



Design and Development of an Intelligent Traffic Density Monitoring and Analysis System Based on Computer Vision Using the YOLOv11 Algorithm

Rancang Bangun Sistem Cerdas Pemantauan dan Analisis Kepadatan Lalu Lintas Berbasis Computer Vision Menggunakan Algoritma YOLOv11

Taufiqul Israt^{1*}, Yeka Hendriyani², Mahesi Agni Zaus³, Vikri Aulia⁴

^{1,2,3,4}Departemen Teknik Elektronika, Fakultas Teknik, Universitas Negeri Padang, Indonesia

E-Mail: ¹taufiqulisrat8@gmail.com, ²yekahendriyani@ft.unp.ac.id,
³mahesiagnizaus@gmail.com, ⁴vikriaulia@unp.ac.id

Received Jun 04th 2026; Revised Jul 11th 2026; Accepted Jul 29th 2026; Available Online Aug 15th 2026

Corresponding Author: Taufiqul Israt

Copyright © 2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

This study developed a computer vision-based traffic monitoring and analysis system by integrating YOLOv11L, ByteTrack, polygon zones, and counting lines. The dataset consisted of 7,061 images covering four vehicle classes: motorcycles, cars, buses, and trucks. The model was trained for 100 epochs using an input image size of 640 × 640 pixels. The evaluation results achieved a precision of 0.94073, a recall of 0.90639, an mAP50 of 0.96290, and an mAP50–95 of 0.85763. Validation using a one-hour video resulted in 1,983 vehicles detected by the system and 2,046 vehicles counted manually, achieving an overall counting accuracy of 96.92% at a processing speed of 24 FPS. Based on the 2023 Indonesian Road Capacity Guidelines (PKJI 2023), the morning traffic flow was 954.10 passenger car units per hour (pcu/h) with a degree of saturation of 0.17, while the afternoon traffic flow reached 1,375.80 pcu/h with a degree of saturation of 0.25. Both values remained below the 0.85 threshold, indicating that traffic conditions during the observation period were still relatively good. The system also recorded 11 vehicle indications in the no-parking zone during the morning and 18 during the afternoon based on vehicle position and a minimum stopping duration of 30 seconds within the polygon. The results demonstrate that the proposed system can effectively integrate vehicle detection, tracking, counting, degree-of-saturation analysis, and no-parking-zone monitoring into an automated traffic monitoring system, providing accurate real-time traffic information and effectively supporting road-condition evaluation and parking enforcement.

Keywords: ByteTrack, Degree Of Saturation, PKJI 2023, Polygon Zone, Vehicle Counting, YOLOv11

Abstrak

Penelitian ini mengembangkan sistem pemantauan dan analisis lalu lintas berbasis computer vision dengan mengintegrasikan YOLOv11L, ByteTrack, polygon zone, dan counting line. Dataset terdiri atas 7.061 citra dengan empat kelas kendaraan, yaitu sepeda motor, mobil, bus, dan truk. Model dilatih selama 100 epoch menggunakan ukuran citra 640 × 640 piksel. Hasil evaluasi menunjukkan precision 0,94073, recall 0,90639, mAP50 0,96290, dan mAP50–95 0,85763. Validasi video berdurasi satu jam menghasilkan 1.983 kendaraan berdasarkan sistem dan 2.046 kendaraan berdasarkan penghitungan manual, dengan akurasi penghitungan 96,92% pada kecepatan pemrosesan 24 FPS. Berdasarkan PKJI 2023, arus lalu lintas pagi sebesar 954,10 smp/jam dengan derajat kejenuhan 0,17, sedangkan sore sebesar 1.375,80 smp/jam dengan derajat kejenuhan 0,25. Kedua nilai tersebut berada di bawah ambang 0,85, sehingga kondisi ruas jalan masih tergolong baik. Sistem juga mencatat 11 indikasi kendaraan pada zona larangan parkir pagi dan 18 indikasi sore berdasarkan posisi serta durasi berhenti minimal 30 detik dalam polygon. Hasil penelitian menunjukkan sistem mampu mengintegrasikan deteksi, pelacakan, penghitungan kendaraan, analisis derajat kejenuhan, dan pemantauan zona larangan parkir secara otomatis dalam satu sistem, sehingga memberikan informasi lalu lintas yang akurat, real-time, dan mendukung evaluasi kondisi jalan serta pengawasan parkir secara efektif dan terintegrasi bagi pengelola jalan.

Kata Kunci: ByteTrack, Derajat Kejenuhan, Penghitungan Kendaraan, PKJI 2023, Polygon Zone, YOLOv11

1. PENDAHULUAN

Peningkatan aktivitas kendaraan di kawasan perkotaan membutuhkan sistem pemantauan lalu lintas yang akurat dan berkelanjutan. Data jumlah dan komposisi kendaraan diperlukan untuk menghitung arus lalu lintas, kapasitas jalan, dan derajat kejenuhan berdasarkan PKJI 2023 [1]. Namun, penghitungan manual membutuhkan waktu, tenaga pengamat, dan berpotensi menimbulkan kesalahan pencatatan. Pemrosesan video dan kecerdasan buatan telah digunakan untuk mengotomatisasi pengumpulan data lalu lintas [2], [3], meskipun perbedaan ukuran kendaraan, sudut kamera, lalu lintas campuran, dan oklusi masih menjadi kendala dalam proses deteksi dan pelacakan [4].

Algoritma YOLO banyak diterapkan karena mampu melakukan deteksi kendaraan dengan cepat dan akurat. Pengembangan tersebut meliputi optimasi YOLOv11 pada kondisi malam hari [5], penerapan model YOLO ringan [6], penggunaan YOLOv3 untuk penghitungan kendaraan [7], serta YOLOv10-nano untuk pemantauan waktu nyata pada perangkat dengan sumber daya terbatas [8]. Berbagai penelitian juga mengintegrasikan YOLO dengan DeepSORT, pelacakan berbasis centroid, OpenCV, serta pengenalan pola untuk mendeteksi, melacak, menghitung, dan memantau perilaku kendaraan [9], [10], [11], [12].

Penerapan YOLO selanjutnya dikembangkan untuk mengestimasi arus dan kepadatan lalu lintas [13]. Penyesuaian *epoch*, *batch size*, *learning rate*, dan parameter pelatihan lainnya juga terbukti memengaruhi kemampuan model dalam mendeteksi kendaraan pada kondisi tertentu [14], [15]. Meskipun demikian, deteksi pada setiap *frame* belum cukup untuk penghitungan karena kendaraan yang sama dapat terdeteksi berulang kali. ByteTrack dikembangkan untuk mempertahankan identitas objek dengan mengasosiasikan kotak deteksi bernilai kepercayaan tinggi dan rendah, sehingga mampu mengurangi lintasan yang terputus akibat oklusi [16]. Integrasi YOLO dan ByteTrack telah digunakan untuk analisis arus lalu lintas berbasis *multi-object tracking* [17], sedangkan pendekatan DeepSORT juga diterapkan untuk pelacakan dan estimasi kecepatan kendaraan [18].

Hasil deteksi dan pelacakan dapat dimanfaatkan untuk memperoleh parameter transportasi yang lebih luas. Sistem berbasis kamera telah digunakan untuk mengukur intensitas arus, arah pergerakan, dan kecepatan kendaraan [19]. Deteksi berbasis YOLO juga telah diintegrasikan dengan nilai *Passenger Car Equivalent* untuk mendukung estimasi lalu lintas dan pengendalian lampu adaptif [20]. Dalam konteks Indonesia, hasil deteksi kendaraan telah dihubungkan dengan perhitungan kapasitas dan derajat kejenuhan berdasarkan PKJI 2023 [21], serta digunakan untuk mendeteksi kondisi antrean kendaraan secara waktu nyata [22].

Berdasarkan penelitian terdahulu, sebagian besar sistem masih berfokus pada deteksi, pelacakan, jumlah kendaraan, kecepatan, kepadatan visual, atau antrean. Integrasi YOLOv11L, ByteTrack, klasifikasi kendaraan, konversi ekuivalensi mobil penumpang, perhitungan arus lalu lintas, kapasitas, derajat kejenuhan, perbandingan dua periode pengamatan, dan pemantauan zona parkir dalam satu sistem masih terbatas. Penelitian ini mengembangkan sistem pemantauan lalu lintas berbasis *computer vision* pada Jalan Pemuda tipe 4/1 dengan mengintegrasikan YOLOv11L, ByteTrack, *polygon zone*, dan *counting line*. Hasil penghitungan dikonversi menggunakan EMP untuk memperoleh arus Q , sedangkan DJ dihitung dari perbandingan Q terhadap kapasitas C . Sistem juga membandingkan periode pagi dan sore serta mencatat indikasi kendaraan pada zona larangan parkir.

2. METODE PENELITIAN

Penelitian ini menggunakan metode penelitian dan pengembangan (*Research and Development*) dengan pendekatan eksperimen kuantitatif untuk membangun sistem pemantauan lalu lintas berbasis *computer vision*. Sistem dirancang untuk mendeteksi, melacak, dan menghitung kendaraan, memantau indikasi kendaraan pada zona larangan parkir, serta menghitung arus lalu lintas dan derajat kejenuhan berdasarkan PKJI 2023.


Tahapan penelitian meliputi pengumpulan data video, persiapan dataset, pelatihan dan evaluasi model YOLOv11, implementasi sistem menggunakan ByteTrack, *polygon zone*, dan *counting line*, pengujian sistem, analisis lalu lintas berdasarkan PKJI 2023, serta perbandingan hasil pengamatan pada periode pagi dan sore. Alur penelitian ditunjukkan pada Gambar 1.

Berdasarkan Gambar 1, penelitian diawali dengan pengumpulan video lalu lintas pada periode pagi dan sore. Video diekstraksi menjadi citra untuk menyusun dataset, kemudian digunakan dalam pelatihan dan evaluasi YOLOv11. Model yang telah dilatih diintegrasikan dengan ByteTrack, *polygon zone*, dan *counting line*. Sistem selanjutnya digunakan untuk mendeteksi, melacak, serta menghitung kendaraan. Hasil penghitungan dianalisis berdasarkan PKJI 2023 dan digunakan untuk memantau kendaraan pada zona parkir. Hasil periode pagi dan sore kemudian dibandingkan.


2.1. Pengumpulan Data dan Penyusunan Dataset

Data penelitian diperoleh dari rekaman video lalu lintas pada ruas Jalan Pemuda, Kota Padang, yang memiliki karakteristik empat lajur satu arah atau tipe 4/1. Pengamatan dilakukan pada periode pagi dan sore dengan durasi masing-masing satu jam. Rekaman video kemudian diekstraksi menjadi sejumlah *frame* dan setiap citra dianotasi menggunakan *bounding box* berdasarkan empat kelas kendaraan, yaitu *motorcycle*, *car*,

bus, dan *truck*. Dataset penelitian berjumlah 7.061 citra yang selanjutnya dibagi menjadi data pelatihan, validasi, dan pengujian, dengan distribusi dataset ditunjukkan pada Gambar 2.



Gambar 1. Alur metode penelitian sistem pemantauan lalu lintas.



Gambar 2. Distribusi dataset penelitian.

Berdasarkan Gambar 2, dataset terdiri atas 4.935 citra pelatihan atau 69,9%, 1.420 citra validasi atau 20,1%, dan 706 citra pengujian atau 10,0%. Data pelatihan digunakan untuk membentuk model, data validasi digunakan untuk memantau kinerja selama pelatihan, sedangkan data pengujian digunakan untuk mengevaluasi kemampuan model terhadap citra yang tidak digunakan dalam proses pelatihan.

2.2. Pelatihan dan Evaluasi Model YOLOv11

Dataset yang telah dianotasi digunakan untuk melatih model YOLOv11L agar mampu mendeteksi lokasi objek dan mengklasifikasikan kendaraan ke dalam empat kelas, yaitu *motorcycle*, *car*, *bus*, dan *truck*. Proses pelatihan menggunakan bobot awal yolo11l.pt dengan ukuran citra masukan 640×640 piksel. Model dilatih selama 100 *epoch* menggunakan *batch size* 4 dan nilai *initial learning rate* sebesar 0,01. Konfigurasi pelatihan model ditunjukkan pada Tabel 1

Tabel 1. Konfigurasi pelatihan model YOLOv11L

Parameter	Nilai
Model awal	YOLOv11L (yolo11l.pt)

Parameter	Nilai
Ukuran citra	640 × 640 piksel
Jumlah epoch	100
Batch size	4
Initial learning rate	0,01

Berdasarkan Tabel 1, penelitian ini menggunakan arsitektur YOLOv11L dengan bobot awal pralatih yolo11l.pt. Seluruh citra diubah ke ukuran 640 × 640 piksel agar memiliki dimensi masukan yang seragam selama proses pelatihan. Pelatihan dilakukan selama 100 *epoch* dengan *batch size* 4, sedangkan nilai *initial learning rate* ditetapkan sebesar 0,01. Konfigurasi tersebut digunakan secara konsisten selama proses pembelajaran model pada dataset kendaraan yang telah disiapkan.

Setelah proses pelatihan selesai, kinerja model dievaluasi menggunakan metrik *precision*, *recall*, mAP50, mAP50–95, *confusion matrix*, kurva *Precision-Recall*, dan kurva *F1-Confidence*. *Precision* digunakan untuk mengukur ketepatan prediksi kendaraan, sedangkan *recall* menunjukkan kemampuan model dalam menemukan objek kendaraan pada data evaluasi. Nilai mAP50 digunakan untuk menilai performa deteksi pada ambang *Intersection over Union* (IoU) sebesar 0,5, sedangkan mAP50–95 digunakan untuk mengevaluasi performa model pada rentang IoU 0,5 hingga 0,95. *Confusion matrix* digunakan untuk menganalisis ketepatan klasifikasi setiap kelas kendaraan, sementara kurva *Precision-Recall* dan *F1-Confidence* digunakan untuk melihat hubungan antara ketepatan deteksi, kemampuan menemukan objek, dan nilai kepercayaan model.

2.3. Implementasi dan Pengujian Sistem

Model YOLOv11L hasil pelatihan diimplementasikan ke dalam aplikasi pemantauan lalu lintas berbasis video. Implementasi sistem meliputi integrasi YOLOv11-L untuk mendeteksi kelas dan posisi kendaraan pada setiap *frame*, ByteTrack untuk memberikan serta mempertahankan identitas kendaraan antar-*frame*, *polygon zone* untuk membatasi area jalan yang dianalisis, dan *counting line* untuk menghitung kendaraan yang melintas. Pada tahap inferensi, nilai *confidence threshold* ditetapkan sebesar 0,10 sehingga deteksi dengan nilai kepercayaan di bawah ambang tersebut tidak digunakan dalam proses selanjutnya.

ByteTrack digunakan untuk mempertahankan *tracking ID* setiap kendaraan selama objek masih berada dalam area pengamatan. Kendaraan hanya dihitung satu kali ketika berada di dalam *polygon zone* dan melintasi *counting line*. Mekanisme tersebut diterapkan untuk mengurangi kemungkinan penghitungan berulang terhadap kendaraan yang sama. Sistem juga menggunakan poligon khusus untuk memantau kendaraan pada zona parkir berdasarkan *tracking ID*, posisi, dan durasi keberadaannya.

Pengujian sistem dilakukan untuk mengukur akurasi penghitungan kendaraan dan kecepatan pemrosesan video. Validasi penghitungan dilakukan dengan membandingkan hasil penghitungan otomatis terhadap penghitungan manual pada video yang sama selama satu jam. Penghitungan manual dan sistem menggunakan ketentuan yang sama, yaitu hanya mencatat kendaraan yang berada di dalam area pengamatan dan melintasi *counting line*. Pengujian dilakukan terhadap empat kelas kendaraan, yaitu mobil, sepeda motor, bus, dan truk.

Selisih antara hasil penghitungan sistem dan penghitungan manual pada setiap kelas kendaraan dihitung menggunakan Persamaan (1).

$$= E_i = |N_{sistem,i} - N_{manual,i}| \quad (1)$$

Akurasi penghitungan setiap kelas dihitung menggunakan Persamaan (2).

$$Akurasi_i = \left(1 - \frac{|N_{sistem,i} - N_{manual,i}|}{N_{manual,i}}\right) \times 100\% \quad (2)$$

Akurasi keseluruhan dihitung berdasarkan total selisih terhadap total hasil penghitungan manual menggunakan Persamaan (3).

$$Akurasi_{keseluruhan} = \left(1 - \frac{\sum_{i=1}^4 |N_{s,i} - N_{m,i}|}{\sum_{i=1}^4 N_{m,i}}\right) \times 100\% \quad (3)$$

Pada persamaan tersebut, E_i merupakan selisih penghitungan pada kelas kendaraan ke- i , $N_{s,i}$ merupakan jumlah kendaraan hasil penghitungan sistem, dan $N_{m,i}$ merupakan jumlah kendaraan hasil penghitungan manual. Nilai indeks i digunakan dari 1 sampai 4, dengan $i = 1$ untuk mobil, $i = 2$ untuk sepeda motor, $i = 3$ untuk bus, dan $i = 4$ untuk truk. Kecepatan pemrosesan sistem diukur menggunakan nilai *frame per second* (FPS) selama video pengujian diproses.

2.4. Analisis Lalu Lintas Berdasarkan PKJI 2023

Hasil penghitungan kendaraan yang diperoleh dari sistem selanjutnya dianalisis berdasarkan Pedoman Kapasitas Jalan Indonesia (PKJI) 2023. Analisis ini dilakukan untuk mengubah data jumlah kendaraan hasil deteksi menjadi parameter lalu lintas yang dapat digunakan dalam perhitungan arus lalu lintas, kapasitas jalan, dan derajat kejenuhan. Ruas jalan yang menjadi lokasi penelitian memiliki karakteristik empat lajur satu arah atau tipe 4/1, sehingga pemilihan kategori kendaraan dan nilai ekuivalensi mobil penumpang disesuaikan dengan ketentuan yang berlaku untuk tipe jalan tersebut.

Kelas kendaraan hasil deteksi YOLOv11 kemudian dipetakan ke dalam kategori kendaraan PKJI 2023. Kelas *motorcycle* dipetakan sebagai sepeda motor (SM), kelas *car* sebagai mobil penumpang (MP), sedangkan kelas *bus* dan *truck* dikelompokkan sebagai kendaraan sedang (KS). Pemetaan ini diperlukan karena setiap jenis kendaraan memiliki pengaruh yang berbeda terhadap arus lalu lintas. Oleh karena itu, masing-masing kategori diberikan nilai ekuivalensi mobil penumpang (EMP) sebagai dasar konversi jumlah kendaraan ke dalam satuan mobil penumpang. Pemetaan kelas kendaraan dan nilai EMP yang digunakan dalam penelitian ini ditunjukkan pada Tabel 2.

Tabel 2. Pemetaan kelas kendaraan berdasarkan PKJI 2023

Kelas Deteksi YOLOv11	Jenis Kendaraan	Kategori PKJI 2023	Nilai EMP
motorcycle	Sepeda Motor	SM	0,40
car	Mobil Penumpang	MP	1,00
bus	Bus	KS	1,30
truck	Truk	KS	1,30

Berdasarkan Tabel 2, setiap kategori kendaraan memiliki nilai EMP yang berbeda sesuai dengan pengaruhnya terhadap arus lalu lintas. Jumlah kendaraan hasil deteksi tidak langsung digunakan sebagai nilai arus, tetapi terlebih dahulu dikonversi ke dalam satuan mobil penumpang (smp). Total hasil konversi kendaraan dihitung menggunakan Persamaan (4).

$$SMP = (SM \times 0,40) + (MP \times 1,00) + (KS \times 1,30) \quad (4)$$

Pada Persamaan (4), SM merupakan jumlah sepeda motor, MP merupakan jumlah mobil penumpang, dan KS merupakan jumlah kendaraan sedang. Karena setiap periode pengamatan berlangsung selama satu jam, total hasil konversi tersebut langsung dinyatakan sebagai arus lalu lintas Q dalam satuan smp/jam. Dengan demikian, tidak diperlukan konversi durasi dari detik ke jam. Kapasitas ruas jalan dihitung berdasarkan kapasitas dasar dan faktor penyesuaian yang sesuai dengan karakteristik ruas jalan. Perhitungan kapasitas ditunjukkan pada Persamaan (5).

$$C = C_0 \times FCLJ \times FCPA \times FCHS \times FCUK \quad (5)$$

Pada Persamaan (5), C merupakan kapasitas jalan dalam smp/jam, C_0 merupakan kapasitas dasar, $FCLJ$ merupakan faktor penyesuaian lebar jalur lalu lintas, $FCPA$ merupakan faktor penyesuaian pemisah arah, $FCHS$ merupakan faktor penyesuaian hambatan samping, dan $FCUK$ merupakan faktor penyesuaian ukuran kota. Nilai arus lalu lintas Q dan kapasitas jalan C selanjutnya digunakan untuk menghitung derajat kejenuhan melalui Persamaan (6).

$$DJ = \frac{Q}{C} \quad (6)$$

Nilai DJ yang diperoleh tidak dikonversi menjadi kategori *Level of Service* (LOS), tetapi dibandingkan secara langsung dengan ambang $DJ = 0,85$. Jika $DJ \leq 0,85$, sistem menampilkan bahwa kinerja segmen masih baik berdasarkan indikator derajat kejenuhan. Jika $DJ > 0,85$, sistem menampilkan bahwa kapasitas atau manajemen lalu lintas perlu dievaluasi. Ambang 0,85 digunakan sebagai batas evaluasi dalam analisis kapasitas PKJI.

2.5. Pemantauan Zona Parkir dan Perbandingan Hasil

Pemantauan zona parkir dilakukan menggunakan *polygon zone*. Kendaraan yang berada di dalam zona dipantau berdasarkan *tracking ID* dan durasi keberadaannya. Kendaraan yang terdeteksi selama sekurang-kurangnya 30 detik dicatat sebagai indikasi parkir. Batas waktu tersebut merupakan parameter operasional sistem, bukan penetapan pelanggaran secara hukum. Hasil video pagi dan sore kemudian dibandingkan berdasarkan jumlah kendaraan, arus lalu lintas Q , derajat kejenuhan DJ , dan jumlah indikasi parkir. Nilai DJ dibandingkan langsung dengan ambang 0,85 tanpa dikonversi menjadi kategori LOS.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pelatihan dan evaluasi model YOLOv11-L, implementasi sistem pemantauan lalu lintas, validasi penghitungan kendaraan, analisis berdasarkan PKJI 2023, serta perbandingan hasil pengamatan pada periode pagi dan sore. Pembahasan juga mencakup hasil pemantauan kendaraan yang terindikasi berada pada zona larangan parkir.

3.1. Hasil Pelatihan dan Evaluasi Model YOLOv11L


Model YOLOv11L dilatih menggunakan dataset sebanyak 7.061 citra yang terdiri atas empat kelas kendaraan, yaitu mobil, motor, bus, dan truk. Dataset dibagi menjadi 4.935 citra pelatihan, 1.420 citra validasi, dan 706 citra pengujian. Proses pelatihan dilakukan selama 100 *epoch* dengan ukuran citra 640 × 640 piksel dan *batch size* sebesar 4. Kinerja model dievaluasi menggunakan metrik *precision*, *recall*, mAP50, dan mAP50-95. Hasil evaluasi model YOLOv11L ditunjukkan pada Tabel 3.

Tabel 3. Hasil evaluasi model YOLOv11L

Metrik evaluasi	Nilai
Precision	0,94073
Recall	0,90639
mAP50	0,96290
mAP50-95	0,85763

Berdasarkan Tabel 3, model YOLOv11-L memperoleh nilai *precision* sebesar 0,94073 atau 94,07%. Nilai tersebut menunjukkan bahwa sebagian besar objek yang diprediksi sebagai kendaraan merupakan hasil deteksi yang akurat. Nilai *recall* sebesar 0,90639 atau 90,64% menunjukkan bahwa model mampu mendeteksi sebagian besar kendaraan yang terdapat dalam data evaluasi.

Nilai mAP50 sebesar 0,96290 atau 96,29% menunjukkan tingkat ketepatan deteksi yang tinggi pada ambang *Intersection over Union* sebesar 0,50. Sementara itu, nilai mAP50-95 sebesar 0,85763 atau 85,76% menunjukkan bahwa model tetap memberikan kinerja yang baik ketika dievaluasi pada rentang ambang IoU yang lebih ketat. Selain metrik tersebut, kemampuan model dalam membedakan setiap kelas kendaraan dianalisis menggunakan *normalized confusion matrix*. Normalisasi digunakan agar kinerja setiap kelas dapat dibandingkan secara proporsional meskipun jumlah objek pada masing-masing kelas tidak seimbang. Hasil *normalized confusion matrix* ditunjukkan pada Gambar 3.



Gambar 3. Normalized confusion matrix hasil evaluasi model YOLOv11L


Berdasarkan Gambar 3, nilai pada diagonal utama menunjukkan proporsi objek yang berhasil dideteksi dan diklasifikasikan dengan benar. Model memperoleh nilai klasifikasi benar sebesar 0,96 pada kelas mobil, 0,86 pada kelas motor, 0,98 pada kelas bus, dan 0,97 pada kelas truk. Hasil tersebut menunjukkan bahwa kelas bus memiliki proporsi deteksi benar tertinggi, diikuti truk dan mobil, sedangkan kelas motor memperoleh nilai paling rendah. Kesalahan deteksi terhadap *background* masing-masing sebesar 0,04 pada mobil, 0,14 pada motor, 0,02 pada bus, dan 0,03 pada truk. Dengan demikian, kelas motor memiliki proporsi objek tidak terdeteksi paling tinggi, yaitu 14%. Kondisi tersebut dapat dipengaruhi oleh ukuran objek motor yang relatif

kecil, posisi kendaraan yang berdekatan, serta oklusi antarkendaraan. Sementara itu, tidak terlihat kesalahan klasifikasi yang berarti antar-kelas kendaraan, yang menunjukkan bahwa model mampu membedakan mobil, motor, bus, dan truk dengan baik. Pada kolom *background*, prediksi tanpa pasangan dengan objek sebenarnya paling banyak terjadi pada kelas motor sebesar 0,34 dan truk sebesar 0,32, diikuti mobil sebesar 0,21 dan bus sebesar 0,13. Hasil tersebut menunjukkan bahwa model masih menghasilkan prediksi positif palsu, terutama pada kelas motor dan truk.

3.2. Implementasi Sistem Pemantauan Lalu Lintas

Tahap implementasi dilakukan untuk menerapkan model hasil pelatihan ke dalam sistem pemantauan lalu lintas berbasis video. Sistem dirancang agar mampu melakukan proses deteksi, pelacakan, dan penghitungan kendaraan secara terintegrasi pada area jalan yang telah ditentukan. Implementasi sistem menggabungkan YOLOv11L, ByteTrack, *polygon zone*, dan *counting line*.

YOLOv11L digunakan untuk mendeteksi kelas dan posisi kendaraan pada setiap *frame*, sedangkan ByteTrack digunakan untuk memberikan serta mempertahankan identitas kendaraan antar *frame*. *Polygon zone* berfungsi membatasi area jalan yang dianalisis, sementara *counting line* digunakan sebagai batas penghitungan kendaraan. Tampilan implementasi sistem ditunjukkan pada Gambar 3.



Gambar 4. Implementasi sistem pemantauan dan penghitungan kendaraan

Berdasarkan Gambar 4, sistem menampilkan *bounding box*, kelas kendaraan, *tracking ID*, area *polygon*, garis penghitungan, serta jumlah kendaraan berdasarkan kelas mobil, sepeda motor, bus, dan truk. Kendaraan dicatat satu kali ketika berada di dalam area pengamatan dan melintasi *counting line*. Penggunaan ByteTrack membantu mempertahankan identitas kendaraan sehingga kemungkinan penghitungan berulang terhadap kendaraan yang sama dapat dikurangi.

Sistem juga menerapkan *polygon* khusus untuk memantau kendaraan pada zona larangan parkir. Kendaraan yang berada di dalam zona tersebut selama sekurang-kurangnya 30 detik dicatat sebagai indikasi kendaraan pada zona larangan parkir. Informasi yang ditampilkan meliputi posisi kendaraan, durasi keberadaan di dalam zona, dan jumlah indikasi yang tercatat. Hasil pemantauan didasarkan pada batas area dan durasi yang ditetapkan sebagai parameter operasional sistem sehingga tidak digunakan untuk menetapkan pelanggaran parkir secara hukum.

3.3. Pengujian Sistem

Pengujian sistem dilakukan dengan membandingkan hasil penghitungan otomatis dan penghitungan manual pada video yang sama selama satu jam. Kendaraan yang dihitung merupakan kendaraan yang berada di dalam *polygon zone* dan melintasi *counting line*. Hasil pengujian ditunjukkan pada Tabel 4.

Tabel 4. Hasil validasi penghitungan kendaraan selama satu jam

Kendaraan	Manual 1 jam	Sistem 1 jam	Selisih	Akurasi
Mobil	944	935	9	99,05%
Motor	1.078	1.024	54	94,99%
Bus	9	9	0	100%
Truk	15	15	0	100%
Total	2.046	1.983	63	96,92%

Berdasarkan Tabel 4, penghitungan manual memperoleh total 2.046 kendaraan, sedangkan sistem menghitung 1.983 kendaraan dengan selisih 63 kendaraan. Akurasi keseluruhan sistem mencapai 96,92%. Akurasi tertinggi diperoleh pada kelas bus dan truk sebesar 100%, diikuti mobil sebesar 99,05% dan motor sebesar 94,99%.

Selisih terbesar terdapat pada kelas motor, yaitu 54 kendaraan. Perbedaan tersebut dapat dipengaruhi oleh ukuran objek motor yang relatif kecil, posisi kendaraan yang saling berdekatan, serta oklusi antarkendaraan. Selain akurasi penghitungan, kecepatan pemrosesan sistem juga diukur menggunakan nilai *frame per second* (FPS). Pada saat pengujian, sistem memperoleh kecepatan pemrosesan sebesar 24 FPS. *Analisis Kepadatan Lalu Lintas Berdasarkan PKJI 2023*

3.4. Analisis Lalu Lintas Berdasarkan PKJI 2023

Analisis lalu lintas dilakukan terhadap hasil penghitungan kendaraan pada periode pagi dan sore. Kendaraan dikelompokkan menjadi sepeda motor (SM), mobil penumpang (MP), dan kendaraan sedang (KS). Kelas bus dan truk digabungkan ke dalam kategori KS. Hasil analisis kedua periode ditunjukkan pada Tabel 5.

Tabel 5. Hasil analisis lalu lintas periode pagi dan sore

Parameter	Pagi	Sore
Sepeda motor (SM)	563	1.024
Mobil penumpang (MP)	699	935
Kendaraan sedang (KS)	23	24
Total kendaraan	1.285	1.983
Arus lalu lintas (Q)	954,10 smp/ jam	1.375,80 smp/ jam
Tipe jalan	04-Jan	04-Jan
Kapasitas dasar (C_0)	6.600 smp/ jam	6.600 smp/ jam
Faktor lebar lajur (FCLJ)	0,92	0,92
Faktor pemisah arah (FCPA)	1,00	1,00
Faktor hambatan samping (FCHS)	0,96	0,96
Faktor ukuran kota (FCUK)	0,94	0,94
Kapasitas jalan (C)	5.479,37 smp/ jam	5.479,37 smp/ jam
Derajat kejenuhan (DJ)	0,17	0,25
Ambang evaluasi	0,85	0,85

Berdasarkan Tabel 5, pada periode pagi sistem mencatat sebanyak 1.285 kendaraan yang terdiri atas 563 sepeda motor, 699 mobil penumpang, dan 23 kendaraan sedang. Jumlah kendaraan tersebut kemudian dikonversi ke dalam satuan mobil penumpang menggunakan nilai EMP sebesar 0,40 untuk sepeda motor, 1,00 untuk mobil penumpang, dan 1,30 untuk kendaraan sedang. Hasil konversi menunjukkan bahwa arus lalu lintas pada periode pagi mencapai 954,10 smp/jam. Dengan kapasitas ruas jalan sebesar 5.479,37 smp/jam, diperoleh nilai derajat kejenuhan DJ sebesar 0,17.

Pada periode sore, sistem mencatat sebanyak 1.983 kendaraan yang terdiri atas 1.024 sepeda motor, 935 mobil penumpang, dan 24 kendaraan sedang. Setelah dikonversi menggunakan nilai EMP yang sama, diperoleh arus lalu lintas sebesar 1.375,80 smp/jam. Karena pengamatan dilakukan pada ruas jalan yang sama dengan karakteristik geometrik dan faktor penyesuaian kapasitas yang sama, nilai kapasitas yang digunakan tetap sebesar 5.479,37 smp/jam. Berdasarkan nilai arus dan kapasitas tersebut, diperoleh derajat kejenuhan DJ pada periode sore sebesar 0,25.

Dibandingkan dengan periode pagi, periode sore mengalami peningkatan sebanyak 698 kendaraan, peningkatan arus lalu lintas sebesar 421,70 smp/jam, dan peningkatan nilai DJ sebesar 0,08. Meskipun arus lalu lintas dan nilai DJ pada periode sore lebih tinggi, nilai derajat kejenuhan pada kedua periode masih berada di bawah ambang evaluasi 0,85. Dengan demikian, berdasarkan indikator derajat kejenuhan, kinerja segmen Jalan Pemuda pada periode pagi dan sore masih berada dalam kondisi baik.

Perbedaan nilai derajat kejenuhan antara periode pagi dan sore menunjukkan bahwa perubahan kondisi lalu lintas terutama dipengaruhi oleh besarnya arus kendaraan yang melintasi ruas jalan. Sementara itu, nilai kapasitas tetap sama karena tipe jalan, jumlah lajur, lebar lajur, pemisah arah, hambatan samping, dan ukuran kota yang digunakan dalam perhitungan tidak berubah. Oleh karena itu, peningkatan nilai DJ pada sore hari mencerminkan bertambahnya beban lalu lintas dibandingkan periode pagi. Namun, nilai DJ sebesar 0,25 masih jauh di bawah ambang evaluasi 0,85, sehingga berdasarkan hasil pengamatan belum menunjukkan perlunya evaluasi kapasitas atau penerapan manajemen lalu lintas secara khusus pada ruas tersebut.

3.5. Hasil Pemantauan Zona Parkir

Pemantauan zona parkir dilakukan berdasarkan posisi dan durasi kendaraan di dalam *polygon zone*. Kendaraan yang berada di dalam zona selama sekurang-kurangnya 30 detik dicatat sebagai indikasi kendaraan pada zona larangan parkir. Hasil pemantauan periode pagi dan sore ditunjukkan pada Tabel 6.

Tabel 6. Hasil pemantauan kendaraan pada zona larangan parkir

Jenis kendaraan	Pagi	Sore
Mobil	4	8
Motor	6	9
Truk	1	1
Total	11	18

Berdasarkan Tabel 6, sistem mencatat 11 indikasi kendaraan pada periode pagi yang terdiri atas 4 mobil, 6 sepeda motor, dan 1 truk. Pada periode sore, jumlah indikasi meningkat menjadi 18 kendaraan, terdiri atas 8 mobil, 9 sepeda motor, dan 1 truk. Dengan demikian, jumlah indikasi pada sore hari lebih tinggi, yaitu sebanyak 7 kendaraan, dibandingkan dengan periode pagi. Peningkatan ini sejalan dengan meningkatnya volume kendaraan yang melintas pada sore hari. Namun, hasil tersebut hanya menunjukkan indikasi berdasarkan posisi dan durasi kendaraan di dalam zona pengamatan, bukan merupakan penetapan pelanggaran parkir secara hukum.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem pemantauan lalu lintas berbasis *computer vision* yang mengintegrasikan YOLOv11L, ByteTrack, *polygon zone*, dan *counting line*. Sistem mampu mendeteksi, melacak, dan menghitung empat kelas kendaraan, yaitu mobil, sepeda motor, bus, dan truk, serta mengolah hasil penghitungan tersebut untuk memperoleh arus lalu lintas dan derajat kejenuhan berdasarkan PKJI 2023.

Hasil evaluasi model YOLOv11L menunjukkan nilai *precision* sebesar 0,94073, *recall* sebesar 0,90639, mAP50 sebesar 0,96290, dan mAP50-95 sebesar 0,85763. Validasi penghitungan menggunakan video berdurasi satu jam menghasilkan 1.983 kendaraan berdasarkan sistem dan 2.046 kendaraan berdasarkan penghitungan manual. Selisih sebanyak 63 kendaraan menghasilkan akurasi keseluruhan sebesar 96,92%. Sistem juga mampu memproses video dengan kecepatan 24 FPS. Selisih penghitungan terbesar terdapat pada kelas sepeda motor, yang dapat dipengaruhi oleh ukuran objek yang relatif kecil, posisi kendaraan yang berdekatan, dan oklusi antarkendaraan.

Analisis berdasarkan PKJI 2023 menunjukkan bahwa periode pagi menghasilkan arus lalu lintas sebesar 954,10 smp/jam dengan derajat kejenuhan sebesar 0,17, sedangkan periode sore menghasilkan arus lalu lintas sebesar 1.375,80 smp/jam dengan derajat kejenuhan sebesar 0,25. Dengan kapasitas jalan sebesar 5.479,37 smp/jam, nilai derajat kejenuhan pada kedua periode masih berada di bawah batas evaluasi sebesar 0,85. Hasil tersebut menunjukkan bahwa kinerja ruas jalan selama periode pengamatan masih berada dalam kondisi baik berdasarkan indikator derajat kejenuhan sesuai PKJI 2023.

Sistem juga mencatat 11 indikasi kendaraan pada zona larangan parkir pada periode pagi dan 18 indikasi kendaraan pada periode sore. Indikasi tersebut ditentukan berdasarkan posisi kendaraan yang berada di dalam *polygon* selama sekurang-kurangnya 30 detik. Oleh karena itu, hasil pemantauan hanya digunakan sebagai indikator operasional sistem untuk mengidentifikasi kendaraan yang berpotensi berhenti pada zona larangan parkir dan bukan sebagai dasar penetapan pelanggaran parkir secara hukum.

Secara keseluruhan, sistem yang dikembangkan mampu mengintegrasikan proses deteksi, pelacakan, penghitungan kendaraan, analisis derajat kejenuhan, dan pemantauan zona larangan parkir dalam satu sistem terkomputerisasi. Penelitian selanjutnya disarankan melakukan pengujian pada berbagai tipe jalan, kondisi cuaca, waktu pengamatan, dan tingkat kepadatan lalu lintas yang lebih beragam untuk mengevaluasi kemampuan generalisasi sistem. Selain itu, pengembangan metode pelacakan yang lebih robust terhadap oklusi dan kepadatan kendaraan yang tinggi diharapkan dapat meningkatkan akurasi dan keandalan sistem pada kondisi lalu lintas yang lebih kompleks.

REFERENSI

- [1] Direktorat Jenderal Bina Marga, *Pedoman Kapasitas Jalan Indonesia*. Jakarta: Kementerian Pekerjaan Umum dan Perumahan Rakyat, Direktorat Jenderal Bina Marga, 2023. [Online]. Available: <https://binamarga.pu.go.id/index.php/nspp/detail/09pbm2023-pedoman-kapasitas-jalan-indonesia->
- [2] R. A. P. U. S. Perera, H. M. O. K. Herath, B. Ayesha, T. Sivakumar, A. S. Kumara, and A. S. Perera, "Evaluation of Manual and Video-Based Automated Classified Vehicle Counting Methods for Heterogeneous Traffic Flow," in *Proceedings of the Eastern Asia Society for Transportation Studies*, Japan: Eastern Asia Society for Transportation Studies, 2021, pp. 1–14. [Online]. Available: https://www.easts.info/on-line/proceedings/vol.13/pdf/PP3016_R1_F.pdf
- [3] D.-L. Dinh, H.-N. Nguyen, H.-T. Thai, and K.-H. Le, "Towards AI-Based Traffic Counting System with Edge Computing," *J. Adv. Transp.*, vol. 2021, no. 1, pp. 1–15, 2021, doi: 10.1155/2021/5551976.
- [4] R. Feng, C. Fan, Z. Li, and X. Chen, "Mixed Road User Trajectory Extraction from Moving Aerial Videos Based on Convolution Neural Network Detection," *IEEE Access*, vol. 8, pp. 43508–43519, 2020, doi: 10.1109/ACCESS.2020.2976890.

- [5] I. A. Zulkarnain and K. Kusriani, "Yolov11 Optimization Through Hyperparameter Tuning and Data Augmentation to Improve Vehicle Detection Accuracy at Night," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 4, pp. 1294–1303, 2025, doi: 10.57152/malcom.v5i4.2250.
- [6] I. Ashari, I. S. M. Negara, and A. S. S. A., "Lightweight YOLO Models for Real-Time Multi-Vehicle Detection," *Sinkron: Jurnal dan Penelitian Teknik Informatika*, vol. 9, no. 3, pp. 1795–1810, 2025, doi: 10.33395/sinkron.v9i3.15071.
- [7] M. Fachrie, "A Simple Vehicle Counting System Using Deep Learning with YOLOv3 Model," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 4, no. 3, pp. 462–468, 2020, doi: 10.29207/resti.v4i3.1871.
- [8] I. Kutika, V. Lahimade, T. Todingan, S. R. Sentinuwo, and M. D. Putro, "Real-time Vehicle Detection using YOLOv10-nano Algorithm for Monitoring Traffic Analysis," *Jurnal Teknik Elektro dan Komputer*, vol. 14, no. 2, pp. 1–6, 2025, doi: 10.35793/jtek.v14i2.61469.
- [9] A. Saadeldin, M. M. Rashid, A. A. Shafie, and T. F. Hasan, "Real-time vehicle counting using custom YOLOv8n and DeepSORT for resource-limited edge devices," *TELKOMNIKA Telecommunication Computing Electronics and Control*, vol. 22, no. 1, pp. 104–112, 2024, doi: 10.12928/TELKOMNIKA.v22i1.25096.
- [10] A. S. Kusuma, A. I. Pradana, and B. W. Pamekas, "Pengembangan Sistem Perhitungan Jumlah Kendaraan Berdasarkan Jenis Kendaraan Menggunakan Algoritma YOLO Secara Realtime," *SKANIKA: Sistem Komputer dan Teknik Informatika*, vol. 7, no. 2, pp. 166–179, 2024, doi: 10.36080/skanika.v7i2.3201.
- [11] R. Juliansyah *et al.*, "Development of a Real-Time Traffic Density Detection Website Using YOLOv8-Based Digital Image Processing with OpenCV," *Journal of Information Systems and Informatics*, vol. 6, no. 4, pp. 2649–2678, 2024, doi: 10.51519/journalisi.v6i4.912.
- [12] P. Setiaji, W. A. Triyanto, and M. Nurhaliza, "Real-Time Traffic Density and Anomaly Monitoring Using YOLOv8, OpenCV and Pattern Recognition for Smart City Applications in Demak," *Jurnal Teknik Informatika (Jutif)*, vol. 6, no. 4, pp. 1769–1782, 2025, doi: 10.52436/1.jutif.2025.6.4.4867.
- [13] S. Pudaruth, I. M. Boodhun, and C. W. Onn, "Reducing Traffic Congestion Using Real-Time Traffic Monitoring with YOLOv8," *International Journal of Advanced Computer Science and Applications*, vol. 15, no. 10, pp. 1068–1079, 2024, doi: 10.14569/IJACSA.2024.01510109.
- [14] I. G. A. Saputra, I. N. E. Indrayana, and I. B. A. Peling, "Hyperparameter Tuning of YOLOv8n for Real-Time Material Truck Detection," *Jurnal Teknologi Informasi dan Pendidikan*, vol. 19, no. 2, pp. 1565–1579, 2026, doi: 10.24036/jtip.v19i2.1138.
- [15] I. N. E. Indrayana, M. Sudarma, I. K. G. D. Putra, and A. A. K. O. Sudana, "Hyperparameter Tuning Strategy for YOLOv8n in Real-Time Post-Accident Traffic Monitoring," *Jurnal Teknologi Informasi dan Pendidikan*, vol. 19, no. 2, pp. 1580–1599, 2026, doi: 10.24036/jtip.v19i2.1132.
- [16] Y. Zhang *et al.*, "ByteTrack: Multi-object Tracking by Associating Every Detection Box," in *Computer Vision – ECCV 2022*, S. Avidan, G. Brostow, M. Cissé, G. M. Farinella, and T. Hassner, Eds., Springer Nature Switzerland, 2022, pp. 1–21. doi: 10.1007/978-3-031-20047-2_1.
- [17] M. M. Fahrezi and E. A. Laksana, "Traffic Flow and Congestion Detection with YOLOv8 and ByteTrack-Based Multi Object Tracking," *Jurnal Teknik Informatika (Jutif)*, vol. 5, no. 4, pp. 253–261, 2024, doi: 10.52436/1.jutif.2024.5.4.2063.
- [18] M. A. Marzouk and M. Elkholy, "Tracking and Estimating the Speed of Vehicles Using an Enhanced R-CNN and Deep SORT Architecture," *Journal of Advances in Information Technology*, vol. 16, no. 2, pp. 204–214, 2025, doi: 10.12720/jait.16.2.204-214.
- [19] K. Khazukov *et al.*, "Real-time monitoring of traffic parameters," *J. Big Data*, vol. 7, no. 1, p. 84, 2020, doi: 10.1186/s40537-020-00358-x.
- [20] M. Raza *et al.*, "An Edge-Deployed Real-Time Adaptive Traffic Light Control System Using YOLO-Based Vehicle Detection and PCE-Aware Density Estimation," *IEEE Access*, vol. 13, pp. 153586–153613, 2025, doi: 10.1109/ACCESS.2025.3602844.
- [21] A. A. Amir, Sukman, A. D. Lihara, M. Nabil, and D. Nurmayanti, "Optimization of Traffic Performance Analysis in Kendari City with Deep Learning," *PENA TEKNIK: Jurnal Ilmiah Ilmu-Ilmu Teknik*, vol. 11, no. 01, pp. 34–43, 2026, doi: 10.51557/3fxt8a88.
- [22] A. Battal, Y. E. Avci, and A. Tuncer, "Real-Time Detection of Vehicle Queue States in Urban Traffic Using Deep Learning," *El-Cezeri Journal of Science and Engineering*, vol. 12, no. 3, pp. 356–364, 2025, doi: 10.31202/ecjse.1755333.