkatkan kecepatan pemrosesan sistem (FPS).
2. Pengembangan selanjutnya dapat difokuskan padapada pengembangan sistem pengenalan wajah yang lebih kompleks dan optimal dengan mengintegrasikan berbagai fitur tambahan, seperti pengenalan ekspresi wajah, deteksi usia, dan jenis kelamin. Untuk meningkatkan generalisasi model, perluasan dataset yang mencakup gambar wajah dalam berbagai pose, ekspresi, pencahayaan, dan latar belakang sangat penting. Selain itu, kombinasi algoritma yang berbeda dapat diterapkan untuk meningkatkan akurasi dan efisiensi deteksi wajah. Penerapan nilai cahaya yang optimal, terutama dalam kondisi pencahayaan yang bervariasi, akan meningkatkan kinerja sistem secara signifikan, mengurangi ketergantungan pada pencahayaan ideal, dan membuat sistem lebih adaptif terhadap perubahan pencahayaan di berbagai lingkungan.

Daftar Pustaka

- [1] J. T. Santoso, *Kecerdasan Buatan (Artificial Intelligence)*, vol. 1. Semarang: Yayasan Prima Agus Teknik, 2023.
- [2] N. Kühn, M. Schemmer, M. Goutier, dan G. Satzger, “Artificial intelligence and machine learning,” *Electronic Markets*, vol. 32, no. 4, hlm. 2235–2244, Des 2022, doi: 10.1007/s12525-022-00598-0.
- [3] L. S. Moonlight, “Sistem Pengenalan Wajah Berbasis Jaringan Syaraf Tiruan Self Organizingmap (Som) Dengan Pemrosesan Awal Discrete Cosine Transform (Dct),” *Jurnal Penelitian*, vol. 4, no. 3, hlm. 29–39, Nov 2019, doi: 10.46491/jp.v4e3.372.29-39.
- [4] Agus Suharto, *Fundamental Bahasa Pemrograman Python*. Purbalingga: Cv.Eureka Media Aksara, 2023.
- [5] Indah Widhi Prastika dan Eri Zuliarso, “Deteksi Penyakit Kulit Wajah Menggunakan Tensorflow Dengan Metode Convolutional Neural Network,” *Jurnal Manajemen informatika & Sistem Informasi*, vol. 4, no. 2, 2021.
- [6] Miftakhurrokhmat, “Presensi Kelas Berbasis Pola Wajah dan Tersenyum Menggunakan Deep Learning,” Universitas Islam Indonesia, Yogyakarta, 2023.
- [7] Srinivas Rao P, Rohan Gudla, Vijay Shankar Telidevulapalli, Jayasree Sarada Kota, dan Gayathri Mandha, “Review on self-driving cars using neural network architectures,” *World Journal of Advanced Research and Reviews*, vol. 16, no. 2, hlm. 736–746, Nov 2022, doi: 10.30574/wjarr.2022.16.2.1240.
- [8] K. D. Anggara, D. P. Kartikasari, dan F. A. Bakhtiar, “Implementasi Algoritma MTCNN dalam Mekanisme Autentikasi berbasis Pengenalan Wajah,” vol. 7, no. 8, hlm. 3613–3621, 2023.
- [9] X. Li, Z. Yang, dan H. Wu, “Face detection based on receptive field enhanced multi-task cascaded convolutional neural networks,” *IEEE Access*, vol. 8, hlm. 174922–174930, 2020, doi: 10.1109/ACCESS.2020.3023782.
- [10] Ferry Cahyono, “Pengenalan Wajah Menggunakan Model Facenet Untuk Presensi Pegawai,” Institut Teknologi Sepuluh Nopember, Surabaya, 2020.
- [11] Hanif Naufal Arif, “Pengenalan Wajah Bermasker dan Tanpa Masker dengan Menggunakan MTCNN dan VGG Face untuk Wajah Bagian Atas,” Universitas Gadjah Mada, 2023.

- [12] E. Chodry, “Implementasi Arsitektur Resnet50 Dan Resnet101 Pada Sistem Kehadiran Berbasis Face Recognition,” Universitas Lampung, Bandar Lampung, 2024.
- [13] F. T. Nugroho dan E. I. Sela, “Deteksi Citra Wajah Menggunakan Algoritma Haar Cascade Classifier,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 1, hlm. 37–44, Des 2023, doi: 10.57152/malcom.v4i1.988.
- [14] Y. Ma, T. Xu, S. Han, dan K. Kim, “Ensemble Learning of Multiple Deep CNNs Using Accuracy-Based Weighted Voting for ASL Recognition,” *Applied Sciences (Switzerland)*, vol. 12, no. 22, Nov 2022, doi: 10.3390/app122211766.
- [15] L. Nadjamuddin, A. Arwansyah, S. Sukmawati, dan W. Windayanti, “Development of a Model for Predicting Students’ Achievement,” *International Journal of Social Science Humanity & Management Research*, vol. 3, no. 06, Jun 2024, doi: 10.58806/ijsshmr.2024.v3i6n13.
- [16] V.K.N Kamlesh Pai, “Face recognition using Convolutional Neural Networks,” *IEEE*, hlm. 165–170, 2018, doi: 10.1109/ICOEI.2018.8553969.
- [17] D. I. Mulyana *dkk.*, “Penerapan Face Recognition Dengan Algoritma Haar Cascade Untuk Sistem Absensi Pada Yayasan Pusat Pengembangan Anak Jakarta,” *Jurnal Cahaya Mandalika*, vol. 3, no. 3, 2023, doi: <https://doi.org/10.36312/jcm.v3i3>.