

# Detection of Vehicle License Plates Using YOLO11

Deteksi Tanda Nomor Kendaraan Bermotor menggunakan Algoritma YOLO11

Samuel Meinus Untu, Salvius P. Lengkong, Muhamad D. Putro

Dept. of Electrical Engineering, Sam Ratulangi University Manado, Kampus Bahu St., 95115, Indonesia

e-mails: samueluntu026@student.unsrat.ac.id, salviuslengkong@unsrat.ac.id,

dwisnantoputro@unsrat.ac.id

Received: 20 August 2025; revised: 2 March 2026; accepted: 1 April 2026

**Abstract** — An automatic vehicle license plate detection and recognition system was developed by integrating the YOLO11n algorithm with EasyOCR. The objective is to build a computer vision-based system capable of accurately detecting license plate positions and recognizing alphanumeric characters under real-world campus conditions at Sam Ratulangi University. The detection model achieved high performance with 97% precision, 98.4% recall, 97.7% F1-score, and 99% mAP@0.5. Character recognition using EasyOCR demonstrated near-zero Character Error Rate (CER) and Word Error Rate (WER) across most test images. Video testing with a three-hour duration recorded 1,757 successfully detected vehicles out of 2,866, resulting in a 61.3% detection accuracy. These results indicate that the integration of YOLO11n and EasyOCR provides an efficient, accurate, and adaptive solution for Automatic License Plate Recognition (ALPR) systems under varying lighting and plate orientation conditions.

**Key words** — YOLO11n; EasyOCR; object detection; character recognition; Automatic License Plate Recognition (ALPR)

**Abstrak** — Sistem deteksi dan pengenalan tanda nomor kendaraan bermotor otomatis dikembangkan dengan mengintegrasikan algoritma YOLO11n dan EasyOCR. Tujuannya adalah membangun sistem berbasis visi komputer yang mampu mendeteksi posisi plat nomor serta membaca karakter alfanumeriknya secara akurat pada kondisi nyata di lingkungan kampus Universitas Sam Ratulangi. Hasil pengujian menunjukkan performa deteksi tinggi dengan nilai precision sebesar 97%, recall 98,4%, F1-score 97,7%, dan mAP@0.5 99%. Proses pengenalan karakter melalui EasyOCR menunjukkan tingkat kesalahan rendah dengan nilai CER dan WER mendekati 0 pada sebagian besar citra uji. Pengujian video berdurasi tiga jam menunjukkan sistem mampu mendeteksi 1.757 dari total 2.866 kendaraan dengan tingkat keberhasilan 61,3%. Hasil tersebut membuktikan bahwa integrasi YOLO11n dan EasyOCR efektif diterapkan untuk sistem Automatic License Plate Recognition (ALPR) yang efisien, akurat, dan adaptif terhadap variasi pencahayaan serta orientasi plat nomor di lapangan.

**Kata kunci** — YOLO11n; EasyOCR; deteksi objek; pengenalan karakter; Automatic License Plate Recognition (ALPR)

## I. PENDAHULUAN

Pertumbuhan jumlah kendaraan bermotor di Indonesia menuntut adanya sistem identifikasi kendaraan yang mampu bekerja secara otomatis, akurat, dan efisien pada berbagai

kondisi lingkungan. Sistem *Automatic License Plate Recognition* (ALPR) banyak diterapkan pada pengawasan lalu lintas, manajemen parkir, dan penegakan hukum, namun performanya sering dipengaruhi oleh variasi format plat nomor, sudut pengambilan gambar, kualitas citra, serta kondisi pencahayaan yang tidak terkontrol [1]. Selain itu, sejumlah penelitian terdahulu menunjukkan bahwa sebagian besar model ALPR menggunakan dataset luar negeri, sehingga belum sepenuhnya sesuai dengan karakteristik visual plat nomor Indonesia yang memiliki struktur dan warna berbeda [2].

Pada sistem visi komputer berbasis pembelajaran mendalam, *CNN* (*Convolutional Neural Network*) berperan dalam mengekstraksi fitur visual dari citra secara otomatis. Penelitian mengenai arsitektur CNN ringan menunjukkan bahwa desain jaringan yang efisien mampu menghasilkan representasi fitur yang akurat dengan kompleksitas komputasi lebih rendah. Efisiensi ekstraksi fitur tersebut menjadi aspek penting dalam mendukung kinerja sistem ALPR yang mengintegrasikan deteksi objek berbasis YOLO dan pengenalan karakter menggunakan OCR [3].

Kemajuan metode deteksi objek berbasis *deep learning*, khususnya keluarga YOLO (*You Only Look Once*), telah memberikan peningkatan signifikan dalam akurasi dan kecepatan deteksi real-time dibandingkan metode konvensional. Evolusi YOLO dari versi awal hingga YOLO11 menghasilkan model yang lebih efisien dalam pemrosesan citra, memiliki jumlah parameter lebih ringan, serta menawarkan peningkatan akurasi dalam mendeteksi objek berukuran kecil dan dinamis [4]. Sejumlah penelitian telah menerapkan YOLO untuk deteksi plat nomor maupun kendaraan, namun sebagian besar masih terbatas pada model seperti YOLOv4, YOLOv5, atau YOLOv8 dan belum mengevaluasi performa YOLO11 dalam konteks ALPR [5].

Tahap penting berikutnya dalam sistem ALPR adalah pengenalan karakter melalui *Optical Character Recognition* (OCR). Pendekatan OCR tradisional seperti Tesseract dan *rule-based recognition* cenderung memiliki keterbatasan ketika citra mengalami rotasi, noise, atau variasi font, yang umum terjadi pada plat nomor di lingkungan nyata [6]. Penelitian terbaru menunjukkan bahwa metode berbasis *deep learning* memberikan performa OCR yang lebih baik pada citra kompleks, termasuk karakter dengan deformasi dan latar belakang bising [7]. Namun, penelitian yang mengintegrasikan

deteksi objek berbasis YOLO dengan OCR modern dalam satu alur masih terbatas, terutama untuk domain plat nomor Indonesia.

Dari tinjauan pustaka, terdapat beberapa celah penelitian yang belum terjawab. Pertama, belum banyak studi yang memanfaatkan arsitektur YOLO11 untuk deteksi plat nomor kendaraan, padahal model ini menawarkan peningkatan efisiensi inferensi dibandingkan generasi sebelumnya. Kedua, penelitian ALPR di Indonesia masih jarang menggunakan dataset citra kendaraan nyata dari berbagai kondisi lingkungan. Ketiga, sebagian besar penelitian hanya mengevaluasi tahap deteksi tanpa mengukur performa pembacaan karakter secara terintegrasi menggunakan OCR [8].

Penelitian ini berkontribusi dengan merancang dan mengevaluasi sistem deteksi dan pengenalan plat nomor kendaraan Indonesia berbasis model YOLO11n untuk tahap deteksi dan EasyOCR untuk tahap ekstraksi karakter secara end-to-end. Model YOLO11n dilatih menggunakan dataset citra kendaraan Indonesia dan menghasilkan performa deteksi sebesar 99% mAP, yang menunjukkan keandalannya dalam mendeteksi plat nomor pada berbagai kondisi visual. Selain itu, integrasi YOLO11n dan EasyOCR memungkinkan proses ALPR berlangsung secara *real-time* sekaligus memungkinkan evaluasi menyeluruh terhadap akurasi deteksi dan pembacaan karakter. Tujuan penelitian ini adalah mengukur performa sistem ALPR berbasis YOLO11n dalam konteks data Indonesia dan memberikan dasar teknis bagi pengembangan sistem pemantauan kendaraan otomatis di masa mendatang.

#### A. Sistem ALPR (Automatic License Plate Recognition)

*Automatic License Plate Recognition* (ALPR) merupakan sistem yang dirancang untuk mendeteksi dan mengenali plat nomor kendaraan secara otomatis melalui proses berbasis visi komputer. Secara umum, ALPR terdiri atas dua tahapan utama, yaitu deteksi lokasi plat nomor dan pengenalan karakter di dalamnya menggunakan OCR. Sistem ini telah dimanfaatkan pada aplikasi penegakan hukum, manajemen parkir otomatis, sistem tol, dan pemantauan lalu lintas [9]. Pada konteks Indonesia, variasi font, warna latar, serta karakteristik pencahayaan dan sudut pengambilan citra menimbulkan tantangan yang memerlukan pendekatan berbasis *deep learning* untuk menjaga akurasi sistem dalam kondisi nyata [10].

#### B. CNN (Convolutional Neural Networks)

*CNN (Convolutional Neural Network)* merupakan arsitektur *deep learning* yang dirancang untuk mengekstraksi fitur visual dari citra secara otomatis melalui operasi konvolusi bertingkat. CNN bekerja dengan menerapkan kernel berukuran kecil untuk menangkap pola lokal seperti tepi, tekstur, dan bentuk objek, yang kemudian direpresentasikan dalam *feature map*. Seiring bertambahnya kedalaman jaringan, CNN mampu mempelajari fitur visual yang lebih kompleks dan diskriminatif, sehingga efektif digunakan dalam sistem deteksi objek. Namun, arsitektur CNN yang dalam memiliki beban komputasi tinggi. Oleh karena itu, pendekatan CNN ringan dikembangkan dengan mengurangi kompleksitas jaringan tanpa mengorbankan kemampuan ekstraksi fitur, sehingga tetap efektif untuk aplikasi deteksi objek secara *real-time* pada perangkat dengan sumber daya terbatas [11].

#### C. YOLO (You Only Look Once)

*YOLO (You Only Look Once)* merupakan model deteksi objek satu tahap yang melakukan prediksi *bounding box* dan klasifikasi secara langsung pada satu proses inferensi. Sejak diperkenalkan, YOLO terus berkembang hingga versi terbaru, YOLO11, yang menawarkan peningkatan akurasi, efisiensi, dan kemampuan mendeteksi objek kecil [12]. YOLO11n sebagai varian ringan mengadopsi blok C2f sebagai *backbone*, modul SPPF (*Spatial Pyramid Pooling Fast*) untuk memperluas konteks fitur, serta mekanisme *Progressive Sparse Attention* (PSA) untuk meningkatkan representasi fitur tanpa menambah beban komputasi [13]. Selain itu, YOLO11 memakai arsitektur *decoupled head* yang memisahkan tugas regresi dan klasifikasi untuk meningkatkan stabilitas pelatihan dan akurasi prediksi [14]. Fitur-fitur tersebut menjadikan YOLO11n relevan untuk sistem ALPR real-time pada perangkat terbatas.

#### D. OCR (Optical Character Recognition)

*Optical Character Recognition* (OCR) bertujuan mengubah citra karakter menjadi teks digital. Metode OCR berbasis *rule-based* seperti Tesseract bersifat sensitif terhadap rotasi, noise, distorsi, dan variasi font, sehingga akurasinya menurun pada citra dunia nyata [15]. Pendekatan modern seperti EasyOCR memanfaatkan CNN dan transformer untuk mengekstraksi fitur karakter secara adaptif, sehingga lebih robust terhadap variasi bentuk karakter, latar belakang, dan kualitas citra rendah [16]. Dalam sistem ALPR, OCR berfungsi membaca karakter alfanumerik pada plat yang dapat terdiri atas font khusus serta dikombinasikan dengan kode wilayah tertentu, sehingga pemilihan metode berbasis *deep learning* menjadi krusial untuk meminimalkan kesalahan pembacaan.

#### E. Evaluasi

Kinerja model deteksi objek dievaluasi menggunakan *mean Average Precision* (mAP), yang dirumuskan sebagai:

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i = \frac{1}{n} \sum_{i=1}^n \int_0^1 P_i(R_i) dR_i \quad (1)$$

Dengan  $n$  adalah jumlah kelas dan  $AP_i$  adalah *Average Precision* tiap kelas. Metrik *Precision* dan *Recall* digunakan untuk mengevaluasi kesesuaian prediksi *bounding box*, masing-masing dihitung sebagai:

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

Dengan TP (*true positive*), FP (*false positive*), dan FN (*false negative*).

Untuk tahap OCR, evaluasi dilakukan menggunakan *Character Error Rate* (CER) dan *Word Error Rate* (WER). CER dihitung sebagai:

$$CER = \frac{I + D + S}{N} \quad (4)$$

$$WER = \frac{I + D + S}{N} \quad (5)$$

Dengan S adalah jumlah kesalahan substitusi, D adalah jumlah karakter atau kata yang dihapus, dan I adalah jumlah penambahan karakter atau kata, dan N adalah jumlah karakter atau kata benar pada *ground truth* [17]. Kombinasi mAP dan CER/WER memungkinkan evaluasi menyeluruh pada sistem ALPR, bukan hanya deteksi tetapi juga keberhasilan pembacaan karakter.

## II. METODE

Penelitian ini dirancang menggunakan pendekatan berbasis *deep learning* untuk membangun sistem Automatic License Plate Recognition (ALPR) yang terdiri dari dua tahap utama, yaitu deteksi plat nomor menggunakan model YOLO11n dan pengenalan karakter menggunakan EasyOCR. Metode penelitian disusun secara berurutan, dimulai dari pembuatan dataset, pelatihan model, proses inferensi, hingga evaluasi performa berbasis citra dan video. Alur lengkap proses penelitian ditunjukkan pada Gambar 1.

### A. Pembuatan Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 2.000 citra kendaraan dengan fokus pada objek plat nomor sebagai satu-satunya kelas deteksi. Citra diperoleh melalui kombinasi pengambilan gambar langsung di jalan raya dan area parkir serta pengumpulan dari sumber *open-source* untuk memastikan variasi kondisi pencahayaan, sudut pengambilan, dan jenis kendaraan. Seluruh citra kemudian dianotasi menggunakan format YOLO.

Sebelum proses pelatihan, citra diubah ke ukuran input  $640 \times 640$  piksel dan dibagi menjadi tiga subset data: 70% data pelatihan, 20% data validasi, dan 10% data pengujian. Proses augmentasi diterapkan untuk meningkatkan keragaman data, meliputi perubahan skala, rotasi, serta modifikasi tingkat kecerahan secara acak, sehingga model lebih adaptif terhadap kondisi dunia nyata.

### B. Pelatihan Model YOLO11n

Model yang digunakan adalah YOLO11n. Proses pelatihan dilakukan menggunakan platform Google Colab dengan GPU NVIDIA T4 16GB. Pelatihan berlangsung selama 200 epoch dengan ukuran batch 16, sementara pengaturan optimisasi menggunakan konfigurasi otomatis dari framework, termasuk penyesuaian *learning rate* awal sebesar 0,01.

Selama pelatihan, metrik dan grafik pemantauan seperti *training loss*, *validation loss*, dan *kurva precision recall* dicatat untuk memastikan model tidak mengalami *overfitting*. Hasil pelatihan akhir berupa model terbaik yang dipilih berdasarkan performa pada data validasi menggunakan nilai mAP pada ambang IoU 0,5.

### C. Deteksi Plat Nomor

Model YOLO11n yang telah dilatih digunakan untuk mendeteksi lokasi plat nomor pada citra uji. Proses inferensi menghasilkan *bounding box* beserta nilai *confidence score* untuk setiap objek terdeteksi. Hasil deteksi kemudian dipotong

(*cropping*) dan diteruskan ke tahap pengenalan karakter menggunakan OCR.

### D. Pengenalan Karakter (OCR)

Tahap pengenalan karakter dilakukan menggunakan EasyOCR dengan mode pembacaan langsung satu baris, tanpa segmentasi karakter per huruf. OCR diterapkan terhadap citra hasil *cropping* plat nomor yang diperoleh dari deteksi YOLO11n. Pengujian OCR dilakukan pada 9 citra plat nomor acak dari data uji untuk mengevaluasi kemampuan pembacaan karakter dalam kondisi variatif, termasuk kemiringan plat, kualitas citra, dan keberadaan noise visual.

### E. Evaluasi Sistem

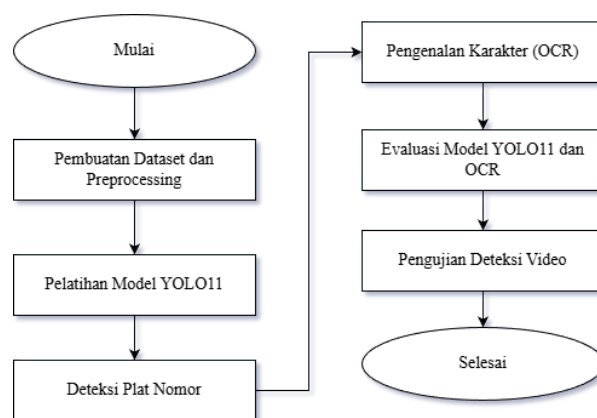
Evaluasi performa deteksi objek dilakukan menggunakan metrik mAP@0.5, serta *precision* dan *recall* untuk mengukur tingkat keberhasilan model dalam mengidentifikasi plat nomor secara benar maupun salah. Selain itu, confusion matrix digunakan untuk memvisualisasikan distribusi prediksi terhadap data anotasi sebenarnya sehingga pola kesalahan dapat dianalisis lebih lanjut.

Pada tahap OCR, proses evaluasi dilakukan dengan menghitung nilai CER dan WER berdasarkan perbandingan antara hasil keluaran OCR dan *ground truth* teks plat nomor. Kedua metrik ini digunakan untuk menilai tingkat kesalahan pembacaan karakter maupun keseluruhan string plat nomor.

### F. Pengujian Video

Pengujian lanjutan dilakukan menggunakan sebuah video rekaman berdurasi tiga jam, yang diambil pada kondisi lalu lintas nyata. Video digunakan untuk menguji stabilitas dan performa sistem. Jumlah kendaraan yang melintas pada video dihitung secara manual sebagai pembandingan, dengan total 2.866 kendaraan selama periode perekaman.

Model YOLO11n digunakan untuk mendeteksi plat nomor pada setiap frame video, kemudian OCR membaca karakter dari setiap deteksi valid. Hasil pengujian dianalisis berdasarkan tingkat keberhasilan deteksi per frame, jumlah plat yang berhasil terbaca, dan perbandingan dengan jumlah kendaraan yang terhitung manual untuk mengetahui tingkat error sistem dalam konteks dunia nyata.



Gambar 1 Alur sistem penelitian

### III. HASIL DAN PEMBAHASAN

#### A. Hasil Pelatihan Model YOLO11n

Proses pelatihan model YOLO11n dilakukan menggunakan 1.400 citra untuk data pelatihan, 399 citra untuk validasi, dan 201 citra untuk pengujian. Pelatihan berlangsung selama 200 epoch dengan ukuran input 640×640 piksel. Hasil proses pelatihan ditunjukkan melalui grafik metrik dan tabel evaluasi berikut.

Gambar 2 menunjukkan grafik perubahan nilai *Box Loss*, *Classification Loss*, dan *Distribution Focal Loss* (DFL) selama proses pelatihan dan validasi. Kurva pada grafik memperlihatkan penurunan nilai loss yang berlangsung secara bertahap seiring bertambahnya epoch, baik pada data pelatihan maupun validasi.

Tabel 1 menampilkan nilai akhir *Box Loss*, *Classification Loss*, dan *Distribution Focal Loss* (DFL) pada data pelatihan dan validasi. Nilai loss pada data pelatihan lebih rendah dibandingkan validasi pada seluruh komponen, yang menunjukkan bahwa model menghasilkan prediksi lebih optimal pada data pelatihan. Perbedaan ini mencerminkan tingkat kesalahan model dalam menentukan posisi bounding box, klasifikasi objek, serta distribusi spasial bounding box.

Tabel 1  
Perbandingan Performa Training dan Validation

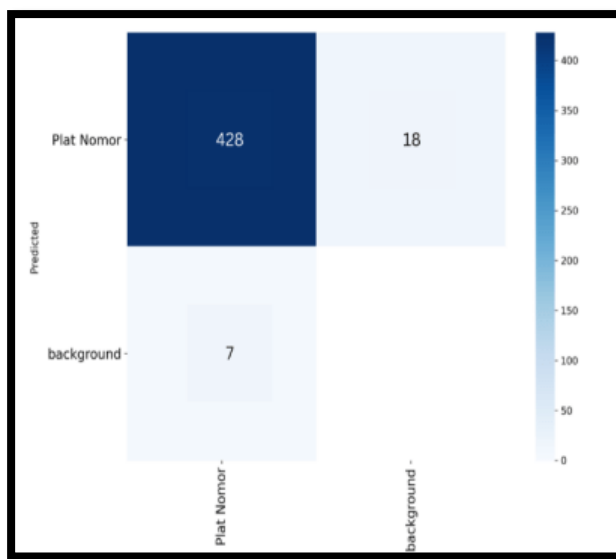
Metrik	Training	Validation
Box Loss	0,451	0,632
Classification Loss	0,264	0,343
DFL Loss	0,888	1,073

Tabel 2  
Performa Metrik Klasifikasi

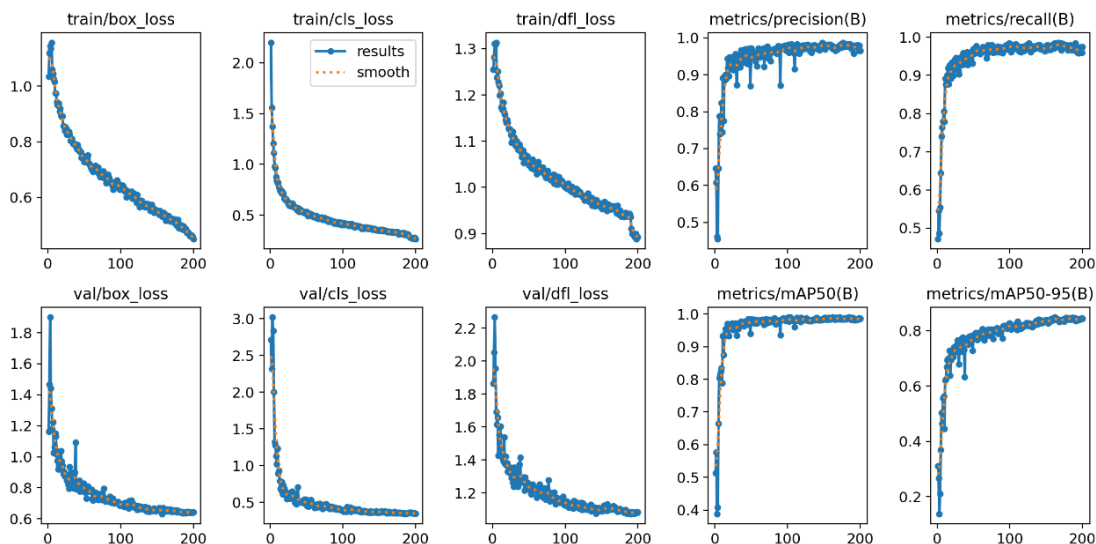
Metrik	Skor
Precision	97%
Recall	98,4%
F1-Score	97,7%
mAP@0.5	99%
mAP@0.5:0.95	84,9%

Gambar 2 menunjukkan bahwa precision, recall, mAP@0.5, dan mAP@0.5:0.95 meningkat tajam pada epoch awal, kemudian stabil hingga akhir pelatihan. Pola ini menandakan model cepat mempelajari karakteristik plat nomor dan mencapai konvergensi dengan fluktuasi minimal. Nilai mAP@0.5 yang mendekati 1,0 menunjukkan akurasi deteksi yang sangat tinggi pada IoU standar, sedangkan mAP@0.5:0.95 yang lebih rendah mencerminkan evaluasi yang lebih ketat namun tetap konsisten.

Berdasarkan Tabel 2, model memperoleh precision 97%, recall 98,4%, dan F1-score 97,7%, yang menunjukkan deteksi plat nomor dengan tingkat kesalahan rendah serta cakupan deteksi yang tinggi. Nilai mAP@0.5 sebesar 99% menegaskan akurasi bounding box yang sangat baik, sementara mAP@0.5:0.95 sebesar 84,9% menunjukkan performa tetap stabil pada ambang IoU yang lebih ketat.



Gambar 3 Confusion Matrix hasil training model YOLO11n




Gambar 2 Metrik Training dan Validation YOLO11n

Gambar 3 menampilkan confusion matrix hasil validasi model terhadap dataset pengujian. Model berhasil mendeteksi 428 plat nomor secara benar (*true positive*), menghasilkan 7 deteksi yang salah terhadap objek non-plat (*false positive*), dan gagal mendeteksi 18 instance plat nomor (*false negative*). Distribusi nilai ini menggambarkan tingkat kesesuaian antara prediksi model dan anotasi sebenarnya, serta memberikan gambaran mengenai jumlah deteksi yang berhasil, keliru, dan terlewat selama proses inferensi pada data validasi.

**B. Hasil Deteksi Plat Nomor**

Implementasi model YOLO11n untuk deteksi plat nomor dilakukan pada dataset uji yang berisi citra kendaraan dari lingkungan kampus Universitas Sam Ratulangi dengan variasi sudut pandang, jarak kamera, dan kondisi pencahayaan. Hasil deteksi dianalisis berdasarkan visualisasi bounding box dan nilai *confidence score* untuk mengukur tingkat keyakinan model dalam mengenali area plat nomor.

Gambar 4 memperlihatkan hasil deteksi pada sembilan citra uji. Pada citra 1 hingga citra 6, model berhasil mendeteksi plat nomor dengan *bounding box* yang presisi serta *confidence score* yang berada pada rentang 0,847 hingga 0,897. Deteksi yang stabil pada berbagai tipe kendaraan (mobil dan sepeda motor) menunjukkan konsistensi model dalam mengekstraksi fitur visual plat nomor meskipun terdapat variasi latar belakang maupun orientasi objek. Pada citra ke-6, model mendeteksi lebih dari satu objek plat dalam satu frame, menandakan kemampuan *multi-object detection* yang efektif, serta menunjukkan bahwa model tetap bekerja dengan baik pada perbedaan pencahayaan, jarak kamera, sudut pengambilan gambar, dan kondisi lingkungan yang beragam.



Gambar 4 Hasil deteksi plat nomor kendaraan menggunakan YOLO11n

Tabel 3 memuat informasi koordinat *bounding box* serta nilai *confidence score* untuk setiap citra yang berhasil terdeteksi. Citra 1 hingga 6 memperoleh nilai *confidence score* di atas 0,84, yang menunjukkan tingkat keyakinan model yang tinggi terhadap lokasi objek plat nomor. Sebaliknya, citra 7, 8, dan 9 tidak menghasilkan *bounding box*, ditandai dengan nilai *confidence score* 0. Kondisi ini terutama terjadi pada citra dengan jarak pengambilan terlalu jauh, intensitas bayangan tinggi, atau objek kendaraan berposisi kecil di dalam frame, sehingga fitur karakter plat nomor tidak teridentifikasi dengan optimal.

Secara umum, hasil deteksi menunjukkan bahwa model mampu bekerja dengan baik pada citra yang memiliki kontras cukup dan ukuran objek yang proporsional terhadap resolusi input. Namun, kegagalan pada citra dengan karakteristik tertentu menunjukkan adanya batasan performa pada kondisi ekstrem, yang relevan sebagai dasar perbaikan dataset melalui augmentasi atau penambahan sampel citra berjarak jauh.

**C. Hasil Optical Character Recognition (OCR)**

Tahap *Optical Character Recognition (OCR)* dilakukan untuk mengekstraksi teks dari area plat nomor yang telah terdeteksi oleh model YOLO11n. Proses ini menggunakan EasyOCR sebagai engine pembacaan karakter, dengan input berupa citra hasil *cropping bounding box* dari model deteksi. Pengujian dilakukan terhadap sembilan citra hasil deteksi untuk menilai tingkat akurasi pembacaan teks dalam kondisi visual yang bervariasi, termasuk perbedaan sudut, pencahayaan, dan jenis kendaraan.

Tabel 3  
 Detail koordinat *bounding box* dan *confidence score* hasil deteksi YOLO11n

Nama File	Koordinat (x1,y1,x2,y2)	Confidence Score
Citra (1)	(265,376,318,404)	0,897
Citra (2)	(395,458,457,490)	0,889
Citra (3)	(149,374,193,395)	0,859
Citra (4)	(353,373,407,394)	0,850
Citra (5)	(255,267,371,306)	0,891
Citra (6)	(250,275,353,315)	0,871
Citra (6)	(198,457,272,512)	0,882
Citra (6)	(317,283,351,306)	0,857
Citra (7)	(219,291,248,310)	0,847
Citra (8)	(28,265,78,305)	0,896
Citra (9)	(242,270,290,304)	0,879



Gambar 5 Hasil pembacaan OCR pada sampel citra plat nomor kendaraan

Gambar 5 memperlihatkan hasil pembacaan OCR pada sembilan citra plat nomor yang sebelumnya telah berhasil dideteksi oleh model YOLO11n. Sistem OCR mampu mengekstraksi karakter alfanumerik secara langsung dari citra input tanpa segmentasi huruf per karakter, dan seluruh hasil pembacaan dibandingkan dengan ground truth untuk menilai kesesuaian. Secara visual, sebagian besar plat nomor berhasil dikenali dengan benar, menunjukkan bahwa kombinasi deteksi YOLO11n dan OCR berbasis EasyOCR dapat bekerja secara terpadu untuk membaca teks pada plat nomor kendaraan.

Tabel 4 menunjukkan bahwa tujuh dari sembilan citra berhasil dibaca dengan benar oleh OCR, ditandai dengan nilai CER dan WER sebesar 0. Hal ini menunjukkan bahwa sistem mampu mengenali teks plat nomor secara akurat pada kondisi citra yang jelas dan kontras tinggi. Dua citra terakhir menghasilkan kesalahan pembacaan pada karakter pertama, di mana huruf “D” terbaca sebagai “I” dan “P”. Kesalahan tersebut berdampak langsung pada nilai CER dan WER, yang meningkat menjadi 10% dan 33,33%.

Kesalahan pembacaan ini terutama dipengaruhi oleh faktor visual seperti kontras rendah, pantulan cahaya, dan bentuk karakter yang serupa secara morfologis. Namun demikian, performa keseluruhan tetap berada pada tingkat yang sangat baik, dengan akurasi 77,7% pada tingkat kata dan 93,7% pada tingkat karakter. Hasil ini menunjukkan bahwa OCR mampu bekerja secara efektif ketika kualitas citra memungkinkan karakter terbaca dengan jelas, tetapi masih sensitif terhadap kondisi pencahayaan dan distorsi lokal pada area plat nomor.

Meskipun hasil OCR menunjukkan performa yang baik, evaluasi pada penelitian ini masih terbatas pada sembilan sampel citra hasil deteksi. Jumlah tersebut belum sepenuhnya merepresentasikan variasi kondisi lapangan secara menyeluruh, sehingga diperlukan pengujian dengan dataset yang lebih besar dan kondisi pencahayaan yang lebih beragam untuk memperoleh evaluasi performa yang lebih komprehensif.

Tabel 4

Hasil Pembacaan OCR pada Beberapa Sampel Citra Plat Nomor

Citra	Ground Truth	Hasil OCR	CER	WER
Citra 1	DB 71 SOO	DB 71 SOO	0	0
Citra 2	DB 5516 MJ	DB 5516 MJ	0	0
Citra 3	DB 1381 VB	DB 1381 VB	0	0
Citra 4	DB 1527 RH	DB 1527 RH	0	0
Citra 5	DB 1038 RL	DB 1038 RL	0	0
Citra 6	DB 1485 FD	DB 1485 FD	0	0
Citra 7	DB 1976 GC	DB 1976 GC	0	0
Citra 8	DB 1925 LO	IB 1925 LO	10%	33,33%
Citra 9	DB 1173 LA	PB 1173 LA	10%	33,33%



Gambar 6 Hasil Deteksi Kendaraan dan Pembacaan Plat Nomor pada Video 1

#### D.Hasil Pengujian Deteksi Video

Pengujian deteksi video dilakukan untuk mengevaluasi kemampuan sistem dalam mendeteksi dan menghitung kendaraan secara otomatis berdasarkan keberadaan plat nomor. Pengujian dilaksanakan pada 27 Mei 2025 menggunakan rekaman berdurasi tiga jam (08.00 -11.00 WITA) di Gerbang Barat Fakultas Perikanan dan Ilmu Kelautan (FPIK) Universitas Sam Ratulangi. Rentang waktu tersebut dipilih karena merepresentasikan kondisi lalu lintas padat pada jam kerja dan perkuliahan. Berdasarkan penghitungan manual, total kendaraan yang melintas selama periode pengamatan mencapai 2.866 unit.

Dari sisi pencahayaan, rentang waktu pagi dinilai sesuai untuk sistem berbasis visi komputer karena intensitas cahaya cukup terang untuk menampilkan detail plat nomor tanpa pantulan berlebih. Kondisi ini menghasilkan kontras citra yang stabil dan meminimalkan risiko overexposure atau refleksi kuat yang dapat mengganggu identifikasi fitur oleh model YOLO11n.

Untuk mendukung proses penghitungan kendaraan, sistem menerapkan dua garis virtual sebagai area pengamatan lintasan. Mekanisme ini bertujuan meningkatkan peluang deteksi apabila plat nomor gagal teridentifikasi pada salah satu titik akibat kecepatan kendaraan atau gangguan pencahayaan dapat menyebabkan plat nomor tidak terdeteksi pada beberapa frame. Dengan dua garis penghitungan pada posisi berbeda, peluang kendaraan terdeteksi dapat ditingkatkan sehingga mengurangi kemungkinan kendaraan terlewat.



Gambar 7 Hasil Deteksi Kendaraan dan Pembacaan Plat Nomor pada Video 2



Gambar 8 Hasil Deteksi Kendaraan dan Pembacaan Plat Nomor pada Video 3

Gambar 6 memperlihatkan kondisi awal area pengawasan beserta dua garis penghitungan (Line 1 dan Line 2) yang digunakan sebagai acuan perhitungan kendaraan. Pada frame awal, sistem belum mendeteksi plat nomor sehingga penghitung kendaraan masih bernilai nol (sudut kanan atas). Visual ini menunjukkan tahap inialisasi sistem, di mana kamera, area jalan, serta posisi garis ditetapkan sebelum kendaraan memasuki zona deteksi dan proses penghitungan dimulai.

Gambar 7 menunjukkan kondisi ketika kendaraan mulai mendekati Line 1 dan area plat nomor telah berhasil dikenali oleh model. *Bounding box* berwarna oranye menandakan objek telah terdeteksi namun belum melewati garis penghitungan, sehingga sistem belum menambah jumlah kendaraan. Tahap ini berfungsi sebagai validasi awal lintasan kendaraan untuk memastikan proses penghitungan dilakukan secara akurat dan tidak terjadi kesalahan pencatatan.

Gambar 8 menampilkan frame di mana kendaraan telah melewati garis penghitungan dan status deteksi berubah menjadi terhitung (*bounding box* berwarna hijau), sehingga penghitung kendaraan otomatis bertambah. Setelah plat nomor terhitung pada saat melewati garis penghitungan pertama, sistem memberikan status terhitung pada kendaraan tersebut sehingga pada saat kendaraan melewati garis penghitungan kedua, plat nomor yang sama tidak akan dihitung kembali. Mekanisme ini diterapkan untuk mencegah terjadinya penghitungan ganda pada kendaraan yang sama. Gambar ini menggambarkan integrasi antara hasil deteksi objek dan logika penambahan hitungan berdasarkan lintasan kendaraan.

Dari total 2.866 kendaraan yang tercatat secara manual, sistem berhasil mendeteksi 1.757 kendaraan berdasarkan keberhasilan pembacaan plat nomor. Selisih jumlah ini disebabkan oleh beberapa faktor, antara lain kendaraan tanpa plat nomor, penggunaan pelindung plat, ukuran plat terlalu kecil relatif terhadap jarak kamera, orientasi miring terhadap sumbu pandang, serta pantulan cahaya tinggi pada permukaan plat. Faktor-faktor tersebut menyebabkan sebagian area plat tidak terbaca dengan jelas oleh model.

Secara umum, sistem menunjukkan performa yang baik pada kondisi pencahayaan pagi dengan keberhasilan menghitung kendaraan yang melintas. Hasil ini menunjukkan bahwa algoritma YOLO11n dapat diimplementasikan untuk pemantauan lalu lintas otomatis di lingkungan kampus. Namun, peningkatan akurasi masih dimungkinkan melalui optimasi posisi kamera, penambahan variasi data pelatihan untuk kondisi refleksi tinggi, serta pengaturan parameter pencahayaan (*exposure*) kamera untuk menjaga kestabilan deteksi pada berbagai kondisi cahaya.

#### IV. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengimplementasikan sistem deteksi dan pembacaan plat nomor kendaraan berbasis YOLO11n dan EasyOCR. Model deteksi menunjukkan performa tinggi dengan precision 97%, recall 98,4%, F1-score 97,7%, dan mAP@0.5 sebesar 99%. Integrasi dengan OCR memungkinkan pembacaan karakter secara akurat pada sebagian besar sampel uji, meskipun masih ditemukan kesalahan pada kondisi kontras rendah dan pantulan cahaya tinggi.

Pengujian video menunjukkan sistem mampu mendeteksi 1.757 dari 2.866 kendaraan dalam kondisi lalu lintas nyata. Hasil ini menunjukkan bahwa sistem memiliki potensi untuk diterapkan pada pemantauan kendaraan otomatis di lingkungan kampus, dengan tetap memerlukan peningkatan pada aspek generalisasi data, optimasi posisi kamera, dan pengujian pada kondisi pencahayaan yang lebih beragam.

Selain aspek teknis, penerapan sistem ALPR perlu mempertimbangkan aspek privasi dan perlindungan data kendaraan. Data plat nomor yang terekam berpotensi dikategorikan sebagai informasi identitas yang sensitif apabila dikaitkan dengan pemilik kendaraan. Oleh karena itu, implementasi sistem harus disertai kebijakan pengelolaan data yang jelas, pembatasan akses, serta penggunaan data hanya untuk tujuan operasional yang sah sesuai dengan regulasi perlindungan data yang berlaku.

#### V. KUTIPAN

- [1] C. O. Y. Afita, "Penegakan hukum terhadap tindak pidana pemalsuan tanda nomor kendaraan bermotor (TNKB)," *DATIN LAW JURNAL*, vol. 2, no. 1, pp. 57–65, 2021.
- [2] E. P. Silmina and R. A. Y. Arjun, "Pemanfaatan Model YOLOv8 Untuk Mendeteksi Plat Nomor Kendaraan Mobil Pada Gerbang Masuk Universitas XYZ," *Jurnal Sains dan Informatika*, vol. 11, no. 1, pp. 50–59, 2025.
- [3] M. D. Putro, D. -L. Nguyen and K. -H. Jo, "A Fast CPU Real-Time Facial Expression Detector Using Sequential Attention Network for Human-Robot Interaction," in *IEEE Transactions on Industrial Informatics*, vol. 18, no. 11, pp. 7665-7674, Nov. 2022
- [4] N. Jegham, C. Y. Koh, M. Abdelatti, and A. Hendawi, "Evaluating the evolution of YOLO (You Only Look Once) models: A comprehensive benchmark study of YOLO11 and its predecessors," *arXiv preprint arXiv:2411*, 2024.
- [5] A. Sharma, V. Kumar, and L. Longchamps, "Comparative performance of YOLOv8, YOLOv9, YOLOv10, YOLOv11 and Faster R-CNN models for detection of multiple weed species," *Smart Agricultural Technology*, vol. 9, p. 100648, 2024.
- [6] S. Drobac and K. Lindén, "Optical character recognition with neural networks and post-correction with finite state methods," *International Journal on Document Analysis and Recognition (IJDAR)*, vol. 23, no. 4, pp. 279–295, 2020.
- [7] S. A. Francis and M. Sangeetha, "A comparison study on optical character recognition models in mathematical equations and in any language," *Results in Control and Optimization*, vol. 18, p. 100532, 2025.
- [8] J. Bai, W. Zhu, Z. Nie, X. Yang, Q. Xu, and D. Li, "HFC-YOLO11: A Lightweight Model for the Accurate Recognition of Tiny Remote Sensing Targets," *Computers*, vol. 14, no. 5, p. 195, 2025.
- [9] M. Safran, A. Alajmi, and S. Alfarhood, "Efficient multistage license plate detection and recognition using YOLOv8 and CNN for smart parking systems," *Journal of Sensors*, vol. 2024, p. 4917097, 2024.

- [10] M. I. Wiawan, S. N. S. Nur, and W. S. G. Gumelar, "Prototipe Sistem Deteksi Dan Pengenalan Plat Nomor Sepeda Motor Di Indonesia Menggunakan YOLOv4," *Abditek Nusantara*, vol. 5, no. 2, pp. 42–52, 2023.
- [11] M. D. Putro, D.-L. Nguyen, and K.-H. Jo, "Lightweight Convolutional Neural Network for Real-Time Face Detector on CPU Supporting Interaction of Service Robot," International Conference on Human System Interaction (HSI), Tokyo, Japan, 2020.
- [12] X. Ji et al., "Ecological monitoring of invasive species through deep learning-based object detection," *Ecological Indicators*, vol. 175, p. 113572, 2025.
- [13] J. Vempati, "Real-time detection and recognition of license plate using YOLO11 object detection model," Ph.D. dissertation, Kansas State University, 2024.
- [14] S. Yang et al., "Fuzzy EfficientDet: An approach for precise detection of larch infestation severity in UAV imagery under dynamic environmental conditions," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 17, pp. 8810–8822, 2024.
- [15] J. Shen, Z. Zhang, J. Luo, and X. Zhang, "YOLOv5-TS: Detecting traffic signs in real-time," *Frontiers in Physics*, vol. 11, p. 1297828, 2023.
- [16] A. Ignasius, J. C. Chandra, R. Oscadinata, and D. Suhartono, "Image Pre-Processing Effect on OCR's Performance for Image Conversion to Braille Unicode," *Procedia Computer Science*, vol. 227, pp. 922–931, 2023.
- [17] U. Poudel et al., "Applicability of OCR engines for text recognition in vehicle number plates, receipts and handwriting," *Journal of Circuits, Systems and Computers*, vol. 32, no. 18, p. 2350321, 2023.

#### TENTANG PENULIS



**Samuel Meinus Untu** lahir di Wioi, Sulawesi Utara pada tanggal 07 Mei 2001. Penulis mengawali pendidikan formal di Taman Kanak-kanak GMIM Monika Wioi pada tahun 2006 hingga 2007. Pada jenjang sekolah dasar, penulis menempuh pendidikan di SD GMIM Wioi pada tahun 2007 hingga 2015. Pendidikan tingkat menengah pertama ditempuh di SMP Negeri 3 Ratahan pada periode 2015 hingga 2018. Selanjutnya, penulis melanjutkan pendidikan menengah atas di SMAS Kristen 1 Tomohon dari tahun 2018 hingga 2021. Pada tahun 2021, penulis melanjutkan studi Strata-1 di Universitas Sam Ratulangi pada Program Studi Teknik Informatika, Jurusan Elektro, Fakultas Teknik. Selama masa perkuliahan, penulis pernah mengikuti program Kampus Merdeka melalui Pertukaran Mahasiswa Merdeka (PMM) batch 3 di Institut Teknologi Malang sebagai bagian dari pengembangan wawasan akademik dan perluasan pengalaman belajar di lingkungan akademik yang berbeda.