Populer: Jurnal Penelitian Mahasiswa
Volume. 5 Nomor. 3 September 2026
E-ISSN: 2963-5306, P-ISSN: 2962-116X, Hal 113-119
DOI: https://doi.org/10.58192/populer.v5i3.5487
Tersedia: https://journal.unimar-amni.ac.id/index.php/Populer

Identifikasi Pelanggaran Lalu Lintas Kendaraan Mobil terhadap Larangan Putar Balik menggunakan Algoritma *You Only Look Once* (YOLOv11)

Tiza Farhani Maulia[1*], Dedy Kurniadi[2], Ghufron[3]
[1-3]Program Studi Teknik Informatika, Fakultas Teknologi Industri, Universitas Islam Sultan Agung, Indonesia
**Penulis Korespondensi: tizafarhani48@gmail.com*

Abstract. *The purpose of this study is to identify and analyze traffic violations involving cars that violate U-Turn prohibitions using the You Only Look Once (YOLOv11) algorithm. Illegal U-Turns in restricted areas are a primary cause of traffic congestion and accidents. This study develops an automated, real-time U-Turn violation monitoring system by integrating the YOLOv11n model, ByteTrack tracking algorithm, and Streamlit interface using 2-zone polygon logic. The dataset covers 7 vehicle classes evaluated on 1,072 validation images. Experimental results show that the YOLOv11n model achieves a mean Average Precision (mAP@50) of 66.5%, Precision of 68.4%, and Recall of 64.2%. With an inference speed of 3.2 ms per frame (169 FPS), the 2-zone logic integrated into Streamlit accurately detects illegal maneuvers, updates real-time metrics, and minimizes false alarms without frame lag. The proposed system demonstrates the potential of combining object detection, vehicle tracking, and zone-based logic for automated monitoring of U-Turn violations in restricted areas.*

Keywords: *ByteTrack; Streamlit; Traffic Violation; U-Turn; YOLOv11.*

Abstrak. Tujuan penelitian ini adalah untuk mengidentifikasi dan menganalisis pelanggaran lalu lintas kendaraan mobil terhadap larangan putar balik menggunakan algoritma You Only Look Once (YOLOv11). Pelanggaran U-Turn ilegal pada area terlarang menjadi salah satu penyebab utama kemacetan dan kecelakaan lalu lintas. Penelitian ini membangun sistem pemantauan pelanggaran U-Turn secara otomatis dan real-time dengan mengintegrasikan model YOLOv11n, algoritma pelacak ByteTrack, dan antarmuka Streamlit berbasis poligon 2-zone. Dataset mencakup 7 kelas kendaraan yang dievaluasi menggunakan 1.072 citra validasi. Hasil pengujian menunjukkan bahwa model YOLOv11n memperoleh nilai mean Average Precision (mAP@50) sebesar 66,5%, Precision sebesar 68,4%, dan Recall sebesar 64,2%. Dengan kecepatan inferensi 3,2 ms per frame (169 FPS), integrasi logika 2-zone pada Streamlit terbukti mampu mendeteksi manuver pelanggaran secara akurat, memperbarui metrik secara real-time, dan meminimalkan peringatan palsu tanpa menyebabkan frame lag. Sistem yang dikembangkan menunjukkan potensi integrasi deteksi objek, pelacakan kendaraan, dan logika berbasis zona untuk pemantauan otomatis pelanggaran U-Turn pada area terlarang.

Kata Kunci: *ByteTrack*; Pelanggaran Lalu Lintas; Putar Balik; Streamlit; YOLOv11.

1. PENDAHULUAN

Kelan*Car*an sistem transportasi darat memiliki peran yang sangat besar dalam mendukung berbagai aktivitas ekonomi dan sosial masyarakat di era perkotaan modern. Namun, seiring dengan pesatnya pertumbuhan jumlah kendaraan bermotor, tantangan untuk menjaga ketertiban dan keselamatan di jalan raya semakin berat. Salah satu persoalan krusial yang sering ditemui adalah rendahnya tingkat kepatuhan pengendara terhadap rambu-rambu lalu lintas, khususnya larangan untuk melakukan putar balik *(U-Turn)* di titik-titik rawan kemacetan. Tindakan memutar balik kendaraan di lokasi terlarang t*ID*ak hanya memotong arus utama kendaraan se*Car*a tiba-tiba, melainkan juga memicu tundaan arus lalu lintas yang signifikan serta meningkatkan risiko terjadinya kecelakaan fatal.

Se*Car*a teknis transportasi, pergerakan putar balik pada bukaan median jalan memberikan pengaruh negatif yang besar terhadap karakteristik arus lalu lintas. Volume

Naskah Masuk: 25 Juni 2026; Revisi: 15 Agustus 2026; Diterima: 15 September 2026; Terbit: 22 September 2026

kendaraan yang memaksakan manuver *U-Turn* ilegal berbanding lurus dengan peningkatan nilai tundaan dan antrean di ruas jalan tersebut, yang pada akhirnya menurunkan tingkat pelayanan jalan *(Level of Service*) hingga ke titik terendah. Pengawasan konvensional yang mengandalkan kehadiran fisik petugas polisi lalu lintas di lapangan memiliki keterbatasan yang nyata dari segi jumlah personel, cakupan wilayah, dan durasi operasional. Di sisi lain, infrastruktur kamera *Closed-Circuit Television* (CCTV) yang terpasang di perkotaan umumnya masih berfungsi sebatas perekam v*ID*eo pasif. Proses penindakan hukum memerlukan verifikasi v*ID*eo se*Car*a manual satu per satu, sehingga dinilai t*ID*ak efisien dan t*ID*ak dapat dilakukan se*Car*a *real-time.*

Melihat kompleksitas dan keterbatasan tersebut, pemanfaatan teknologi kecerdasan buatan, khususnya b*ID*ang *Computer Vision* berbasis *Deep Learning,* hadir sebagai solusi strategis. Dengan menerapkan algoritma deteksi objek mutakhir seperti *You Only Look Once* versi 11 (YOLOv11) yang dipadukan dengan algoritma *multi-object tracking ByteTrack*, sistem pengawasan lalu lintas cerdas dapat dibangun untuk melakukan *ID*entifikasi pelanggaran *U-Turn* se*Car*a otomatis, presisi, dan kontinu selama 24 jam. Penelitian ini bertujuan untuk menguji keandalan arsitektur YOLOv11n dan integrasi logika *poligon 2-zone* pada antarmuka Streamlit dalam mendeteksi dan mengkalkulasi pelanggaran *U-Turn* pada rekaman v*ID*eo jalan raya se*Car*a *real-time.*

2. KAJIAN TEORITIS

Rambu lalu lintas merupakan salah satu elemen infrastruktur transportasi darat yang berfungsi memberikan peringatan, larangan, perintah, atau petunjuk bagi pengguna jalan demi mewujudkan ketertiban umum. Rambu larangan putar balik umumnya d*ID*esain dengan simbol panah melengkung berlatar putih dengan bingkai dan garis silang merah. Dalam sistem pemantauan otomatis, keberadaan rambu dan manuver kendaraan menjadi dua objek utama yang harus dianalisis se*Car*a simultan.

Convolutional Neural Network (CNN) menjadi arsitektur landasan dalam pengolahan citra digital berbasis *Deep Learning*. CNN mampu mengekstraksi fitur spasial se*Car*a bertahap mulai dari tingkat rendah (tepi dan garis) hingga tingkat tinggi (bentuk geometris kendaraan). Algoritma YOLO (*You Only Look Once*) mempopulerkan pendekatan single-stage detector yang memformulasi tugas deteksi objek sebagai masalah regresi tunggal dari *piksel input* langsung ke koordinat *bounding box* dan probabilitas kelas.

YOLOv11 hadir sebagai salah satu iterasi tercanggih yang membawa optimasi pada struktur *Backbone, Neck,* dan *Head*. Pada bagian *Backbone*, YOLOv11 menerapkan *improved lightweight network* berbasis *CSPDarknet* yang efisien dalam menangkap informasi kontekstual. Komponen *Neck* menggabungkan *Feature PyramID Network* (FPN) dan *Path Aggregation Network* (PAN) untuk memperkuat representasi fitur multi-skala. Sementara pada bagian *Head,* penerapan strategi *anchor-free detection* memungkinkan prediksi lokasi objek se*Car*a *fleksibel* tanpa bergantung pada ukuran kotak awal. Dipadukan dengan algoritma *ByteTrack* yang memanfaatkan asosiasi *matriks IoU* dan nilai kepastian rendah-tinggi, sistem dapat mempertahankan *ID* unik kendaraan meskipun terjadi *oklusi parsial* di jalan raya.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental kuantitatif. Pengmbangan sistem dilakukan melalui beberapa tahapan sistematis meliputi pengumpulan *dataset, preprocessing data*, anotasi dan pelabelan, pelatihan model YOLOv11n, evaluasi metrik kuantitatif, serta integrasi sistem pada antarmuka aplikasi pemantauan *Streamlit*.

Pengumpulan dan *Preprocessing Dataset*

Dataset yang digunakan bersumber dari platform *Kaggle* (*Vehicle Detection Image Dataset*) dengan total 9.440 citra yang mencakup berbagai variasi sudut pandang, tingkat pencahayaan, dan kepadatan lalu lintas. Dataset ini dibagi se*Car*a terstruktur menjadi tiga bagian: 7.556 citra (~80%) untuk training set, 1.072 citra (~11%) untuk *valIDation set*, dan 812 citra (~9%) untuk *testing set.* Seluruh citra diseragamkan resolusinya menjadi 640×640 *piksel*. Pelabelan dilakukan menggunakan *platform Roboflow* ke dalam 7 kategori kelas kendaraan: Mobil (*Car*), Becak/Bajaj (*Rickshaw*), Bus, Truk (*Truck*), Sepeda Motor (Motorbike), Sepeda (*Bicycle*), dan Minibus/Van (*Van*).

Pelatihan Model YOLOv11n

Proses pelatihan model dieksekusi menggunakan kerangka kerja *Ultralytics* pada perangkat keras berkemampuan GPU NV*ID*IA *GeForce RTX* 3050 Laptop. Parameter pelatihan yang ditetapkan disajikan se*Car*a lengkap pada Tabel 1 di bawah ini:

Tabel 1. Konfigurasi *Hyperparameter* Pelatihan YOLOv11n.

Nama Parameter	Nilai Pengaturan	Fungsi Teknis & Deskripsi
Epochs	100	Batas maksimum iterasi siklus pembelajaran
Batch Size	16	Jumlah sampel citra diproses per iterasi GPU
Image Size (imgsz)	640 × 640	Resolusi spasial citra masukan

		jaringan
Initial Learning Rate (lr0)	0.0001	Laju pembelajaran awal pada algoritma optimasi
Final Learning Rate (lrf)	0.1	Faktor pengali laju pembelajaran akhir
Dropout Rate	0.1	Rasio pemutusan neuron acak pencegah overfitting
Patience	50	Batas penghentian dini (early stopping)
Device / Seed	GPU 0 / Seed 0	Alokasi CUDA GPU dan pengunci reproduksibilitas

Logika *Poligon 2-zone* dan Multi-*Object Tracking*

Untuk meng*ID*entifikasi manuver putar balik ilegal, sistem menerapkan logika spasial *poligon 2-zone* pada antarmuka Streamlit. Wilayah pengamatan dibagi menjadi *Zone A* (Zona Masuk/Pendekatan) dan *Zone B* (Zona Larangan Putar Balik). Algoritma ByteTrack memberikan *ID* unik pada setiap kendaraan terdeteksi. Logika pemicu (*trigger logic*) menganalisis pergerakan titik pusat (*centroID*) kendaraan: jika suatu kendaraan ber-*ID* sama se*Car*a sekuensial terdeteksi bergerak dari *Zone A* lalu masuk ke dalam Zone B, sistem mengategorikannya sebagai pelanggaran *U-Turn*, mengubah warna *bounding box* menjadi merah, serta menambahkan nilai pada *counter* pelanggaran unik se*Car*a otomatis.

4. HASIL DAN PEMBAHASAN

Evaluasi Metrik Performa Kuantitatif

Evaluasi kuantitatif dilakukan terhadap berkas bobot terbaik (best.pt) menggunakan 1.072 citra *validasi* yang mencakup total 3.375 objek kendaraan (*instances*). Hasil pengujian metrik performa disajikan pada Tabel 2 berikut:

Tabel 2. Evaluasi Metrik Performa YOLOv11n per Kategori Kendaraan.

Kategori Kelas	Jumlah Instances	Precision (P)	Recall (R)	mAP@50	mAP@50-95
Keseluruhan (All)	3.375	0.684	0.642	0.665	0.453
Mobil (*Car*)	2.021	0.837	0.801	0.848	0.628
Becak/Bajaj (*Rickshaw*)	325	0.741	0.757	0.764	0.585
Bus	428	0.739	0.675	0.720	0.504
Truk (*Truck*)	63	0.729	0.603	0.697	0.401
Sepeda Motor (*Motorbike*)	313	0.674	0.629	0.627	0.397
Sepeda (*Bicycle*)	109	0.581	0.624	0.613	0.396
Minibus/*Van*	116	0.488	0.405	0.390	0.261

Berdasarkan Tabel 2, model YOLOv11n secara kumulatif mencatatkan nilai Precision sebesar 68,4%, *Recall* 64,2%, dan mAP@50 sebesar 66,5%. Kategori Mobil (*Car*) memperoleh hasil tertinggi dengan mAP@50 mencapai 84,8% dan *Precision* 83,7%, yang didorong oleh dominasi sampel data pelatihan (59,8% dari total objek). Sementara itu, kelas *Minibus/Van*

memperoleh mAP@50 terendah (39,0%) akibat keterbatasan sampel data dan fenomena tumpang-tindih *fitur visual* (*feature overlap*) dengan tipe kendaraan SUV maupun bus kecil.

Analisis Efisiensi Komputasi dan *Speed Latency*

Arsitektur YOLOv11n memiliki profil jaringan yang sangat ringan dengan 2.583.517 *parameter* teroptimasi dan beban komputasi 6.4 GFLOPs.

Log pengujian pada *GPU NVIDIA RTX* 3050 Laptop mencatatkan rincian durasi pemrosesan per citra sebagai berikut: pra-pemrosesan (*preprocess*) 0.3 ms, inferensi (*inference*) 3.2 ms, dan pasca-pemrosesan (*postprocess*) 2.4 ms. Total latensi 5.9 ms per *frame* setara dengan kecepatan *throughput* 169 *Frame* Per *Second* (FPS). Kecepatan ini jauh melampaui batas standar pemantauan *video* waktu nyata (30 FPS), sehingga menjamin keberlangsungan pelacakan tanpa kendala penundaan bingkai (*frame lagging*).

Analisis Kurva Performa dan *Determination Threshold*

Berdasarkan evaluasi *F1-confidence Curve*, *kurva* cembung rata-rata seluruh kelas mencapai titik puncak skor F1 maksimum sebesar 0.66 pada nilai *confidence threshold* 0,343. *Parameter threshold* 0.343 (dibulatkan menjadi 0.35) ini ditetapkan sebagai nilai acuan utama pada antarmuka aplikasi. Penerapan angka ini terbukti *optimal* dalam menyeimbangkan sensitivitas deteksi terhadap kendaraan roda dua/kecil sekaligus menyaring *noise visual* pada latar belakang jalan raya.

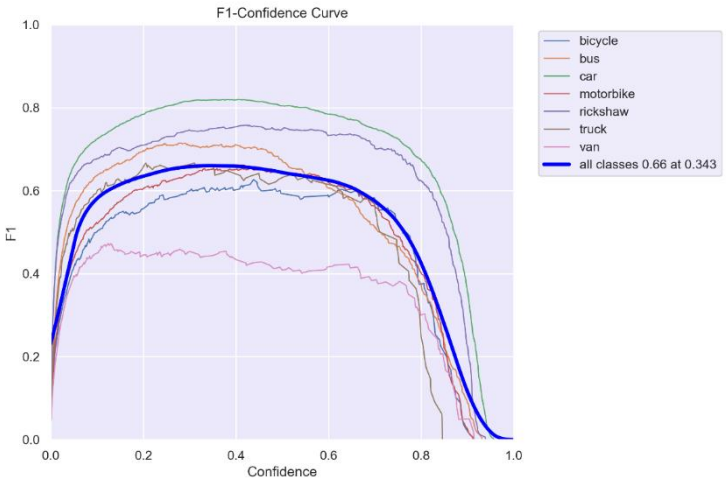

Gambar 1. F1 *ConfIDence Curve.*

Pengujian Integrasi Sistem pada Aplikasi *Streamlit*

Pengujian *integrasi* akhir dilakukan pada *skenario video* nyata (lokasi Jalan Supriyadi, Kota Semarang). Pada kondisi arus lalu lintas normal, kendaraan yang bergerak lurus di dalam *Zone A* teridentifikasi aman dengan *bounding box* hijau. Ketika kendaraan (seperti *ID*:343) melakukan *manuver* melintas dari *Zone A* menuju *Zone B*, sistem secara instan mengubah

warna *bounding box* kendaraan menjadi merah, memberikan label "PELANGGARAN *U-TURN*", memperbarui *panel Metrik Real-Time* (Jumlah Pelanggaran Unik = 1), serta memunculkan notifikasi peringatan merah tanpa mengalami hambatan komputasi.

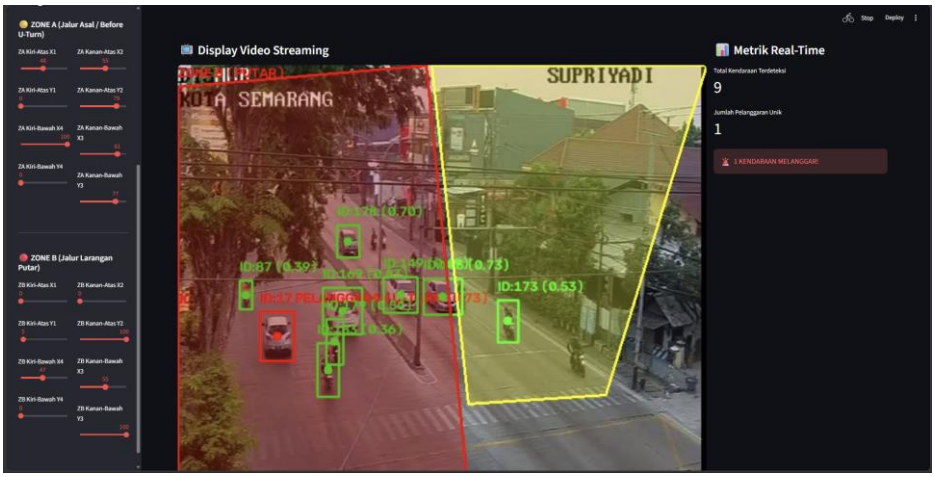

Gambar 2. Pengujian integrasi sistem pada aplikasi *streamlit.*

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil merancang dan mengimplementasikan sistem pemantauan pelanggaran *U-Turn* secara otomatis dan *real-time* menggunakan integrasi YOLOv11n, *ByteTrack,* dan antarmuka *Streamlit berbasis poligon 2-zone.* Model YOLOv11n mencatatkan kinerja mAP@50 sebesar 66,5% dengan kecepatan *inferens*i 3,2 ms per *frame* (169 FPS). Ambang batas kepercayaan optimal sebesar 0,343 berhasil menyeimbangkan *Precision* dan *Recall. Integrasi* logika sekuensial *poligon* terbukti presisi mendeteksi *manuver* pelanggaran *U-Turn* dan mengeliminasi alarm palsu.

Saran untuk pengembangan penelitian selanjutnya yaitu Penambahan variasi dataset untuk kategori kendaraan berakurasi rendah seperti *Minibus/Van* dan Sepeda Motor, Perluasan skenario pengujian pada kondisi lingkungan menantang seperti malam hari, hujan deras, dan pantulan lampu silau, Pengembangan fitur *Optical Character Recognition* (OCR) untuk pengenalan plat nomor kendaraan otomatis (ANPR) guna mendukung integrasi sistem *Electronic Traffic Law Enforcement* (ETLE).

DAFTAR PUSTAKA

Bagus, J. (2023). Klasifikasi rambu lalu lintas Indonesia menggunakan algoritma YOLOv5. *Jurnal Teknologi Informasi dan Terapan, 10*(1), 15–22.

Budiharto, W. (2021). *Deep learning modern dengan Python*. Andi Offset.

Harahap, dkk. (2023). Analisis efektivitas rambu lalu lintas terhadap kelancaran arus kendaraan. *Jurnal Teknik Sipil dan Lingkungan, 11*(2), 85–94. https://doi.org/10.30743/jtsip.v2i1.7660

Hidayat, T., & Pratama, R. (2023). Implementasi deep learning untuk deteksi pelanggaran rambu lalu lintas berbasis computer vision. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi), 7*(3), 512–520.

Kusuma, W. P., & Setiawan, A. B. (2024). Deteksi objek real-time berbasis YOLO untuk monitoring pelanggaran lalu lintas secara otomatis. *Jurnal Riset Informatika dan Komputer, 6*(1), 88–96.

Pradana, A., dkk. (2024). Implementasi YOLOv11 untuk pengenalan rambu lalu lintas otomatis. *Jurnal Informatika dan Sistem Komputer, 8*(2), 101–110.

Pratama, M. R., & Shidiq, M. J. (2024). Analisis performa algoritma You Only Look Once (YOLO) dalam deteksi objek real-time. *Jurnal Teknologi Informasi dan Terapan, 11*(1), 30–38.

Priadini, A. (2024). Deteksi rambu lalu lintas berbasis YOLOv8 untuk meningkatkan keselamatan berkendara. *Jurnal Riset Komputer (JURIKOM), 11*(2), 205–212.

Putrada, A. G., & Abdurohman, M. (2022). *Pengantar deep learning: Implementasi object detection*. Informatika.

Putra, P., & Nurchim, M. (2024). Strategi augmentasi data untuk pelabelan dataset lalu lintas di Indonesia. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, *8*(4), 1420–1428.

Ramadhan, H., & Cahyono, B. (2025). Perbandingan arsitektur deep learning pada dataset rambu lalu lintas lokal. *Jurnal Tekno Kompak, 19*(1), 55–64.

RI, K. P. (2014). *Peraturan Menteri Perhubungan Nomor 13 Tahun 2014 tentang rambu lalu lintas*. Direktorat Jenderal Perhubungan Darat.

Santoso, B., & Ahmad, F. (2023). Analisis dampak pelanggaran rambu lalu lintas terhadap risiko kecelakaan di jalan raya. *Jurnal Transportasi dan Logistik*, *10*(2), 115–124.

Taufiqurrahman, dkk. (2024). Evaluasi model deteksi objek pada variasi pencahayaan dan kepadatan lalu lintas Indonesia. *Jurnal RESTI, 8*(1), 77–85.

Wadu, M., dkk. (2024). Pengaruh pergerakan putar balik (U-Turn) terhadap tundaan lalu lintas jalan perkotaan. *Jurnal Teknik Sipil dan Lingkungan, 12*(1), 33–42.