

BAB IV

ANALISIS DAN HASIL

4.1 Validasi Sistem Persepsi Visual

Validasi awal digunakan untuk memastikan kamera, inferensi, modul obstacle, lane stream, dan orientasi citra tersedia sebelum pengujian. Satu capture validasi direkam pada 20 September 2026. Karena jumlah data hanya satu, hasil ini dibaca sebagai readiness gate dan bukan sebagai uji kestabilan statistik.

Tabel 4.1 Hasil validasi sistem persepsi

Parameter	Hasil
Camera stream	TRUE
Camera healthy	TRUE
Orientasi kiri/kanan	TRUE / TRUE
YOLOPv2 active	TRUE
Obstacle stream / status	LIVE / OK
Lane stream	LIVE
Stream status	LIVE
Pipeline FPS	1,385
Inference time	653,091 ms
Frame age	93,39 ms

Seluruh gate utama berada pada kondisi aktif/LIVE sehingga sistem dinyatakan siap untuk pengambilan data 4.2–4.5. Nilai performa pada tahap ini hanya digunakan sebagai indikator kesiapan awal; evaluasi performa secara khusus dibahas pada Subbab 4.4.

4.2 Pengujian Deteksi Manusia dan Estimasi Jarak

4.2.1 Kondisi Pengujian

Pengujian deteksi manusia dan estimasi jarak dilakukan pada dua kondisi, yaitu malam dan siang. Masing-masing kondisi diuji pada jarak referensi 1, 2, 3, 4, dan 5 m. Pada setiap jarak diambil 10 capture, sehingga diperoleh 50 capture untuk kondisi malam dan 50 capture untuk kondisi siang, atau total 100 capture. Setiap


capture menyimpan status deteksi, confidence, geometri bounding box, dan estimasi jarak hasil kalibrasi.

Model kalibrasi yang sama diterapkan pada kedua kondisi agar hasil malam dan siang dapat dibandingkan secara langsung. Hubungan yang digunakan didasarkan pada rasio lebar citra terhadap lebar bounding box manusia, dengan koefisien $a = 0,463525$ dan $b = -0,057497$. Dengan model ini, bounding box yang relatif lebih besar akan menghasilkan estimasi jarak yang lebih pendek.

$$r = \frac{W_{\text{image}}}{W_{\text{bbox}}} \quad (4.1)$$

$$\hat{d} = 0,463525 r - 0,057497 \quad (4.2)$$

Dokumentasi contoh hasil deteksi manusia pada kondisi malam dan siang ditunjukkan pada Gambar 4.1. Masing-masing komposit menampilkan lima jarak pengujian, yaitu 1 m sampai 5 m.



Gambar 4.1 Contoh capture deteksi manusia pada jarak 1–5 m pada kondisi malam dan siang

Sumber: Dokumentasi Penelitian (2026)

4.2.2 Detection Rate dan Confidence

Detection rate dihitung dari jumlah capture yang menghasilkan kandidat manusia terhadap seluruh capture pengujian. Confidence digunakan untuk menggambarkan tingkat keyakinan model terhadap kandidat manusia yang terdeteksi, tetapi tidak digunakan sebagai ukuran langsung akurasi estimasi jarak.

Tabel 4.2 Hasil deteksi manusia pada kondisi malam dan siang


(a) Kondisi malam

Jarak (m)	Deteksi (n/N)	Detection rate (%)	Confidence mean $\pm$ std
1	10/10	100	$0,991 \pm 0,002$
2	10/10	100	$0,967 \pm 0,009$
3	10/10	100	$0,777 \pm 0,035$
4	10/10	100	$0,658 \pm 0,043$
5	10/10	100	$0,941 \pm 0,011$
Total 1–5	50/50	100	$0,867 \pm 0,131$

(b) Kondisi siang

Jarak (m)	Deteksi (n/N)	Detection rate (%)	Confidence mean $\pm$ std
1	10/10	100	$0,993 \pm 0,001$
2	10/10	100	$0,996 \pm 0,001$
3	10/10	100	$0,996 \pm 0,002$
4	10/10	100	$0,995 \pm 0,001$
5	10/10	100	$0,891 \pm 0,054$
Total 1–5	50/50	100	$0,974 \pm 0,048$

Perbandingan confidence rata-rata pada setiap jarak untuk kondisi malam dan siang ditunjukkan pada Gambar 4.2.



Gambar 4.2 Perbandingan confidence deteksi manusia pada kondisi malam dan siang

Sumber: Hasil Pengolahan Data Penelitian (2026)

Hasil pada Tabel 4.2 menunjukkan bahwa seluruh 50 capture malam dan 50 capture siang menghasilkan kandidat manusia, sehingga detection rate pada kedua kondisi mencapai 100%. Confidence rata-rata kondisi malam adalah 0,867, sedangkan confidence rata-rata kondisi siang meningkat menjadi 0,974. Pada malam hari confidence cenderung turun pada jarak 3 m dan 4 m, sedangkan pada kondisi siang confidence berada di sekitar 0,99 pada jarak 1–4 m dan turun pada 5 m.

Hasil tersebut menunjukkan bahwa perubahan kondisi pengujian tidak menurunkan keberhasilan identifikasi kandidat manusia. Bahkan, confidence kondisi siang lebih tinggi dibanding malam. Namun demikian, confidence yang tinggi tidak otomatis menghasilkan estimasi jarak yang lebih akurat karena estimasi jarak ditentukan oleh geometri bounding box.

4.2.3 Hasil Estimasi Jarak

Model kalibrasi yang sama diterapkan pada seluruh 100 capture. Nilai estimasi jarak kemudian dibandingkan dengan jarak referensi. Error didefinisikan sebagai estimasi dikurangi jarak referensi, sehingga bias positif menunjukkan over-estimation dan bias negatif menunjukkan under-estimation.

Tabel 4.3 Hasil estimasi jarak manusia setelah kalibrasi pada kondisi malam dan siang


(a) Kondisi malam

Jarak aktual (m)	Estimasi mean (m)	Bias (m)	MAE / RMSE (m)
1	1,022	+0,022	0,026 / 0,029
2	2,445	+0,445	0,445 / 0,447
3	2,979	-0,021	0,025 / 0,030
4	3,565	-0,435	0,435 / 0,437
5	4,711	-0,289	0,289 / 0,299
Keseluruhan	-	-0,056	0,244 / 0,310

(b) Kondisi siang

Jarak aktual (m)	Estimasi mean (m)	Bias (m)	MAE / RMSE (m)
1	0,882	-0,118	0,118 / 0,119
2	1,704	-0,296	0,296 / 0,297
3	2,437	-0,563	0,563 / 0,565
4	3,285	-0,715	0,715 / 0,715
5	3,995	-1,005	1,005 / 1,015
Keseluruhan	-	-0,539	0,539 / 0,627

Perbandingan MAE pada setiap jarak referensi untuk kondisi malam dan siang ditunjukkan pada Gambar 4.3.




Gambar 4.3 Perbandingan MAE estimasi jarak pada kondisi malam dan siang


Sumber: Hasil Pengolahan Data Penelitian (2026)

Pada kondisi malam, estimasi rata-rata pada 1 m dan 3 m berada paling dekat dengan nilai referensi, yaitu 1,022 m dan 2,979 m. Penyimpangan yang lebih besar muncul pada 2 m dengan bias +0,445 m, serta pada 4 m dan 5 m dengan bias masing-masing -0,435 m dan -0,289 m. Secara keseluruhan, kondisi malam menghasilkan MAE 0,244 m dan RMSE 0,310 m.

Pada kondisi siang, seluruh jarak menunjukkan bias negatif, yaitu -0,118 m pada 1 m, -0,296 m pada 2 m, -0,563 m pada 3 m, -0,715 m pada 4 m, dan -1,005 m pada 5 m. Pola tersebut menunjukkan kecenderungan under-estimation yang sistematis. MAE keseluruhan kondisi siang meningkat menjadi 0,539 m dan RMSE menjadi 0,627 m. Dengan demikian, MAE siang sekitar 2,21 kali MAE malam dan RMSE siang sekitar 2,02 kali RMSE malam.



(a) Jarak referensi dan estimasi rata-rata



(b) Rasio lebar bounding box terhadap lebar citra

Gambar 4.4 Perbandingan estimasi jarak dan karakteristik geometri bounding box pada kondisi malam dan siang

Sumber: Hasil Pengolahan Data Penelitian (2026)

4.2.4 Analisis Perbandingan Kondisi Siang dan Malam

Perbedaan utama antara kondisi malam dan siang terdapat pada karakteristik geometri bounding box terhadap model kalibrasi. Rata-rata rasio lebar bounding box terhadap lebar citra pada malam adalah 0,199, sedangkan pada siang meningkat menjadi 0,239. Karena persamaan kalibrasi menggunakan rasio W_image/W_bbox ,

bounding box yang secara relatif lebih besar akan menurunkan nilai rasio dan menghasilkan estimasi jarak yang lebih pendek.

Sebagai contoh, pada jarak referensi 2 m, rasio lebar bounding box malam sekitar 0,185 dan menghasilkan estimasi rata-rata 2,445 m. Pada kondisi siang, rasio tersebut meningkat menjadi sekitar 0,263 sehingga estimasi turun menjadi 1,704 m. Pada jarak 5 m, rasio lebar bounding box meningkat dari sekitar 0,097 pada malam menjadi 0,115 pada siang, sedangkan estimasi turun dari 4,711 m menjadi 3,995 m. Pola ini konsisten dengan bias negatif yang semakin besar pada data siang.

Hasil tersebut menunjukkan bahwa error estimasi jarak pada kondisi siang bukan berasal dari kegagalan deteksi kelas manusia. Detection rate pada kedua kondisi tetap 100% dan confidence kondisi siang justru lebih tinggi. Dengan demikian, sumber utama perbedaan hasil berada pada sensitivitas metode estimasi jarak berbasis bounding box terhadap perubahan geometri keluaran deteksi dan kondisi visual saat pengujian.

Jika seluruh 100 capture digabungkan tanpa membedakan kondisi, diperoleh MAE sekitar 0,392 m dan RMSE sekitar 0,495 m. Namun, nilai gabungan tersebut tidak dijadikan hasil utama karena dapat menutupi perbedaan karakteristik siang dan malam. Pelaporan terpisah menunjukkan bahwa sistem memiliki konsistensi deteksi manusia yang baik pada kedua kondisi, tetapi akurasi estimasi jarak pada malam lebih baik dibanding siang.


Berdasarkan pengujian 4.2, sistem mampu mendeteksi manusia pada rentang 1–5 m pada kondisi malam dan siang dengan detection rate 100%. Akan tetapi, model estimasi jarak belum memiliki robustness yang sama terhadap perubahan kondisi visual. Temuan ini menunjukkan bahwa model kalibrasi berbasis geometri bounding box masih sensitif terhadap perubahan karakteristik proyeksi objek pada citra.

4.3 Pengujian Lane Safety

4.3.1 Hasil enam kondisi Lane Safety

Pengujian dilakukan pada enam kondisi status Lane Safety. Kondisi GRAY|GRAY merepresentasikan drivable area yang tidak valid atau tidak tersedia sebagai evidence yang dapat digunakan sistem, bukan kepastian fisik bahwa jalan

tidak dapat dilalui. Masing-masing kondisi diambil 10 kali sehingga total 60 capture.



Gambar 4.5 Enam kondisi pengujian Lane Safety

Sumber: Dokumentasi Penelitian (2026)


Ringkasan status match, gap rata-rata, dan recommended action pada keenam kondisi tersebut ditunjukkan pada Tabel 4.4.

Tabel 4.4 Hasil enam kondisi Lane Safety

* Mean gap kiri pada kondisi GREEN|RED dihitung dari 5 sampel yang memiliki nilai gap valid ($n_{\text{valid}} = 5$).

Kondisi	N	Status match (%)	Gap kiri mean (px)	Gap kanan mean (px)	Recommended action
GREEN GREEN	10	100	167,82	153,19	CLEAR
YELLOWGREEN	10	100	3,59	339,33	RECENTER_RIGHT
RED GREEN	10	100	-19,80	358,98	RECENTER_RIGHT
GREEN YELLOW	10	100	283,95	31,66	WARNING
GREEN RED	10	100	288,45*	-25,87	RECENTER_LEFT
GRAY GRAY	10	100	—	—	STOP_NO_DRIVER


Kesesuaian status Lane Safety pada setiap kondisi divisualisasikan pada Gambar 4.6.



Gambar 4.6 Kesesuaian status Lane Safety pada enam kondisi

Sumber: Hasil Pengolahan Data Penelitian (2026)

Perbandingan gap kiri dan kanan yang menjadi dasar penentuan status ditunjukkan pada Gambar 4.7.



Gambar 4.7 Perbandingan gap internal pada kondisi Lane Safety

Sumber: Hasil Pengolahan Data Penelitian (2026)

Seluruh 60 capture menghasilkan pasangan status sesuai kondisi acuan sehingga status match pada enam skenario terkontrol mencapai 100%. Nilai tersebut menunjukkan konsistensi logika status pada skenario yang diuji dan tidak digunakan sebagai klaim akurasi segmentasi lane universal.

Tanda gap konsisten terhadap status internal: gap positif yang cukup besar berkaitan dengan GREEN, gap yang mendekati boundary berkaitan dengan

YELLOW, gap negatif berkaitan dengan RED, dan kondisi GRAY|GRAY tidak menghasilkan gap yang dapat digunakan. Mean gap dihitung hanya dari sampel yang memiliki nilai valid; pada GREEN|RED, gap kiri tersedia pada 5 dari 10 capture.

Pada kondisi YELLOW|GREEN, recommendation yang terekam adalah RECENTER_RIGHT. Kondisi ini konsisten dengan mekanisme hysteresis/latch, yaitu status visual dapat telah berubah menjadi YELLOW sementara state koreksi masih dipertahankan sampai ambang release terpenuhi.

4.4 Pengujian Performa Pemrosesan Sistem Persepsi


4.4.1 Hasil pengujian tiga kondisi visual

Hasil pengujian performa pemrosesan pada tiga kondisi visual dirangkum pada Tabel 4.5.

Tabel 4.5 Hasil pengujian performa pemrosesan sistem persepsi

Kondisi	N snapshot	Pipeline	Inference	Processing	Frame age
		Throughput	(ms)	(ms)	(ms)
		(FPS) mean ± std	mean ± std	mean ± std	mean ± std
Jalur relatif kosong	99	1,618 ± 0,048	598,7 ± 83,2	624,0 ± 82,8	124,1 ± 122,5
Satu manusia	106	1,619 ± 0,050	589,9 ± 75,5	615,5 ± 75,1	176,8 ± 140,9
Kondisi kompleks	99	1,587 ± 0,060	614,9 ± 90,7	641,0 ± 90,3	148,9 ± 123,3


Perbandingan pipeline throughput rata-rata pada ketiga kondisi visual ditunjukkan pada Gambar 4.8.



Gambar 4.8 Perbandingan throughput pemrosesan pipeline pada tiga kondisi visual

Sumber: Hasil Pengolahan Data Penelitian (2026)


Selanjutnya, waktu inferensi rata-rata pada ketiga kondisi visual ditunjukkan pada Gambar 4.9.



Gambar 4.9 Perbandingan waktu inferensi

Sumber: Hasil Pengolahan Data Penelitian (2026)

Sementara itu, frame age pada ketiga kondisi visual ditunjukkan pada Gambar 4.10.



Gambar 4.10 Perbandingan frame age

Sumber: Hasil Pengolahan Data Penelitian (2026)

4.4.2 Analisis performa

Frame rate kamera dan throughput pemrosesan merupakan dua parameter yang berbeda. Kamera RGB Astra dikonfigurasi dengan request frame rate sebesar 15 FPS, yaitu laju frame yang diminta pada tahap akuisisi citra. Nilai tersebut tidak digunakan sebagai nilai FPS hasil pengujian pada Tabel 4.5.

FPS pada Tabel 4.5 berasal dari parameter `pipeline_fps`, yaitu laju penyelesaian frame setelah melewati proses pemrosesan pada sistem persepsi. Dengan demikian, nilai sekitar 1,6 FPS tidak menunjukkan bahwa kamera hanya menghasilkan 1,6 frame per detik, melainkan menunjukkan bahwa pada konfigurasi CPU Intel NUC, pipeline persepsi mampu menyelesaikan sekitar 1,6 frame setiap detik.

Untuk menghindari perbedaan interpretasi antara frame rate kamera dan FPS hasil pengujian, parameter performa yang digunakan pada penelitian dirangkum pada Tabel 4.6.

Tabel 4.6 Pembeda parameter laju dan waktu pemrosesan

Parameter	Nilai/kisaran	Makna
Request frame rate kamera	15 FPS	Laju akuisisi citra yang diminta dari kamera
Pipeline throughput	1,587–1,619 FPS	Laju frame yang selesai diproses pipeline
Inference time	589,9–614,9 ms	Waktu proses forward model YOLOPv2
Processing time	615,5–641,0 ms	Waktu satu siklus pemrosesan pipeline
Frame age	124,1–176,8 ms (rata-rata)	Umur frame ketika mulai diproses

Tabel 4.6 menunjukkan bahwa nilai 15 FPS berada pada sisi akuisisi kamera, sedangkan nilai 1,587–1,619 FPS berada pada sisi throughput pemrosesan. Oleh karena itu, nilai sekitar 1,6 FPS tidak menunjukkan keterbatasan kamera dalam menghasilkan frame, tetapi menunjukkan kemampuan CPU Intel NUC dalam menyelesaikan pipeline YOLOPv2 pada konfigurasi penelitian.

Perbedaan tersebut terjadi karena akuisisi kamera dan pemrosesan model merupakan dua proses yang berbeda. Frame dapat diperoleh kamera dengan laju yang lebih tinggi daripada kemampuan pipeline untuk menyelesaikan pemrosesannya. Pipeline YOLOPv2 membutuhkan waktu inferensi rata-rata 589,9–614,9 ms dan waktu pemrosesan total 615,5–641,0 ms per siklus. Oleh karena itu, throughput penyelesaian pipeline berada pada rentang 1,587–1,619 FPS.

Tahap inferensi merupakan komponen waktu dominan pada processing time. Berdasarkan nilai rata-rata yang diperoleh, waktu inferensi mencakup sekitar 95,9% dari waktu processing. Hal ini menunjukkan bahwa keterbatasan throughput terutama berkaitan dengan beban komputasi proses inferensi YOLOPv2 pada CPU Intel NUC.

Pada kondisi kompleks, throughput pipeline turun sekitar 1,9% dibandingkan jalur relatif kosong, sedangkan inference time meningkat sekitar 2,7%. Perbedaan rata-rata tersebut lebih kecil dibandingkan variasi per sampel sehingga belum cukup untuk menyatakan hubungan kausal langsung antara jumlah objek pada citra dan performa pemrosesan.

Status stream tercatat LIVE pada seluruh snapshot telemetry yang dianalisis. Nilai throughput aktual sekitar 1,6 FPS berada di bawah konfigurasi scheduling inferensi sekitar 3 Hz, tetapi nilai tersebut tidak dibandingkan langsung dengan request kamera 15 FPS sebagai kriteria keberhasilan karena kedua parameter merepresentasikan proses yang berbeda. Frame age merepresentasikan umur frame ketika mulai diproses, bukan end-to-end latency.

Counter capture/overwrite pada data mentah tidak disamakan dengan jumlah frame kamera yang hilang. Selain itu, 304 baris GUI merupakan snapshot telemetry dari tiga run dan tidak dianggap sebagai 304 frame inferensi independen.

4.5 Pengujian Integrasi Keluaran Sistem Persepsi

Pengujian 4.5 dilakukan untuk mengamati keterhubungan keluaran persepsi pada sistem ADV ketika kendaraan berada pada kondisi dinamis. Batas evaluasi tetap berada pada subsistem persepsi: obstacle diverifikasi sampai membentuk marking pada representasi lingkungan, sedangkan Lane Safety diverifikasi dari perubahan status kiri-kanan. Perencanaan lintasan, Navigation2, pengendali aktuator, dan keberhasilan mencapai goal tidak digunakan sebagai parameter penilaian.

4.5.1 Integrasi Informasi Obstacle pada Representasi Lingkungan

Pengujian integrasi obstacle dilakukan untuk mengetahui apakah informasi manusia hasil deteksi dapat diteruskan menjadi representasi obstacle pada sistem ADV. Pengujian ini dibatasi pada keterhubungan keluaran sistem persepsi dengan representasi lingkungan kendaraan dan tidak digunakan untuk mengevaluasi performa algoritma perencanaan lintasan maupun keberhasilan kendaraan dalam melakukan penghindaran obstacle.


Hasil pengujian integrasi obstacle dirangkum pada Tabel 4.7. Data yang digunakan merupakan lima rekaman saat sistem pengujian diaktifkan yang berasal dari tiga trial. Parameter yang diamati meliputi confidence kandidat manusia, keberadaan representasi obstacle, dan keberadaan marking obstacle pada *local costmap*.

Tabel 4.7 Hasil pengujian integrasi obstacle

Rekaman	Confidence awal	Object cloud	Costmap marking	Interpretasi
Trial 1 - C2	0,986	Ada	Ada	Terintegrasi
Trial 2 - C2	0,997	Ada	Ada	Terintegrasi
Trial 3 - C2	0,999	Ada	Ada	Terintegrasi
Trial 3 - C3	0,982	Ada	Ada	Terintegrasi
Trial 3 - C4	0,889	Ada	Ada	Terintegrasi

Berdasarkan Tabel 4.7, manusia terdeteksi pada seluruh lima rekaman dengan confidence antara 0,889–0,999. Pada seluruh rekaman tersebut, informasi obstacle juga telah muncul pada representasi lingkungan dan membentuk marking pada *local costmap*. Dengan demikian, lima rekaman yang dianalisis menunjukkan bahwa keluaran deteksi manusia dapat diteruskan dari pipeline persepsi menuju representasi obstacle pada sistem ADV. Hasil ini tidak digunakan untuk menghitung kembali tingkat keberhasilan deteksi manusia karena kemampuan deteksi telah dievaluasi secara terpisah pada Subbab 4.2.

Salah satu contoh proses integrasi tersebut ditunjukkan pada Gambar 4.11. Gambar menampilkan kondisi pada waktu yang bersesuaian antara hasil deteksi dari kamera dan representasi obstacle pada *local costmap*

**Gambar 4.11** Integrasi informasi obstacle dari deteksi visual menuju marking pada local costmap

Sumber: Dokumentasi Penelitian (2026)

Pada Gambar 4.11 terlihat manusia telah terdeteksi pada citra kamera dan pada saat yang sama informasi tersebut telah direpresentasikan sebagai obstacle pada *local costmap*. Hasil ini memperkuat data pada Tabel 4.7 bahwa keluaran persepsi tidak hanya ditampilkan pada GUI, tetapi telah diteruskan melalui ROS 2

menuju representasi lingkungan yang dapat digunakan oleh subsistem lain pada ADV.

Meskipun pembentukan marking obstacle berhasil, pada pengujian aktual ditemukan keterbatasan ketika kendaraan mulai melakukan manuver penghindaran. Saat kendaraan berbelok, arah pandang kamera ikut berubah sehingga manusia dapat keluar dari bidang pandang kamera. Ketika manusia tidak lagi teramati, informasi obstacle yang sebelumnya terdapat pada representasi lingkungan dapat menghilang sebelum kendaraan benar-benar melewati posisi obstacle.

Hilangnya representasi obstacle tersebut menyebabkan subsistem perencanaan kembali menerima kondisi lintasan yang dianggap bebas dari obstacle. Jalur kemudian diperbarui menjadi lintasan yang lebih langsung menuju goal karena lintasan tersebut kembali menjadi jalur terpendek yang tersedia. Kendaraan selanjutnya bergerak kembali menuju jalur awal. Namun, pada saat kendaraan kembali mendekati jalur tersebut, posisi kendaraan telah berada terlalu dekat dengan obstacle sehingga ruang yang tersedia untuk melakukan manuver penghindaran tidak lagi mencukupi. Kondisi tersebut menyebabkan kendaraan berhenti di depan obstacle.

Berdasarkan pengamatan tersebut, keterbatasan yang relevan terhadap sistem persepsi bukan terletak pada kemampuan awal mendeteksi manusia atau membentuk marking obstacle, tetapi pada kontinuitas representasi obstacle ketika objek sementara keluar dari bidang pandang kamera. Oleh karena itu, informasi obstacle perlu dikembangkan dengan mekanisme tracking atau persistensi sehingga keberadaan obstacle tetap dipertahankan sampai kendaraan benar-benar melewati objek atau terdapat informasi bahwa area tersebut telah kembali bebas. Evaluasi terhadap algoritma perencanaan lintasan itu sendiri tidak dilakukan karena berada di luar ruang lingkup penelitian sistem persepsi visual.


4.5.2 Pembaruan Status Lane Safety pada Kondisi Dinamis

Pengujian Lane Safety dinamis dilakukan untuk melengkapi pengujian enam kondisi statis pada Subbab 4.3. Kondisi awal yang digunakan pada rekaman ARMED adalah GREEN|RED. Status Lane Safety kemudian dicatat kembali ketika hubungan visual kendaraan terhadap batas lane berubah.

Tabel 4.8 Pembaruan status Lane Safety pada kondisi dinamis

Rekaman	Status awal	Status saat capture	Perubahan	Keterangan
Trial 1 - C2	GREEN RED	GREEN RED	Belum berubah	Fase awal
Trial 1 - C3	GREEN RED	GREEN GREEN	Berubah	Kondisi aman teramati
Trial 2 - C2	GREEN RED	GREEN GREEN	Berubah	Kondisi aman teramati
Trial 3 - C2	GREEN RED	GREEN RED	Belum berubah	Fase awal
Trial 3 - C3	GREEN RED	GREEN GREEN	Berubah	Kondisi aman teramati
Trial 3 - C4	GREEN RED	GREEN GREEN	Berubah	Kondisi aman teramati

Contoh perubahan keluaran Lane Safety pada salah satu rekaman ditunjukkan pada Gambar 4.12.



Gambar 4.12 Perubahan keluaran Lane Safety dari GREEN|RED menjadi GREEN|GREEN pada kondisi dinamis

Sumber: Dokumentasi Penelitian (2026)

Empat dari enam snapshot merekam kondisi GREEN|GREEN setelah kondisi awal GREEN|RED, sedangkan dua snapshot masih merekam GREEN|RED pada fase sebelum transisi. Jumlah tersebut tidak diperlakukan sebagai persentase keberhasilan karena setiap snapshot merepresentasikan fase waktu yang berbeda, bukan enam pengulangan independen. Gambar 4.12 menunjukkan contoh Trial 3 ketika status kanan berubah dari RED menjadi GREEN setelah kondisi lane pada citra berubah.

Hasil ini memberikan bukti bahwa keluaran Lane Safety tidak mempertahankan status awal secara tetap, tetapi diperbarui berdasarkan informasi lane yang tersedia pada frame berikutnya. Pergerakan steering, perpindahan authority, dan keberhasilan kendaraan mencapai goal tidak digunakan sebagai dasar kesimpulan karena berada di luar ruang lingkup sistem persepsi.

4.5.3 Keterbatasan Pengujian Integrasi

Pengujian integrasi menunjukkan dua keterbatasan utama. Pertama, informasi obstacle dapat menjadi stale ketika manusia keluar dari bidang pandang kamera sehingga diperlukan mekanisme tracking atau persistensi temporal agar hilangnya deteksi pada beberapa frame tidak langsung disamakan dengan hilangnya obstacle secara fisik. Kedua, pipeline throughput sekitar 1,6 FPS pada CPU menyebabkan interval antarpembaruan persepsi relatif besar pada kondisi kendaraan bergerak. Keterbatasan tersebut menjadi dasar saran pengembangan dan tidak mengubah hasil verifikasi bahwa obstacle telah membentuk marking serta status Lane Safety dapat diperbarui secara dinamis.

4.6 Rekapitulasi Hasil Pengujian

Tabel 4.9 Rekapitulasi hasil BAB IV

Subbab	Data	Hasil utama	Interpretasi
4.1 Validasi	1 capture	Semua gate utama aktif/LIVE	Readiness gate
4.2 Deteksi manusia & jarak	100 capture (50 malam + 50 siang)	Detection rate 100% (malam dan siang); confidence mean 0,867 (malam) / 0,974 (siang); MAE/RMSE 0,244/0,310 m (malam) dan 0,539/0,627 m (siang)	Deteksi konsisten; estimasi jarak sensitif terhadap kondisi visual

Lanjutan Tabel 4.9 Rekapitulasi hasil BAB IV

Subbab	Data	Hasil utama	Interpretasi
4.3 Lane Safety	60 capture	60/60 status sesuai pada 6 kondisi	Kesesuaian status skenario terkontrol
			Performa pemrosesan pipeline YOLOPv2 pada CPU Intel NUC; nilai FPS bukan frame rate input kamera
4.4 Performa pemrosesan	3 run / 304 snapshot	Pipeline throughput 1,587–1,619 FPS; inference time 589,9–614,9 ms; processing time 615,5–641,0 ms	
4.5 Integrasi keluaran	5 rekaman obstacle + 6 snapshot lane	Obstacle membentuk marking; perubahan GREEN RED → GREEN GREEN teramati	Bukti keterhubungan keluaran persepsi

4.7 Pembahasan Keseluruhan Hasil

Hasil penelitian menjawab empat tujuan utama. Sistem persepsi berbasis YOLOPv2 telah diimplementasikan pada Astra, Intel NUC, dan ROS 2; YOLOPv2 menghasilkan object detection, drivable area, dan lane line. Pada pengujian manusia, seluruh 100 capture pada kondisi malam dan siang menghasilkan kandidat manusia. Estimasi jarak terkalibrasi memperoleh MAE 0,244 m dan RMSE 0,310 m pada kondisi malam, serta MAE 0,539 m dan RMSE 0,627 m pada kondisi siang. Lane Safety menghasilkan status match 60/60 pada enam kondisi terkontrol. Pengujian integrasi selanjutnya menunjukkan object cloud dan costmap marking pada lima dari lima rekaman ARMED obstacle serta pembaruan status GREEN|RED menjadi GREEN|GREEN pada kondisi Lane Safety dinamis.

Keterbatasan utama terdapat pada performa komputasi CPU, persistensi informasi obstacle, dan sensitivitas estimasi jarak berbasis geometri bounding box terhadap perubahan kondisi visual. Pada sisi performa komputasi, pipeline throughput sekitar 1,6 FPS dengan inference time sekitar 0,6 s per frame. Nilai tersebut tidak merepresentasikan frame rate kamera karena kamera dikonfigurasi

secara terpisah dengan request akuisisi 15 FPS, melainkan frekuensi frame yang berhasil menyelesaikan keseluruhan rangkaian pemrosesan persepsi pada CPU. Pada integrasi obstacle, informasi dapat menjadi stale ketika manusia keluar dari bidang pandang kamera. Pada estimasi jarak, kondisi siang menunjukkan under-estimation yang sistematis sehingga model kalibrasi belum sepenuhnya robust terhadap perubahan kondisi visual. Oleh karena itu, hasil 4.5 digunakan untuk menyimpulkan keterhubungan keluaran persepsi, bukan kemampuan planner, closed-loop aktuator, atau keberhasilan navigasi kendaraan.

Perbedaan antara laju input dan throughput pemrosesan menunjukkan bahwa pipeline komputasi menjadi bottleneck sistem, khususnya pada tahap inferensi YOLOPv2 yang mencakup sekitar 95,9% processing time. Oleh karena itu, peningkatan performa pada pengembangan berikutnya lebih tepat diarahkan pada optimasi komputasi inferensi dan pipeline dibandingkan sekadar meningkatkan frame rate kamera.