

## Analisis Performa Haar Cascade untuk Estimasi Jarak Aman Kendaraan Berbasis Monocular Vision pada Kondisi Dinamis

<sup>1</sup>Thiara Tri Funny Manguma, <sup>2</sup>Emil Fatra

<sup>1</sup>Informatika, Bisnis Teknologi dan Sosial, Universitas Almarisah Madani Makassar

<sup>2</sup>Ilmu Komunikasi, Bisnis Teknologi dan Sosial, Universitas Almarisah Madani Makassar

<sup>1</sup>thiaramanguma014@gmail.com\*, <sup>2</sup>emilfatra21@gmail.com

### INFO ARTIKEL

#### Riwayat Artikel :

Diterima : 6 Juli 2026

Disetujui : 31 Agustus 2026

Kata Kunci : Deteksi Jarak, Haar Cascade, Detection Rate, MSE, Jarak Aman, Monocular Vision

### ABSTRAK

Penelitian ini mengevaluasi performa Haar Cascade untuk deteksi pelat kendaraan dan estimasi jarak berbasis monocular vision pada kondisi dinamis. Pengujian dilakukan pada tiga variasi kecepatan rencana (10, 20, dan 30 km/jam) dan tiga jarak (5, 10, dan 30 meter). Sistem dilatih menggunakan 30 citra positif dan 30 citra negatif, kemudian diuji menggunakan 2.700 observasi yang berasal dari satu video berdurasi 255 detik. Hasil menunjukkan tingkat deteksi pelat berada pada rentang 18,00% - 91,67% dengan rata-rata 65,55%. Performa terbaik diperoleh pada jarak 5 meter, sedangkan pada jarak 30 meter tingkat deteksi menurun menjadi 18,00% - 70,33%. Analisis menunjukkan bahwa penyusutan ukuran pelat menjadi sekitar 20 - 25 piksel pada jarak 30 meter mengurangi informasi visual yang tersedia bagi classifier. Temuan ini menunjukkan bahwa Haar Cascade masih berpotensi sebagai pendekatan lightweight untuk deteksi jarak dekat, tetapi belum memberikan performa yang konsisten untuk mendukung estimasi jarak aman pada jarak jauh. Keterbatasan utama penelitian meliputi ukuran dataset latih yang kecil, penggunaan satu video pengujian, dan belum tersedianya ground truth jarak per frame sehingga MAE/RMSE jarak serta precision, specificity, dan F1-score penuh belum dapat dihitung secara valid.

### ARTICLE INFO

#### Article History :

Received : Jul 6, 2026

Accepted : Aug 31, 2026

#### Keywords:

Distance Detection, Haar Cascade, Detection Rate, MSE, Safe Distance, Monocular Vision

### ABSTRACT

This study evaluates the performance of Haar Cascade for vehicle license-plate detection and monocular distance estimation under dynamic conditions. The experiment used three planned speed levels (10, 20, and 30 km/h) and three distances (5, 10, and 30 m). The classifier was trained using 30 positive and 30 negative images and evaluated on 2,700 observations extracted from a single 255-second video. The detection rate ranged from 18.00% to 91.67%, with an overall mean of 65.55%. The best performance occurred at 5 m, whereas detection at 30 m decreased to 18.00% - 70.33%. The decline is associated with the reduction of the license-plate representation to approximately 20 - 25 pixels, which weakens the visual features available to the cascade classifier. These findings indicate that Haar Cascade remains a potential lightweight approach for short-range detection, but it does not provide sufficiently consistent performance for safe-distance estimation at longer ranges. The main limitations are the small training set, the use of a single test video, and the absence of per-frame ground-truth distance, which prevents valid calculation of distance MAE/RMSE and a complete set of precision, specificity, and F1-score metrics.

## 1. PENDAHULUAN

Kepadatan lalu lintas meningkatkan risiko kecelakaan ketika pengemudi gagal mempertahankan jarak pengereman yang aman (Berhanu et al., 2024). Dalam konteks Advanced Driver Assistance Systems (ADAS), informasi jarak kendaraan (Mehta et al., 2024) di depan merupakan komponen penting untuk fungsi seperti adaptive cruise control dan collision warning. Pendekatan berbasis kamera menjadi alternatif yang menarik karena biaya dan kebutuhan perangkat kerasnya lebih rendah dibandingkan LiDAR (Hao et al., 2026), sedangkan penelitian monocular distance estimation terbaru menunjukkan bahwa satu kamera dapat digunakan untuk memperoleh informasi jarak melalui geometri kamera, fitur objek, maupun estimasi depth berbasis pembelajaran mesin (Lee et al., 2022). Namun, estimasi jarak monocular tetap menghadapi tantangan perubahan sudut kamera, ukuran objek yang kecil, occlusion, dan perubahan kondisi lingkungan.

Berbagai pendekatan modern menggabungkan object detection, depth estimation, tracking, dan model geometris (Zhao et al., 2026). (Lee et al., 2022) mengembangkan kerangka estimasi jarak kendaraan dari kamera monocular dengan object detector, depth estimator, dan distance predictor. Roll angle kamera dapat memengaruhi pengukuran jarak berbasis geometri dan perlu dikompensasi. Kamera stereo mampu memperoleh informasi depth secara langsung tanpa model ukuran objek, namun memerlukan kalibrasi kompleks, komputasi berat, dan baseline fisik yang lebar sehingga kurang sesuai untuk kendaraan kompak (Chen and Chen, 2011). Sebagai alternatif, metode berbasis monocular vision (Zhsou et al., 2026) menggunakan satu kamera dengan model geometris berbasis ukuran referensi objek. Pendekatan ini dipilih dalam penelitian ini karena biayanya rendah, integrasinya mudah, dan kebutuhan komputasinya ringan, sehingga lebih realistis untuk diimplementasikan pada perangkat dengan sumber daya terbatas dibanding LiDAR maupun kamera stereo.

Penelitian lain menggabungkan YOLOv5 dengan tracking dan filtering temporal untuk mengurangi fluktuasi estimasi jarak yang disebabkan oleh pergerakan kendaraan dan

occlusion (Lv et al., 2024). Perkembangan detector real-time juga semakin mengarah pada model yang lebih efisien, seperti YOLOv10, yang dirancang untuk meningkatkan trade-off akurasi dan latensi pada object detection real-time (Wang et al., 2025).

Di antara pendekatan monocular yang ringan, Haar Cascade (Viola and Jones, 2001) tetap menarik sebagai baseline karena struktur cascade dan penggunaan fitur Haar memungkinkan deteksi berbasis CPU dengan kebutuhan komputasi relatif rendah (Viola and Jones, 2001). Akan tetapi, karakteristik tersebut harus dipertimbangkan bersama keterbatasan representasi fitur ketika objek berukuran sangat kecil pada citra. Studi terbaru menunjukkan bahwa sistem berbasis deep learning dapat memberikan performa yang lebih stabil untuk deteksi dan estimasi jarak kendaraan pada rentang yang lebih panjang. (Donghao Qiao, 2020), misalnya, melaporkan estimasi jarak kendaraan hingga rentang longitudinal 50 m dengan rata-rata relative error 1,87% pada kondisi tanpa occlusion. (Kumar et al., 2026), juga menunjukkan bahwa kombinasi depth estimation dan object detection dapat menghasilkan estimasi metrik dengan MAE 1,18 m dan RMSE 2,03 m pada KITTI. Perbandingan tersebut tidak dimaksudkan sebagai perbandingan langsung karena dataset, sensor, metrik, dan kondisi eksperimen berbeda, tetapi digunakan untuk menempatkan Haar Cascade sebagai baseline lightweight yang perlu diuji secara empiris.

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan mengevaluasi performa Haar Cascade untuk deteksi pelat dan estimasi jarak monocular pada kondisi dinamis melalui tiga variasi kecepatan rencana (10, 20, dan 30 km/jam) dan tiga variasi jarak (5, 10, dan 30 meter). Penelitian secara khusus menganalisis perubahan tingkat deteksi ketika ukuran objek dalam piksel semakin kecil, menentukan batas operasional berdasarkan kondisi yang benar-benar diuji, serta membandingkan posisi pendekatan ini dengan perkembangan metode object detection dan monocular distance estimation terbaru. Kontribusi penelitian dinyatakan sebagai evaluasi empiris pada konfigurasi pengujian tersebut, bukan sebagai

klaim bahwa penelitian ini merupakan yang pertama.

## 2. METODE

### 2.1 Data Sampel

Input data dalam penelitian ini adalah citra pelat kendaraan, diambil di sepanjang jalan kampus Teknik Universitas Hasanuddin pada kondisi pencahayaan yang dinamis. Pengambilan data menggunakan kamera GoPro Hero X dengan resolusi  $640 \times 360$  piksel (rasio aspek 16:9, setara  $\pm 0,23$  megapiksel) yang ditempatkan di bagian dalam kaca depan mobil pada ketinggian  $\pm 1,2$  meter sejajar dengan jalan. Fitur zoom, autofocus, dan stabilisasi digital pada kamera tidak dinonaktifkan selama proses pengambilan data. Proses deteksi dan pelatihan classifier dijalankan menggunakan OpenCV versi 4.8.0 dan Python versi 3.10 pada jarak kendaraan uji yang bervariasi. Data pelatihan terdiri atas 30 sampel positif (citra pelat kendaraan dari berbagai sudut dan kondisi pencahayaan) dan 30 sampel negatif (citra non-pelat seperti jalan, pohon, gedung, dan latar belakang lain). Data pengujian menggunakan 1 video berdurasi 4 menit 15 detik (255 detik) yang diambil pada 3 skenario kecepatan (10, 20, 30 km/jam) dan 3 variasi jarak (5, 10, 30 meter), dengan total 7.500 frame terekam setara dengan frame rate sekitar 29,4 fps ( $7.500 \div 255$  detik), mendekati 30 fps.

Dari 7.500 frame total, sebanyak 2.700 frame (masing-masing 300 frame untuk setiap kombinasi 3 kecepatan  $\times$  3 jarak) digunakan pada pengujian deteksi pelat (Tabel 3), sedangkan 465 pengamatan pengenalan pelat pada sepuluh interval waktu digunakan pada Tabel 4. Meskipun jumlah frame relatif besar, seluruh frame berasal dari satu rangkaian video sehingga observasi yang berurutan tidak sepenuhnya independen. Oleh karena itu, 7.500 frame tidak dapat diperlakukan sebagai 7.500 sampel independen dengan keragaman yang setara dengan beberapa video, lokasi, kendaraan, dan kondisi pencahayaan yang berbeda.

Penggunaan 60 data latih, yaitu 30 citra positif dan 30 citra negatif, merupakan keterbatasan utama dibandingkan pendekatan deep learning yang umumnya memanfaatkan dataset yang lebih besar. Ukuran data yang kecil berpotensi menyebabkan overfitting dan

membatasi generalisasi classifier terhadap variasi kendaraan, sudut pelat, pencahayaan, dan latar. Karena itu, hasil penelitian ini diposisikan sebagai studi evaluasi awal (proof of concept), bukan sebagai validasi sistem yang siap untuk implementasi produksi.

### 2.2 Deteksi Jarak Kendaraan

Algoritma Haar Cascade merupakan metode pembelajaran mesin untuk deteksi objek yang diperkenalkan oleh Viola dan Jones. Metode ini menggunakan data positif dan negatif untuk membangun classifier, mengekstraksi fitur Haar, dan memanfaatkan integral image untuk mempercepat perhitungan. Walaupun jauh lebih ringan daripada detector deep learning modern, performanya sangat bergantung pada kemiripan pola objek uji dengan data latih dan pada ukuran objek dalam citra. Hal tersebut menjadi penting dalam penelitian ini karena pelat kendaraan pada jarak jauh hanya direpresentasikan oleh sejumlah kecil piksel.

Fitur-fitur yang relevan dipilih melalui proses boosting, di mana setiap fitur dievaluasi berdasarkan ambang batas terbaik untuk memisahkan objek positif dan negatif, dan fitur dengan tingkat kesalahan klasifikasi minimum dipilih. Struktur akhir sistem deteksi berbentuk cascade, yaitu rangkaian classifier bertahap yang semakin kompleks, sebuah wilayah citra harus lolos seluruh tahap untuk dinyatakan sebagai objek yang terdeteksi, dan akan langsung ditolak apabila gagal pada tahap awal yang sederhana. Strategi ini mempercepat proses deteksi secara keseluruhan karena area non-objek dibuang lebih awal.

Pelatihan dilakukan menggunakan OpenCV `opencv_traincascade` dengan parameter `-numPos 30 -numNeg 30 -numStages 10 -minHitRate 0.995 -maxFalseAlarmRate 0.5 -mode ALL`.

Proses klasifikasi berjalan tiga tahap: (1) setiap sub-citra diklasifikasikan menggunakan satu fitur pada filter pertama; sub-citra yang tidak memenuhi ambang batas langsung ditolak dan algoritme berpindah ke sub-jendela berikutnya, (2) sub-citra yang lolos dilanjutkan ke filter berikutnya hingga jumlah sub-jendela yang tersisa mendekati area objek sebenarnya, (3) OpenCV bersama pembungkus Python (cv2) memanggil classifier untuk mendeteksi objek

dari video dan menghasilkan keputusan akhir berupa pelat kendaraan atau bukan.

### 2.3 Sistem Pengukuran jarak

Sistem pengukuran jarak kendaraan didasarkan pada lebar pelat nomor sebagai ukuran referensi tetap. Prinsip tersebut memanfaatkan hubungan geometris antara ukuran objek sebenarnya dan proyeksinya pada bidang citra melalui model pinhole. Pendekatan berbasis ukuran pelat masih digunakan dalam penelitian monocular ranging karena sederhana dan dapat dijalankan dengan sumber daya komputasi terbatas; namun, penelitian yang lebih baru cenderung menggabungkannya dengan object detection, depth estimation, tracking, atau koreksi pose kamera untuk meningkatkan ketahanan terhadap variasi kondisi (Donghao Qiao, 2020).

$$D' = \frac{W XF}{p} \quad (1)$$

Persamaan tersebut digunakan pada fase kalibrasi untuk memperoleh panjang fokus efektif (F) dalam satuan piksel: sebuah pelat nomor dengan lebar fisik W yang diketahui ditempatkan pada jarak D yang telah diukur, kemudian lebar pelat pada citra diukur dalam piksel (P) untuk menghitung F (Yao et al., 2017). Kalibrasi dilakukan pada jarak 5 meter dengan lebar pelat standar 0,45 meter.

Setelah F diperoleh, sistem mengestimasi jarak (D) ke kendaraan lain secara dinamis menggunakan persamaan yang sama: sistem mendeteksi dan memotong (cropping) wilayah pelat pada citra kendaraan target, mengukur lebar pelat dalam piksel (P), lalu menghitung D menggunakan W dan F yang telah dikalibrasi. Semakin besar P (pelat tampak lebih lebar dalam piksel), semakin kecil D yang dihasilkan, dan sebaliknya (Sreevidya et al., 2020).

Perhitungan bertumpu pada tiga asumsi: (1) pelat terdeteksi secara horizontal tanpa rotasi signifikan, (2) kamera sejajar dengan bidang pelat, dan (3) tidak ada distorsi lensa yang signifikan. Asumsi tersebut sulit dipenuhi sepenuhnya pada jalan nyata. (Yang et al., 2023) menunjukkan bahwa roll angle kamera dapat memengaruhi hasil pengukuran monocular berbasis geometri. Oleh karena itu, hasil penelitian ini perlu dipahami sebagai estimasi pada konfigurasi kamera dan kondisi pengujian yang digunakan. Pengembangan berikutnya

perlu melakukan kalibrasi intrinsik, koreksi distorsi, pencatatan pose kamera, dan ground truth jarak per frame.

Penentuan status jarak berkendara pada penelitian ini mengacu pada panduan praktis jarak aman yang umum digunakan oleh instansi perhubungan di Indonesia (lih. Dinas Perhubungan Kabupaten Sleman, n.d.), sebagaimana ditampilkan pada Tabel 1. Perlu ditegaskan bahwa tabel ini merupakan panduan jarak aman kendaraan, bukan kutipan langsung pasal PP No. 43 Tahun 1993.

Tabel 1. Panduan Jarak Aman Kendaraan Berdasarkan Kecepatan

| Kecepatan  | Jarak Minimal | Jarak Aman |
|------------|---------------|------------|
| 30 km/jam  | 15 meter      | 30 meter   |
| 40 km/jam  | 20 meter      | 40 meter   |
| 50 km/jam  | 25 meter      | 50 meter   |
| 60 km/jam  | 40 meter      | 60 meter   |
| 70 km/jam  | 50 meter      | 70 meter   |
| 80 km/jam  | 60 meter      | 80 meter   |
| 90 km/jam  | 70 meter      | 90 meter   |
| 100 km/jam | 80 meter      | 100 meter  |

Evaluasi utama pada penelitian ini menggunakan detection rate, yaitu proporsi frame yang berhasil mendeteksi pelat terhadap seluruh frame yang memang mengandung target pada setiap skenario. Metrik ini dipilih karena dataset pengujian yang tersedia belum menyediakan subset frame negatif yang terpisah dan terannotasi secara memadai. Akibatnya, True Negative dan False Positive tidak dapat ditentukan secara lengkap, sehingga accuracy klasifikasi, precision, specificity, dan F1-score penuh belum dapat dihitung secara sah. Kondisi ini dinyatakan sebagai keterbatasan metodologis, bukan sebagai alasan untuk menyamakan detection rate dengan accuracy klasifikasi.

$$\text{Tingkat Deteksi} = \frac{(\text{Benar Deteksi})}{\text{Total Observasi}} \times 100\% \quad (2)$$

Istilah TP (True Positive), TN (True Negative), FP (False Positive), dan FN (False Negative) merujuk pada matriks kebingungan (confusion matrix) (Erbani et al., 2024) standar (Tabel 2), yang banyak digunakan dalam biostatistik, penilaian kredit, dan sistem deteksi

objek untuk mengukur kinerja klasifikasi (Mohammadi, 2024).

Tabel 2. Struktur Confusion Matriks

| Data Aktual | Prediksi Positif | Prediksi Negatif |
|-------------|------------------|------------------|
| Positif     | True Positive    | False Negative   |
| Negatif     | False Positive   | True Negative    |

Untuk menggambarkan dispersi tingkat deteksi pada sembilan skenario, MSE dihitung terhadap rata-rata sembilan nilai detection rate pada Tabel 3, bukan terhadap rata-rata interval waktu pada Tabel 4. Rata-rata sembilan skenario adalah 65,55%. Dengan demikian, MSE digunakan hanya sebagai ukuran dispersi hasil antar-skenario, bukan sebagai ukuran error estimasi jarak dalam satuan meter. Metrik yang lebih tepat untuk menilai akurasi estimasi jarak adalah MAE atau RMSE dalam meter terhadap ground truth per frame, tetapi data ground truth tersebut belum tersedia pada eksperimen ini.

$$MSE = \sum (e_i^2) / n \quad (3)$$

Dengan  $n = 9$  skenario dan  $e_i = x_i - \bar{x}$ , nilai MSE dihitung dari sembilan detection rate pada Tabel 3 terhadap rata-ratanya sebesar 65,55%. Nilai MSE yang besar menunjukkan adanya variasi performa yang lebar antar-skenario. Karena satuannya berupa kuadrat percentage point, nilai ini tidak boleh ditafsirkan sebagai error jarak dalam meter.

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Pengujian Deteksi Pelat pada Berbagai Kecepatan dan Jarak

Proses pengujian dirancang untuk mengevaluasi ketahanan sistem pada kondisi dinamis dan tidak sepenuhnya terkontrol. Pengujian menggunakan tiga kecepatan rencana, yaitu 10, 20, dan 30 km/jam, serta tiga jarak, yaitu 5, 10, dan 30 meter. Kecepatan aktual tidak selalu konstan karena dipengaruhi tikungan, pejalan kaki, kendaraan lain, dan kondisi jalan. Variasi alami tersebut memberikan gambaran kondisi lapangan, tetapi sekaligus menyebabkan faktor kecepatan, pencahayaan, sudut pelat, dan posisi kendaraan tidak dapat dipisahkan secara kausal. Oleh karena itu, analisis difokuskan pada pola performa yang teramati, bukan pada klaim bahwa kecepatan tertentu secara kausal meningkatkan akurasi.

Beberapa kondisi spesifik di lapangan secara langsung mempengaruhi kecepatan dan menjadi skenario uji yang berharga. Sebagai contoh, ketika rute pengujian melewati area jalan dengan lengkungan yang tajam, pengemudi terpaksa mengurangi kecepatan secara signifikan demi keamanan, sehingga menciptakan momen uji pada kecepatan rendah yang tidak terencana. Selain itu, kehadiran pejalan kaki yang menyeberang jalan secara tak terduga memaksa mobil untuk melambat atau berhenti, menguji respons sistem terhadap objek bergerak lain yang dapat mengganggu bidang pandang. Demikian pula, interaksi dengan kendaraan lain yang berada di depan maupun di samping kiri-kanan jalan menyebabkan variasi kecepatan dan perubahan posisi relatif, yang pada akhirnya menguji kemampuan sistem dalam mempertahankan deteksi dan pengukuran yang akurat di tengah lingkungan lalu lintas yang padat dan kompleks.



Gambar 1. Contoh Deteksi Pelat (Positif)



Gambar 2. Contoh Deteksi bukan Pelat (Negatif)

Hasil pengujian sistem menggunakan 2.700 observasi (300 observasi per kombinasi kecepatan-jarak) ditampilkan pada Tabel 3.

Tabel 3. Hasil Deteksi Pelat pada Berbagai Kecepatan dan Jarak

| Rencana Kecepatan | Jarak    | Salah deteksi | Benar deteksi | Tingkat Deteksi |
|-------------------|----------|---------------|---------------|-----------------|
| 10km/jam          | 5 meter  | 84            | 216           | 71,67%          |
|                   | 10 meter | 95            | 205           | 68,33%          |
|                   | 30 meter | 246           | 54            | 18,00%          |
| 20km/jam          | 5 meter  | 83            | 217           | 72,00%          |
|                   | 10 meter | 77            | 223           | 74,33%          |
|                   | 30 meter | 197           | 103           | 34,33%          |
| 30km/jam          | 5 meter  | 25            | 275           | 91,67%          |
|                   | 10 meter | 32            | 268           | 89,33%          |
|                   | 30 meter | 89            | 211           | 70,33%          |

Rata-rata detection rate dari sembilan skenario adalah  $(71,67 + 68,33 + 18,00 + 72,00 + 74,33 + 34,33 + 91,67 + 89,33 + 70,33) / 9 = 65,55\%$ . Nilai ini menunjukkan bahwa performa umum sistem berada pada tingkat moderat dan tidak konsisten pada seluruh kondisi pengujian. Nilai maksimum 91,67% hanya dicapai pada satu konfigurasi, sedangkan nilai minimum 18,00% menunjukkan adanya kegagalan deteksi yang besar pada kondisi tertentu.

Berdasarkan Tabel 3, jarak merupakan faktor yang paling jelas berkaitan dengan penurunan detection rate. Pada jarak 5 meter, lebar pelat diperkirakan sekitar 120 - 150 piksel; pada 10 meter sekitar 60 - 80 piksel; sedangkan pada 30 meter hanya sekitar 20 - 25 piksel. Ketika representasi objek menjadi sangat kecil, informasi tepi, kontras, dan pola karakter yang digunakan classifier menjadi semakin terbatas dan lebih mudah terpengaruh noise serta perubahan pencahayaan. Temuan ini konsisten dengan persoalan small-object dan pixel-sparse pada monocular distance estimation yang juga menjadi tantangan pada metode modern. Dengan demikian, penurunan pada 30 meter lebih tepat dijelaskan sebagai keterbatasan representasi visual dan generalisasi classifier, bukan semata-mata akibat jarak geometris.

Tingkat deteksi tertinggi, 91,67%, diperoleh pada konfigurasi 30 km/jam dan 5 meter. Konfigurasi ini merupakan titik optimal deteksi dalam eksperimen, tetapi bukan kondisi jarak aman pada kecepatan 30 km/jam karena tabel panduan penelitian menetapkan 30 meter sebagai jarak aman. Sebaliknya, pada jarak 30 meter detection rate berada pada 18,00%, 34,33%, dan 70,33% untuk masing-masing

kecepatan 10, 20, dan 30 km/jam. Artinya, kondisi yang paling relevan dengan kebutuhan jarak aman justru menunjukkan ketidakstabilan deteksi yang membuat Haar Cascade belum layak dijadikan satu-satunya komponen ADAS. Pada jarak yang sama, skenario 30 km/jam menghasilkan detection rate lebih tinggi daripada beberapa skenario 10 dan 20 km/jam. Namun, pola tersebut tidak boleh ditafsirkan sebagai bukti bahwa kecepatan tinggi meningkatkan kemampuan Haar Cascade. Eksperimen tidak mengontrol seluruh variabel seperti pencahayaan, sudut pelat, jenis kendaraan, dan posisi relatif secara ketat. Dengan demikian, perbedaan tersebut lebih tepat diperlakukan sebagai variasi empiris dalam dataset pengujian dan perlu diverifikasi dengan pengujian yang lebih terkontrol serta pencatatan kecepatan aktual menggunakan GPS logger.

### 3.2 Tingkat Deteksi per Interval Waktu

Tingkat deteksi juga dihitung per interval waktu ditampilkan pada Tabel 4.

Tabel 4. Tingkat Deteksi Pelat per Interval Waktu

| Waktu (detik) | Pengenalan pelat |       | Tingkat Deteksi   |
|---------------|------------------|-------|-------------------|
|               | Ya               | Tidak |                   |
| 0-25          | 38               | 10    | 79.17%            |
| 26-50         | 35               | 18    | 66.04%            |
| 51-75         | 38               | 3     | 92.68%            |
| 75-100        | 36               | 10    | 78.26%            |
| 101-125       | 37               | 18    | 67.27%            |
| 126-150       | 36               | 9     | 80.00%            |
| 151-175       | 36               | 9     | 80.00%            |
| 176-200       | 39               | 8     | 82.98%            |
| 201-225       | 38               | 4     | 90.48%            |
| 226-255       | 36               | 7     | 83.72%            |
| TOTAL         | 369              | 96    | Rata-Rata= 80.06% |

Terdapat dua cara menghitung rata-rata pada Tabel 4. Macro-average dari sepuluh interval adalah 80,06%, sedangkan micro-average berdasarkan total 369 deteksi berhasil dari 465 observasi adalah 79,35%. Kedua nilai tersebut hanya digunakan untuk mendeskripsikan kestabilan deteksi sepanjang waktu dan tidak digunakan sebagai acuan MSE untuk sembilan skenario pada Tabel 3, karena kedua tabel memiliki unit agregasi yang berbeda. Fluktuasi detection rate antar-interval menunjukkan nilai tertinggi pada interval 51-75 detik sebesar 92,68% dan terendah pada interval

26–50 detik sebesar 66,04%. Fluktuasi tersebut kemungkinan dipengaruhi perubahan pencahayaan, sudut pandang, posisi kendaraan, dan dinamika lalu lintas selama satu perjalanan. Karena seluruh interval berasal dari video yang sama, hasil ini tidak dapat digunakan untuk menyimpulkan generalisasi temporal pada lingkungan yang berbeda.

MSE untuk analisis dispersi sembilan skenario kemudian dihitung ulang menggunakan

Tabel 5. Perhitungan MSE Dispersi Detection Rate terhadap Mean 65,55%

| Kecepatan | Jarak    | Tingkat Deteksi Skenario ( $\hat{y}_i$ ) | Rata-Rata ( $y_i$ ) | Selisih ( $e = \hat{y}_i - y_i$ ) | $e^2$   |
|-----------|----------|------------------------------------------|---------------------|-----------------------------------|---------|
| 10 km/jam | 5 meter  | 71,67%                                   | 65,55%              | +6,12%                            | 37,40   |
|           | 10 meter | 68,33%                                   | 65,55%              | +2,78%                            | 7,70    |
|           | 30 meter | 18,00%                                   | 65,55%              | -47,55%                           | 2261,43 |
| 20 km/jam | 5 meter  | 72,00%                                   | 65,55%              | +6,45%                            | 41,55   |
|           | 10 meter | 74,33%                                   | 65,55%              | +8,78%                            | 77,01   |
|           | 30 meter | 34,33%                                   | 65,55%              | -31,22%                           | 974,97  |
| 30 km/jam | 5 meter  | 91,67%                                   | 65,55%              | +26,12%                           | 682,02  |
|           | 10 meter | 89,33%                                   | 65,55%              | +23,78%                           | 565,28  |
|           | 30 meter | 70,33%                                   | 65,55%              | +4,78%                            | 22,81   |

Dengan  $n = 9$  skenario,  $\Sigma e^2 = 4.670,16$  dan  $MSE = 4.670,16/9 = 518,91$  (% point)<sup>2</sup>. Akar kuadrat MSE (RMSE terhadap mean detection rate) adalah sekitar 0,2278 percentage points. Nilai tersebut menunjukkan variasi performa yang cukup lebar antar-skenario. Namun, statistik ini

mean 65,55% dari Tabel 3. Penggunaan mean 80,06% dari Tabel 4 dihapus karena merupakan rata-rata dari interval waktu dan bukan rata-rata dari sembilan skenario. Perubahan ini membuat perhitungan statistik konsisten dengan tujuan analisis, yaitu mengukur sebaran detection rate antar kombinasi kecepatan dan jarak.

bukan pengganti MAE/RMSE estimasi jarak dalam meter karena penelitian belum memiliki ground truth jarak aktual per frame.

### 3.3 Perbandingan dengan Penelitian Terkait dan Analisis Kebaruan

Tabel 6. Analisis Kebaruan

| Metode                     | Penelitian          | Akurasi/Error                                                | Komputasi     | Dataset/Latih           | Jarak/Domain     | Keunggulan                                       | Keterbatasan                                |
|----------------------------|---------------------|--------------------------------------------------------------|---------------|-------------------------|------------------|--------------------------------------------------|---------------------------------------------|
| Monocular + depth + ML     | Lee et al. (2022)   | Outperformed prior methods; dataset-specific                 | GPU/ML        | Dataset eksperimen      | ADAS/vehicle     | Menggabungkan detector, depth, dan predictor     | Arsitektur lebih kompleks                   |
| Monocular + YOLOv5s        | Yang et al. (2023)  | Improved ranging; roll-angle correction                      | GPU           | Dataset jalan dua lajur | Multi-lane road  | Memperhitungkan roll angle kamera                | Lebih kompleks daripada geometri sederhana  |
| YOLO + monocular           | Zheng et al. (2024) | Error < 0,15 m pada metode plate-width                       | GPU, 24 fps   | 15.000 gambar           | Hingga 50 m      | Akurasi tinggi, multi-objek                      | Dataset besar dan GPU                       |
| YOLOv5 + tracking + filter | Lv et al. (2024)    | Estimasi lebih stabil secara temporal                        | GPU           | Dataset jalan           | Road environment | Mengatasi fluktuasi akibat gerak/occlusion       | Pipeline lebih kompleks                     |
| YOLOv10                    | Wang et al. (2024)  | Efisiensi/akurasi state-of-the-art pada benchmark            | GPU           | COCO                    | Object detection | NMS-free dan efisien                             | Tetap membutuhkan model deep learning       |
| YOLOv8n + tracking         | Xu & Wang (2025)    | Relative error 1,87% tanpa occlusion; 2,02% dengan occlusion | 260,11 fps    | Dataset uji kendaraan   | Hingga 50 m      | Ringan, cepat, tracking                          | Memerlukan training dan model deep learning |
| YOLO + Kalman + monocular  | Miao et al. (2025)  | Collision warning pada skenario lalu lintas                  | GPU/real-time | Real traffic scenes     | Forward vehicle  | Menggabungkan detection, tracking, distance, TTC | Pipeline multi-modul                        |

|                                    |                     |                                                |                      |                                  |                                |                                                 |                                                   |
|------------------------------------|---------------------|------------------------------------------------|----------------------|----------------------------------|--------------------------------|-------------------------------------------------|---------------------------------------------------|
| YOLOv8-PEL                         | Wang et al. (2025)  | Lightweight vehicle detection; fokus efisiensi | Resource-constrained | Dataset kendaraan                | Fixed-camera vehicle detection | Lebih efisien untuk perangkat terbatas          | Fokus utama deteksi, bukan validasi ranging       |
| Depth Anything V2 + YOLOv11 + LSTM | Kumar et al. (2026) | MAE 1,18 m; RMSE 2,03 m pada KITTI             | GPU/deep learning    | KITTI + mixed datasets           | Metric distance                | Zero-shot depth dan generalisasi lintas dataset | Model lebih kompleks dan berat                    |
| Haar + Monocular                   | Penelitian ini      | 18,00–91,67%; mean 65,55%                      | CPU, OpenCV          | 60 citra latih + 2.700 frame uji | 5–30 m; menurun pada 30 m      | Ringan, sederhana, proof of concept dinamis     | Dataset kecil, satu video, belum ada GT per frame |

Kontribusi penelitian ini tidak dinyatakan sebagai klaim “penelitian pertama”, karena pembuktian klaim tersebut memerlukan kajian literatur sistematis. Kebaruan penelitian diletakkan pada evaluasi empiris Haar Cascade pada kombinasi tiga variasi kecepatan dan tiga variasi jarak dalam kondisi dinamis, serta identifikasi batas operasional metode berdasarkan kondisi yang benar-benar diuji. Posisi ini melengkapi penelitian monocular distance estimation berbasis deep learning dan hybrid detection-tracking yang berkembang pada periode 2022 - 2026.

a. Evaluasi dinamis: penelitian menguji Haar Cascade pada sembilan kombinasi kecepatan dan jarak dalam kondisi lapangan yang tidak sepenuhnya terkontrol. Pendekatan ini memberikan bukti empiris mengenai variasi performa yang tidak terlihat jika pengujian hanya dilakukan pada kondisi statis.

b. Evaluasi terhadap kebutuhan jarak aman: penelitian menguji hingga 30 meter sehingga dapat menunjukkan apakah metode lightweight tersebut tetap memiliki kemampuan deteksi pada rentang yang relevan dengan kebutuhan keselamatan. Hasil menunjukkan bahwa performa pada 30 meter belum konsisten.

c. Identifikasi batas operasional: berdasarkan kondisi yang diuji, Haar Cascade relatif lebih andal pada jarak 5 - 10 meter dan mengalami penurunan signifikan pada 30 meter. Batas ini merupakan temuan empiris untuk konfigurasi kamera, classifier, dan dataset penelitian, bukan batas universal Haar Cascade.

d. Posisi terhadap metode mutakhir: penelitian ini melengkapi studi yang menggunakan monocular depth, YOLO, tracking, dan filtering dengan menyediakan baseline lightweight berbasis Haar Cascade. Perbandingan kuantitatif langsung tetap harus dilakukan secara hati-hati karena dataset, ground

truth, perangkat keras, dan metrik antarpencapaian berbeda.

Keterbatasan desain pengujian membatasi metrik evaluasi yang dapat dihitung secara sah. False Negative Rate dapat didekati hanya jika setiap frame memang mengandung target yang seharusnya terdeteksi, tetapi pendekatan tersebut tetap tidak menggantikan confusion matrix lengkap. False Positive Rate, precision, specificity, dan F1-score tidak dihitung. Demikian pula, MAE dan RMSE estimasi jarak dalam meter belum dapat dihitung karena ground truth jarak per frame belum dicatat. Keterbatasan ini dinyatakan secara eksplisit agar interpretasi hasil tidak melampaui bukti eksperimen.

## 4. PENUTUP

### 4.1. Kesimpulan

Penelitian ini mengevaluasi performa Haar Cascade untuk deteksi pelat kendaraan dan estimasi jarak berbasis monocular vision pada kondisi dinamis dengan tiga variasi kecepatan rencana (10, 20, dan 30 km/jam) dan tiga jarak (5, 10, dan 30 meter). Detection rate bervariasi dari 18,00% hingga 91,67%, dengan rata-rata sebesar 65,55%. Performa terbaik sebesar 91,67% terjadi pada 30 km/jam dan 5 meter, sedangkan pada jarak 30 meter detection rate berada pada rentang 18,00% - 70,33%. Analisis MSE yang telah diperbaiki menunjukkan MSE sebesar 518,91 (% point)<sup>2</sup> atau RMSE dispersi sebesar 22,78 percentage points terhadap mean 65,55%. Hasil tersebut menunjukkan bahwa Haar Cascade belum memberikan performa yang konsisten untuk kebutuhan deteksi jarak aman pada jarak jauh dan lebih tepat diposisikan sebagai baseline lightweight atau modul awal. Kesimpulan ini berlaku untuk konfigurasi eksperimen yang diuji dan belum dapat digeneralisasi ke seluruh kondisi lalu lintas.

### 4.2. Saran

Penelitian selanjutnya disarankan memperbesar dataset latih menjadi sedikitnya 1.000 citra dengan variasi kendaraan, sudut pelat, pencahayaan, latar, dan kondisi cuaca; menggunakan beberapa video dari lokasi dan waktu berbeda; serta menyediakan dataset uji independen yang memuat frame positif dan negatif. Evaluasi sebaiknya melaporkan precision, recall, F1-score, confusion matrix, serta MAE dan RMSE estimasi jarak dalam meter terhadap ground truth per frame yang diperoleh menggunakan laser rangefinder, LiDAR, atau perangkat pengukur jarak yang tervalidasi. Kamera perlu dikalibrasi secara intrinsik dan distorsi lensa dikoreksi. Sebagai pengembangan metode, Haar Cascade dapat dibandingkan pada dataset dan perangkat keras yang sama dengan HOG-SVM, MobileNet-SSD, YOLOv8, YOLOv10, atau detector lightweight lainnya. Integrasi object tracking, Kalman filter, depth estimation, dan time-to-collision juga dapat diuji untuk meningkatkan stabilitas estimasi pada kondisi dinamis. Kecepatan aktual perlu dicatat menggunakan GPS logger agar pengaruh kecepatan dapat dianalisis secara kuantitatif.

#### DAFTAR PUSTAKA

- Berhanu, Y., Schröder, D., Wodajo, B.T., Alemayehu, E., 2024. Machine learning for predictions of road traffic accidents and spatial network analysis for safe routing on accident and congestion-prone road networks. *Results in Engineering* 23, 102737.  
<https://doi.org/10.1016/J.RINENG.2024.102737>
- Chen, S.H., Chen, R.S., 2011. Vision-based distance estimation for multiple vehicles using single optical camera, in: *Proceedings - 2011 2nd International Conference on Innovations in Bio-Inspired Computing and Applications, IBICA 2011*. pp. 9–12.  
<https://doi.org/10.1109/IBICA.2011.7>
- Donghao Qiao, 2020. Vision-based Vehicle Detection and Distance Estimation. *IEEE*.
- Erbani, J., Portier, P.É., Egyed-Zsigmond, E., Nurbakova, D., 2024. Confusion Matrices: A Unified Theory. *IEEE Access* 12, 181372–181419.
- <https://doi.org/10.1109/ACCESS.2024.3507199>
- Hao, Y., Zhu, Q., Ye, H., Zang, Z., Xia, A., Zheng, S., Chang-Hasnain, C., Fu, H.Y., 2026. Cost-effective frequency-chirped amplitude-modulated continuous-wave LiDAR via MZI-coupled quadratic optical frequency sweep. *Opt. Laser Technol.* 204, 116137.  
<https://doi.org/10.1016/J.OPTLASTEC.2026.116137>
- Kumar, S., Karthika, R., Kumar, A., 2026. A monocular vision-based framework for metric distance estimation of vehicles and pedestrians using a zero-shot depth estimation model. *Ain Shams Engineering Journal* 17, 104246.  
<https://doi.org/10.1016/J.ASEJ.2026.104246>
- Lee, S., Han, K., Park, S., Yang, X., 2022. Vehicle Distance Estimation from a Monocular Camera for Advanced Driver Assistance Systems. *Symmetry (Basel)*. 14.  
<https://doi.org/10.3390/sym14122657>
- Lv, H., Du, Y., Ma, Y., Yuan, Y., 2024. Object Detection and Monocular Stable Distance Estimation for Road Environments: A Fusion Architecture Using YOLO-RedeCa and Abnormal Jumping Change Filter. *Electronics (Switzerland)* 13.  
<https://doi.org/10.3390/electronics13153058>
- Mehta, A.A., Padaria, A.A., Bavisi, D.J., Ukani, V., Thakkar, P., Geddam, R., Kotecha, K., Abraham, A., 2024. Securing the Future: A Comprehensive Review of Security Challenges and Solutions in Advanced Driver Assistance Systems. *IEEE Access* 12, 643–678.  
<https://doi.org/10.1109/ACCESS.2023.3347200>
- Mohammadi, K., 2024. Prioritized Object Detection Integrating Fuzzy Logic Risk assessment and Planned Path.
- Sreevidya, P., Veni, S., Rajeev, V., Krishnanugrah, P.U., 2020. Compressive Sensing-Aided Collision Avoidance System. *The Cognitive Approach in Cloud Computing and Internet of Things Technologies for Surveillance Tracking Systems* 121–140.

<https://doi.org/10.1016/B978-0-12-816385-6.00009-X>

- Viola, P., Jones, M., 2001. Rapid Object Detection using a Boosted Cascade of Simple Features.
- Wang, Z., Zhang, K., Wu, F., Lv, H., 2025. YOLO-PEL: The Efficient and Lightweight Vehicle Detection Method Based on YOLO Algorithm. *Sensors* 25. <https://doi.org/10.3390/s25071959>
- Yang, R., Yu, S., Yao, Q., Huang, J., Ya, F., 2023. Vehicle Distance Measurement Method of Two-Way Two-Lane Roads Based on Monocular Vision. *Applied Sciences* (Switzerland) 13. <https://doi.org/10.3390/app13063468>
- Yao, C., Feng, S., Zhang, F., Si, H., 2017. Vehicle-Distance Measurement Based on Plate Area. *Xitong Fangzhen Xuebao / Journal of System Simulation* 29, 2820–2827. <https://doi.org/10.16182/j.issn1004731x.joss.201711031>
- Zhao, D., Yu, J., Wei, Y., Huang, K., Xiang, P., Zhou, H., Asano, Y., Li, Y., Arun, P. V., 2026. Depth–area estimation-based hyperspectral video tracker for scale variation adaptation. *Eng. Appl. Artif. Intell.* 181, 115778. <https://doi.org/10.1016/J.ENGAPPAL.2026.115778>
- Zhou, J., Sun, C., Seo, Y., Kim, Y., 2026. A Framework for Monocular Distance Estimation of Visually Small Objects Under Pixel-Sparse Conditions. *IEEE Access* 14, 90487–90500. <https://doi.org/10.1109/ACCESS.2026.3703860>