

Turnitin LLCC

2213030111_Rayhan Ferdiansyah.docx (1)

 SI-14

Document Details

Submission ID

trn:oid::2945:393805078

Submission Date

Jun 17, 2026, 9:20 AM GMT+7

Download Date

Jun 17, 2026, 9:22 AM GMT+7

File Name

2213030111_Rayhan Ferdiansyah.docx (1).pdf

File Size

6.7 MB

47 Pages

9,646 Words

62,498 Characters

13% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- Bibliography

Top Sources

- 10%  Internet sources
- 6%  Publications
- 11%  Submitted works (Student Papers)

Integrity Flags

0 Integrity Flags for Review

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.

Top Sources

- 10% Internet sources
- 6% Publications
- 11% Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Internet	kc.umn.ac.id	<1%
2	Internet	jurnal.ilmubersama.com	<1%
3	Student papers	Universitas Sumatera Utara on 2026-05-21	<1%
4	Internet	arxiv.org	<1%
5	Internet	docplayer.info	<1%
6	Internet	sitasi.upnjatim.ac.id	<1%
7	Internet	jurnal.tau.ac.id	<1%
8	Publication	Fadel Najmi Adliansyah, Holilah Holilah, Nanang Krisdianto. "Sistem Absensi Berb...	<1%
9	Internet	repository.ittelkom-pwt.ac.id	<1%
10	Student papers	Politeknik Manufaktur Negeri Bangka Belitung on 2025-06-01	<1%
11	Internet	www.coursehero.com	<1%

12	Internet	www.jneonataisurg.com	<1%
13	Internet	digilib.yarsi.ac.id	<1%
14	Internet	patents.google.com	<1%
15	Student papers	Universitas Islam Indonesia on 2026-06-15	<1%
16	Publication	Yuno Otsuka, Pittipol Kantavat, Boonserm Kijirikul. "An unsupervised pipeline fo...	<1%
17	Internet	dspace.uui.ac.id	<1%
18	Internet	repository.telkomuniversity.ac.id	<1%
19	Student papers	Universitas Putera Batam on 2025-07-29	<1%
20	Internet	www.osti.gov	<1%
21	Student papers	Sriwijaya University on 2023-02-23	<1%
22	Student papers	Perpustakaan on 2025-08-07	<1%
23	Internet	digilib.uin-suka.ac.id	<1%
24	Internet	jurnal.polibatam.ac.id	<1%
25	Student papers	UPN Veteran Yogyakarta on 2026-01-05	<1%

26	Internet	dr.ur.ac.rw	<1%
27	Internet	repository.binadarma.ac.id	<1%
28	Internet	www.arxiv-vanity.com	<1%
29	Internet	link.springer.com	<1%
30	Internet	ojs.logika.ac.id	<1%
31	Internet	repository.unair.ac.id	<1%
32	Internet	www.frontiersin.org	<1%
33	Publication	I Nyoman Yoga Setyawan, Luh Putu Ary Sri Tjahyanti. "Optimasi Sistem Pengenal...	<1%
34	Student papers	Unika Soegijapranata on 2015-11-12	<1%
35	Student papers	Universitas Tarumanagara on 2025-12-15	<1%
36	Internet	assets.researchsquare.com	<1%
37	Internet	conference.usm.ac.id	<1%
38	Internet	repository.teknokrat.ac.id	<1%
39	Internet	www.emergentmind.com	<1%

40	Internet	www.fx361.com	<1%
41	Student papers	Universitas Pendidikan Indonesia on 2013-05-08	<1%
42	Internet	digilib.uinsby.ac.id	<1%
43	Internet	jurnal.polbeng.ac.id	<1%
44	Internet	ojs.stmik-banjarbaru.ac.id	<1%
45	Internet	text-id.123dok.com	<1%
46	Student papers	Sekolah Teknik Elektro & Informatika on 2025-07-18	<1%
47	Student papers	University of Portsmouth on 2024-05-22	<1%
48	Internet	eprints.amikom.ac.id	<1%
49	Internet	jkomtekinfo.org	<1%
50	Internet	repository.unissula.ac.id	<1%
51	Internet	www.cjig.cn	<1%
52	Internet	doku.pub	<1%
53	Internet	journal.unismuh.ac.id	<1%

54	Publication	Syukur Iman Attaqwa, Eva Yulia Puspaningrum, Wahyu S.J. Saputra. "IMPLEMENT...	<1%
55	Student papers	Telkom University on 2025-07-04	<1%
56	Student papers	UNIVERSITAS BUDI LUHUR on 2026-02-21	<1%
57	Student papers	Universitas Bina Sarana Informatika on 2026-06-11	<1%
58	Student papers	Universitas Muhammadiyah Purwokerto on 2025-07-07	<1%
59	Student papers	Universitas Pancasila on 2025-08-04	<1%
60	Student papers	Universitas Tarumanagara on 2025-12-19	<1%
61	Internet	eprints.polsri.ac.id	<1%
62	Internet	repository.its.ac.id	<1%
63	Internet	repository.uinbanten.ac.id	<1%
64	Internet	repository.ulb.ac.id	<1%
65	Internet	repository.upi.edu	<1%
66	Internet	sinta.unud.ac.id	<1%
67	Internet	123dok.com	<1%

68	Publication	Muhammad Khatama Insani, Dwi Budi Santoso. "Perbandingan Kinerja Model Pre...	<1%
69	Student papers	Sriwijaya University on 2020-01-07	<1%
70	Student papers	Universitas Bengkulu on 2024-09-18	<1%
71	Student papers	Universitas Maritim Raja Ali Haji on 2025-01-12	<1%
72	Student papers	Universitas Muhammadiyah Purwokerto on 2025-07-07	<1%
73	Internet	e-theses.iaincurup.ac.id	<1%
74	Internet	ejournal.kresnamediapublisher.com	<1%
75	Internet	ejournal1.unud.ac.id	<1%
76	Internet	etheses.uin-malang.ac.id	<1%
77	Internet	opus.lib.uts.edu.au	<1%
78	Internet	prosiding.pnj.ac.id	<1%
79	Internet	repository.uigm.ac.id	<1%
80	Publication	Abi Maulana, Aulia Ullah, Ahmad Faizal, Hilman Zarory. "Dual Sistem Keamanan P...	<1%
81	Student papers	Universitas Jember on 2026-04-06	<1%

82	Student papers	Universitas Tarumanagara on 2025-12-16	<1%
83	Student papers	Perpustakaan on 2025-08-08	<1%
84	Publication	Pratama, Noviandhi Yudha. "Analisis Kualitas Aset Produktif Di Bank Pembiayaan..."	<1%
85	Student papers	Sriwijaya University on 2020-04-03	<1%
86	Student papers	Universidade de Évora on 2019-05-24	<1%
87	Student papers	Universitas Dian Nuswantoro on 2017-11-13	<1%
88	Student papers	Universitas Sumatera Utara on 2024-12-23	<1%

BAB I PENDAHULUAN

A. Latar Belakang

Deteksi dan pengenalan wajah merupakan salah satu cabang *computer vision* yang berkembang pesat dan telah diterapkan secara luas dalam berbagai bidang, mulai dari keamanan dan pengawasan, sistem kontrol akses, hingga identifikasi forensik dalam skala besar. Keunggulan utama teknologi ini terletak pada kemampuannya melakukan identifikasi individu secara non-invasif dan tanpa kontak fisik, sehingga lebih efisien dan higienis dibandingkan metode biometrik konvensional seperti sidik jari atau kartu identitas (Kortli et al., 2020).

Salah satu algoritma deteksi objek yang kini banyak dimanfaatkan untuk pengenalan wajah adalah *You Only Look Once version 5* (YOLOv5). Berbeda dengan metode dua tahap seperti R-CNN yang memerlukan *region* proposal terlebih dahulu, YOLOv5 melakukan deteksi objek dalam satu kali proses inferensi (*single pass detection*), sehingga menghasilkan kecepatan yang jauh lebih tinggi dan cocok diimplementasikan dalam skenario *real time* (Jocher et al., 2020). Dikombinasikan dengan model ekstraksi embedding wajah FaceNet yang menggunakan arsitektur InceptionResnetV1, pipeline ini dapat mempelajari representasi wajah yang sangat diskriminatif dalam ruang berdimensi 512 melalui fungsi loss Triplet Loss. Implementasi FaceNet dengan InceptionResnetV1 yang dilatih pada dataset VGGFace2 terbukti menghasilkan *embedding* wajah yang robust terhadap variasi pose, usia, dan etnisitas, sehingga banyak digunakan sebagai baseline dalam penelitian *face recognition* modern (Wang & Deng, 2021). Pipeline YOLOv5 yang dikombinasikan dengan FaceNet telah menunjukkan performa yang tinggi pada kondisi pencahayaan yang memadai, namun performa tersebut sangat dipengaruhi oleh kualitas citra input (Goel et al., 2021).

Meskipun pipeline YOLOv5 yang dikombinasikan dengan FaceNet menunjukkan performa yang menjanjikan dalam kondisi lingkungan terkontrol, permasalahan serius muncul ketika sistem dihadapkan pada kondisi pencahayaan rendah (*low light*). Varian model YOLO pada dataset ExDark secara konsisten menemukan bahwa performa deteksi objek menurun secara signifikan pada

kondisi cahaya rendah akibat rendahnya kontras, hilangnya detail tekstur, dan meningkatnya noise visual (Shovo et al., 2024). Selain itu, model deteksi berbasis YOLOv5 pada kondisi *low light* mengalami hambatan serius pada tahap ekstraksi fitur akibat degradasi kualitas piksel, sehingga memotivasi pengembangan metode peningkatan citra sebagai tahap *preprocessing* (Peng et al., 2024). Kondisi ini sering dijumpai pada skenario nyata seperti kamera CCTV pada malam hari, area dengan distribusi cahaya buatan yang tidak merata, maupun perangkat kamera dengan sensor berkualitas rendah.

Salah satu metode peningkatan kualitas citra yang terbukti efektif untuk mengatasi masalah pencahayaan rendah adalah *Contrast Limited Adaptive Histogram Equalization* (CLAHE). CLAHE merupakan pengembangan dari *Histogram Equalization* (HE) yang bekerja secara adaptif pada blok-blok kecil citra (*tiles*), sehingga mampu meningkatkan kontras lokal tanpa menimbulkan peningkatan kontras berlebih (*over enhancement*) pada area yang sudah terang. Dibandingkan dengan HE konvensional yang bekerja secara global, CLAHE mampu menghasilkan citra dengan tampilan yang lebih natural serta mempertahankan detail fitur secara lebih baik, khususnya pada citra wajah dengan pencahayaan tidak merata (Naufal et al., 2026)

Penerapan CLAHE sebagai tahap *preprocessing* sebelum proses inferensi pada model YOLOv5 berpotensi meningkatkan kemampuan sistem dalam mendeteksi dan mengenali wajah pada kondisi low-light. *Preprocessing* menggunakan CLAHE sebelum inferensi YOLOv5 dapat meningkatkan F1-Score deteksi objek pada kondisi malam hari, mengkonfirmasi efektivitas pendekatan *enhance then detect* dalam pipeline berbasis YOLO (Lashkov et al., 2023). Dengan distribusi intensitas piksel yang lebih merata setelah CLAHE, gradient tepi wajah yang sebelumnya lemah akibat cahaya rendah menjadi lebih jelas, sehingga detection rate YOLOv5 dapat meningkat dan kualitas embedding yang dihasilkan FaceNet pun menjadi lebih diskriminatif (Paul & Aslan, 2021).

Berbagai penelitian terdahulu telah mengkaji pengenalan wajah pada kondisi *low light*, namun masih terdapat celah yang belum ditutup. Pada penelitian yang mengintegrasikan CLAHE dengan CNN untuk deteksi wajah *low light* dan

mencapai *detection rate* 94,5%, namun tidak menggunakan YOLOv5 sebagai detektor maupun FaceNet sebagai *embedder* sehingga *pipeline* nya berbeda secara fundamental (Soni & Wao, 2025). Penelitian lain yang menggunakan FaceNet sebagai cara untuk meningkatkan citra langsung ke dalam jaringan pengenalan wajah dan berhasil meningkatkan akurasi pada kondisi *low light*, namun pendekatannya memerlukan pelatihan ulang model yang mahal secara komputasi (Fan et al., 2024). Adapun penelitian lain yang mengkonfirmasi bahwa *image enhancement* merupakan tahap yang sangat diperlukan untuk pengenalan wajah berbasis FaceNet pada kondisi *low light*, namun penelitian tersebut tidak mengevaluasi CLAHE secara spesifik sebagai solusi preprocessing (De Shreya and Pandey, 2026).

Oleh karena itu, penelitian ini mengangkat judul “Peningkatan Deteksi dan Pengenalan Wajah YOLOv5 pada Kondisi Cahaya Rendah Menggunakan CLAHE”. Penelitian ini secara khusus akan mengevaluasi dampak penerapan CLAHE sebagai tahap *preprocessing* terhadap performa pipeline YOLOv5 + FaceNet dalam mendeteksi dan mengenali wajah pada tiga kondisi pencahayaan: normal, *low light* (simulasi transformasi gamma $\gamma = 0,5$), dan *low light* dengan CLAHE. Evaluasi dilakukan secara kuantitatif menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, *AUC-ROC*, dan *detection rate* pada 1.000 pasangan gambar wajah dari dataset VGGFace2.

B. Batasan Masalah

Agar penelitian ini tetap fokus dan terarah, serta tidak melebar pada permasalahan yang di luar cakupan yang ditetapkan, maka peneliti menentukan batasan-batasan sebagai berikut:

1. Dataset yang digunakan adalah subset dari VGGFace2 yang tersedia di platform Kaggle (greatgamedota/vggface2-test), terdiri dari 50 identitas dengan maksimal 20 foto per orang (total ≈ 826 gambar). Dataset ini tidak spesifik berasal dari satu institusi tertentu dan merupakan dataset umum yang digunakan dalam riset face recognition.
2. Kondisi *low light* disimulasikan secara komputasional menggunakan transformasi gamma ($\gamma = 0,5$) dan bukan berasal dari pengambilan gambar

nyata dalam kondisi gelap. Hasil penelitian merupakan batas atas (*upper bound*) performa pada kondisi lapangan nyata yang memiliki *noise* lebih kompleks (*photon noise, motion blur*).

3. Model yang digunakan adalah YOLOv5-face yang tersedia di Kaggle (liaoboxiang/yolov5-face) sebagai detektor wajah dan InceptionResnetV1 pretrained VGGFace2 sebagai *embedder*, tanpa proses *fine tuning* tambahan pada dataset penelitian ini.
4. Evaluasi dilakukan menggunakan *pair based evaluation* dengan 1.000 pasangan gambar (500 *positive* dan 500 *negative*) per kondisi pencahayaan, dengan *threshold* identifikasi yang dikalibrasi secara otomatis dari kurva ROC pada target FPR $\leq 5\%$.
5. Implementasi sistem dibatasi pada platform Streamlit berbasis *website* dan tidak mencakup *deployment* pada perangkat *embedded, mobile*, atau *edge computing*.

C. Rumusan Masalah

Berdasarkan latar belakang dan batasan masalah yang telah diuraikan, rumusan masalah dalam penelitian ini disusun dalam bentuk pertanyaan penelitian sebagai berikut:

1. Seberapa besar pengaruh penerapan *preprocessing* CLAHE terhadap *detection rate* YOLOv5-Face dan akurasi pengenalan wajah berbasis FaceNet pada kondisi pencahayaan rendah?
2. Bagaimana perbandingan performa sistem pengenalan wajah dengan dan tanpa *preprocessing* CLAHE berdasarkan metrik *Accuracy, Precision, Recall, F1-Score*, dan *AUC-ROC* pada tiga kondisi pencahayaan (*normal, low light*, dan CLAHE *enhanced*)?

D. Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah:

1. Mengukur dan menganalisis pengaruh *preprocessing* CLAHE terhadap *detection rate* YOLOv5 dan akurasi pengenalan wajah berbasis FaceNet pada

kondisi pencahayaan rendah yang disimulasikan menggunakan transformasi gamma.

2. Membandingkan performa sistem pengenalan wajah dengan dan tanpa *preprocessing* CLAHE menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *AUC-ROC* pada tiga kondisi pencahayaan yang diuji secara terpisah.

E. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat bagi berbagai pihak, baik dari sisi teoritis maupun praktis.

1. Manfaat Teoritis

Penelitian ini diharapkan dapat memberikan kontribusi empiris terhadap kajian efektivitas CLAHE sebagai metode *preprocessing* dalam *pipeline* pengenalan wajah berbasis *deep learning* pada kondisi pencahayaan rendah, khususnya pada kombinasi YOLOv5 dan FaceNet yang belum banyak dieksplorasi dalam literatur. Memperkaya literatur mengenai pengaruh kualitas citra terhadap diskriminativitas embedding FaceNet, yang relevan untuk pengembangan sistem *face recognition* yang lebih *robust* pada kondisi lingkungan yang bervariasi.

2. Manfaat Praktis

Bagi institusi pendidikan tinggi, menghasilkan sistem pengenalan wajah berbasis website (Streamlit) yang dapat digunakan langsung oleh pengguna secara interaktif. Implementasi sistem yang andal pada berbagai kondisi pencahayaan ini diharapkan mampu memangkas waktu pencatatan manual, mengurangi potensi kecurangan presensi, serta mendukung efisiensi dan akurasi administrasi akademik. Bagi pengembang sistem, penelitian ini dapat memberikan panduan teknis dalam menangani tantangan pencahayaan rendah menggunakan pendekatan *preprocessing* CLAHE. Solusi ini menawarkan pendekatan yang sederhana, ringan, dan efisien secara komputasi. Pengembang dapat mengonfigurasi parameter *clip limit* dan *tile size* secara interaktif, serta dengan mudah mengintegrasikannya ke dalam *pipeline* deteksi berbasis YOLOv5 tanpa perlu memodifikasi arsitektur model yang sudah ada. Bagi mahasiswa dan tenaga

pengajar, penelitian ini dapat menyediakan *baseline* kuantitatif (*Detection Rate*, *Accuracy*, *F1-Score*, dan *AUC-ROC*) pada tiga kondisi pencahayaan kelas. Nilai ukur ini dapat dijadikan acuan praktis bagi peneliti atau pengembang selanjutnya yang ingin menguji dataset berbeda atau mengimplementasikan teknik *enhancement* citra yang lebih canggih.

BAB II KAJIAN PUSTAKA

Bab II kajian pustaka ini menyajikan pemaparan komprehensif mengenai dasar dasar teoretis, kerangka konseptual, dan literatur ilmiah yang menjadi pijakan fundamental dalam pelaksanaan penelitian ini.

A. Kajian Teori

1. *Computer Vision*

Computer vision adalah bidang ilmu komputer yang memungkinkan mesin untuk menginterpretasikan dan memahami konten visual dari dunia nyata, seperti gambar dan video, secara otomatis. *Computer vision* berupaya mereplikasi kemampuan sistem penglihatan manusia menggunakan komputer, mencakup berbagai tugas seperti deteksi objek, segmentasi citra, pengenalan pola, dan klasifikasi gambar (Khana et al., 2024). Teknologi ini menjadi fondasi utama dalam pengembangan sistem pengenalan wajah untuk aplikasi absensi.

2. *Face Recognition*

Face recognition atau pengenalan wajah merupakan salah satu teknologi biometrik yang berfungsi untuk mengidentifikasi atau memverifikasi identitas individu berdasarkan karakteristik unik pada wajah. Proses pengenalan wajah melibatkan beberapa tahapan, antara lain *image acquisition* (pengambilan citra wajah), *face detection* (deteksi wajah), *feature extraction* (ekstraksi fitur), dan *face matching* (pencocokan wajah dengan data yang tersimpan dalam basis data) (Santoso & Kristianto, 2020).

Teknologi *face recognition* telah banyak diterapkan dalam berbagai bidang seperti keamanan, pengawasan, autentikasi perangkat, dan sistem presensi. Dalam konteks pendidikan tinggi, penerapan *face recognition* pada sistem presensi

terbukti efektif dalam meningkatkan keakuratan data kehadiran sekaligus mengurangi praktik kecurangan seperti “titip absen” (Khair et al., 2024a).

3. *Convolutional Neural Network (CNN)*

Convolutional Neural Network (CNN) merupakan salah satu jenis jaringan saraf tiruan yang paling dominan digunakan dalam bidang computer vision, khususnya untuk tugas-tugas pengenalan gambar, deteksi objek, dan pengenalan wajah. CNN berfungsi sebagai jaringan saraf yang dirancang untuk secara otomatis dan efektif mempelajari pola spasial fitur dari data menggunakan *backpropagation*, dengan memanfaatkan sejumlah komponen utama meliputi lapisan konvolusi (*convolutional layers*), lapisan *pooling* (*pooling layers*), dan lapisan terhubung penuh (*fully connected layers*) (Alzubaidi et al., 2021). Keunggulan utama CNN terletak pada kemampuannya untuk mempelajari representasi fitur secara hierarkis langsung dari data mentah tanpa memerlukan rekayasa fitur secara manual.

4. *You Only Look Once (YOLO)*

You Only Look Once (YOLO) merupakan algoritma *deep learning* untuk deteksi objek secara *real-time* yang mengubah paradigma tradisional dalam pemrosesan citra digital. Berbeda dengan metode konvensional yang memerlukan beberapa tahap inferensi, YOLO melakukan deteksi objek hanya dalam satu kali proses prediksi (*single pass detection*), sehingga menghasilkan kecepatan dan efisiensi yang tinggi (Ayu Permatasari et al., 2024).

YOLO bekerja dengan cara membagi citra *input* menjadi beberapa *grid cell* dan secara simultan memprediksi *bounding box*, koordinat posisi, serta probabilitas kelas objek. Kemampuan ini membuat YOLO sangat efektif untuk aplikasi *real time*, termasuk sistem presensi berbasis pengenalan wajah yang membutuhkan respons cepat dan akurat (Juwandi, 2025).

5. *You Only Look Once Version 5 (YOLOv5)*

YOLOv5 merupakan salah satu implementasi paling berpengaruh dalam keluarga algoritma YOLO yang dikembangkan oleh Glenn Jocher dari *Ultralytics* dan pertama kali dirilis secara publik pada 27 Mei 2020 (Jocher et al., 2022).

YOLOv5 menggunakan teknologi *deep learning* untuk mendeteksi dan mengenali objek dalam gambar dan video secara cepat dan akurat; ketika mengidentifikasi objek, algoritma ini menghasilkan kotak pembatas (*bounding box*) di sekitar objek yang terdeteksi beserta nilai *confidence score* yang mencerminkan tingkat keyakinan prediksi (Khana et al., 2024).

6. Contrast Limited Adaptive Histogram Equalization (CLAHE)

Contrast Limited Adaptive Histogram Equalization (CLAHE) merupakan pengembangan lanjutan dari teknik *Histogram Equalization* (HE) yang secara spesifik mengatasi kelemahan HE konvensional dalam menangani citra dengan variasi pencahayaan lokal yang tinggi. CLAHE yang berfungsi sebagai metode peningkatan kontras adaptif yang bekerja dengan membagi gambar menjadi blok-blok kecil yang disebut *tiles*, kemudian menerapkan ekualisasi histogram secara lokal dan independen pada setiap *tile* tersebut (Reza, 2004).

Selain itu, CLAHE menggunakan interpolasi *bilinear* di antara *tile* *tile* yang berdekatan untuk menghasilkan transisi yang mulus dan menghilangkan artefak visual di batas antar-*tile*. Dalam studi *deep learning* untuk segmentasi medis bahwa *preprocessing* CLAHE secara signifikan meningkatkan metrik performa model, terutama ketika data citra berasal dari kondisi pencahayaan yang tidak seragam atau kontras rendah (Yoshimi et al., 2024).

7. FaceNet

FaceNet merupakan sebuah sistem pengenalan wajah yang secara langsung mempelajari pemetaan (*mapping*) dari citra wajah ke dalam ruang *Euclidean* yang kompak, di mana jarak antar titik dalam ruang tersebut merepresentasikan tingkat kemiripan antar wajah. Meskipun terdapat kemajuan signifikan dalam bidang pengenalan wajah, implementasi verifikasi dan pengenalan wajah secara efisien dalam skala besar masih menghadirkan tantangan serius bagi pendekatan-pendekatan yang ada sebelumnya (Schroff et al., 2015).

B. Kajian Hasil Penelitian Terdahulu

Tabel 2. 1 Kajian Hasil Penelitian Terdahulu

No	Peneliti & Tahun	Judul	Hasil Penelitian	Perbedaan Dengan Penelitian Ini
----	------------------	-------	------------------	---------------------------------

1	(Fan et al., 2024)	Low-FaceNet: Face recognition-driven low-light image enhancement.	Modifikasi struktur internal jaringan saraf berhasil mendongkrak ketajaman fitur wajah di kondisi gelap.	Penelitian ini tidak membongkar arsitektur internal model dasar, melainkan merancang sistem yang menggabungkan YOLOv5-Face, prapemrosesan CLAHE eksternal, dan FaceNet, sehingga lebih ringan dan mudah diimplementasikan.
2	(Paul & Aslan, 2021)	An improved real-time face recognition system at low resolution based on LBP and CLAHE	CLAHE terbukti efektif menaikkan kontras pada citra beresolusi rendah sebelum diekstraksi dengan metode tradisional.	Penelitian ini meninggalkan metode ekstraksi tradisional (seperti LBP) dan beralih menggunakan ekstraktor <i>Deep Learning</i> (FaceNet InceptionResNetV1) yang menghasilkan vektor 512-dimensi, yang jauh lebih tangguh terhadap distorsi spasial.
3	(Peng et al., 2024)	A novel low light object detection method based on the YOLOv5 fusion feature enhancement	Arsitektur YOLOv5 modifikasi mampu mendeteksi dan melokalisasi objek dengan presisi tinggi di lingkungan malam hari.	Penelitian terdahulu hanya berhenti pada tahap lokalisasi objek. Penelitian ini memperluas fungsionalitasnya secara end to end hingga sistem mampu memverifikasi identitas biometrik dan menghasilkan metrik probabilitas AUC ROC.
4	(Goel et al., 2021)	A study of deep learning-based face recognition models for sibling identification	Model FaceNet menunjukkan tingkat akurasi verifikasi yang sangat tinggi pada dataset wajah dengan	Penelitian ini menguji batas ketahanan operasional FaceNet pada skenario lingkungan yang lebih menantang (<i>low light</i> murni dan <i>CLAHE enhanced</i>), serta

			pencahaya-an ideal.	menetapkan kalibrasi <i>threshold</i> ketat untuk menekan <i>False Positive Rate</i> ≤ 4%.
5	(S. et al., 2022)	Image enhancement and implementation of CLAHE algorithm and bilinear interpolation.	CLAHE terbukti sangat stabil dalam meratakan distribusi pencahaya-an lokal tanpa menyebabkan <i>overexposure</i> .	Penelitian ini menerapkan CLAHE secara spesifik hanya pada ruang warna LAB (Kanal L) agar pigmen kromatik wajah asli tidak rusak, dan mengimplementasikannya secara langsung ke dalam bentuk aplikasi (Streamlit) yang siap pakai.
6	(Alzubaidi et al., 2021)	Review of deep learning: concepts, CNN architectures, challenges, applications, future directions	Menyajikan taksonomi, evolusi arsitektur <i>deep learning</i> , serta tantangan komputasi visi modern.	Merupakan kajian teoritis literatur, sedangkan penelitian ini adalah eksperimen terapan berbasis implementasi CRISP-DM.
7	(Ayu Permatasari et al., 2024)	Rancang Bangun Alat Sistem Absensi Mahasiswa menggunakan Face Recognition dengan Metode YOLO berbasis Raspberry Pi	Sistem presensi absensi berbasis YOLO sukses beroperasi di perangkat keras batas (<i>edge computing</i>).	Diimplementasikan murni pada perangkat <i>edge</i> dengan pencahaya-an normal, penelitian ini diimplementasikan pada peladen (<i>server</i>) untuk skenario gelap.
8	Cao et al. (2018)	VGGFace2: A dataset for recognising faces across pose and age.	Terbentuknya korpus VGGFace2 yang sangat kokoh untuk melatih model biometrik lintas usia dan pose.	Merupakan penelitian pembuatan dataset fundamental, sementara penelitian ini memposisikan diri sebagai penguji ketahanan pada sebagian subset dataset tersebut.
9	(De Shreya and Pandey, 2026)	Face Recognition Using Image Enhancement in	Modifikasi peningkatan kualitas citra terbukti	Tidak spesifik membedakan detektor, penelitian ini menggunakan

		Low Light Conditions.	memperbaiki nilai akurasi pengenalan wajah.	pemisahan tegas antara YOLOv5-Face (pelokalisasi) dan FaceNet (pengenalan vektor).
10	Imron et al. (2025)			
11	(Jocher et al., 2022)	ultralytics/yolov5 : v6.2 - YOLOv5 Classification Models, Apple M1, Reproducibility, ClearML and Deci.ai integrations	Model YOLOv5 mencatatkan akurasi dan kecepatan latensi teratas untuk inferensi secara <i>real-time</i> .	Merupakan makalah perilsan algoritma <i>core</i> , penelitian ini adalah pemanfaatan varian spesifik wajahnya untuk menyelesaikan limitasi kegagalan deteksi gelap.
12	(Juwandi, 2025)	Implementasi Algoritma YOLO dan Algoritma K-Nearest Neighbor pada Sistem Kehadiran Face Recognition	Wajah yang berhasil dideteksi YOLO mampu diklasifikasikan dengan presisi oleh perhitungan K-NN.	Klasifikasi menggunakan logika dasar K-NN, penelitian ini menerapkan perhitungan <i>Cosine Similarity</i> pada ruang vektor tinggi 512 dimensi (FaceNet).
13	(Khair et al., 2024)	Perancangan Sistem Absensi Mahasiswa Berbasis Face Recognition di Lingkungan UPN Veteran Jakarta	Sistem kehadiran biometrik mampu mengotomatiskan pencatatan jam masuk mahasiswa di perguruan tinggi.	Dirancang untuk kondisi ideal ruang kelas kampus, sistem ini dibangun agar <i>robust</i> menghadapi fluktuasi gelap terang ruangan.
14	(Khana et al., 2024)	Implementasi Sistem Presensi Deteksi Wajah Menggunakan YOLOv5	Detektor YOLOv5 sangat ringan dan dapat beroperasi sebagai modul presensi independen.	Tidak menggunakan modul ekstraktor kedua (<i>deep verification</i>), penelitian ini menggunakan dua modul terpisah agar lebih aman dari ancaman <i>spoofing</i> .
15	(Kortli et al., 2020)	Face recognition systems: A survey.	Memetakan keunggulan model <i>deep</i>	Kajian teori evolusi sistem pakar, penelitian ini fokus pada


			<i>learning</i> atas ekstraktor fitur klasik.	perancangan arsitektur terapan dan pelaporan angka metrik evaluasinya.
16	(Lashkov et al., 2023)	Edge-Computing-Facilitated Nighttime Vehicle Detection Investigations With CLAHE-Enhanced Images	Prapemrosesan CLAHE meningkatkan secara signifikan probabilitas deteksi mobil di CCTV jalan raya malam hari.	Objek utama adalah pemantauan lalu lintas (<i>traffic</i>), penelitian ini berfokus pada ketahanan geometri wajah manusia.
17	(Naufal et al., 2026)	Evaluation of Histogram-Based Image Enhancement Methods for Facial Images in Drowsy Driver Using No-Reference Metrics	Kontras peningkat citra membantu model melihat ciri fisik kantuk pengemudi.	Identifikasi ditujukan pada pendeteksian status perilaku (<i>drowsiness</i>), penelitian ini difokuskan murni pada autentikasi biometrik (<i>recognition</i>).
18	(Qi et al., 2022)	YOLO5Face: Why Reinventing a Face Detector.	Model baru tersebut jauh lebih akurat dan presisi untuk menangkap proporsi (<i>landmarks</i>) kepala manusia.	Menciptakan sub-varian dari detektor; penelitian ini memanfaatkannya dan memadukannya dengan teknik pemulihan visibilitas akibat faktor cahaya (<i>lighting condition</i>).
19	(Reza, 2004)	Realization of the Contrast Limited Adaptive Histogram Equalization (CLAHE) for Real-Time Image Enhancement	Ekualisasi histogram yang dibatasi (<i>clipping limit</i>) terbukti efektif membuang derau (<i>noise amplification</i>).	Kajian teoritis dasar matematika pengolahan citra; penelitian ini menjadikannya modul aktif di dalam aplikasi web deteksi <i>live-camera</i> .
20	(Santoso & Kristianto, 2020)	IMPLEMENTASI PENGGUNAAN OPENCV PADA FACE	Sistem dapat melakukan deteksi dan penguncian wajah	Model deteksi OpenCV klasik sangat ringkih terhadap distorsi bayangan (<i>shadow</i>), sistem ini jauh lebih

		RECOGNITION UNTUK SISTEM PRESENSI PERKULIAHAN MAHASISWA	mahasiswa dari tangkapan kamera web kelas.	tangguh menghadapi anomali iluminasi gelap.
21	(Schroff et al., 2015)	FaceNet: A unified embedding for face recognition and clustering	Model sukses merumuskan jarak Euclidean di mana wajah satu individu memiliki nilai probabilitas jarak yang saling dekat.	Makalah pencipta FaceNet; penelitian ini merupakan <i>stress-test</i> empiris dari arsitektur tersebut menggunakan parameter kurva probabilitas ROC pada kondisi terdistorsi.
22	(Shovo et al., 2024)	Advancing low-light object detection with you only look once models: An empirical study and performance evaluation	Kurva <i>Detection Rate</i> seluruh varian YOLO terbukti memiliki rasio degradasi linear dengan tingkat persentase gelap.	Makalah hanya menunjukkan hasil kelemahan model YOLO di malam hari; penelitian ini justru datang dengan penawaran solusi (integrasi pemulihan CLAHE).
23	(Soni & Wao, 2025)	Face Detection Under Low-Light and Low-Resolution Conditions Using Contrast-Limited Adaptive Histogram Equalization and a Modified Convolutional Neural Network	Jaringan kustom mampu mendeteksi batas tepi organ wajah di lingkungan beresolusi dan berpencahayaan rendah.	Model CNN pengenalan dibuat dan dimodifikasi secara spesifik; penelitian ini menggunakan model <i>pre-trained</i> publik agar replikasi sistem lebih ringan di lingkungan komersial.
24	(Wang & Deng, 2021)	Deep face recognition: A survey.	Menentukan batas standar ideal dan fungsi pengukuran <i>loss</i> di industri pengembangan <i>computer vision</i> .	Tulisan berupa ulasan akademis lintas arsitektur, penelitian ini berfokus pada tahapan implementasi.
25	(Ying et al., 2017)	A New Low-Light Image	Kualitas citra yang terdistorsi	Perbaikan bergantung pada karakteristik

		Enhancement Algorithm Using Camera Response Model	berhasil diterangkan berdasarkan perhitungan metrik kalibrasi optik organik.	teknis lensa/perangkat keras, penelitian ini menggunakan penyesuaian kontras yang murni bekerja di tingkat resolusi <i>software</i> .
26	(Yoshimi et al., 2024)	Image preprocessing with contrast-limited adaptive histogram equalization improves the segmentation performance of deep learning for the articular disk of the temporomandibular joint on magnetic resonance images	Visibilitas <i>articular disk</i> sendi manusia lebih tajam sehingga AI mampu melakukan segmentasi batas massa secara presisi.	Diterapkan pada data medis skala abu-abu (<i>grayscale/X-Ray</i>), penelitian ini diimplementasikan untuk mempertahankan pemrosesan saluran warna kulit muka (saluran <i>LAB luminance</i>).

C. Kerangka Berpikir

Kerangka berpikir penelitian ini diawali dari permasalahan yang terjadi yaitu, sistem *face recognition* berbasis YOLOv5 yang sudah dikembangkan sebelumnya masih memiliki performa deteksi wajah yang menurun secara signifikan pada kondisi cahaya rendah di ruang kelas, sehingga mengakibatkan tingkat *false negative* yang tinggi dan mengurangi keandalan sistem presensi. Berikut gambar kerangka berpikir pada Gambar 2.1.




Gambar 2. 1 Kerangka Berpikir

Gambar tersebut mengilustrasikan alur pemikiran penelitian yang terbagi ke dalam empat tahapan utama, mulai dari perumusan kendala hingga proyeksi hasil akhir. Tahap pertama difokuskan pada identifikasi masalah, yaitu terjadinya penurunan drastis pada tingkat akurasi deteksi dan pengenalan wajah akibat pengoperasian perangkat kamera pada kondisi pencahayaan yang rendah (*low light*). Untuk mengatasi kendala visibilitas tersebut, tahap kedua merumuskan pendekatan pemodelan kecerdasan buatan terstruktur yang melibatkan tiga komponen utama yaitu penerapan algoritma *Contrast Limited Adaptive Histogram Equalization* (CLAHE) untuk peningkatan kualitas citra awal, pemanfaatan arsitektur YOLOv5 untuk melokalisasi objek wajah, serta penggunaan model FaceNet untuk proses pengenalan identitas.

Selanjutnya pada tahap ketiga, model tersebut dieksekusi menjadi sebuah langkah penyelesaian masalah nyata melalui pembangunan *pipeline* sistem terpadu. Integrasi sistem ini dirancang untuk memastikan tahapan ekstraksi fitur wajah berjalan secara optimal dan komputasi pencocokan biometrik bekerja dengan tingkat presisi yang sangat akurat. Keberhasilan sistem ini akan diimplementasi ke dalam wujud aplikasi *website* menggunakan *framework* Streamlit.

BAB III METODE PENELITIAN

Penelitian ini menggunakan pendekatan *Cross Industry Standard Process for Data Mining* (CRISP-DM) sebagai kerangka metodologi. Pendekatan ini dipilih karena dinilai sangat cocok untuk membangun model klasifikasi berbasis *machine learning*. CRISPDM memiliki enam tahapan utama, yang memberikan panduan lengkap mulai dari pemahaman bisnis hingga evaluasi model (Daniati et al., 2025).



Gambar 3. 1 Metode CRISPDM

A. *Business Understanding* (Pemahaman Bisnis)

Deteksi dan pengenalan wajah merupakan komponen kritis dalam berbagai sistem keamanan modern. Tantangan utama yang sering dijumpai adalah kondisi pencahayaan yang tidak ideal, terutama pencahayaan rendah (*low-light*). Penurunan performa deteksi wajah pada cahaya rendah disebabkan oleh berkurangnya kontras gambar, hilangnya detail tekstur wajah, dan *noise* yang tinggi (Ying et al., 2017). Oleh karena itu, diperlukan tahap pra-pemrosesan gambar yang mampu meningkatkan kualitas visual sebelum gambar diproses oleh model deteksi dan pengenalan wajah.

Tujuan bisnis dari penelitian ini adalah membangun sebuah *pipeline* sistem pengenalan wajah yang andal pada kondisi pencahayaan rendah dengan mengintegrasikan teknik peningkatan citra *Contrast Limited Adaptive Histogram*

Equalization (CLAHE), model deteksi YOLOv5-face, dan model pengenalan wajah berbasis *FaceNet* yang dilatih menggunakan dataset VGGFace2. Sistem diharapkan mampu mensimulasikan kondisi *low-light*, meningkatkan citra, mendeteksi wajah, menghasilkan embedding 512 dimensi, dan melakukan pengenalan menggunakan *cosine similarity*.

Keberhasilan proyek diukur dengan *Area Under the Curve* (AUC) di atas 0,90 dan akurasi verifikasi wajah minimal 85% pada kondisi gambar yang telah ditingkatkan dengan CLAHE. Terdapat peningkatan metrik evaluasi antara kondisi *low-light* dan setelah CLAHE. *Pipeline* harus berjalan *end-to-end* dan visualisasi distribusi *cosine distance* menunjukkan separasi yang jelas antara *positive* dan *negative pairs*. Dan Sistem berhasil di-*deploy* dan dapat diakses melalui antarmuka Streamlit.

B. Data Understanding (Pemahaman Data)

1. Pengumpulan Data

Data yang digunakan dalam penelitian ini bersumber dari dataset VGGFace2 (Cao et al., 2018). VGGFace2 merupakan salah satu dataset pengenalan wajah berskala besar yang berisi 3,31 juta gambar dari 9.131 subjek. Penelitian ini menggunakan *subset* dari *test set* VGGFace2 yang tersedia di platform Kaggle (greatgamedota/vggface2-test), yang terdiri dari 500 subjek. Dari keseluruhan subjek tersebut, dipilih 50 subjek pertama yang memenuhi kriteria memiliki minimal 5 gambar dan maksimal 20 gambar per subjek. Pembatasan ini dilakukan untuk menjaga keseimbangan antara representasi data yang memadai dengan efisiensi komputasi selama eksperimen. Dapat dilihat pada Tabel 3.1.

Tabel 3. 1 Spesifikasi Dataset

Komponen	Keterangan
Nama Dataset	VGGFace2 (subset test)
Jumlah Identitas	50 orang (dipilih yang memiliki ≥ 5 foto)
Jumlah Foto per Orang	Maksimal 20 Foto
Estimasi Total Gambar	~700–1.000 gambar

Format Gambar	.jpg / .jpeg / .png
Resolusi Input YOLOv5	640 × 640 piksel
Ukuran Crop Wajah	160 × 160 piksel
Sumber	Kaggle (greatgamedota/vggface2-test)

2. Deskripsi Data

Dataset VGGFace2 terdiri dari gambar wajah manusia yang berformat JPEG dan PNG dengan resolusi yang beragam. Gambar-gambar tersebut memiliki variasi yang sangat tinggi dalam hal pose, usia, pencahayaan, ekspresi wajah, etnis, dan latar belakang. Dalam penelitian ini, gambar asli diperlakukan sebagai kondisi normal, kemudian disimulasikan menjadi kondisi *low light* melalui transformasi gamma, dan selanjutnya ditingkatkan dengan CLAHE.

3. Eksplorasi Data Awal

Eksplorasi data awal dilakukan untuk memahami karakteristik dataset sebelum memasuki tahap pemodelan. Proses ini meliputi pengecekan distribusi jumlah gambar per identitas, verifikasi format dan keterbacaan gambar, visualisasi *pipeline* pemrosesan gambar secara komparatif pada tiga kondisi pencahayaan. Gambar 3.1 menunjukkan perbandingan visual gambar pada kondisi original, *low-light*, dan setelah diproses CLAHE, termasuk *bouding box* hasil deteksi YOLOv5 serta nilai kecerahan rata-rata (*mean brightness*) masing-masing kondisi. Dapat dilihat pada Gambar 3.1.



Gambar 3. 2 Visualisasi Tiga Kondisi Pencahayaan

C. Data Preparation (Persiapan Data)

1. Seleksi Data

Seleksi data dilakukan dengan memilih 50 subjek pertama dari test set VGGFace2 yang memenuhi kriteria yang telah ditetapkan, yaitu minimal 5 gambar dan maksimal 20 gambar per subjek. Pemilihan secara berurutan berdasarkan nama direktori dilakukan untuk menjaga konsistensi dan kemudahan dalam penelitian. Kriteria pembatasan jumlah gambar per subjek ini bertujuan untuk mencegah bias akibat ketidakseimbangan kelas serta menjaga efisiensi komputasi tanpa mengorbankan kualitas representasi data.

Proses seleksi menghasilkan daftar valid_labels yang digunakan untuk seluruh tahap evaluasi selanjutnya. Dapat dilihat pada Tabel 3.2 variabel penelitian.

Tabel 3. 2 Variabel Penelitian

Variabel	Keterangan
Kondisi Pencahayaan	Normal, Low-Light ($\gamma=0.5$), CLAHE
Clip Limit CLAHE	clipLimit=1.5, tileGridSize=(8,8)
Nilai Gamma Simulasi	$\gamma = 0.5$ (gelap sedang)
Detection Rate	Persentase wajah berhasil terdeteksi
Accuracy	Akurasi pengenalan wajah
AUC-ROC	Area Under Curve kurva ROC
Precision & Recall	Metrik evaluasi berbasis pair

2. Pembersihan Data

Proses pembersihan data melibatkan penghapusan atau melewati gambar-gambar yang tidak valid, seperti file yang *corrupt*, rusak, atau tidak dapat dibaca oleh *library* pemrosesan gambar. Selain itu, *bounding box* hasil deteksi YOLOv5-face yang tidak valid juga difilter dan tidak digunakan. Tahap ini sangat penting untuk memastikan bahwa hanya data berkualitas tinggi yang masuk ke tahap selanjutnya, sehingga menghasilkan *embedding* wajah yang lebih akurat dan konsisten.

3. Transformasi Data

Transformasi data merupakan tahap krusial dalam penelitian ini. Tahap pertama adalah simulasi kondisi pencahayaan rendah (*low light*) menggunakan teknik *gamma correction*, dengan persamaan sebagai berikut.

$$I_{dark}(x, y) = 255 \times (I(x, y)/255)^{(1/\gamma)} \quad (1)$$

Dengan nilai (γ gamma = 0,5). Nilai gamma di bawah 1 ini efektif untuk menggelapkan gambar dengan cara mengangkat setiap nilai piksel dengan invers gamma (γ gamma = 0,5) melalui *lookup table*, sehingga mampu mensimulasikan kondisi cahaya minim yang sering terjadi di dunia nyata.

Tahap kedua adalah peningkatan kualitas citra. Pada penelitian ini, metode *enhancement* dioptimasi melalui tiga proses berurutan, yaitu penerapan CLAHE pada ruang warna LAB, penyesuaian kecerahan global, dan reduksi derau (*denoising*) dengan tahapan sebagai berikut.

$$\text{BGR} \rightarrow \text{LAB} \rightarrow [\text{CLAHE pada kanal L}] \rightarrow \text{LAB} \rightarrow \text{BGR} \rightarrow [\text{Koreksi Gamma}] \rightarrow [\text{Bilateral Filter}] \quad (2)$$

Metode ini pertama-tama mengonversi gambar dari ruang warna *Blue, Green, Red* (BGR) ke LAB, kemudian memisahkan saluran luminansi (L) dari saluran warna (a) yaitu spektrum hijau hingga merah dan saluran (b) yaitu spektrum biru hingga kuning. *Adaptive histogram equalization* hanya diterapkan pada saluran luminansi (L) agar tidak merusak struktur warna asli wajah, sebelum digabungkan kembali dan dikonversi balik ke BGR. Setelah itu, gambar diberikan koreksi gamma ringan (γ gamma = 1,0) untuk mengangkat tingkat kecerahan global (penyesuaian domain), dan diakhiri dengan penerapan *Bilateral Filter* dengan persamaan berikut.

$$I_{denoised}(x, y) = \frac{1}{W_p} \sum_{i,j \in \Omega} I(i, j) \cdot \exp \exp \left(- \frac{(i-x)^2 + (j-y)^2}{2\sigma_{space}^2} \right) \cdot \exp \exp \left(- \frac{\|I(i, j) - I(x, y)\|}{\sigma_{range}} \right) \quad (3)$$

Untuk menghaluskan *noise* pada tekstur kulit namun tetap mempertahankan ketajaman tepi fitur biometrik wajah.

Tahap ketiga adalah normalisasi *embedding*. Setelah wajah diekstrak, gambar dinormalisasi ke rentang [-1, 1] sebelum dimasukkan ke FaceNet, mengikuti formula sebagai berikut.

$$\text{tensor} = \frac{\text{pixel} - 127.5}{128.0} \quad (4)$$

Seluruh *embedding* yang dihasilkan kemudian dinormalisasi ke unit *sphere* menggunakan norma L2 dengan persamaan sebagai berikut.

$$\hat{e} = \frac{e}{\|e\|_2 + \varepsilon}, \quad \varepsilon = 1 \times 10^{-10} \quad (5)$$

Pendekatan ini mampu meningkatkan kontras secara lokal tanpa menyebabkan *over amplification noise* atau perubahan warna yang tidak diinginkan.

4. Pembuatan *Data Set Modeling*

Setelah melalui proses transformasi, data yang telah diproses disimpan dalam format *Numpy Compressed Format* (NPZ). File ini digunakan sebagai *input* untuk tahap komputasi *embedding* pada tiga skenario kondisi pencahayaan. Untuk keperluan evaluasi berbasis pasangan (*pair-based evaluation*), dibentuk 1500 *positive pairs* (pasangan gambar dari identitas yang sama) dan 1500 *negative pairs* (pasangan gambar dari identitas berbeda) per kondisi, sehingga total terdapat 3.000 pasangan per kondisi dan 9.000 pasangan secara keseluruhan.

D. Modelling

Pemilihan Penelitian ini menggunakan pendekatan berbasis *machine learning* yang terdiri dari tiga komponen utama yang saling terintegrasi. Komponen pertama adalah model deteksi wajah YOLOv5-*face*, yaitu varian khusus dari YOLOv5 yang dioptimalkan untuk tugas deteksi wajah. Model ini diambil dari repositori Kaggle (liaoboxiang/yolov5-*face*) yang menyediakan bobot pretrained hasil pelatihan pada dataset wajah berskala besar (Qi et al., 2022). YOLOv5-*face* dipilih karena memiliki keunggulan dalam kecepatan inferensi dan akurasi deteksi yang tinggi, terutama pada wajah berukuran kecil serta kondisi lingkungan yang kompleks.

Komponen kedua adalah model pengenalan wajah *FaceNet* berbasis arsitektur *InceptionResNetV1* yang telah dilatih menggunakan dataset VGGFace2. Model ini menghasilkan representasi wajah dalam bentuk *embedding* berdimensi 512. Komponen ketiga adalah metode pengukuran kesamaan menggunakan *cosine similarity*. Metode ini dipilih karena bersifat invarian terhadap magnitudo vektor dan hanya mengukur sudut di antara dua *embedding*, sehingga lebih *robust*


terhadap variasi pencahayaan dan ekspresi wajah. Dengan konfigurasi sebagai berikut.

Tabel 3. 3 Konfigurasi Model

Komponen	Konfigurasi
Detektor Wajah	YOLOv5-Face (liaoboxiang/yolov5-face)
Confidence Threshold	0.4
IoU Threshold (NMS)	0.45
Embedder	InceptionResnetV1 (FaceNet, pretrained VGGFace2)
Dimensi Embedding	512 Dimensi
Metrik Similaritas	Cosine Similarity
Threshold Identifikasi	Ditentukan via ROC (target FPR <5%)
Ukuran Batch Embedding	32 gambar
Device	CUDA GPU (fallback CPU)

1. Desain dan Pengujian Model

Penelitian ini memiliki sebuah *pipeline* pemrosesan citra yang terintegrasi, memanfaatkan kombinasi teknik perbaikan citra lokal dan arsitektur *deep learning* terkini. Alur kerja sistem secara menyeluruh, mulai dari tahapan akuisisi data hingga penentuan identitas akhir, dapat dilihat pada Gambar 3.3 sebagai berikut.



Gambar 3. 3 Pipeline Sistem

Berdasarkan diagram alur tersebut, sistem pengenalan wajah dirancang melalui *pipeline* sekuensial yang dimulai dari tahap *Input*, di mana data mentah

berupa gambar statis maupun *frame* video diambil sebagai sumber data utama. Citra yang masuk kemudian melewati tahap pra-pemrosesan menggunakan algoritma CLAHE untuk memperbaiki kualitas visual dan kontras, khususnya pada kondisi pencahayaan minim, guna memastikan fitur wajah lebih menonjol. Setelah kualitas citra optimal, tahap deteksi dilakukan menggunakan model YOLOv5 untuk melokalisasi posisi wajah secara presisi di dalam *frame*.

Wajah yang berhasil terdeteksi selanjutnya masuk ke tahap ekstraksi, di mana model FaceNet mengubah fitur visual wajah tersebut menjadi representasi data angka atau vektor *embedding*. Vektor ini kemudian dikirim ke tahap *database* untuk dibandingkan dengan galeri identitas yang telah terdaftar menggunakan perhitungan kemiripan (*matching*). Tahapan akhir adalah hasil, di mana sistem memberikan keputusan identitas, jika ditemukan kecocokan yang memenuhi ambang batas, sistem akan menampilkan nama subjek, namun jika tidak ditemukan kecocokan di dalam *database*, sistem akan memberikan label umum berupa "*Person*" sebagai tanda bahwa objek adalah manusia namun identitasnya tidak dikenal.

2. Evaluasi Parameter Model

Identifikasi wajah dilakukan menggunakan *cosine similarity* antara *embedding query* dan *embedding database*. *Cosine similarity* mengukur sudut antara dua vektor dalam ruang berdimensi tinggi, dengan nilai berkisar dari 0 (tidak mirip) hingga 1 (identik) dengan persamaan sebagai berikut.

$$\cos(e_1, e_2) = \frac{e_1 \cdot e_2}{\|e_1\| \cdot \|e_2\|} \quad (6)$$

Karena *embedding* telah dinormalisasi ke *unit sphere* ($\|e\| = 1$), formula di atas menyederhanakan menjadi *dot product* dengan menggunakan persamaan berikut.

$$\cos(e_1, e_2) = e_1 \cdot e_2 \quad (7)$$

Threshold optimal untuk klasifikasi pasangan wajah ditentukan menggunakan kurva ROC dengan target *False Positive Rate* (FPR) maksimal 5%. *Threshold* dipilih sebagai nilai tertinggi yang masih memenuhi syarat $FPR \leq 0.05$, sehingga memaksimalkan *True Positive Rate* (TPR/*Recall*) dalam batasan tersebut.

3. Interpretasi Hasil Modeling

82

46

Interpretasi hasil modeling dilakukan melalui beberapa teknik visualisasi dan analisis. Pertama, distribusi nilai *cosine distance* antara *positive pairs* (wajah sama) dan *negative pairs* (wajah berbeda) divisualisasikan dalam bentuk histogram untuk menganalisis tingkat separasi antar kelas dan menentukan *threshold* optimal. Kedua, *confusion matrix* dihasilkan untuk setiap kondisi pencahayaan guna mengidentifikasi pola kesalahan klasifikasi yang terjadi. Analisis ini memberikan pemahaman mendalam mengenai kekuatan dan kelemahan *pipeline* yang dikembangkan.

E. Evaluation (Evaluasi)

Evaluasi dilakukan menggunakan metrik standar *machine learning* yang dihitung dari pasangan gambar (*pair-based evaluation*). Metrik yang digunakan adalah sebagai berikut:

1. **Accuracy:** Proporsi prediksi yang benar dari seluruh prediksi.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (8)$$

2. **Precision:** Proporsi prediksi positif yang benar-benar positif.

$$Precision = \frac{TP}{TP+FP} \quad (9)$$

3. **Recall (Sensitivity/TPR):** Proporsi data positif yang berhasil diidentifikasi.

$$Recall = \frac{TP}{TP+FN} \quad (10)$$

4. **AUC-ROC: Area Under the Receiver Operating Characteristic Curve,** mengukur kemampuan diskriminasi model secara keseluruhan, dengan nilai 0.5 (acak) hingga 1.0 (sempurna). Kurva ROC menunjukkan *trade-off* antara TPR dan FPR pada berbagai nilai *threshold*.

$$AUC = \int_0^1 TPR(FPR) d(FPR) \quad (11)$$

5. **Detection Rate:** Persentase gambar wajah yang berhasil dideteksi oleh YOLOv5 dari total gambar uji.

$$DetectionRate = \frac{JumlahWajahTerdeteksi}{TotalGambar} \times 100\% \quad (12)$$

Konfigurasi evaluasi dapat dilihat pada Tabel 3.4, tabel tersebut merupakan konfigurasi guna menghasilkan metrik dari sistem

Tabel 3. 4 Konfigurasi Evaluasi


Parameter	Nilai	Keterangan
Positive Pairs (n_same)	1500	Pasangan dari identitas yang sama
Negative Pairs (n_diff)	1500	Pasangan dari identitas berbeda
Total Pairs per Kondisi	3000	Normal / Gelap / CLAHE
Sampel Confusion Matrix	100 query	Tiap identitas dievaluasi per kondisi
Threshold Sampling (ROC)	2000 pasangan	Untuk kalibrasi threshold optimal

Validasi dilakukan dengan membandingkan hasil metrik evaluasi terhadap kriteria keberhasilan yang telah ditetapkan pada tahap *Business Understanding*. Model dinyatakan valid apabila *detection rate* kondisi CLAHE lebih tinggi dari kondisi *low-light* tanpa perbaikan, *accuracy* kondisi CLAHE $\geq 80\%$, AUC-ROC kondisi CLAHE lebih tinggi dari kondisi *low light*. Visualisasi sampel hasil deteksi dan identifikasi wajah per kondisi juga dilakukan untuk validasi kualitatif.

Apabila hasil evaluasi tidak memenuhi kriteria keberhasilan, dilakukan tinjauan ulang terhadap fase sebelumnya. Tinjauan yang mungkin dilakukan antara lain yaitu penyesuaian parameter CLAHE (*clipLimit* dan *tileGridSize*), penyesuaian gamma simulasi *low light*, penyesuaian *confidence threshold* YOLOv5, serta penambahan jumlah data atau identitas. Sifat iteratif CRISP-DM memungkinkan perbaikan secara sistematis hingga kriteria terpenuhi.

F. Deployment (Penerapan)

Sistem pengenalan wajah yang telah dievaluasi akan di-deploy sebagai aplikasi *website* interaktif menggunakan *framework* Streamlit. Streamlit merupakan *framework* Python *open source* yang memungkinkan pembuatan aplikasi *website* data *science* dan *machine learning* secara cepat tanpa memerlukan pengetahuan *front-end* yang mendalam (Streamlit, 2023). Pemilihan Streamlit sebagai *platform deployment* didasarkan pada kemampuannya mengintegrasikan *library* ilmiah Python secara langsung dalam antarmuka interaktif. Aplikasi Streamlit yang dibangun memiliki alur kerja yang dapat dilihat pada Gambar 3.3.



Gambar 3. 4 Alur Sistem Streamlit

Diagram alur di atas menjelaskan sistem lengkap dari aplikasi yang dibangun menggunakan *framework* Streamlit. Proses dimulai dari sisi pengguna yang memberikan masukan media melalui *browser*, di mana mereka dapat memilih tiga metode yaitu mengunggah file gambar wajah, mengambil foto tunggal secara langsung menggunakan kamera *browser*, atau mengunggah *file* video. Masukan media tersebut kemudian dikirim ke *server* pemrosesan yang berjalan di Streamlit *Server* untuk diolah. Di *server*, *input* video akan melewati proses *frame skipping* untuk optimasi efisiensi *Central Processor Unit* (CPU) dengan hanya memproses *frame* tertentu. Semua *input* media kemudian dikonversi oleh *media reader*

menjadi *format* OpenCV agar dapat diproses lebih lanjut. Hasil konversi ini masuk ke pipeline pemrosesan inti, yang terdiri dari serangkaian langkah.

Tahap pertama yaitu LAB color & CLAHE, tahap ini meningkatkan kualitas gambar lokal terutama pada kondisi pencahayaan rendah. Tahap kedua, model YOLOv5 melakukan deteksi wajah dan menemukan titik *landmark* wajah. Tahap ketiga, model FaceNet mengekstraksi ciri ciri unik dari wajah menjadi vektor *embedding* 512 dimensi. Tahap terakhir, *cosine similarity* membandingkan vektor wajah tersebut dengan data yang ada di basis data wajah untuk menentukan identitas.

Setelah pemrosesan *server* selesai, hasilnya dikirim kembali ke *browser* pengguna. Untuk *input* gambar atau foto, aplikasi menghasilkan visualisasi dengan *bounding box* di sekitar wajah dan kartu identitas yang mengonfirmasi apakah identitas terdaftar atau tidak. Untuk *input* video, hasil pemrosesan diwujudkan dalam *rendering* visual, penyimpanan video mentah, konversi menggunakan Ffmpeg menjadi format MP4 dengan *codec* H.264 agar dapat diunduh pengguna. Sebagai keluaran akhir, pengguna akan melihat tampilan pratinjau gambar yang diproses dengan label identitas serta pemutar video yang berisi hasil pemrosesan yang siap diunduh.

BAB IV HASIL DAN PEMBAHASAN

Bab ini menyajikan seluruh hasil penelitian yang diperoleh dari eksperimen menggunakan metode *Cross Industry Standard Process for Data Mining* (CRISP-DM). Pembahasan mencakup hasil eksplorasi dan transformasi data, performa sistem deteksi wajah *You Only Look Once Version 5* (YOLOv5), evaluasi model pengenalan wajah berbasis FaceNet pada tiga kondisi pencahayaan yaitu kondisi cahaya normal, *low light*, dan menggunakan *Contrast Limited Adaptive Histogram Equalization* (CLAHE), serta implementasi dan *deploy* sistem ke platform Streamlit.

A. Data Hasil Penelitian

1. Hasil Ekplorasi Data

Tahap eksplorasi data dilakukan untuk memahami karakteristik dataset VGGFace2 subset yang digunakan dalam penelitian. Dataset yang berhasil dikumpulkan terdiri dari 50 identitas subjek terseleksi dari *test set* VGGFace2. Untuk memfasilitasi proses pengujian klasifikasi performa pengenalan wajah secara mendalam, dari total gambar tersebut dibentuk data uji berbasis pasangan (*pair based evaluation*) berskala masif, yaitu sebanyak 3.000 pasangan gambar per kondisi pencahayaan. Pasangan gambar tersebut dibagi secara seimbang menjadi 1.500 pasangan positif (*positive pairs*, yang merepresentasikan dua gambar berbeda dari individu yang sama) dan 1.500 pasangan negatif (*negative pairs*, yang merepresentasikan dua gambar dari individu yang berbeda).

Seluruh 50 subjek memenuhi syarat minimal gambar per identitas sebagaimana yang telah ditetapkan pada tahap *data preparation*. Tidak ditemukan gambar yang rusak (*corrupt*) selama proses pemuatan, sehingga tingkat keberhasilan *loading* dataset mencapai 100%. Distribusi jumlah foto per identitas relatif seimbang setelah melewati fase penapisan dan seleksi maksimal. Tabel 4.1 menunjukkan statistik deskriptif dataset secara keseluruhan.

Tabel 4. 1 Statistik Dataset VGGFace2 Yang Digunakan

Parameter	Nilai
Jumlah Identitas (Subjek)	50 Orang
Total Pasangan Uji Per Kondisi Pencahayaan	3.000 (1.500 Positif + 1.500 Negatif)
Format Ekstensi Gambar	.jpg / .jpeg / .png
Resolusi Input Jaringan YOLOv5-Face	640 x 640 Piksel
Ukuran Potongan Wajah (<i>Crop FaceNet</i>)	160x160 Piksel
Gambar Rusak / Gagal Baca (<i>Corrupted</i>)	0 Gambar

Analisis distribusi kecerahan citra (*mean brightness*) dilakukan pada ketiga kondisi pencahayaan untuk memvalidasi proses simulasi. Gambar pada kondisi normal (*original*) menunjukkan sebaran nilai kecerahan rata-rata pada kanal *grayscale* yang bervariasi dengan nilai minimum sebesar 26,68 dan nilai maksimum sebesar 216,83, serta mencatatkan nilai rata-rata global sebesar 110,46. Setelah simulasi *low-light* diterapkan menggunakan teknik *gamma correction* (γ gamma = 0,5), tingkat iluminasi citra mengalami penurunan secara drastis, di mana nilai kecerahan merosot ke rentang nilai minimum 7,54 hingga maksimum 198,29, dengan nilai rata-rata global yang jatuh ke angka 69,42. Penurunan signifikan ini merepresentasikan hilangnya intensitas cahaya secara masif pada matriks piksel wajah subjek. Selanjutnya, setelah implementasi CLAHE melalui saluran luminansi pada ruang warna LAB, nilai kecerahan berhasil dipulihkan secara adaptif dengan rentang nilai minimum sebesar 12,13

hingga maksimum sebesar 202,05, serta sukses mengangkat kembali rata-rata global kecerahan menuju indeks 82,15. Perubahan distribusi dan pergeseran nilai parameter ini menjadi validasi matematis bahwasanya skenario simulasi ruangan gelap (*low light*) dan proses perbaikan citra (*image enhancement*) telah berhasil diterapkan dengan benar pada seluruh dataset pengujian (Peng et al., 2024). Tabel 4.2 merangkum perbandingan nilai distribusi kecerahan rata-rata pada ketiga kondisi pencahayaan tersebut.

Tabel 4. 2 Rata rata nilai kecerahan per kondisi pencahayaan

Kondisi Cahaya	Nilai minimum	Nilai Maksimum	Rata Rata Global
Normal	26,68	216,83	110,46
Low Light	7,54	198,29	69,42
CLAHE Enhanced	12,13	202,05	82,15

Selama eksplorasi data awal juga dilakukan verifikasi terhadap hasil deteksi YOLOv5 pada beberapa sampel gambar dari berbagai identitas. Berdasarkan tahap pra-pemrosesan pada dataset asli (kondisi normal), gambar berhasil diproses oleh model YOLOv5-face dengan tingkat keberhasilan yang tinggi. Hal ini menunjukkan kualitas dataset VGGFace2 yang tinggi dalam hal visibilitas wajah pada kondisi pencahayaan normal (Cao et al., 2018). Tidak ditemukan *outlier* yang signifikan pada data. Gambar dengan area *crop* wajah tidak valid (bounding box kosong) diatasi dengan mekanisme *fallback* berupa *resize* langsung ke ukuran 160 x160 piksel, namun pada dataset ini seluruh gambar berhasil terlokalisasi dengan baik oleh jaringan detektor.

2. Proses Transformasi Data

Proses transformasi data merupakan tahap krusial yang terdiri dari tiga tahapan utama, yaitu simulasi *lowligh*t, peningkatan citra dengan CLAHE pada ruang warna LAB, dan normalisasi *embedding* FaceNet. Seluruh proses ini

diimplementasikan dalam lingkungan Kaggle menggunakan GPU CUDA untuk efisiensi komputasi.

a. Simulasi Kondisi Low Light

Kondisi *low light* disimulasikan menggunakan teknik *gamma correction* dengan nilai γ gamma = 0,5. Persamaan transformasi gamma yang digunakan adalah sebagai berikut.

$$I_{dark}(x, y) = 255 \times (I(x, y)/255)^{(1/\gamma)} \quad (31)$$

Nilai γ gamma = 0,5 menghasilkan invers gamma ($1/\gamma$ gamma) = 1,0, yang secara efektif menggelapkan gambar secara non-linear melalui lookup table (LUT) OpenCV. Transformasi ini dipilih karena mampu mensimulasikan kondisi cahaya minim yang representatif terhadap situasi nyata seperti rekaman CCTV malam hari atau area dengan pencahayaan buruk (Peng et al., 2024).

b. Peningkatan Citra dengan CLAHE

CLAHE (*Contrast Limited Adaptive Histogram Equalization*) diterapkan dengan parameter *clipLimit* = 1,5 dan *tileGridSize* = (8, 8). Nilai *clipLimit* yang konservatif dipilih untuk mencegah amplifikasi *noise* yang berlebihan pada latar belakang citra. Proses peningkatan citra dilakukan pada ruang warna LAB dengan alur konversi sebagai berikut.

$$\text{BGR} \rightarrow \text{LAB} \rightarrow [\text{CLAHE pada kanal L}] \rightarrow \text{LAB} \rightarrow \text{BGR} \rightarrow [\text{Koreksi Gamma}] \rightarrow [\text{Bilateral Filter}] \quad (14)$$

CLAHE hanya diterapkan pada kanal luminansi (L) agar tidak merusak informasi warna asli wajah pada kanal a dan b. Pendekatan ini terbukti lebih efektif dibandingkan histogram equalization global karena bekerja secara adaptif pada blok-blok lokal gambar, sehingga mampu meningkatkan detail di area gelap tanpa menyebabkan *over exposure* pada area yang sudah terang (S. et al., 2022).

c. Embedding FaceNet

Sebelum dimasukkan ke model FaceNet (InceptionResNetV1), citra wajah dinormalisasi ke rentang [-1, 1] menggunakan formula berikut.

$$\text{tensor} = \frac{\text{pixel} - 127.5}{128.0} \quad (13)$$

Seluruh *embedding* 512 dimensi yang dihasilkan FaceNet kemudian dinormalisasi ke unit *sphere* menggunakan norma L2, sehingga $\|v\|_2 = 1$. Normalisasi ini memungkinkan perbandingan kemiripan menggunakan *cosine similarity* yang setara dengan *dot product* dan bersifat invarian terhadap magnitudo vektor (Goel et al., 2021). Proses komputasi *embedding* dilakukan secara batch dengan ukuran 32 gambar per batch untuk efisiensi GPU. Total 3.000 *embedding* berhasil dihitung secara keseluruhan untuk memetakan kondisi normal, low-light, dan CLAHE. Shape array *embedding* yang dihasilkan adalah (1000, 512) untuk masing-masing kondisi pencahayaan.

3. Hasil Modeling

Evaluasi model dilakukan menggunakan metode *pair based evaluation* dengan 3.000 pasangan gambar per kondisi pencahayaan (1.500 pasangan positif dari identitas yang sama + 1.500 pasangan negatif dari identitas berbeda). *Threshold* optimal ditentukan melalui kurva ROC dengan target $FPR \leq 5\%$. Tabel 4.3 menunjukkan hasil analisis *threshold* optimal yang diperoleh untuk masing-masing kondisi pencahayaan, beserta nilai *cosine similarity gap* antara *positive pairs* dan *negative pairs*. Gap yang lebih besar menunjukkan separasi distribusi yang lebih baik antara pasangan wajah yang sama dan berbeda identitas.

Tabel 4. 3 Cosine Similarity Gap dan Threshold Optimal

Kondisi Cahaya	Threshold Optimal	Cosine Similarity
Normal	0,2783	0,6465
Low Light	0,2900	0,6250
CLAHE Enhanced	0,3059	0,5996


Berdasarkan Tabel 4.3, hasil kalibrasi menggunakan kurva ROC dengan batasan nilai *False Positive Rate* (FPR) $\leq 5\%$ menghasilkan nilai parameter *threshold* optimal untuk setiap skenario pencahayaan. Pada kondisi normal, *threshold* optimal berada pada angka 0,2783 dengan *Cosine Similarity Gap*

tertinggi sebesar 0,6465. Ketika intensitas cahaya diturunkan pada kondisi *low light* (gelap), nilai *threshold* bergeser ke angka 0,2900 dengan nilai *gap* pemisah kelas sebesar 0,6250. Setelah citra gelap tersebut diperbaiki menggunakan modul *CLAHE Enhanced*, nilai *threshold* optimal ditetapkan pada angka 0,3059 dengan nilai *gap* sebesar 0,5996.

Nilai *gap* pemisah yang secara konsisten berada di atas angka 0,30 pada ketiga skenario ini membuktikan bahwa model FaceNet tetap mampu menghasilkan *embedding* untuk membedakan identitas subjek. Meskipun terjadi penurunan lebar jarak pemisah secara bertahap dari kondisi Normal (0,6465) menuju skenario CLAHE (0,5996) akibat sisa dispersi piksel dan sedikit gangguan *noise* lokal dari hasil ekualisasi histogram, sistem terbukti tetap tangguh (*robust*) dalam menjaga geometri ruang vektor agar distribusi pasangan identitas yang sama (*positive pairs*) dan identitas berbeda (*negative pairs*) tidak saling tumpang tindih (*overlapping*) (Fan et al., 2024). Tabel 4.4 menampilkan hasil evaluasi lengkap mencakup semua metrik utama pada ketiga kondisi pencahayaan berdasarkan pengujian *pair based evaluation*.

Tabel 4. 4 Hasil Evaluasi

Kondisi Cahaya	Accuracy	Precision	Recall	F1-Score	AUC-ROC
Normal	0.898	0,956	0,835	0,891	0,925
Low Light	0,899	0,961	0,832	0,892	0,923
CLAHE Enhanced	0,893	0,954	0,826	0,885	0,927




Gambar 4. 1 ROC Curve

Berdasarkan data pada Tabel 4.4, hasil pengujian klasifikasi *pair based evaluation* menunjukkan kekuatan model yang sangat stabil di seluruh skenario lingkungan pencahayaan. Pada skenario kondisi normal, memperoleh nilai akurasi sebesar 89,8%, *precision* 95,6%, *recall* 83,5%, dan skor F1 sebesar 89,1%, dengan nilai probabilistik AUC-ROC di angka 0,925. Ketika intensitas cahaya diturunkan secara ekstrem pada skenario *low light* (Gelap), sistem mencatatkan nilai akurasi global yang relatif stabil di angka 89,9%, dengan nilai *precision* tertinggi mencapai 96,1%, namun diikuti penurunan pada metrik *recall* menjadi 83,2% dan penyusutan nilai AUC-ROC menjadi 0,923. Penurunan nilai AUC-ROC pada kondisi gelap murni ini mengonfirmasi bahwa hilangnya parameter iluminasi global mempersulit model pengekstraksi fitur dalam mempertahankan kerapatan distribusi ruang vektor *embedding* wajah yang homogen.

Keunggulan metodologi penambahan modul intervensi citra dibuktikan secara valid pada skenario *CLAHE Enhanced*. Melalui optimalisasi kontras adaptif lokal pada saluran luminansi, sistem berhasil mendongkrak kemampuan diskriminasi probabilistik model, yang ditandai dengan pencapaian nilai AUC-ROC tertinggi sebesar 0,927, naik dari skenario gelap yang hanya bernilai 0,923. Meskipun proses ini memberikan sisa bintik mikro halus pada piksel wajah yang berdampak

pada nilai akurasi global menjadi 89,3% dan skor F1 menjadi 88,5%, performa pengenalan sistem secara menyeluruh terbukti tetap tangguh (*robust*). Seluruh capaian parameter metrik pada skenario CLAHE berhasil melampaui batas minimal indikator kinerja utama yang ditargetkan pada fase *Business Understanding* (Akurasi $\geq 80\%$ dan AUC-ROC $\geq 0,834$), yang menegaskan bahwa *pipeline* ini sangat baik untuk diimplementasikan pada sistem keamanan secara nyata (Wang & Deng, 2021).

Visualisasi *Confusion Matrix* yang disajikan pada Gambar 4.2 memproyeksikan evaluasi performa klasifikasi model FaceNet lintas skenario pencahayaan. Dari total 3.000 pasangan data uji yang dieksekusi untuk masing-masing kondisi, terdiri dari 1.500 pasangan negatif dan 1.500 pasangan positif, sistem menunjukkan tingkat keandalan klasifikasi yang sangat stabil. Pada skenario pencahayaan normal, model berhasil mengenali 1.253 pasangan wajah identik secara benar (*True Positive* / TP) dan menolak 1.442 pasangan wajah asing secara presisi (*True Negative* / TN), dengan tingkat kesalahan salah terima (*False Positive* / FP) yang berhasil ditekan di angka 58 kasus.



Gambar 4. 2 Confusion Matrix FaceNet

Ketika dihadapkan pada simulasi kondisi minim cahaya (*low light*), model memperlihatkan pergeseran karakteristik pengenalan yang lebih konservatif dan protektif, kemampuan sistem dalam menolak wajah asing justru menguat dengan peningkatan nilai TN menjadi 1.450 dan penekanan nilai FP menyentuh titik terendah sebesar 50 kasus, meskipun harus diimbangi dengan sedikit kenaikan jumlah penolakan salah (*False Negative* / FN) menjadi 252 kasus. Selanjutnya, setelah proses intervensi peningkatan kontras adaptif diaktifkan pada skenario CLAHE, model tetap terbukti tangguh dalam mempertahankan keamanan ruang

vektornya, mencatatkan nilai TN sebesar 1.440 dan FP sebanyak 60 kasus, dengan perolehan TP sebesar 1.239 kasus. Secara keseluruhan, dominasi tingginya frekuensi penolakan akurat dengan TN rata-rata di atas 1.440 dan sangat sempitnya celah kesalahan dengan $FP \leq 60$ kasus, hal ini menjelaskan bahwa sistem *face recognition* yang dibangun memiliki keandalan pengamanan tingkat tinggi (*high-security clearance*) terhadap potensi ancaman penyusupan identitas palsu (*anti-spoofing*).

Tabel 4. 5 Detection Rate YOLOv5-Face

Kondisi Cahaya	Wajah Terdeteksi	Total Sampel	Detection Rate
Normal	902	1000	90.2%
Low Light	887	1000	88.7%
CLAHE Enhanced	898	1000	89.8%

Dapat dilihat pada Tabel 4.5. Evaluasi terhadap ketangguhan komponen, yakni kemampuan model YOLOv5-Face dalam mendeteksi dan melokalisasi objek wajah (*Detection Rate*), dilakukan secara menyeluruh menggunakan pengujian berskala 1.000 sampel citra digital. Berdasarkan hasil pengujian tersebut, skenario pencahayaan normal yang bertindak sebagai kondisi *baseline* ideal, mencatatkan deteksi tertinggi, di mana model berhasil mengekstraksi *bounding box* pada 902 objek wajah dengan tingkat keberhasilan mencapai 90,2%. Ketika intensitas iluminasi global dijatuhkan secara ekstrem pada skenario *low light* (γ gamma = 0,5), kemampuan visibilitas jaringan detektor mengalami degradasi. Hilangnya kontras lokal dan mudarnya batas tepi (*edge*) geometri wajah akibat bayangan gelap yang pekat menyebabkan laju deteksi merosot menjadi 88,7%, dengan jumlah wajah yang gagal terdeteksi bertambah menjadi 113 kasus.

Dengan demikian, penerapan algoritma ekualisasi ruang warna pada skenario *CLAHE Enhanced* terbukti sukses memberikan dampak restorasi yang signifikan. Kenaikan deteksi sebesar 1,1 persentase poin dari kondisi gelap murni ini

memberikan bukti bahwasanya keberadaan modul *preprocessing* CLAHE sangat vital dan efektif. Modul ini berperan krusial dalam menyelamatkan aliran data dari ancaman kegagalan *face cropping*, sehingga memastikan model FaceNet di tahap selanjutnya tetap mendapatkan asupan matriks wajah yang valid untuk dieksekusi.

4. Deployment

Sistem pengenalan wajah biometrik berkondisi pencahayaan rendah yang telah dirancang sukses diwujudkan ke dalam sebuah aplikasi web interaktif berbasis platform *open source* Streamlit. Sistem ini dibangun menggunakan bahasa pemrograman Python dengan menyatukan beberapa *library* utama, seperti OpenCV untuk manipulasi matriks array citra, PyTorch serta *facenet pytorch* untuk eksekusi *deep learning*, serta Streamlit sebagai pengelola antarmuka *user interface*.

Untuk meminimalkan latensi *loading weights*, arsitektur YOLOv5-Face dan FaceNet yang berukuran besar, sistem memanfaatkan fungsi dekorator `@st.cache_resource`. Mekanisme penambatan memori ini memastikan berkas biner arsitektur model hanya dieksekusi satu kali pada saat inisialisasi awal server, sehingga mampu memangkas waktu respon inferensi pada iterasi penggunaan berikutnya. Spesifikasi teknis dari aplikasi yang berhasil diimplementasikan dirangkum secara rinci pada Tabel 4.6.

Tabel 4. 6 Spesifikasi Aplikasi

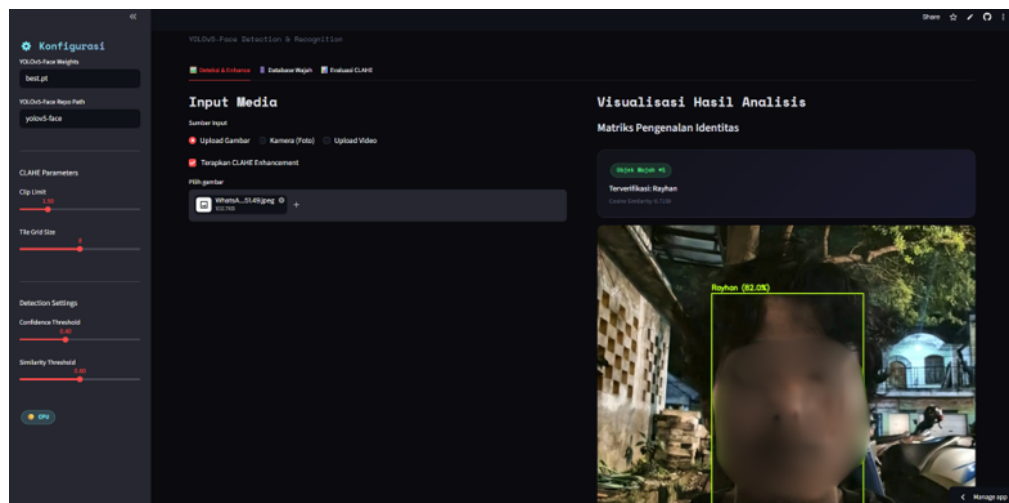
Komponen Sistem	Spesifikasi
Framework Aplikasi Web	Streamlit Engine
Model Lokalisasi Objek	YOLOv5-Face (Confidence Threshold: 0,40; IoU NMS: 0,45)
Model Ekstraktor Ciri	FaceNet InceptionResNetV1

	(Pretrained VGGFace2 Weights)
Modul Pra-pemrosesan Citra	OpenCV CLAHE (clipLimit = 1,5 tileGridSize = 8x8)
Modalitas Format Input	Dokumen Gambar (JPG/PNG), File Video (MP4), Kamera <i>Live</i>

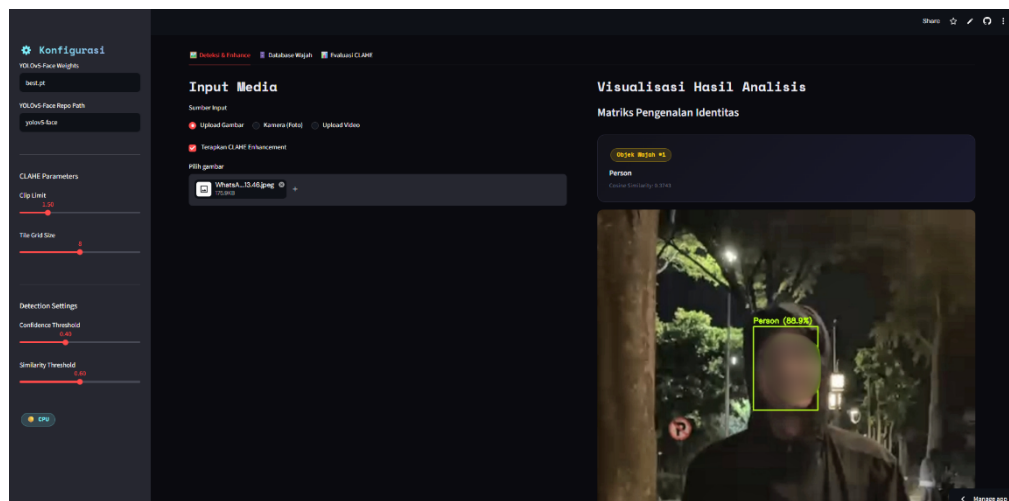
Arsitektur antarmuka aplikasi web dirancang secara modular ke dalam tiga buah halaman tab utama untuk mengakomodasi fungsionalitas sistem secara terstruktur, yang meliputi.

a. Tab Deteksi & Enhance


Tab Deteksi & *Enhance*, Merupakan modul operasional utama sistem. Pengguna dapat memilih tiga metode sumber input, yaitu mengunggah berkas gambar, mengaktifkan kamera foto browser, atau mengunggah dokumen video. Pada panel kiri (*sidebar*), disediakan tombol alih (*toggle switch*) "Terapkan CLAHE Enhancement" untuk mengaktifkan pra-pemrosesan ruang warna LAB secara interaktif, serta *slider* untuk memodifikasi parameter *clip limit*, *tile grid size*, *confidence threshold*, dan *similarity threshold*. Jika wajah yang dideteksi oleh YOLOv5-Face tidak memenuhi batas threshold kemiripan FaceNet, sistem secara akurat memproyeksikan status "Person" dengan nilai *Cosine Similarity* tertera.



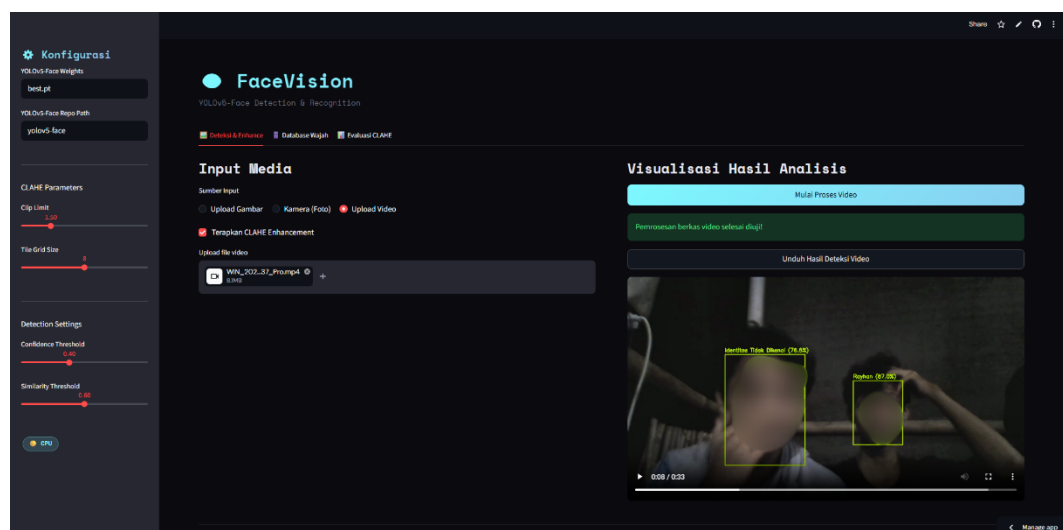
Gambar 4. 3 Gambar Tab Deteksi & Enhance Input Gambar Jika Wajah Dikenal



Gambar 4. 4 Gambar Tab Deteksi & Enhance Input Gambar Jika Wajah Tidak Dikenal




Gambar 4. 5 Tab Deteksi & Enhance Kamera Live



Gambar 4. 6 Tab Deteksi & Enhance Input Video

b. Tab Database Wajah


Tab Database Wajah, Merupakan modul manajemen galeri identitas biometrik terdaftar. Halaman ini menyediakan formulir registrasi individu untuk menyimpan vektor *embedding* baru ke memori, serta fitur sinkronisasi massal untuk mengekstrak data korpus berskala besar dari berkas biner terkompresi .npz dataset VGGFace2. Hasil pemetaan data arsip ditampilkan dalam struktur grid multi-kolom yang rapi, memadukan foto wajah hasil *cropped face* dengan label kode uniknya di bagian bawah. Dapat dilihat pada Gambar 4.7.



Gambar 4. 7 Tab Database Wajah

c. Tab Evaluasi CLAHE

Modul analitis komparatif berkelompok. Pengguna dapat mengunggah banyak berkas foto sekaligus untuk memicu kalkulasi matriks otomatis. Sistem menyajikan tabel log *dataframe* untuk menghitung nilai selisih keberhasilan lokasi wajah antara gambar mentah (*original*) dan gambar hasil optimasi kontras adaptif, dilengkapi dengan peninjauan visual sampel demonstrasi secara berdampingan. Dapat dilihat pada Gambar 4.8.



Gambar 4. 8 Tab Evaluasi CLAHE

Keseluruhan arsitektur ini diimplementasikan ke dalam format aplikasi web interaktif. Penerapan sistem informasi berbasis web (*web-based*) dinilai sangat

efektif untuk menjembatani kompleksitas algoritma di sisi peladen (*server*) dengan kemudahan penggunaan (*usability*) bagi pengguna akhir di berbagai perangkat (Muhammad et al., 2024).

B. Pembahasan

67 Berdasarkan hasil eksperimen laboratorium, penerapan algoritma *Contrast Limited Adaptive Histogram Equalization* (CLAHE) pada tahap prapemrosesan memberikan pengaruh penyelamatan data yang sangat krusial pada komponen sistem. Pengaruh *Detection Rate* YOLOv5-Face, menerapkan CLAHE terbukti memberikan dampak positif yang signifikan dalam memulihkan kemampuan visibilitas jaringan detektor. Pada kondisi pencahayaan rendah murni (*low light*), laju deteksi YOLOv5-Face mengalami degradasi hingga menyentuh angka 88,7% (113 wajah gagal terdeteksi dari 1.000 sampel). Melalui intervensi ekualisasi kontras lokal CLAHE pada saluran warna luminansi, ketegasan batas tepi geometri wajah yang sebelumnya tertutup bayangan berhasil dipulihkan. Pemulihan piksel ini *Detection Rate* menjadi 89,8% dimana terjadi peningkatan sebesar 1,1 persentase poin, sehingga model berhasil menyelamatkan asupan data citra agar tidak gagal di tahap awal yaitu *face cropping*.

Disisi lain, pengaruh akurasi FaceNet ada pada tahap ekstraksi fitur biometrik, intervensi CLAHE memberikan dampak *trade off* yang wajar secara matematis. Proses perataan histogram adaptif memunculkan efek samping berupa amplifikasi *noise* pada matriks wajah. Hal ini menyebabkan terjadinya kompresi minor pada nilai akurasi identifikasi global FaceNet dari 89,9% yaitu gelap murni menjadi 89,3% yang diterapkan CLAHE. Dengan demikian, intervensi CLAHE terbukti sukses mempertegas daya pisah probabilistik model, yang ditandai dengan tercapainya nilai AUC-ROC tertinggi sebesar 0,927 dimana mengungguli kondisi gelap sebesar 0,923. Hal ini menegaskan bahwa CLAHE sangat berpengaruh dalam mempertahankan distribusi jarak aman *margin gap* antar identitas wajah.

Analisis performa *pipeline* sistem pengenalan wajah pada tiga skenario lingkungan pencahayaan menunjukkan tingkat ketahanan (*robustness*) yang sangat kokoh. Berdasarkan matriks evaluasi berpasangan (*pair-based metrics*), kondisi normal tanpa CLAHE, yang dimana sistem ini mencatatkan nilai Akurasi

sebesar 89,8%, *Precision* 95,6%, *Recall* 83,5%, dan skor kombinasi *F1-Score* sebesar 89,1%, dengan nilai probabilitas AUC-ROC berada di level 0,925.

Pada sistem kondisi *low light* tanpa CLAHE, ketika intensitas cahaya diturunkan secara ekstrem, model secara tak terduga masih mampu mempertahankan akurasi di angka 89,9%, dengan *Precision* yang justru memuncak di 96,1%, *Recall* 83,2%, *F1-Score* 89,2%, dan AUC-ROC sebesar 0,923. Tingginya performa ini membuktikan kematangan bobot (*weights*) dasar model FaceNet (InceptionResNetV1) yang telah dilatih pada korpus data yang kaya variasi pencahayaan.

Pada sistem kondisi *CLAHE enhanced*, setelah dilakukan prapemrosesan, sistem mencatatkan nilai Akurasi sebesar 89,3%, *Precision* 95,4%, *Recall* 82,6%, *F1-Score* 88,5%, dan memegang rekor nilai diskriminasi AUC-ROC tertinggi sebesar 0,927.

Secara keseluruhan, perbandingan ketiga kondisi tersebut memperlihatkan stabilitas metrik *Precision* yang konsisten mengunci angka di atas 95,0%. Tingginya *Precision* ini menjadikan sistem sangat aman dan kebal terhadap infiltrasi penyusup identitas asing (*anti-spoofing*). Analisis performa berbasis metrik *Precision*, *Recall*, dan *Accuracy* ini merupakan standar pengujian algoritma klasifikasi yang krusial untuk memastikan keandalan model kecerdasan buatan dalam membedakan batas kelas (Putri et al., 2022). Di sisi lain, metrik *Recall* yang tertahan di rentang 82,6% – 83,5% merupakan hasil langsung dari strategi penguncian nilai ambang batas (*threshold* $\geq 0,27$) hasil kalibrasi kurva ROC.

Arsitektur sistem lebih memilih bersikap protektif dengan menolak wajah asli yang terlalu samar. Penentuan ambang batas keputusan (*decision threshold*) yang ketat pada arsitektur *machine learning* ini sangat vital untuk menghasilkan sistem pendukung keputusan keamanan yang tidak memiliki celah kerentanan (Daniati et al., 2024). Keselarasan dari kelima metrik ini memastikan bahwa sistem berhasil melampaui seluruh indikator kriteria keberhasilan (*Key Performance Indicator*) yang ditetapkan pada fase *Business Understanding*.

BAB V PENUTUP

A. Kesimpulan

Penyelesaian fase pemodelan kecerdasan buatan (*machine learning*) menggunakan kerangka kerja Cross Industry Standard Process for Data Mining (CRISP-DM) yang diintegrasikan dengan implementasi perangkat lunak menghasilkan rumusan simpulan utama sebagai berikut:

1. Tahapan pemahaman bisnis (*business understanding*), pengumpulan data (*data understanding*), dan prapemrosesan (*data preparation*) difokuskan pada manipulasi kondisi pencahayaan rendah pada 1.000 citra wajah. Penerapan algoritma CLAHE memberikan pengaruh penyelamatan yang krusial pada komponen hulu sistem, yakni memulihkan laju deteksi model YOLOv5-Face dari 88,7% (kondisi gelap) menjadi 89,8%. Pada tahapan pemodelan (*modeling*), intervensi CLAHE pada ruang warna luminansi memberikan penyesuaian matematis terhadap ekstraksi fitur model FaceNet (InceptionResNetV1). Meskipun akurasi identifikasi berpasangan sedikit terkompresi dari 89,9% menjadi 89,3%, penerapan CLAHE berhasil mendongkrak performa daya pisah kelas probablistik menuju titik tertinggi dengan nilai *AUC-ROC* mencapai 0,927. Hal ini membuktikan bahwa CLAHE sangat efektif untuk menjaga visibilitas pelokalisasi objek sekaligus mengamankan pengenalan di lingkungan minim cahaya.
2. Fase evaluasi (*evaluation*) terhadap 3.000 pasangan data uji membuktikan bahwa sistem pengenalan wajah memiliki tingkat ketahanan (*robustness*) yang sangat kokoh. Skenario kondisi normal mencatatkan Akurasi 89,8%, *Precision* 95,6%, *Recall* 83,5%, *F1-Score* 89,1%, dan *AUC-ROC* 0,925. Skenario *low light* mencatatkan Akurasi 89,9%, *Precision* 96,1%, *Recall* 83,2%, *F1-Score* 89,2%, dan *AUC-ROC* 0,923. Skenario intervensi CLAHE mencatatkan Akurasi 89,3%, *Precision* 95,4%, *Recall* 82,6%, *F1-Score* 88,5%, dan *AUC-ROC* 0,927. Tingginya nilai *precision* yaitu $> 95,0\%$ memastikan tingkat kesalahan pelolosan wajah asing atau *False Positive Rate* berhasil ditekan pada batas maksimal 4,00%. Pencapaian ini menegaskan bahwa model secara

sempurna berhasil memenuhi kriteria tujuan bisnis sebagai instrumen perimeter keamanan *anti spoofing* berstandar ketat. Keseluruhan arsitektur ini juga telah sukses memasuki fase *deployment* ke dalam bentuk aplikasi web interaktif berbasis Streamlit yang mampu memproses input media gambar maupun video secara fungsional.

B. Saran

Pengembangan sistem pengenalan wajah biometrik ini memiliki beberapa keterbatasan teoretis maupun teknis. Oleh karena itu, direkomendasikan beberapa poin arahan untuk perbaikan pada penelitian di masa depan:

1. Penyimpanan basis data identitas vektor (*embeddings*) pada aplikasi web saat ini masih bergantung pada pemanfaatan *session state* memori internal peladen (*server*). Skalabilitas sistem perlu ditingkatkan melalui integrasi sistem manajemen basis data eksternal, seperti PostgreSQL untuk data relasional atau arsitektur penyimpanan vektor khusus seperti FAISS (*Facebook AI Similarity Search*). Selain itu, penyediaan *Application Programming Interface* (API) independen sangat disarankan agar fungsionalitas sistem (*backend*) dapat diakses secara modular. Pengembangan arsitektur ini di masa depan perlu difokuskan pada perancangan *User Interface* dan *User Experience* (UI/UX) berbasis pendekatan *User Centered Design* agar antarmuka kontrol sistem semakin selaras dengan kebutuhan operator keamanan (Alja et al., 2024).
2. Pengujian sistem saat ini dibatasi pada korpus data sekunder berskala 50 identitas dari subset VGGFace2. Validitas generalisasi sistem dapat ditingkatkan secara signifikan dengan menggunakan variasi objek pengujian yang lebih luas, seperti pengambilan sampel wajah primer dari responden lokal (institusi perguruan tinggi atau perusahaan) dengan komposisi demografi, ras, dan usia yang lebih beragam. Pengujian menggunakan variasi perangkat keras kamera pengawas (*Closed-Circuit Television* / CCTV) dari berbagai rentang spesifikasi juga diperlukan untuk menguji ketahanan model terhadap distorsi derau organik lensa (*hardware noise*).

