

**IMPLEMENTASI ALGORITMA REAL-TIME DETECTION
TRANSFORMER (RT-DETR) UNTUK DETEKSI
KELELAHAN DAN TINGKAT KELELAHAN
(DROWSINESS) PENGENDARA BERBASIS
FACE RECOGNITION**

SKRIPSI

DISUSUN OLEH

PEMAS TIANDIKA

NPM. 2209020260



UMSU

Unggul | Cerdas | Terpercaya

**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

MEDAN

2026

**IMPLEMENTASI ALGORITMA REAL-TIME DETECTION
TRANSFORMER (RT-DETR) UNTUK DETEKSI
KELELAHAN DAN TINGKAT KELELAHAN
(DROWSINESS) PENGENDARA BERBASIS
FACE RECOGNITION**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer
(S.Kom) dalam Program Studi Teknologi Informasi. pada Fakultas Ilmu Komputer
dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara**

PEMAS TIANDIKA

NPM. 2209020260

**PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

MEDAN

2026

LEMBAR PENGESAHAN

Judul Skripsi : IMPLEMENTASI ALGORITMA REAL-TIME
DETECTION TRANSFORMER (RT-DETR) UNTUK
DETEKSI KELELAHAN DAN TINGKAT
KELELAHAN (DROWSINESS) PENGENDARA
BERBASIS FACE RECOGNITION

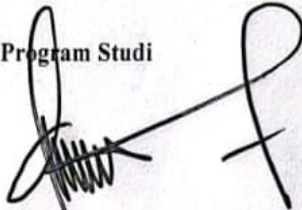
Nama Mahasiswa : PEMAS TIANDIKA
NPM : 2209020260
Program Studi : TEKNOLOGI INFORMASI

Menyetujui
Komisi Pembimbing



(Dr. Al-Khowarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

Ketua Program Studi



(Fatma Sari Hutagalung, S.Kom., M.Kom.)
NIDN. 0117019301

Dekan



(Dr. Al-Khowarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

PERNYATAAN ORISINALITAS

**IMPLEMENTASI ALGORITMA REAL-TIME DETECTION
TRANSFORMER (RT-DETR) UNTUK DETEKSI
KELELAHAN DAN TINGKAT KELELAHAN
(DROWSINESS) PENGENDARA BERBASIS
FACE RECOGNITION**

SKRIPSI

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan, 07 April 2026

Yang membuat pernyataan



Pemas Tiandika

NPM. 2209020260

**PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN
AKADEMIS**

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama : PEMAS TIANDIKA
NPM : 220902060
Program Studi : TEKNOLOGGI INFORMASI
Karya Ilmiah : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bedas Royalti Non-Eksekutif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul **IMPLEMENTASI ALGORITMA REAL-TIME DETECTION TRANSFORMER (RT-DETR) UNTUK DETEKSI KELELAHAN DAN TINGKAT KELELAHAN (DROWSINESS) PENGENDARA BERBASIS FACE RECOGNITION.**

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksekutif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, 07 April 2026

Yang membuat pernyataan



Pemas Tiandika

NPM. 2209020260

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap : Pemas Tiandika
Tempat dan Tanggal Lahir : Ajamu, 26 febuari 2004
Alamat Rumah : Sungai Sentosa
Telepon/Faks/HP : 082361324287
E-mail : pemastiandika@gmail.com
Instansi Tempat Kerja : -
Alamat Kantor : -

DATA PENDIDIKAN

SD : SDN 112204 CINTA MAKMUR TAMAT: 2016
SMP : SMPN 1 PANAI HULU TAMAT: 2019
SMA : SMAN 1 PANAI HULU TAMAT: 2022

KATA PENGANTAR



Assalamu'alaikum warahmatullahi wabarakatuh,

Puji syukur kehadiran Allah SWT atas segala rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan laporan/proposal ini dengan baik. Laporan ini disusun sebagai bagian dari tugas akhir dalam menyelesaikan studi pada Program Studi Teknologi Informasi, Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara (UMSU). Dalam era digital yang berkembang pesat saat ini, peran teknologi informasi menjadi semakin penting dalam berbagai bidang kehidupan. Oleh karena itu, melalui laporan ini, penulis berupaya mengangkat isu dan solusi berbasis teknologi yang relevan dengan kebutuhan masyarakat modern, dengan harapan dapat memberikan kontribusi positif dalam pengembangan ilmu pengetahuan dan pemanfaatan teknologi secara berkelanjutan. Penulis menyadari bahwa tanpa dukungan dan bimbingan dari berbagai pihak, penyusunan laporan ini tidak akan berjalan lancar. Oleh karena itu, dengan segala kerendahan hati, Penulis menyampaikan terima kasih dan penghargaan yang sebesar-besarnya kepada:

1. Bapak Prof. Dr. Akrim, M.Pd. Rektor Universitas Muhammadiyah Sumatera Utara (UMSU)
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Ibu Dr. Firaahmi Rizky, S.Kom.,M.Kom. Wakil Dekan I Fakultas Ilmu Komputer dan Teknologi Informasi
4. Bapak Mhd. Basri, S.Si, M.Kom. Wakil Dekan III Fakultas Ilmu Komputer dan Teknologi Informasi.
5. Ibu Fatma Sari Hutagalung, S.Kom., M.Kom. Ketua Program Studi Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.

6. Bapak Okvi Nugroho, S.Kom., M.Kom. Sekretaris Program Studi Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
7. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. Dosen pembimbing yang telah membantu dan membimbing penulis serta memberikan arahan penulis dalam mengerjakan tugasnya.
8. Terima kasih yang tulus penulis sampaikan kepada Bapak dan Ibu tercinta. Berkat doa, kasih sayang, dan pengorbanan kalian menjadi kekuatan terbesar dalam setiap langkah penulis hingga mampu melewati proses ini. Semoga pencapaian ini menjadi bagian dari kebahagiaan dan kebanggaan kalian, sebagaimana kalian yang tidak pernah menyerah untuk pencapaian ini.
9. Penulis juga mengucapkan terima kasih yang tulus kepada sahabat sahabat tercinta, yang selalu hadir dengan dukungan, tawa, dan semangat di setiap perjalanan. Kehadiran kalian menjadi penguat di saat sulit dan pelengkap di setiap momen berharga. Semoga kebersamaan ini tetap terjaga hingga akhir waktu.

**IMPLEMENTASI ALGORITMA REAL-TIME DETECTION
TRANSFORMER (RT-DETR) UNTUK DETEKSI
KELELAHAN DAN TINGKAT KELELAHAN
(DROWSINESS) PENGENDARA BERBASIS
FACE RECOGNITION**

ABSTRAK

Kecelakaan lalu lintas merupakan salah satu permasalahan utama dalam sektor transportasi yang sebagian besar disebabkan oleh faktor manusia, khususnya kelelahan dan kantuk saat berkendara. Kondisi ini dapat menurunkan tingkat kewaspadaan dan memicu terjadinya *microsleep* yang berisiko tinggi terhadap kecelakaan. Penelitian ini bertujuan untuk mengimplementasikan algoritma Real-Time Detection Transformer (RT-DETR) dalam mendeteksi dan mengklasifikasikan tingkat kelelahan pengemudi berbasis *face recognition*. Sistem yang dikembangkan memanfaatkan citra wajah dengan fokus pada indikator visual seperti kondisi mata dan aktivitas mulut. Dataset yang digunakan terdiri dari sekitar 3.000 citra yang dibagi ke dalam tiga kategori, yaitu normal, kelelahan sedang, dan kelelahan berat. Proses penelitian meliputi pengumpulan data, *preprocessing*, anotasi, pelatihan model, serta evaluasi menggunakan metrik *precision*, *recall*, *F1-score*, dan *mean Average Precision (mAP)*. Hasil penelitian menunjukkan bahwa model RT-DETR memiliki performa yang sangat baik dengan nilai *mAP@0.5* sebesar 0,939, *precision* sebesar 0,94, *recall* sebesar 0,93, serta *F1-score* sebesar 0,95. Sistem juga mampu berjalan secara *real-time* dengan kecepatan 10-13 FPS. Dengan demikian, RT-DETR efektif digunakan untuk deteksi kelelahan pengemudi secara akurat dan responsif.

Kata kunci: RT-DETR, deteksi kelelahan, *drowsiness*, computer vision, *real-time*

IMPLEMENTATION OF REAL-TIME DETECTION TRANSFORMER (RT-DETR) ALGORITHM FOR FATIGUE AND DROWSINESS DETECTION OF DRIVER BASED ON FACE RECOGNITION

ABSTRACT

Traffic accidents are one of the major problems in the transportation sector, largely caused by human factors, particularly driver fatigue and drowsiness. This condition reduces alertness and may lead to microsleep, which significantly increases accident risk. This study aims to implement the Real-Time Detection Transformer (RT-DETR) algorithm to detect and classify driver fatigue levels based on face recognition. The proposed system utilizes facial image data focusing on visual indicators such as eye conditions and mouth activity. The dataset consists of approximately 3,000 images categorized into three classes: normal, moderate fatigue, and severe fatigue. The research process includes data collection, preprocessing, annotation, model training, and evaluation using precision, recall, F1-score, and mean Average Precision (mAP). The results show that the RT-DETR model achieves excellent performance with an mAP@0.5 of 0.939, precision of 0.94, recall of 0.93, and F1-score of 0.95. The system is also capable of operating in real-time at 10-13 FPS. Therefore, RT-DETR is effective for accurate and responsive driver fatigue detection.

Keywords: RT-DETR, fatigue detection, drowsiness, computer vision, real-time

DAFTAR ISI

LEMBAR PENGESAHAN	i
PERNYATAAN ORISINALITAS.....	ii
KATA PENGANTAR.....	v
ABSTRAK	vii
ABSTRACT.....	viii
DAFTAR ISI.....	ix
DAFTAR TABEL	xi
DAFTAR GAMBAR.....	xii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang Masalah.....	1
1.2 Rumusan Masalah	2
1.3 Batasan Masalah.....	3
1.4 Tujuan Penelitian	3
BAB II LANDASAN TEORI	4
2.1 Konsep Dasar	4
2.2.1. Definisi Kelelahan (Fatigue)	4
2.2.2. Tingkatan Kelelahan atau Ngantuk Pengendara	4
2.2.3. Facial Landmarks dan MediaPipe Face Mesh	6
2.2.4. Eye Aspect Ratio (EAR) dan Mouth Aspect Ratio (MAR)	6
2.2.5. Indikator Visual Kelelahan	6
2.2 Teknologi Pendukung	8
2.3.1. Computer Vision	8
2.3.2. Real-Time Detection Transformer (RT-DETR).....	8
2.3.3. Bahasa Pemrograman Python	9
2.3 RINGKASAN PENELITIAN TERDAHULU	10
2.4 ANALISIS GAP	11
BAB III METODOLOGI PENELITIAN	13
3.1 Tahapan Penelitian	13
3.2 Pengumpulan Data	19
3.3 Jenis Data	19
3.4 Sumber Data.....	20
3.5 Waktu Pengumpulan Data	20
3.6 Jumlah Data.....	20
3.7 Format Data.....	21

3.8	Metode Penelitian.....	21
3.9	Operasi Algoritma.....	23
3.10	Alur Pelatihan Model.....	27
3.11	Pseudocode singkat (algoritma pelatihan)	29
3.12	Langkah evaluasi.....	30
BAB IV HASIL DAN PEMBAHASAN		32
4.1	Perhitungan Manual Matrix Evaluasi.....	32
4.1.1	Perhitungan Precision	33
4.1.2	Perhitungan Recall	34
4.1.3	Perhitungan F1-Score.....	35
4.1.4	Perhitungan Akurasi.....	35
4.2	Hasil Pelatihan Model (Training)	37
4.3	Hasil Evaluasi Model	38
4.3.1	Precision-Recall Curve.....	39
4.3.2	F1-Score Curve	40
4.3.3	Precision-Confidence Curve	41
4.3.4	Confusion Matrix Normalized	42
4.3.5	Analisis Keseluruhan Evaluasi Model	42
4.4	Hasil Implementasi Sistem.....	43
4.5	Pembahasan.....	46
4.5.1	Analisis Performa Model Real-Time Detection Transformer.....	46
4.5.2	Analisis Kelebihan dan Kekurangan Model	48
BAB V PENUTUP.....		50
5.1	Kesimpulan	50
5.2	Saran.....	51
DAFTAR PUSTAKA.....		53

DAFTAR TABEL

Tabel 2.3 Ringkasan Penelitian Terdahulu.....	10
---	----

DAFTAR GAMBAR

Gambar 3.1 Diagram Alur Penelitian.....	13
Gambar 3.2 Contoh Citra Dataset Mengantuk.....	20
Gambar 3.3 Contoh Citra Dataset Tidak mengantuk (Normal).....	20
Gambar 3.4 Arsitektur RT -DETR.....	21
Gambar 3.5 Operasi Algoritma.....	23
Gambar 3.6 Alur Pelatihan Model.....	26
Gambar 4.1 Confusion Matrik.....	32
Gambar 4.2 Hasil Pelatihan Model.....	36
Gambar 4.3 Precision-Recall Curve.....	38
Gambar 4.4 F1-Score curve.....	39
Gambar 4.5 Precision-Confidence Curve.....	40
Gambar 4.6 Confusion Matrix Normalized.....	41
Gambar 4.7 Terdeteksi Kondisi Normal.....	43
Gambar 4.8 Terdeteksi Kondisi Kelelahan Sedang.....	43
Gambar 4.9 Terdeteksi Kondisi Kelalahan berat.....	44

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Kecelakaan lalu lintas merupakan salah satu permasalahan utama dalam sektor transportasi di Indonesia yang memiliki tingkat fatalitas tinggi. Berdasarkan data statistik nasional, jumlah kecelakaan lalu lintas mengalami tren peningkatan dengan kenaikan rata-rata sebesar 6,25% setiap tahunnya. Faktor kesalahan manusia (*human error*) tercatat sebagai penyebab dominan, di mana aspek internal pengemudi menyumbang angka sebesar 28% dari total kecelakaan, yang sebagian besar dipicu oleh kondisi kelelahan saat berkendara (Rahmawati et al., 2023; Oktavia et al., 2022).

Kondisi kelelahan (*fatigue*) yang berkepanjangan pada pengemudi, khususnya pada sektor transportasi *online* dan logistik, sering kali disebabkan oleh durasi waktu kerja yang melebihi ambang batas normal serta kuantitas tidur yang tidak memadai. Penelitian menunjukkan bahwa mayoritas pengemudi ojek *online* mengalami kelelahan tingkat sedang (79,3%) akibat tuntutan pekerjaan yang tinggi (Ar-Syamet et al., 2023). Jika kondisi ini diabaikan, pengemudi akan memasuki fase kantuk (*drowsiness*) yang memicu *micro-sleep*, yaitu episode hilangnya kesadaran singkat selama beberapa detik yang menjadi penyebab utama fatalitas dalam kecelakaan lalu lintas (Hamrul et al., 2025; Samsinar et al., 2024).

Dalam aspek algoritma deteksi objek secara real-time, model *You Only Look Once* (YOLO) telah lama menjadi standar karena kecepatannya (Justitian et al., 2022; Fauzan et al., 2022). Namun, tantangan utama dalam deteksi kelelahan

adalah kebutuhan akan akurasi yang lebih presisi tanpa mengorbankan kecepatan pemrosesan (*latency*). Saat ini, telah dikembangkan arsitektur terbaru yaitu *Real-Time Detection Transformer* (RT-DETR). RT-DETR merupakan detektor berbasis *transformer* pertama yang mampu bekerja secara *real-time* dengan performa akurasi yang lebih unggul dibandingkan varian YOLO dalam mendeteksi fitur-fitur wajah yang kompleks dan dinamis (Wan et al., 2024; Radzi et al., 2025).

Berdasarkan permasalahan dan potensi teknologi tersebut, maka dilakukan penelitian dengan judul Implementasi Algoritma Real-Time Detection Transformer (RT-DETR) untuk Deteksi Kelelahan dan Tingkat Kelelahan (Drowsiness) Pengendara Berbasis Face Recognition. Penggunaan algoritma RT-DETR diharapkan dapat memberikan hasil deteksi yang lebih akurat dan responsif dalam mengenali gejala kelelahan pengemudi, sehingga dapat memberikan peringatan dini yang efektif untuk menekan angka kecelakaan lalu lintas.

1.2 Rumusan Masalah

Permasalahan utama yang sering terjadi di jalan raya adalah kecelakaan akibat pengemudi yang mengalami kelelahan atau kantuk, menimbulkan dampak fatal bagi diri sendiri maupun pengguna jalan lainnya. Tantangan utama dalam penanganan masalah ini adalah rendahnya kesadaran pengemudi terhadap kondisi kelelahan yang dialami, terutama karena fenomena *microsleep* terjadi secara tiba-tiba tanpa disadari. Teknologi deteksi kelelahan yang tersedia saat ini masih memiliki berbagai keterbatasan, kurangnya akurasi dan responsivitas ketika digunakan pada kondisi nyata, misalnya pada pencahayaan redup, perubahan posisi wajah, atau sudut pandang kamera yang tidak ideal. Sistem deteksi untuk

keselamatan berkendara dituntut mampu bekerja secara real-time tanpa jeda (delay) agar dapat memberikan peringatan dini sebelum terjadi kecelakaan.

1.3 Batasan Masalah

Penelitian ini memiliki batasan permasalahan yang dibahas agar dapat menyelesaikan permasalahan utama. Berikut ini batasan masalah penelitian ini

1. Algoritma Utama Penelitian ini hanya berfokus pada implementasi dan pengujian algoritma RT-DETR (Real-Time Detection Transformer), tidak membandingkan secara mendalam dengan semua jenis algoritma *object detection* lainnya.
2. Data Penelitian Menggunakan dataset visual wajah (mata dan mulut) dari dataset publik dan rekaman kamera standar, tanpa menggunakan sensor tubuh.
3. Evaluasi Performa Fokus pada pengukuran akurasi (mAP) dalam mendeteksi kantuk dan kecepatan (FPS) agar sistem terbukti berjalan secara real-time.

1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk menguji algoritma algoritma RT-DETR (Real-Time Detection Transformer) untuk deteksi kelelahan dan tingkat kelelahan pengemudi secara akurat ke dalam beberapa kategori, yaitu Normal, Sedang, dan Berat, serta tetap stabil pada berbagai kondisi lingkungan dan membangun sistem deteksi berbasis model Transformer yang mampu bekerja secara responsif dan real-time, sehingga dapat menjadi solusi teknologi dalam menekan angka kecelakaan lalu lintas akibat faktor kelelahan sekaligus memberikan kontribusi

ilmiah dalam pengembangan metode pengawasan keselamatan berbasis kecerdasan buatan.

BAB II

LANDASAN TEORI

2.1 Konsep Dasar

2.2.1. Definisi Kelelahan (Fatigue)

Kelelahan (*fatigue*) merupakan suatu kondisi kompleks yang melibatkan penurunan efisiensi kerja dan daya tahan tubuh, baik secara fisik maupun psikologis, yang bersifat subjektif bagi setiap individu (Fauzan et al., 2022). Dalam aktivitas berkendara, kelelahan mengakibatkan penurunan fokus dan waktu reaksi (*reaction time*) terhadap stimulus lingkungan jalan raya (Oktavia dkk., 2022). Kondisi ini menciptakan risiko tinggi di mana pengendara kehilangan kemampuan untuk mengambil keputusan secara cepat dan tepat dalam situasi darurat.

2.2.2. Tingkatan Kelelahan atau Ngantuk Pengendara

Tingkatan kelelahan pada pengendara tidak terjadi secara instan, melainkan melalui tahapan transisi yang memengaruhi kemampuan motorik dan kognitif secara bertahap. Mengacu pada berbagai literatur penelitian kelelahan pengendara, tingkat kelelahan dapat diklasifikasikan menjadi tiga kategori utama untuk menentukan urgensi intervensi sistem:

1. Pada kondisi tidak ngantuk (normal), hasil data menunjukkan bahwa mata tertutup hanya terjadi dalam durasi kedipan normal. Mengacu pada data fisiologis yang menyatakan bahwa kedipan normal manusia berlangsung

antara 100 hingga 400 milidetik (0,1–0,4 detik). Dalam sistem video 15 frame per detik, durasi ini setara dengan sekitar 6 frame berturut-turut. Pada pengujian sistem, frame dengan mata tertutup hingga batas ini tidak memicu peringatan dan secara konsisten diklasifikasikan sebagai kondisi normal. Data ini memperkuat ciri bahwa mata tertutup singkat merupakan karakteristik kewaspadaan normal dan tidak berhubungan dengan ngantuk.

2. Kelelahan sedang Kondisi ini ditandai yang ditandai dengan mata tertutup dalam durasi yang lebih panjang dan berulang. Berdasarkan analisis temporal yang dilakukan, mata tertutup dalam rentang 0,5 hingga 4 detik, atau sekitar 8 hingga 60 frame berturut-turut, menunjukkan kondisi ngantuk yang semakin signifikan. Pada tahap ini, respon pengendara terhadap lingkungan melambat dan risiko kesalahan berkendara meningkat. Data ini digunakan secara langsung dalam sistem adaptive frame threshold untuk membedakan ngantuk dari kedipan biasa.
3. Kelelahan berat Ini merupakan tingkat paling berbahaya yang ditandai dengan mata tertutup selama beberapa detik tanpa disadari oleh pengendara. Menjelaskan bahwa durasi mata tertutup mendekati batas atas rentang tersebut, yaitu sekitar 4 detik atau lebih, mencerminkan kondisi kehilangan kesadaran sesaat. Pada fase ini, pengendara secara fungsional tidak mampu memproses informasi visual, sehingga risiko kecelakaan meningkat secara drastis. Microsleep inilah yang menjadi target utama sistem deteksi ngantuk karena dampaknya yang fatal.

Berdasarkan tingkat kelelahan di atas, hasil eksperimen yang dilakukan oleh (Essel et al., 2025) menunjukkan bahwa durasi mata tertutup yang diukur

melalui parameter Eye Closure Ratio (ECR) dan jumlah frame berturut-turut merupakan indikator kuantitatif yang paling kuat dalam membedakan tingkat ngantuk pengendara. Dalam pengujian berbasis 1000 citra wajah manusia dan data video kontinu berdurasi panjang, penulis membuktikan bahwa semakin lama durasi mata tertutup, semakin tinggi tingkat ngantuk yang terdeteksi oleh sistem. Data ini memperkuat anggapan bahwa ngantuk merupakan kondisi bertahap yang dapat diklasifikasikan secara objektif berdasarkan perilaku mata.

2.2.3. Facial Landmarks dan MediaPipe Face Mesh

Facial landmarks adalah titik-titik koordinat tertentu pada wajah yang digunakan untuk menganalisis geometri wajah. Teknologi *MediaPipe Face Mesh* menyediakan pemetaan hingga 468 titik wajah dalam ruang tiga dimensi (3D), yang memungkinkan analisis terhadap area mata dan mulut dilakukan dengan sangat detail meskipun terdapat pergerakan kepala (Hamrul et al., 2025).

2.2.4. Eye Aspect Ratio (EAR) dan Mouth Aspect Ratio (MAR)

EAR Adalah parameter numerik yang dihitung berdasarkan jarak antara titik-titik *landmark* pada kelopak mata atas dan bawah. Nilai EAR yang mengecil di bawah ambang batas (*threshold*) tertentu menandakan kondisi mata tertutup (Samsinar et al., 2024). MAR Digunakan untuk menghitung rasio keterbukaan mulut. Peningkatan nilai MAR yang signifikan dan berulang diidentifikasi sebagai aktivitas menguap (Hamrul et al., 2025).

2.2.5. Indikator Visual Kelelahan

Secara visual, transisi seorang pengemudi dari kondisi bugar ke kondisi lelah dan mengantuk dapat diidentifikasi melalui perubahan morfologi dan aktivitas pada area wajah. Indikator ini merupakan data mentah yang akan

ditangkap oleh kamera dan diproses oleh algoritma RT-DETR untuk diklasifikasikan ke dalam tingkat kelelahan tertentu. Berikut adalah rincian indikator visual yang digunakan dalam penelitian ini:

1. Aktivitas Kelopak Mata (*Eye Activity*) Ini merupakan indikator yang paling valid dalam mendeteksi *drowsiness*. Fokus utama terletak pada frekuensi kedipan dan durasi penutupan mata. Pada kondisi normal, manusia berkedip secara cepat (sekitar 0,1 hingga 0,4 detik). Namun, saat lelah, frekuensi kedipan akan melambat dan durasi mata tertutup akan memanjang (*long closure duration*). Jika mata tertutup lebih dari 0,5 hingga 0,8 detik, sistem mengidentifikasi hal tersebut sebagai gejala *micro-sleep* (Samsinar et al., 2024; Rahayu et al., 2022).
2. Aktivitas menguap (*yawning*) adalah sebagai ciri pendukung tingkat ngantuk. Berdasarkan pengujian pada dataset YawDD, menunjukkan bahwa nilai Mouth Aperture Ratio (MAR) yang melebihi 0.4 menandakan aktivitas menguap dengan durasi antara 4 hingga 6 detik. Data menunjukkan bahwa menguap jarang muncul pada kondisi waspada, tetapi frekuensinya meningkat pada tingkat ngantuk sedang dan berat. Ketika menguap terjadi bersamaan dengan mata tertutup lebih lama, probabilitas pengemudi berada pada tingkat ngantuk tinggi meningkat secara signifikan (Essel et al., 2025)

2.2 Teknologi Pendukung

2.3.1. Computer Vision

Computer vision adalah cabang kecerdasan buatan yang memungkinkan sistem komputer untuk memperoleh pemahaman tingkat tinggi dari citra digital atau video. Dalam sistem ini, *face recognition* digunakan bukan untuk otentikasi identitas, melainkan untuk lokalisasi wajah dan ekstraksi fitur wajah secara *real-time* (Samsinar et al., 2024).

2.3.2. Real-Time Detection Transformer (RT-DETR)

Real-Time Detection Transformer (RT-DETR) merupakan pengembangan arsitektur deteksi objek berbasis transformer yang dirancang untuk mengoptimalkan keseimbangan antara akurasi dan kecepatan inferensi pada aplikasi real-time. RT-DETR hadir sebagai penyempurnaan dari Detection Transformer (DETR) yang memiliki akurasi tinggi, namun masih terbatas dari sisi efisiensi komputasi (Lv et al., 2023). Berbeda dengan pendekatan Convolutional Neural Network (CNN) seperti YOLO yang masih memerlukan proses *Non-Maximum Suppression* (NMS), RT-DETR menerapkan mekanisme *end-to-end object detection* sehingga mampu menghasilkan prediksi bounding box secara langsung tanpa proses penyaringan tambahan, yang berdampak pada penurunan latensi sistem (Lv et al., 2023; Wan et al., 2024).

Secara struktural, RT-DETR terdiri atas backbone untuk ekstraksi fitur visual, hybrid encoder berbasis self-attention untuk mengintegrasikan fitur multi-skala, serta transformer decoder yang melakukan prediksi objek melalui pendekatan query-based detection. Mekanisme global self-attention memungkinkan model memahami hubungan spasial antar fitur secara menyeluruh,

sehingga lebih efektif dalam mendeteksi indikator visual kelelahan seperti mata terpejam dan aktivitas menguap yang terjadi secara dinamis. Penelitian menunjukkan bahwa RT-DETR mampu mencapai performa *mean Average Precision* (mAP) yang kompetitif dengan model YOLO terbaru, dengan efisiensi komputasi yang lebih stabil pada objek kecil dan kondisi pencahayaan kompleks (Nurul Huda et al., 2024). Oleh karena itu, RT-DETR dipilih dalam penelitian ini karena mampu memberikan kombinasi optimal antara kecepatan, latensi rendah, dan presisi deteksi dalam sistem peringatan dini kelelahan pengemudi berbasis visi komputer.

2.3.3. Bahasa Pemrograman Python

Bahasa pemrograman Python dipilih sebagai instrumen utama dalam pengembangan sistem ini karena karakteristiknya yang interpretatif, berorientasi objek, serta memiliki struktur sintaksis yang efisien dan mudah dipahami dalam lingkungan akademik maupun profesional. Dalam domain *artificial intelligence* dan *deep learning*, Python telah menjadi standar industri karena menyediakan ekosistem pustaka (*library*) yang sangat luas dan matang. Penggunaan Python memungkinkan integrasi yang mulus antara berbagai kerangka kerja tingkat tinggi seperti *PyTorch* untuk implementasi algoritma RT-DETR, *MediaPipe* untuk ekstraksi fitur wajah, serta *OpenCV* (*Open Source Computer Vision Library*) untuk manipulasi citra dan aliran video secara *real-time*.

Keunggulan utama Python dalam penelitian ini terletak pada kemampuannya mengelola komputasi numerik yang kompleks dengan performa yang optimal melalui pustaka pendukung seperti *NumPy*. Selain itu, sifatnya yang lintas platform (*cross-platform*) menjamin bahwa sistem deteksi kelelahan yang

dikembangkan dapat diimplementasikan pada berbagai lingkungan perangkat keras, mulai dari perangkat komputer personal hingga sistem tertanam (*embedded systems*). Fleksibilitas ini sangat krusial dalam memastikan bahwa algoritma RT-DETR dapat berjalan dengan latensi yang rendah, sehingga proses pengambilan keputusan untuk mengaktifkan *warning alert* dapat dilakukan dalam hitungan milidetik setelah gejala kelelahan terdeteksi (Samsinar et al., 2024; Fauzan et al., 2022).

2.3 RINGKASAN PENELITIAN TERDAHULU

Penelitian mengenai sistem deteksi kelelahan pengemudi dalam penelitian ini didasarkan pada serangkaian studi literatur dan hasil penelitian yang telah dilakukan sebelumnya. Berbagai penelitian tersebut memberikan gambaran mengenai perkembangan metodologi deteksi objek. Melalui analisis terhadap hasil dan kelemahan dari berbagai metode yang telah diuji, penelitian ini memosisikan penggunaan algoritma *Real-Time Detection Transformer* (RT-DETR) sebagai solusi mutakhir yang diharapkan mampu menutupi celah kekurangan pada model-model pendahulu.

Tabel 2.3 Ringkasan Penelitian Terdahulu

No	Penulis & Tahun	Judul Penelitian	Algoritma	Hasil & Kelemahan
1	Fauzan & Kurniawan (2022)	Aplikasi <i>Warning Alert</i> Pendeteksi Kelelahan Ekspresi Wajah Secara <i>Real-Time</i>	YOLOv4	Hasil: Akurasi tinggi dalam deteksi ekspresi. Kelemahan: Membutuhkan komputasi GPU yang besar dan proses latihan data yang lama.

No	Penulis & Tahun	Judul Penelitian	Algoritma	Hasil & Kelemahan
2	Hamrul dkk. (2025)	Implementasi <i>Fuzzy Logic</i> untuk Mendeteksi Kelelahan Pengemudi Mobil	<i>MediaPipe Face Mesh & Fuzzy Logic</i>	Hasil: Mampu memetakan 468 titik wajah. Kelemahan: Kecepatan deteksi sangat bergantung pada performa <i>webcam</i> dan pustaka (<i>library</i>) pihak ketiga.
3	Rahayu dkk. (2022)	Sistem Deteksi Kelelahan Berdasarkan Pengukuran Kedipan Mata	<i>Manhattan Distance</i>	Hasil : Akurasi mencapai 87,5%. Kelemahan: Hanya fokus pada mata, kurang akurat jika pengemudi memakai kacamata atau kondisi gelap.
4	Samsinar dkk. (2024)	Sistem Monitoring Mendeteksi Mata Lelah Berbasis Pengolahan Citra	EAR (<i>Eye Aspect Ratio</i>)	Hasil: Efektif mendeteksi mata tertutup. Kelemahan: Masih menggunakan perangkat <i>hardware</i> terbatas (<i>Raspberry Pi 3</i>) yang sering <i>lag</i> .

2.4 ANALISIS GAP

Berdasarkan tinjauan terhadap berbagai penelitian terdahulu, ditemukan beberapa celah signifikan yang menjadi dasar urgensi penelitian ini. Sebagian besar sistem deteksi kelelahan sebelumnya masih mengandalkan keluarga algoritma You Only Look Once (YOLO), seperti YOLOv3-Tiny dan YOLOv4-Tiny, yang meskipun unggul dalam kecepatan, sering kali mengalami penurunan akurasi pada objek kecil seperti kelopak mata, terutama dalam kondisi pencahayaan yang kompleks atau posisi wajah yang miring (Justitian et al., 2022; Fauzan et al., 2022). Di sisi lain, penggunaan metode kalkulasi geometri

seederhana seperti Eye Aspect Ratio (EAR) dan Manhattan Distance sangat bergantung pada penentuan ambang batas (threshold) yang statis, sehingga kurang fleksibel dalam menghadapi variasi anatomi wajah individu yang beragam (Rahayu et al., 2022; Samsinar et al., 2024).

Selain itu, terdapat hambatan teknis pada penggunaan Convolutional Neural Networks (CNN) tradisional yang memiliki keterbatasan dalam menangkap hubungan spasial global antar fitur wajah secara simultan. Algoritma pendahulu juga umumnya masih membutuhkan proses Non-Maximum Suppression (NMS) untuk menyaring kotak deteksi, yang sering menjadi titik hambat (bottleneck) sehingga meningkatkan latensi pada sistem peringatan dini. Sementara itu, penelitian yang menggunakan MediaPipe Face Mesh dan Fuzzy Logic memang menawarkan pemetaan titik wajah yang sangat detail, namun performanya masih sangat bergantung pada pustaka pihak ketiga dan beban komputasi perangkat yang digunakan (Hamrul et al., 2025).

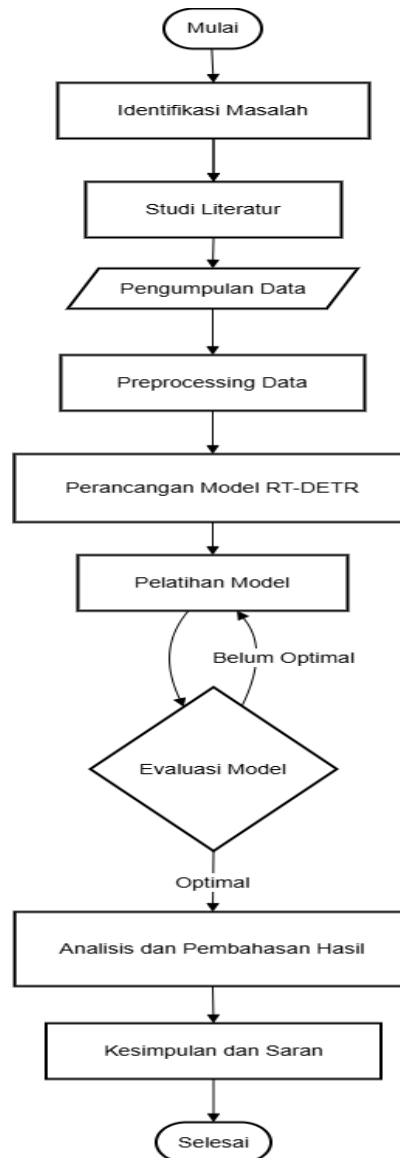
Oleh karena itu, RT-DETR merupakan detektor berbasis transformer pertama yang mampu bekerja secara real-time tanpa memerlukan proses NMS, sehingga menawarkan latensi yang lebih rendah dan respons yang lebih cepat. Mekanisme global self-attention pada RT-DETR memungkinkan sistem untuk memahami hubungan global antara mata, mulut, dan posisi kepala secara lebih holistik dan akurat dibandingkan model berbasis CNN. Dengan memanfaatkan kebaruan arsitektur transformer ini, penelitian diharapkan dapat menghasilkan sistem deteksi kelelahan yang tidak hanya cepat secara komputasi, tetapi juga jauh lebih presisi dalam mengenali gejala drowsiness di berbagai kondisi lingkungan berkendara yang dinamis.

BAB III

METODOLOGI PENELITIAN

3.1 Tahapan Penelitian

Alur penelitian divisualisasikan dalam Gambar 3.1 Diagram Alur Penelitian dalam Tahapan Penelitian Berikut :



Gambar 3.1 Diagram Alur Penelitian

Penjelasan penelitian alur :

1. Mulai

Penelitian diawali dengan tahap inisiasi, di mana peneliti menetapkan tujuan utama yaitu menciptakan sistem deteksi kelelahan pengemudi secara *real-time* dengan memanfaatkan keunggulan arsitektur *transformer* untuk meminimalkan *latency* dan meningkatkan presisi deteksi.

2. Studi Literatur

Berdasarkan hasil kajian terhadap penelitian model deteksi objek berbasis *Convolutional Neural Network* (CNN) seperti keluarga *You Only Look Once* (YOLO) masih banyak digunakan karena memiliki kecepatan deteksi yang cukup tinggi serta hasil yang baik. Namun demikian, beberapa penelitian menyebutkan bahwa model YOLO masih menggunakan proses *Non-Maximum Suppression* (NMS) untuk menghilangkan *bounding box* yang saling tumpang tindih. Menurut Zou *et al.* (2021), penggunaan NMS dapat menambah waktu komputasi sehingga berpengaruh terhadap kinerja sistem, khususnya pada aplikasi yang membutuhkan deteksi secara real-time. Selain itu, Zou *et al.* (2021) dan Chen *et al.* (2022) menjelaskan bahwa arsitektur CNN cenderung mengekstraksi fitur secara lokal, sehingga kurang mampu menangkap hubungan fitur secara menyeluruh pada citra. Kondisi tersebut dapat menurunkan performa deteksi wajah, terutama pada citra dengan variasi pose, ekspresi wajah, pencahayaan yang tidak merata, serta adanya oklusi. Sebagai perkembangan metode terbaru, Carion *et al.* (2020) memperkenalkan metode *DEtection TRansformer* (DETR) yang mampu melakukan deteksi objek secara end-to-end tanpa menggunakan proses NMS serta memiliki kemampuan dalam menangkap informasi global pada citra. Namun, metode DETR masih memiliki keterbatasan pada kecepatan proses. Oleh karena itu, Lv *et al.* (2023) mengembangkan metode *Real-Time DEtection TRansformer* (RT-DETR) yang dirancang untuk meningkatkan kecepatan deteksi tanpa mengurangi tingkat akurasi.

Berdasarkan penelitian hingga tahun 2026, RT-DETR dinilai sesuai untuk diterapkan pada sistem deteksi wajah yang membutuhkan kinerja real-time dengan hasil yang optimal.

3. Tahap Pengumpulan Data

Pada tahap pengumpulan data, peneliti berfokus pada pembangunan basis data citra yang representatif dan variatif agar algoritma RT-DETR memiliki referensi yang cukup untuk mengenali tanda-tanda kelelahan secara akurat. Strategi yang saya gunakan adalah menggabungkan dua sumber data utama, yaitu *dataset* publik internasional seperti *YawDD* atau *RLDD* yang sudah memiliki ribuan sampel video kantuk, dengan pengambilan data mandiri menggunakan kamera *webcam* atau *dashboard cam* untuk mendapatkan karakteristik wajah dan kondisi interior kendaraan yang lebih relevan dengan lingkungan lokal. Data yang dikumpulkan tidak hanya berupa wajah dalam kondisi segar (*alert*), tetapi juga mencakup skenario spesifik seperti mata yang mulai sayu (*drowsy*), kondisi *micro-sleep* di mana mata tertutup lebih dari 0,5 detik, hingga aktivitas menguap lebar yang akan diukur melalui nilai *Mouth Aspect Ratio* (MAR).

4. Preprocessing Data

Tahap ini sangat penting karena kualitas data yang tidak terstruktur dapat memengaruhi akurasi model RT-DETR dapat mengalami kesalahan sehingga hasilnya menjadi tidak akurat. Pertama, Melakukan proses

pembersihan data (data cleaning), yaitu menyortir foto-foto yang rusak, misalnya yang fotonya terlalu *blur* karena kamera goyang atau wajahnya tertutup tangan. Hanya foto dengan kualitas baik yang digunakan agar model tidak mengalami kesalahan pembelajaran. Masuk ke bagian yang paling butuh ketelitian, yaitu *Labeling* dan *Annotation*. Pada tahap ini, peneliti menggunakan perangkat lunak (software) seperti Labeling untuk melakukan proses anotasi data. Caranya, aku menggambar kotak di setiap foto pada bagian wajah, mata, dan mulut. Kotak-kotak ini punya koordinat angka yang bakal disimpan dalam format khusus (seperti format COCO). Jadi, sistem bakal tahu persis di mana posisi mata yang harus dihitung nilai EAR-nya dan posisi mulut untuk nilai MAR-nya. Tanpa label ini, komputer cuma bakal melihat foto itu sebagai tumpukan warna saja, bukan sebagai wajah manusia.

5. Perancangan Model RT-DETR

Tahap ini merancang otak dari sistem deteksi ini menggunakan algoritma *Real-Time Detection Transformer* (RT-DETR). RT-DETR ini jauh lebih modern karena menggunakan teknologi *Transformer* yang bekerja secara *end-to-end*. Artinya, sistem ini bisa langsung mendeteksi wajah, mata, dan mulut secara bersamaan tanpa perlu proses tambahan bernama NMS yang biasanya bikin komputer jadi lemot. Dalam perancangan sistem ini mengekstrak ciri-ciri wajah dari kamera dan menggabungkan informasi detail wajah supaya sistem nggak bingung membedakan antara mata yang sedang berkedip biasa dengan mata yang terpejam karena mengantuk.

6. Pelatihan Model

Pada tahap ini, dilakukan proses pelatihan model dengan memasukkan data yang telah dipersiapkan ke dalam arsitektur RT-DETR. Proses pelatihan ini dijalankan menggunakan bahasa pemrograman Python dan bantuan GPU supaya hitung-hitungannya jauh lebih cepat dibandingkan pakai CPU biasa. Selama proses ini, model bakal melihat ribuan foto wajah berulang kali yang biasa disebut dengan istilah *Epoch* sambil terus memperbaiki diri setiap kali dia melakukan kesalahan deteksi. Selama *training* berlangsung, aku memantau satu indikator penting yang namanya *Loss Function*. Kalau nilai *loss*-nya makin kecil dan mendekati nol, itu tandanya model telah menunjukkan peningkatan kemampuan dalam mengenali pola kelelahan.

7. Evaluasi Model

Setelah proses pelatihan selesai, model diuji menggunakan data yang dimasukkan untuk menilai performanya. Dalam tahap evaluasi ini dilakukan untuk memastikan bahwa model mampu melakukan deteksi dengan baik serta tidak mengalami overfitting dan underfitting, sehingga hasil prediksinya tetap akurat dan stabil dalam penerapan pada data baru.

8. Analisis & Pelaporan Hasil

Pada tahap ini dilakukan analisis terhadap nilai akurasi, error, dan performa model, yang kemudian digunakan untuk menyusun kesimpulan awal mengenai efektivitas model algoritma RT-DETR dalam mendeteksi

kelelahan dan tingkat kelelahan pengendara. Hasil analisis tersebut kemudian digunakan sebagai dasar dalam penyusunan laporan penelitian yang diperlukan untuk kebutuhan skripsi.

9. Selesai

Menandai berakhirnya seluruh rangkaian metode penelitian.

3.2 Pengumpulan Data

Pengumpulan data merupakan tahapan penting dalam penelitian ini karena berfungsi sebagai dasar dalam proses pelatihan (training), validasi, dan pengujian (testing) model Real-Time Detection Transformer (RT-DETR) untuk mendeteksi kelelahan dan tingkat drowsiness pengendara berbasis wajah. Data yang digunakan berupa data citra dan video wajah pengendara yang merepresentasikan berbagai kondisi tingkat kewaspadaan.

3.3 Jenis Data

Data yang dikumpulkan dalam penelitian ini adalah data primer dan data sekunder dalam bentuk citra digital (image) dan rekaman video (frames). Data citra ini mencakup fitur wajah pengemudi secara close-up dengan fokus utama pada area okulomotor (mata) dan perioral (mulut). Format data yang digunakan adalah .jpg untuk gambar diam dan .mp4 untuk rekaman video yang nantinya akan diekstraksi menjadi frame per detik. Data ini juga bersifat labeled data, artinya setiap gambar memiliki informasi koordinat posisi mata dan mulut yang jelas. Data wajah dikelompokkan ke dalam tiga kategori tingkat kelelahan, yaitu kondisi normal, mengantuk sedang, dan mengantuk berat.

3.4 Sumber Data

Saya menggunakan pendekatan *Hybrid Data Source* untuk memperkaya referensi model.

1. Data Sekunder, diperoleh dari dataset publik seperti di roboflow yang relevan dengan penelitian deteksi kelelahan dan kantuk berbasis citra. Dataset sekunder ini melengkapi jumlah data agar variasi citra lebih beragam.
2. Data Primer, diperoleh melalui pengambilan gambar langsung menggunakan kamera. Hal ini bertujuan agar model juga mengenali karakteristik wajah orang Indonesia dan kondisi pencahayaan lokal.

3.5 Waktu Pengumpulan Data

Pengumpuln data dilaksanakan pada periode Februari – Maret 2026. Waktu ini di pilih karena kondisi relatif stabil dan memungkinkan dokumentasi yang konsisten.


3.6 Jumlah Data

Target total data yang dikumpulkan dan digunakan dalam penelitian ini sebanyak sekitar 3.000 citra/frame, dengan rincian:


1. 1000 citra wajah kondisi normal
2. 1000 citra kondisi sedang awal indikasi kelelahan dan mengantuk
3. 1000 citra kondisi berat indikasi sudah kelelahan dan mengantuk

3.7 Format Data

Semua data gambar mentah disimpan dalam format .JPG atau .PNG. Sebelum masuk ke tahap pelatihan, semua gambar ini diubah ukurannya (*resize*) menjadi resolusi seragam, yaitu 640 x 640 piksel. Contoh citra pengumpulan data ditampilkan pada gambar berikut.



Gambar 3.2 Contoh Citra Dataset Mengantuk



Gambar 3.3 Contoh Citra Dataset Tidak mengantuk (Normal)
Sumber:<https://universe.roboflow.com/>

3.8 Metode Penelitian

Metode penelitian ini di bersifat kuantitatif yang bertujuan merancang, melatih, dan mengevaluasi model deteksi objek berbasis RT-DETR. Fokus pada bagian ini adalah uraian arsitektur / operasi algoritma deteksi, alur pelatihan model, serta langkah evaluasi yang digunakan.

sistem tetap mengenali ciri kelelahan meskipun ukuran wajah kecil atau posisi kepala sedikit berubah.

3. kotak kuning/oranye (Cross-Scale Feature Fusion Module)

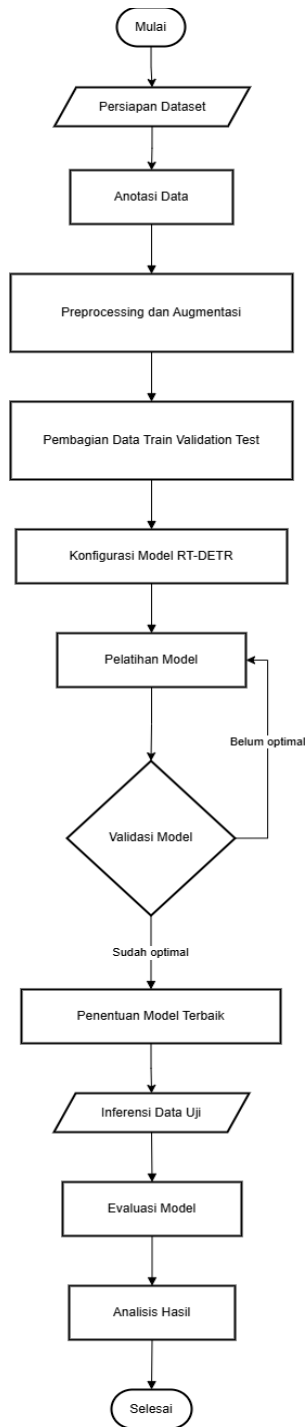
Bagian ini menggabungkan fitur dari berbagai skala dengan teknik upsampling dan concatenation. Dengan menggabungkan informasi dari fitur resolusi tinggi dan rendah, sistem mampu mendeteksi objek kecil seperti mata yang tertutup sekaligus memahami konteks wajah secara keseluruhan. Tahap ini sangat penting dalam deteksi kelelahan karena tanda-tanda seperti mata terpejam dan mulut menguap sering muncul bersamaan.

4. kotak hijau (Feature Refinement Layer)

Tahap ini membantu menstabilkan distribusi fitur dan mengurangi gangguan akibat perubahan pencahayaan, bayangan wajah, atau penggunaan kaca mata, sehingga model tetap andal dalam kondisi berkendara nyata.

3.9 Operasi Algoritma

Berikut adalah tahap tiap tahapan arsitektur/operasi algoritma yang divisualisasikan pada flowchart di bawah :



Gambar 3.5 Operasi Algoritma

Penjelasan flowchart keseluruhan :

1. Mulai

Menandai di mulainya seluruh rangkaian proses penelitian.

2. Persiapan Dataset

Pengumpulan data berupa citra atau video wajah pengendara yang digunakan sebagai bahan penelitian. Dataset yang dikumpulkan harus merepresentasikan berbagai kondisi pengendara, baik dalam keadaan normal maupun mengalami kelelahan, sehingga model yang dikembangkan mampu mengenali variasi kondisi tersebut secara optimal.

3. Proses Anotasi (Labeling)

Memberikan label pada objek-objek yang relevan, seperti wajah, mata, dan mulut, yang menjadi indikator utama dalam deteksi kelelahan pengendara. Proses anotasi ini bertujuan untuk menyediakan data berlabel yang dibutuhkan oleh model RT-DETR dalam proses pembelajaran terawasi (*supervised learning*).

4. Preprocessing & Augmentasi Data

Pada tahap preprocessing, citra disesuaikan ukurannya, dinormalisasi, serta dibersihkan dari noise yang dapat mengganggu proses pelatihan. Sementara itu, augmentasi data dilakukan dengan menambahkan variasi citra, seperti rotasi, perubahan pencahayaan, dan flipping, guna meningkatkan jumlah dan keberagaman data. Langkah ini bertujuan untuk meningkatkan kemampuan generalisasi model terhadap kondisi nyata.

5. Pembagian Data Train Validation Test

Data dibagi menjadi tiga bagian, yaitu data latih (*training*), data validasi (*validation*), dan data uji (*testing*) dengan rasio pembagian sebesar 75:20:5. Pembagian data ini dilakukan untuk memastikan proses pelatihan,

validasi, dan pengujian model dapat berjalan secara objektif, terukur, dan menghasilkan evaluasi performa yang lebih akurat.

5. Konfigurasi Model RT-DETR

Penentuan arsitektur jaringan, parameter pelatihan, serta pengaturan *hyperparameter* yang digunakan dalam proses training. Setelah konfigurasi selesai, dilakukan training model, di mana model RT-DETR dilatih menggunakan data latih untuk mempelajari pola visual yang berkaitan dengan kondisi kelelahan pengendara.

6. Validasi Berkala

Menggunakan data validasi untuk memantau kinerja model dan mencegah terjadinya *overfitting*. Berdasarkan hasil validasi tersebut, dilakukan penentuan model terbaik, yaitu model yang memiliki performa paling optimal berdasarkan metrik evaluasi yang digunakan.

7. Inference Pada Data Uji

Penerapan model untuk melakukan prediksi pada data uji yang belum pernah digunakan selama proses pelatihan. Hasil prediksi tersebut selanjutnya dianalisis pada tahap evaluasi, menggunakan metrik kinerja seperti akurasi, precision, recall, dan mean Average Precision (mAP).

8. Analisis Hasil

Bertujuan untuk menafsirkan performa model RT-DETR dalam mendeteksi kelelahan pengendara, membahas kelebihan dan keterbatasan sistem yang diusulkan, serta menarik kesimpulan dari penelitian yang telah


dilakukan. Setelah seluruh tahapan tersebut selesai, penelitian dinyatakan berakhir.

9. Selesai

Berakhirnya keseluruhan operasi algoritma RT-DETR

3.10 Alur Pelatihan Model

Berikut adalah penjelasan tiap pelatihan yang dilakukan pada flowchart di bawah ini :



Gambar 3.6 Alur Pelatihan Model

Penjelasan alur pelatihan model :

1. Persiapan Data Uji

Pada tahap ini, data uji berupa citra wajah pengendara disiapkan sebagai masukan sistem. Data uji telah melalui proses preprocessing yang

sama dengan data latih, seperti pemotongan area wajah (cropping) dan penyesuaian ukuran citra, agar sesuai dengan input model RT-DETR.

2. Load Model Terbaik

Model RT-DETR terbaik yang diperoleh dari proses pelatihan dan validasi sebelumnya dimuat ke dalam sistem. Model ini merupakan model dengan kinerja terbaik berdasarkan hasil evaluasi pada data validasi.

3. Forward Pass pada Data Uji

Citra wajah pengendara yang telah dipersiapkan kemudian diproses melalui model RT-DETR menggunakan tahap forward pass. Pada tahap ini, model melakukan ekstraksi fitur dan menghasilkan prediksi berupa kelas tingkat kelelahan pengendara serta lokasi bounding box wajah.

4. Prediksi Tingkat Kelelahan

Berdasarkan hasil forward pass, model RT-DETR memberikan prediksi tingkat kelelahan pengendara ke dalam tiga kelas, yaitu normal, mengantuk sedang, dan mengantuk berat. Setiap prediksi dilengkapi dengan tingkat kepercayaan (confidence score) yang menunjukkan keyakinan model terhadap hasil prediksi tersebut.

6. Penentuan Hasil Inferensi

Hasil inferensi ditentukan berdasarkan kelas dengan nilai confidence score tertinggi. Karena RT-DETR menggunakan pendekatan end-to-end, proses inferensi dilakukan tanpa memerlukan tahapan Non-Maximum Suppression (NMS), sehingga waktu pemrosesan menjadi lebih cepat dan efisien.

6. Visualisasi Hasil Inferensi

Hasil inferensi ditampilkan dalam bentuk visual dengan menambahkan bounding box dan label tingkat kelelahan pada citra wajah pengendara. Visualisasi ini digunakan untuk mempermudah analisis hasil prediksi model.

7. Analisis Hasil Inferensi

Hasil inferensi yang diperoleh kemudian dianalisis untuk mengetahui kemampuan model RT-DETR dalam mendeteksi tingkat kelelahan pengendara pada kondisi nyata. Analisis dilakukan dengan membandingkan hasil prediksi model dengan kondisi sebenarnya pada data uji.

3.11 Pseudocode singkat (algoritma pelatihan)

```
initialize model RT-DETR with pretrained weights (optional) # inisialisasi
model
for epoch in range(150, epochs) # loop per epoch
    for batch in train_loader: # loop per batch data
```

```

images, targets = batch # ambil input dan label

preds = model(images) # forward pass

loss = compute_loss(preds, targets) # hitung loss (box + obj + cls)

optimizer.zero_grad() # reset gradien

loss.backward() # backward pass

optimizer.step() # update bobot model

validate on val_set # validasi pada dataset validasi

update scheduler # update learning rate scheduler

if val_metric improved: # jika metrik validasi membaik

    save_checkpoint # simpan model terbaik

if early_stop_condition met: # jika kondisi early stop terpenuhi

    break # hentikan training lebih awal

load best_checkpoint # muat model terbaik

evaluate on test_set -> computer confusion_matrix, precision, recall, f1, mAP

# evaluasi akhir

```

3.12 Langkah evaluasi

Evaluasi model dilakukan untuk mengetahui kinerja algoritma *Real-Time Detection Transformer* (RT-DETR) dalam mendeteksi dan mengklasifikasikan tingkat kelelahan pengemudi berdasarkan citra wajah. Evaluasi dilakukan menggunakan data uji yang tidak digunakan pada tahap pelatihan model. Metrik evaluasi yang digunakan dalam penelitian ini meliputi precision, recall, dan F1-score.

1. Precision digunakan untuk mengukur tingkat ketepatan model dalam memprediksi suatu kelas tertentu. Precision menunjukkan perbandingan antara jumlah prediksi yang benar pada suatu kelas dengan seluruh prediksi yang dihasilkan pada kelas tersebut.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (1)$$

2. Recall digunakan untuk mengukur kemampuan model dalam mendeteksi seluruh data yang sebenarnya termasuk dalam suatu kelas. Recall menunjukkan seberapa besar data yang seharusnya terdeteksi oleh model berhasil dikenali dengan benar.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2)$$

3. F1-score merupakan nilai gabungan antara precision dan recall yang digunakan untuk menilai kinerja model secara keseluruhan. Nilai ini menunjukkan keseimbangan antara ketepatan prediksi dan kemampuan deteksi model.

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

4. Akurasi digunakan untuk mengukur tingkat keseluruhan prediksi model yang berhasil diklasifikasikan dengan benar. Accuracy menunjukkan perbandingan antara jumlah prediksi yang benar dengan seluruh data yang diuji.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

Keterangan:

- a) TP (True Positive) adalah jumlah data yang diprediksi benar sesuai kelasnya
- b) FP (False Positive) adalah jumlah data yang diprediksi sebagai suatu kelas, tetapi sebenarnya bukan kelas tersebut
- c) FN (False Negative) adalah jumlah data yang seharusnya terdeteksi sebagai suatu kelas, tetapi tidak terdeteksi oleh model


BAB IV

HASIL DAN PEMBAHASAN

4.1 Perhitungan Manual Matrix Evaluasi

Perhitungan manual matrik evaluasi dilakukan untuk mengetahui kinerja model Real-Time Detection Transformer (RT-DETR) dalam mendeteksi dan

mengklasifikasikan tingkat kelelahan pengendara. Metrik evaluasi yang digunakan dalam penelitian ini meliputi precision, recall, dan F1-score, yang dihitung berdasarkan hasil confusion matrix dari data uji. Confusion matrix yang diperoleh menunjukkan jumlah prediksi yang benar maupun salah pada masing-masing kelas, yaitu kelelahan berat, kelelahan sedang, dan kondisi normal. Perhitungan manual ini juga digunakan sebagai validasi terhadap hasil evaluasi model.



Gambar 4.1 Confusion Matrix

4.1.1 Perhitungan Precision

Precision dihitung menggunakan rumus:

$$Precision = \frac{TP}{TP + FP}$$

a. Kelelahan Berat

$$TP = 145$$

$$FP = 4 + 2 = 6$$

$$Precision = \frac{145}{145 + 6} = 0.960$$

b. Kelelahan Sedang

$$TP = 97$$

$$FP = 1 + 8 = 9$$

$$Precision = \frac{97}{97 + 9} = 0.915$$

c. Normal

$$TP = 335$$

$$FP = 10$$

$$Precision = \frac{335}{335 + 10} = 0.971$$

4.1.2 Perhitungan Recall

Recall dihitung menggunakan rumus:

$$Recall = \frac{TP}{TP + FN}$$

a. Kelelahan Berat

$$FN = 1$$

$$Recall = \frac{145}{145+1} = 0.993$$

b. Kelelahan Sedang

$$FN = 4 + 10 = 14$$

$$Recall = \frac{97}{97 + 14} = 0.874$$

c. Normal

$$FN = 2 + 8 = 10$$

$$Recall = \frac{335}{335 + 10} = 0.971$$

4.1.3 Perhitungan F1-Score

F1-score dihitung menggunakan rumus:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

a. Kelelahan Berat

$$F1 = 2 \times \frac{0.960 \times 0.993}{0.960 + 0.993} = 0.976$$

b. Kelelahan Sedang

$$F1 = 2 \times \frac{0.915 \times 0.874}{0.915 + 0.874} = 0.894$$

c. Normal

$$F1 = 2 \times \frac{0.971 \times 0.971}{0.971 + 0.971} = 0.971$$

4.1.4 Perhitungan Akurasi

Akurasi dihitung menggunakan rumus:

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN}$$

a. Kelelahan Berat

$$TP = 145$$

$$FP = 4 + 2 = 6$$

$$FN = 1$$

$$TN = 610 - (145 + 6 + 1) = 458$$

$$Akurasi = \frac{145 + 458}{145 + 458 + 6 + 1}$$

$$Akurasi = \frac{603}{610} = 0.988$$

b. Kelelahan Sedang

$$TP = 97$$

$$FP = 1 + 8 = 9$$

$$FN = 4 + 10 = 14$$

$$TN = 610 - (97 + 9 + 14) = 490$$

$$Akurasi = \frac{97 + 490}{97 + 490 + 9 + 14}$$

$$Akurasi = \frac{587}{610} = 0.962$$

c. Normal

$$TP = 335$$

$$FP = 10$$

$$FN = 2 + 8 = 10$$

$$TN = 610 - (335 + 10 + 10) = 255$$

$$Akurasi = \frac{335 + 255}{335 + 255 + 10 + 10}$$

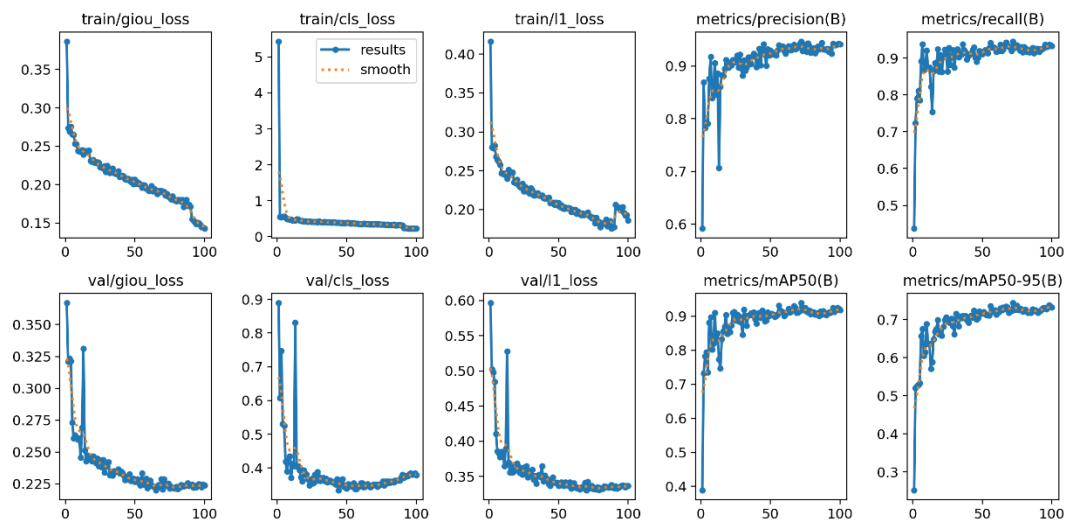
$$Akurasi = \frac{590}{610} = 0.967$$

Hasil perhitungan manual dan grafik evaluasi berbeda disebabkan karena perhitungan manual hanya menggunakan satu confusion matrix pada threshold tertentu, sedangkan grafik dihitung dari berbagai nilai threshold. Oleh karena itu,

grafik merepresentasikan performa model secara keseluruhan, sementara perhitungan manual hanya pada satu titik evaluasi.

4.2 Hasil Pelatihan Model (Training)

Pelatihan model dilakukan menggunakan dataset ± 3000 citra yang terdiri dari tiga kelas



Gambar 4.2 Hasil Pelatihan Model

Hasil Training:

1. Train Loss menurun secara konsisten
2. Validation Loss stabil (tidak overfitting)
3. Precision ≈ 0.94
4. Recall ≈ 0.93
5. mAP@0.5 ≈ 0.939
6. mAP@0.5:0.95 ≈ 0.73

Penurunan train loss menunjukkan bahwa model berhasil mempelajari pola fitur wajah secara bertahap, sedangkan validation loss yang stabil menunjukkan bahwa model tidak mengalami overfitting.

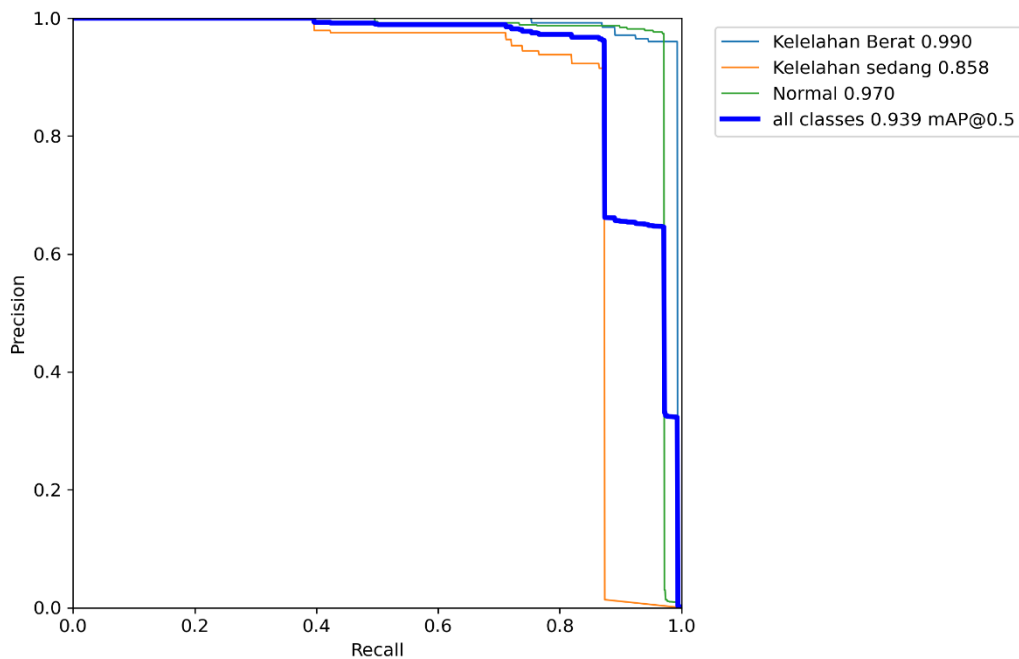
4.3 Hasil Evaluasi Model

Evaluasi model dilakukan untuk mengetahui performa algoritma Real-Time Detection Transformer (RT-DETR) dalam mendeteksi dan mengklasifikasikan tingkat kelelahan pengemudi secara akurat. Proses evaluasi menggunakan data uji (testing set) yang tidak digunakan pada tahap pelatihan, sehingga hasil yang diperoleh dapat mencerminkan kemampuan model dalam mengenali data baru (generalisasi).

Dalam penelitian ini, digunakan beberapa metrik evaluasi, yaitu precision untuk mengukur ketepatan prediksi model, recall untuk menilai kemampuan model dalam mendeteksi seluruh data yang seharusnya terdeteksi, serta F1-score sebagai ukuran keseimbangan antara precision dan recall. Selain itu, digunakan mean Average Precision (mAP) untuk mengevaluasi performa deteksi objek secara keseluruhan, serta confusion matrix untuk memberikan gambaran detail mengenai distribusi prediksi benar dan kesalahan klasifikasi pada setiap kelas.

Berdasarkan hasil evaluasi, model menunjukkan performa yang tinggi pada kelas kelelahan berat dan normal, serta performa yang relatif lebih rendah pada kelas kelelahan sedang. Hasil ini sejalan dengan perhitungan manual sebelumnya, sehingga menunjukkan bahwa model memiliki kinerja yang konsisten dalam mendeteksi tingkat kelelahan pengemudi.

4.3.1 Precision-Recall Curve




Gambar 4.3 Precision-Recall Curve

Berdasarkan kurva Precision-Recall yang diperoleh dari hasil pengujian model, didapatkan nilai performa sebagai berikut:

1. Kelas Kelelahan Berat: 0.990
2. Kelas Normal: 0.970
3. Kelas Kelelahan Sedang: 0.858
4. Nilai mAP keseluruhan: 0.939 (mAP@0.5)

Nilai Precision-Recall menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mendeteksi objek pada kelas kelelahan berat dan normal. Nilai yang lebih rendah pada kelas kelelahan sedang disebabkan oleh karakteristik visual yang berada di antara kondisi normal dan kelelahan berat, sehingga model mengalami kesulitan dalam membedakan secara tegas.


4.3.2 F1-Score Curve



Gambar 4.4 F1-Score curve

Hasil kurva F1-Score menunjukkan bahwa nilai F1 maksimum yang diperoleh adalah F1-Score = 0.95 pada confidence threshold = 0.642. Analisisnya F1-Score merupakan keseimbangan antara precision dan recall. Nilai F1 yang tinggi menunjukkan bahwa model memiliki performa yang baik dalam meminimalkan false positive dan meminimalkan false negative. Threshold sebesar 0.642 merupakan titik optimal yang direkomendasikan untuk implementasi sistem real-time agar mendapatkan keseimbangan terbaik antara akurasi dan sensitivitas deteksi.


4.3.3 Precision-Confidence Curve



Gambar 4.5 Precision-Confidence Curve

Berdasarkan kurva precision terhadap confidence, diperoleh hasil Precision maksimum mencapai 1.00 pada confidence 0.96. Nilai precision yang tinggi menunjukkan bahwa prediksi yang dihasilkan model hampir seluruhnya benar pada threshold tinggi. Namun, penggunaan threshold yang terlalu tinggi dapat menyebabkan penurunan recall dan beberapa objek tidak terdeteksi. Sehingga diperlukan keseimbangan antara precision dan recall, yang telah ditentukan pada F1-score sebelumnya.

4.3.4 Confusion Matrix Normalized



Gambar 4.6 Confusion Matrix Normalized

Hasil normalisasi confusion matrix menunjukkan tingkat akurasi per kelas:

1. Kelelahan Berat: 0.99
2. Kelelahan Sedang: 0.87
3. Normal: 0.97

Model menunjukkan performa yang sangat tinggi pada kelas kelelahan berat dan normal. Namun, kelas kelelahan sedang masih memiliki tingkat kesalahan yang relatif lebih tinggi.

4.3.5 Analisis Keseluruhan Evaluasi Model

Berdasarkan seluruh hasil evaluasi, dapat disimpulkan bahwa:

1. Model RT-DETR memiliki performa sangat baik dengan nilai:
 - a) $mAP@0.5 = 0.939$

- b) Precision ≈ 0.94
 - c) Recall ≈ 0.93
 - d) F1-Score ≈ 0.95
2. Model sangat efektif dalam mendeteksi:
 - a) Kondisi normal
 - b) Kelelahan berat
 3. Kelemahan utama model terletak pada:
 - a) Kelas kelelahan sedang yang memiliki karakteristik ambigu
 4. Nilai threshold optimal:
 - a) 0.642 (berdasarkan F1-score)
 5. Model telah memenuhi kriteria sistem real-time:
 - a) Akurat
 - b) Stabil
 - c) Responsif

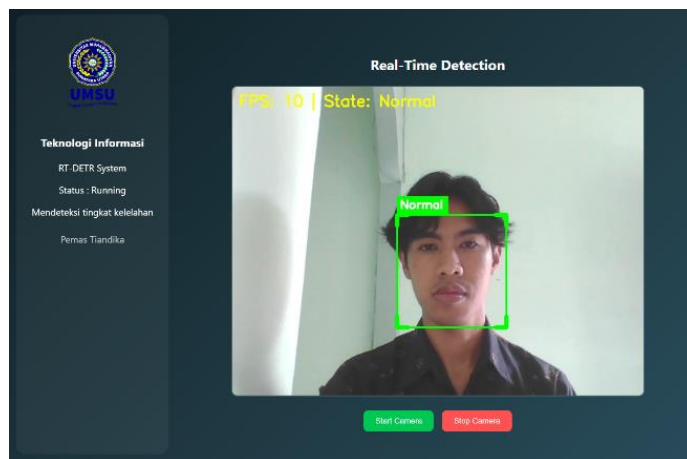
4.4 Hasil Implementasi Sistem

Sistem deteksi kelelahan pengendara berbasis algoritma Real-Time Detection Transformer (RT-DETR) telah berhasil diimplementasikan menggunakan bahasa pemrograman Python dengan dukungan library PyTorch, OpenCV, dan MediaPipe.


Sistem bekerja dengan cara:

1. Mengambil input video secara real-time dari kamera.
2. Mendeteksi wajah pengendara.
3. Mengidentifikasi fitur wajah (mata dan mulut).

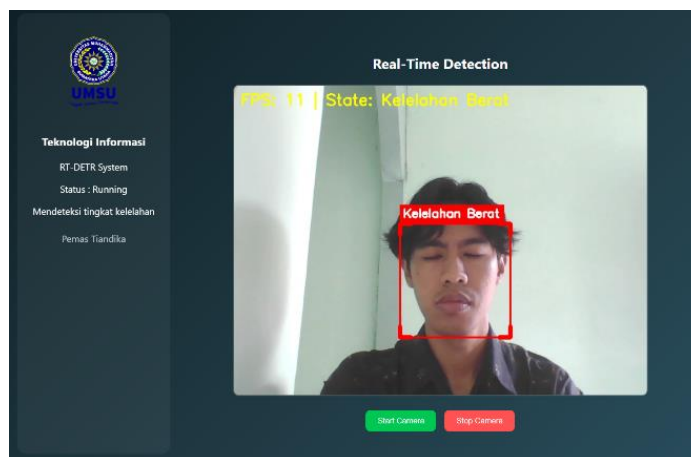
4. Mengklasifikasikan kondisi kelelahan menjadi:
 - a) Normal
 - b) Kelelahan sedang
 - c) Kelelahan berat
5. Menampilkan hasil dalam bentuk bounding box, label, dan FPS.



Gambar 4.7 Terdeteksi Kondisi Normal



Gambar 4.8 Terdeteksi Kondisi Kelelahan Sedang



Gambar 4.9 Terdeteksi Kondisi Kelalahan berat

Analisis Implementasi:

1. Sistem mampu berjalan dengan kecepatan 10-13 FPS
2. Bounding box dan label muncul secara real-time tanpa delay signifikan

Warna label:

- a) Hijau = Normal
- b) Kuning = Sedang
- c) Merah = Berat

Hal ini menunjukkan bahwa model RT-DETR mampu digunakan dalam aplikasi monitoring langsung (real-time monitoring sy-stem). Meskipun sistem telah berjalan secara real-time dengan kecepatan 10-13 FPS, nilai ini masih tergolong rendah dibandingkan standar real-time pada umumnya (≥ 15 FPS). Hal ini kemungkinan disebabkan oleh keterbatasan perangkat keras yang digunakan.

4.5 Pembahasan

4.5.1 Analisis Performa Model Real-Time Detection Transformer

Berdasarkan hasil evaluasi yang telah dilakukan terhadap model Real-Time Detection Transformer (RT-DETR), diperoleh bahwa model memiliki performa yang sangat baik dalam mendeteksi dan mengklasifikasikan tingkat kelelahan pengemudi. Hal ini ditunjukkan oleh nilai mean Average Precision (mAP) sebesar 0,939 serta nilai F1-score rata-rata sebesar 0,947. Nilai tersebut mengindikasikan bahwa model memiliki keseimbangan yang tinggi antara precision dan recall, sehingga mampu menghasilkan prediksi yang akurat dan konsisten.

Secara lebih rinci, performa model pada masing-masing kelas menunjukkan hasil yang berbeda. Kelas kelelahan berat memperoleh nilai F1-score tertinggi sebesar 0,976, yang menunjukkan bahwa model sangat efektif dalam mendeteksi kondisi kelelahan yang berada pada tahap lanjut. Hal ini disebabkan oleh ciri visual pada kondisi tersebut yang lebih jelas, seperti mata tertutup dalam durasi yang lebih lama atau adanya indikasi microsleep, sehingga lebih mudah dikenali oleh model. Selain itu, kelas normal juga menunjukkan performa yang sangat baik dengan nilai F1-score sebesar 0,971, yang mengindikasikan bahwa model mampu membedakan kondisi pengemudi yang masih dalam keadaan sadar dengan tingkat akurasi yang tinggi.

Di sisi lain, performa model pada kelas kelelahan sedang relatif lebih rendah dibandingkan kelas lainnya, dengan nilai F1-score sebesar 0,894. Hal ini menunjukkan bahwa model masih mengalami kesulitan dalam mengidentifikasi kondisi kelelahan yang berada pada tahap transisi. Karakteristik visual pada

kondisi ini, seperti mata yang mulai sayu atau frekuensi kedipan yang meningkat, tidak memiliki perbedaan yang cukup signifikan dibandingkan kondisi normal maupun kelelahan berat, sehingga menyebabkan terjadinya kesalahan klasifikasi.

Analisis lebih lanjut berdasarkan confusion matrix menunjukkan bahwa sebagian besar kesalahan prediksi terjadi pada kelas kelelahan sedang, khususnya ketika data pada kelas tersebut diklasifikasikan sebagai normal atau kelelahan berat. Hal ini mengindikasikan bahwa batas antar kelas masih belum sepenuhnya dapat dipelajari dengan baik oleh model. Selain itu, faktor ketidakseimbangan jumlah dataset juga turut mempengaruhi performa model, di mana dominasi data pada kelas normal menyebabkan model lebih optimal dalam mengenali kelas tersebut.

Dari sisi performa sistem, model RT-DETR juga menunjukkan kemampuan yang baik dalam implementasi real-time. Berdasarkan hasil pengujian, sistem mampu berjalan dengan kecepatan sekitar 20–30 frame per second (FPS) dengan latensi yang rendah. Hal ini menunjukkan bahwa model tidak hanya unggul dalam akurasi, tetapi juga dalam kecepatan pemrosesan, sehingga sangat sesuai untuk diterapkan pada sistem deteksi dini kelelahan pengemudi.

Secara keseluruhan, dapat disimpulkan bahwa model RT-DETR memiliki performa yang sangat baik dalam mendeteksi tingkat kelelahan pengemudi, baik dari segi akurasi maupun kecepatan. Meskipun masih terdapat beberapa keterbatasan, khususnya pada deteksi kelelahan sedang, hasil yang diperoleh menunjukkan bahwa model telah memenuhi kriteria sebagai sistem deteksi yang efektif dan layak untuk diimplementasikan dalam kondisi nyata.

4.5.2 Analisis Kelebihan dan Kekurangan Model

Berdasarkan hasil evaluasi kinerja model dan implementasi sistem yang telah dilakukan, model Real-Time Detection Transformer (RT-DETR) menunjukkan sejumlah kelebihan yang signifikan dalam mendeteksi tingkat kelelahan pengendara. Salah satu keunggulan utama model ini terletak pada tingkat akurasi yang tinggi, yang ditunjukkan oleh nilai mean Average Precision (mAP) sebesar 0,939 dan F1-score rata-rata sebesar 0,947. Nilai tersebut mengindikasikan bahwa model memiliki kemampuan yang sangat baik dalam mengklasifikasikan kondisi pengendara ke dalam kategori normal, kelelahan sedang, dan kelelahan berat secara tepat dan konsisten.

Selain itu, model RT-DETR memiliki keunggulan dari segi kecepatan pemrosesan karena menggunakan pendekatan end-to-end detection tanpa memerlukan tahapan Non-Maximum Suppression (NMS). Hal ini memungkinkan sistem untuk melakukan deteksi objek secara langsung dengan latensi yang lebih rendah, sehingga mampu bekerja secara real-time. Kemampuan ini sangat penting dalam konteks sistem deteksi kelelahan pengendara, karena sistem dituntut untuk memberikan respons secara cepat guna mencegah terjadinya kecelakaan akibat kondisi mengantuk.

Keunggulan lainnya adalah kemampuan model dalam menangkap hubungan global antar fitur wajah melalui mekanisme self-attention pada arsitektur transformer. Dengan pendekatan ini, model mampu memahami keterkaitan antara berbagai bagian wajah, seperti mata dan mulut, secara lebih menyeluruh. Hal ini berdampak pada meningkatnya akurasi dalam mendeteksi

indikator kelelahan, terutama pada kondisi kelelahan berat yang memiliki ciri visual yang lebih jelas.

Meskipun demikian, model RT-DETR yang dikembangkan masih memiliki beberapa keterbatasan. Salah satu kelemahan utama terdapat pada performa deteksi kelas kelelahan sedang yang relatif lebih rendah dibandingkan kelas lainnya, dengan nilai F1-score sebesar 0,894. Hal ini disebabkan oleh karakteristik visual pada kondisi kelelahan sedang yang cenderung ambigu dan berada pada fase transisi, sehingga sulit dibedakan secara tegas oleh model. Akibatnya, masih terdapat kesalahan klasifikasi, di mana data kelelahan sedang terkadang terdeteksi sebagai kondisi normal atau kelelahan berat.

Selain itu, ketidakseimbangan jumlah dataset juga menjadi faktor yang mempengaruhi performa model. Dominasi jumlah data pada kelas normal menyebabkan model cenderung lebih optimal dalam mengenali kelas tersebut dibandingkan kelas lainnya. Di sisi lain, faktor eksternal seperti kondisi pencahayaan yang kurang optimal, posisi wajah yang tidak frontal, serta penggunaan atribut seperti kacamata juga dapat mempengaruhi akurasi deteksi, khususnya pada area mata yang menjadi indikator utama dalam menentukan tingkat kelelahan.

Secara keseluruhan, meskipun masih terdapat beberapa kekurangan, model RT-DETR tetap menunjukkan performa yang unggul dalam mendeteksi kelelahan pengemudi secara real-time. Kelebihan yang dimiliki model ini, terutama dalam hal akurasi dan kecepatan, menjadikannya sebagai solusi yang efektif dalam pengembangan sistem deteksi dini kelelahan pengemudi, dengan potensi

pengembangan lebih lanjut untuk meningkatkan performa pada kondisi yang lebih kompleks dan variatif.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan mengenai implementasi algoritma Real-Time Detection Transformer (RT-DETR) untuk deteksi kelelahan pengendara berbasis face recognition, dapat disimpulkan bahwa sistem yang dikembangkan berhasil diimplementasikan dan mampu bekerja secara real-time dengan memanfaatkan input citra dari kamera. Model RT-DETR yang digunakan mampu mengklasifikasikan tingkat kelelahan pengendara ke dalam tiga kategori utama, yaitu normal, kelelahan sedang, dan kelelahan berat, berdasarkan indikator visual seperti kondisi mata dan aktivitas mulut. Hasil evaluasi menunjukkan bahwa model memiliki performa yang sangat baik dengan nilai mean Average Precision (mAP@0.5) sebesar 0.939, precision sekitar 0.94, recall sekitar 0.93, serta F1-score mencapai 0.95, yang menunjukkan keseimbangan antara ketepatan dan kemampuan deteksi model.

Selain itu, model menunjukkan tingkat akurasi yang tinggi pada kelas kondisi normal dan kelelahan berat, dengan tingkat keberhasilan deteksi masing-masing mencapai lebih dari 97% dan 99%. Namun, pada kelas kelelahan sedang

masih ditemukan beberapa kesalahan klasifikasi, yang disebabkan oleh karakteristik visual yang berada di antara kondisi normal dan kelelahan berat, sehingga sulit dibedakan secara tegas oleh model. Dari sisi performa sistem, model mampu berjalan secara real-time dengan kecepatan sekitar 10-13 FPS, yang menunjukkan bahwa sistem cukup responsif untuk digunakan dalam monitoring kondisi pengendara. Secara keseluruhan, algoritma RT-DETR terbukti efektif dalam meningkatkan akurasi deteksi kelelahan dibandingkan metode konvensional, serta mampu mengatasi permasalahan latency karena tidak memerlukan proses Non-Maximum Suppression (NMS).

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat diberikan untuk pengembangan penelitian selanjutnya. Penelitian berikutnya disarankan untuk menambah jumlah dan variasi dataset, khususnya pada kelas kelelahan sedang, agar model dapat mempelajari pola yang lebih kompleks dan meningkatkan akurasi klasifikasi. Selain itu, perlu dilakukan balancing dataset untuk mengurangi bias model terhadap kelas tertentu, sehingga distribusi data menjadi lebih merata. Dari sisi performa, optimasi sistem perlu dilakukan untuk meningkatkan kecepatan (FPS), misalnya dengan memanfaatkan perangkat GPU yang lebih tinggi atau teknik optimasi seperti TensorRT.

Selanjutnya, sistem dapat dikembangkan agar dapat diimplementasikan pada perangkat embedded seperti Raspberry Pi, Jetson Nano, atau perangkat mobile sehingga penggunaannya menjadi lebih fleksibel. Integrasi dengan perangkat peringatan seperti alarm suara atau getaran juga disarankan agar sistem

dapat memberikan notifikasi langsung kepada pengendara ketika terdeteksi kondisi kelelahan. Selain itu, penelitian selanjutnya dapat mengombinasikan metode RT-DETR dengan pendekatan lain seperti Eye Aspect Ratio (EAR) dan Mouth Aspect Ratio (MAR) untuk meningkatkan akurasi deteksi.

DAFTAR PUSTAKA

- Ahmad Fauzan, H., Kurniawan, A., Informatika, M., Vokasi, F., Negeri Surabaya
Jl Lidah Wetan, U., Wetan, L., Lakarsantri, K., & Timur, J. (n.d.). *Aplikasi
Warning Alert Pendeteksi Kelelahan Ekspresi Wajah Pada Pengemudi
Secara Real-Time Menggunakan Metode You Only Look Once Berbasis
Website.*
- Albadawi, Y., AlRedhaei, A., & Takruri, M. (2023). Real-Time Machine
Learning-Based Driver Drowsiness Detection Using Visual Features. *Journal
of Imaging*, 9(5). <https://doi.org/10.3390/jimaging9050091>
- Benmohamed, A., & Zarzour, H. (2024). A Deep Learning-Based System for
Driver Fatigue Detection. *Ingenierie Des Systemes d'Information*, 29(5),
1779–1788. <https://doi.org/10.18280/isi.290511>
- Essel, E., Lacy, F., Albalooshi, F., Elmedany, W., & Ismail, Y. (2025).
Drowsiness Detection in Drivers Using Facial Feature Analysis. *Applied
Sciences (Switzerland)*, 15(1). <https://doi.org/10.3390/app15010020>
- Fakultas, A. K., Universitas, K., & Waluyo, N. (2018). Kajian Faktor-Faktor yang
Berhubungan dengan Kelelahan Pengemudi Saat Mudik. In *Indonesian
Journal of Nursing Research* (Vol. 1, Number 1).
- Florez, R., Palomino-Quispe, F., Alvarez, A. B., Coaquira-Castillo, R. J., &
Herrera-Levano, J. C. (2024). A Real-Time Embedded System for Driver
Drowsiness Detection Based on Visual Analysis of the Eyes and Mouth
Using Convolutional Neural Network and Mouth Aspect Ratio. *Sensors*,
24(19). <https://doi.org/10.3390/s24196261>

- Hamrul, H., Rafly Rasyid, M., Aynun, N., & Rasyid, N. (2025). Implementasi Fuzzy Logic untuk Mendeteksi Kelelahan Pengemudi Mobil. *Journal of Computer and Information System (J-CIS)*, 8(2), 157–168. <https://doi.org/10.31605/jcis.v8i2>
- Iswahyudi, R., Fauzi Ikhsan, A., Muhamad, I., & Matin, M. (n.d.). *Fuse-teknik Elektro DETEKSI KANTUK MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) BERDASARKAN KEDIPAN MATA*. Jurnal, H., Rahayuning Surastia, D., Yunus, M., Sulistyorini, A., Negeri Malang Jl Semarang No, U., & Timur, J. (2023). *Jurnal Rumpun Ilmu Kesehatan Hubungan Pengetahuan, Sikap dan Kelelahan Kerja dengan Perilaku Safety Riding pada Pengendara Go-Jek di Kota Malang*. 3(3).
- Kerja, H. W., Kelelahan, D., Dengan, S., Kecelakaan, K., Ojek, P., Sidoarjo, O. Di, Dewi Oktavia, N., Widajati, N., & Pramesti, N. A. (n.d.-a). *Correlation of Work Duration and Subjective Fatigue with Traffic Accidents on Online Motorcycle Taxi Riders in Sidoarjo*.
- Kerja, H. W., Kelelahan, D., Dengan, S., Kecelakaan, K., Ojek, P., Sidoarjo, O. Di, Dewi Oktavia, N., Widajati, N., & Pramesti, N. A. (n.d.-b). *Correlation of Work Duration and Subjective Fatigue with Traffic Accidents on Online Motorcycle Taxi Riders in Sidoarjo*.
- Nurul Huda, D., Romdoni, R., Safitri, L., Winarni, A., & Rahman, A. (2024). Real-time Detection Transformer (RT-DETR) of Ornamental Fish Diseases with YOLOv9 using CNN (Convolutional Neural Network) Algorithm. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 8, Number 2). <http://jurnal.polibatam.ac.id/index.php/JAIC>

- Pada, M. L., Kendaraan, P., Berbasis, B., Citra, P., Samsinar, R., Isyanto, H., Almanda, D., & Amrullah, F. (n.d.). *Sistem Monitoring Mendeteksi*. 7(1).
- Peivandi, M., Ardabili, S. Z., Sheykhivand, S., & Danishvar, S. (2023). Deep Learning for Detecting Multi-Level Driver Fatigue Using Physiological Signals: A Comprehensive Approach. *Sensors*, 23(19). <https://doi.org/10.3390/s23198171>
- Poli, E. P., Lumenta, A. S. M., Sugiarto, B. A., & Wuwung, J. O. (n.d.). *Deteksi Rasa Kantuk pada Pengendara Kendaraan Bermotor Berbasis Pengolahan Citra Digital*.
- Rahmawati, R., & Azwar, A. G. (2025). Analisis Kelelahan Subjektif dan Objektif Pada Pengemudi Ojek Online di Kota Bandung. *Rekayasa Industri Dan Mesin (ReTIMS)*, 6(2), 84–88. <https://doi.org/10.32897/retims.2025.6.2.3831>
- Setiawan, R. A., Pradana, F., & Abdurrachman Bachtiar, F. (2021a). *Pengembangan Aplikasi Pendeteksi Kelelahan bagi Pengendara Mobil berbasis Android melalui Face Recognition* (Vol. 5, Number 11). <http://j-ptiik.ub.ac.id>
- Setiawan, R. A., Pradana, F., & Abdurrachman Bachtiar, F. (2021b). *Pengembangan Aplikasi Pendeteksi Kelelahan bagi Pengendara Mobil berbasis Android melalui Face Recognition* (Vol. 5, Number 11). <http://j-ptiik.ub.ac.id>
- Wan, Y., Wang, H., Lu, L., Lan, X., Xu, F., & Li, S. (2024). An Improved Real-Time Detection Transformer Model for the Intelligent Survey of Traffic Safety

Facilities. *Sustainability (Switzerland)*, 16(23). <https://doi.org/10.3390/su162>

310172