Perbandingan YOLOv11m dan YOLOv12m pada Deteksi Plat Nomor Indonesia dan Pengaruhnya terhadap EasyOCR

Comparison of YOLOv11m and YOLOv12m for Indonesian License Plate Detection and Their Impact on EasyOCR

Arief Setiawan[1*], Ernawati[2], Funny Farady Coastera[3]
Program Studi Informatika, Jurusan Informatika, Fakultas Teknik, Universitas Bengkulu
Jl. W.R. Supratman, Kandang Limun, Bengkulu, Indonesia
[1]ariefstw5@gmail.com
[2]ernawati@unib.ac.id
[3]ffaradyc@unib.ac.id

[*]Corresponding Author: ariefstw5@gmail.com

Riwayat Artikel
Naskah diterima: 18/08/2026 | Naskah direvisi: 21/09/2026 | Naskah diterbitkan: 31/10/2026

Creative Commons License 4.0 (CC BY –NC)

Abstract* — *Automatic License Plate Recognition (ALPR) is widely used in Intelligent Transportation Systems (ITS). This study compares the You Only Look Once (YOLO) models YOLOv11m and YOLOv12m for Indonesian vehicle license plate detection and examines how the detection results affect character recognition with EasyOCR as the Optical Character Recognition (OCR) engine. The dataset contains 2,819 vehicle images, consisting of 2,243 training images, 353 validation images, and 223 test images, obtained from Roboflow. Both models were trained for 50 epochs on an NVIDIA Tesla T4 graphics processing unit (GPU) using the same configuration. On the validation set, both models produced nearly identical mean Average Precision (mAP@0.5) values, namely 0.9782 for YOLOv11m and 0.9783 for YOLOv12m. YOLOv11m achieved higher recall (0.9554), a slightly higher test F1-Score (0.9540), and lower validation inference time (24.58 ms). YOLOv12m achieved higher precision (0.9483) and mAP@0.5:0.95 (0.6748). In the OCR evaluation, YOLOv11m detected all 31 test plates and obtained a fuzzy matching score of 0.6632 with a Character Error Rate (CER) of 0.3368. YOLOv12m detected 29 of 31 plates, with a fuzzy score of 0.6139 and CER of 0.3861. The preprocessing sequence used in this study reduced OCR performance for both models compared with the original red, green, and blue (RGB) crops. Based on these results, YOLOv11m provided the better overall balance between detection recall, OCR performance, and inference time in the tested configuration.

***Keywords*— ALPR, EasyOCR, Indonesian License Plate Characteristics, License Plate Detection, YOLOv11m, YOLOv12m.**

Intisari — *Automatic License Plate Recognition* (ALPR) digunakan pada berbagai sistem transportasi cerdas atau *Intelligent Transportation Systems* (ITS). Penelitian ini membandingkan model *You Only Look Once (YOLO), yaitu YOLOv11m* dan *YOLOv12m* untuk deteksi plat nomor kendaraan Indonesia serta melihat pengaruh hasil deteksinya terhadap pengenalan karakter menggunakan *EasyOCR* sebagai sistem *Optical Character Recognition* (OCR). Dataset yang digunakan berjumlah 2.819 citra kendaraan, terdiri dari 2.243 data latih, 353 data validasi, dan 223 data uji yang diperoleh dari *Roboflow*. Kedua model dilatih selama 50 epoch pada unit pemrosesan grafis (GPU) NVIDIA Tesla T4 dengan konfigurasi yang sama. Pada data validasi, nilai *mean Average Precision (mAP@0.5)* kedua model hampir sama, yaitu 0,9782 pada *YOLOv11m* dan 0,9783 pada *YOLOv12m*. *YOLOv11m* memperoleh recall lebih tinggi (0,9554), *F1-Score* data uji sedikit lebih tinggi (0,9540), dan waktu inferensi validasi lebih rendah (24,58 ms). *YOLOv12m* memperoleh precision lebih tinggi (0,9483) dan *mAP@0.5:0.95* sebesar 0,6748. Pada pengujian OCR, *YOLOv11m* mendeteksi seluruh 31 citra dan menghasilkan skor *fuzzy matching* 0,6632 dengan *Character Error Rate* (*CER*) 0,3368. *YOLOv12m* mendeteksi 29 dari 31 citra, dengan skor fuzzy 0,6139 dan *CER* 0,3861. Rangkaian prapemrosesan yang digunakan pada penelitian ini menurunkan kinerja OCR pada kedua model dibandingkan citra asli dengan kanal merah, hijau, dan biru (RGB). Berdasarkan hasil tersebut, *YOLOv11m* memberikan keseimbangan yang lebih baik antara recall deteksi, hasil OCR, dan waktu inferensi pada konfigurasi pengujian ini.

Kata Kunci—ALPR, Deteksi Plat Nomor, EasyOCR, Karakteristik Plat Indonesia, YOLOv11m, YOLOv12m.

I. PENDAHULUAN

Perkembangan kecerdasan buatan dan visi komputer (*computer vision*) mendorong penggunaan sistem transportasi cerdas atau *Intelligent Transportation Systems* (ITS) di berbagai negara [1]. Salah satu penerapannya adalah *Automatic License Plate Recognition* (ALPR), yaitu sistem yang digunakan untuk melokalisasi dan mengenali plat nomor kendaraan dari citra [2]. Di Indonesia, ALPR dapat digunakan untuk mendukung sistem parkir otomatis, *Electronic Traffic Law Enforcement* (ETLE), pemantauan lalu lintas, dan sistem keamanan pada gerbang tol [3], [4].

Penerapan ALPR pada kondisi nyata di Indonesia tetap menghadapi beberapa kendala visual. Tanda Nomor Kendaraan Bermotor (TNKB) memiliki susunan dua baris. Baris pertama memuat kode wilayah, nomor registrasi, dan kode sub-wilayah, sedangkan baris kedua memuat bulan dan tahun masa berlaku [1], [2]. Selain itu, kondisi plat di lapangan cukup beragam, baik dari sisi bentuk huruf, jarak antarkarakter, goresan atau karat, sudut pengambilan gambar, maupun pencahayaan [5], [6]. Variasi tersebut dapat memengaruhi hasil deteksi dan pembacaan karakter.

Sistem ALPR umumnya terdiri dari dua tahap utama, yaitu deteksi lokasi plat nomor sebagai *Region of Interest* (ROI) dan pengenalan karakter pada ROI menggunakan *Optical Character Recognition* (OCR) [1], [7]. Pada tahap deteksi, keluarga *You Only Look Once* (YOLO) banyak digunakan karena melakukan lokalisasi dan klasifikasi objek dalam satu proses inferensi serta memiliki keseimbangan yang baik antara akurasi dan kecepatan [8], [9].

Sejumlah penelitian sebelumnya telah menggunakan YOLO pada sistem ALPR. Suharto et al. [1] membandingkan *YOLOv10n* dan *YOLOv11n* untuk deteksi plat nomor Indonesia yang dilanjutkan dengan *EasyOCR*. Hasilnya menunjukkan bahwa perbedaan hasil deteksi ikut memengaruhi hasil OCR. Martadinata et al. [2] menggunakan *YOLOv11* pada sistem parkir kampus dan memperoleh *mAP@0.5* sebesar 94,2%. Kurniawan dan Sari [3] menerapkan *YOLOv11* untuk deteksi *real-time*, sedangkan Salsabila dan Sriani [4] serta Syihabuddin et al. [6] menggunakan *YOLOv8* dengan mesin OCR. Sutikno et al. [7] juga menggunakan *YOLOv11* dan *CLAHE* pada proses pengolahan citra plat nomor.

Sebagian penelitian tersebut menggunakan varian ringan atau hanya mengevaluasi satu model [1], [2], [10]. Varian *nano* ditujukan untuk perangkat dengan sumber daya terbatas, sedangkan varian *medium* memiliki jumlah parameter dan kapasitas model yang lebih besar. *YOLOv11m* dan *YOLOv12m* sama-sama berada pada kelompok *medium* dengan jumlah parameter sekitar 20 juta, sehingga keduanya dapat dibandingkan pada skala model yang relatif setara [8], [11].

YOLOv11m menggunakan blok C3k2 dan SPPF pada arsitekturnya, sedangkan *YOLOv12m* menambahkan mekanisme *Area Attention* [8], [12], [13]. Perbedaan arsitektur tersebut dapat menghasilkan karakteristik deteksi yang berbeda. Penelitian yang secara khusus membandingkan *YOLOv11m* dan *YOLOv12m* pada plat nomor kendaraan Indonesia, kemudian menilai pengaruh hasil deteksi terhadap *EasyOCR*, masih terbatas [1], [14].

Jika dilihat lebih lanjut, penelitian ALPR berbasis deep learning banyak menggunakan keluarga YOLO sebagai detektor plat nomor. Suharto et al. [1] membandingkan YOLOv10n dan YOLOv11n untuk plat nomor kendaraan Indonesia dan menggunakan EasyOCR pada tahap pengenalan karakter. YOLOv11n memperoleh precision, recall, dan mAP@0.5 yang lebih tinggi daripada YOLOv10n. Penelitian tersebut juga menunjukkan bahwa hasil deteksi berpengaruh pada tahap OCR. Akan tetapi, model yang digunakan masih varian nano. Penelitian ini menggunakan varian medium untuk melihat apakah pola hasilnya tetap sama ketika kapasitas model yang digunakan lebih besar.

Martadinata et al. [2] menggunakan *YOLOv11* dan *EasyOCR* untuk deteksi dan identifikasi plat nomor pada lingkungan kampus. Nilai *mAP@0.5* yang dilaporkan sebesar 94,2%. Penelitian tersebut menunjukkan bahwa *YOLOv11* dapat digunakan pada sistem ALPR, tetapi hanya satu konfigurasi model yang diuji. Kurniawan dan Sari [3] juga menggunakan *YOLOv11* untuk deteksi plat nomor *real-time*. Fokus utama penelitian tersebut berada pada kemampuan deteksi, sehingga perbandingan hasil OCR antar-model tidak menjadi bagian utama analisis.

Penelitian lain masih banyak menggunakan *YOLOv8*. Salsabila dan Sriani [4] menggabungkan *YOLOv8* dengan *EasyOCR*, sedangkan Syihabuddin et al. [6] menggunakan *YOLOv8* dan *PaddleOCR*. Meesad dan Thumthong [5] menguji metode *deep learning* untuk ALPR pada kondisi visual yang beragam, tetapi data yang digunakan tidak khusus untuk plat nomor Indonesia. Dari beberapa penelitian tersebut terlihat bahwa kualitas deteksi tetap berpengaruh pada tahap berikutnya karena OCR bekerja pada area plat yang dihasilkan detektor.

Prapemrosesan citra juga tidak selalu memberikan hasil yang sama pada setiap penelitian. Sutikno et al. [7] menggunakan *YOLOv11* dan *Contrast Limited Adaptive Histogram Equalization* (*CLAHE*) sebagai bagian dari pengolahan citra. Pada penelitian ini, efek prapemrosesan tidak diasumsikan sejak awal. ROI hasil deteksi diuji dalam kondisi *original* dan *preprocessed* agar pengaruh rangkaian prapemrosesan terhadap *EasyOCR* dapat dilihat langsung dari hasil pengujian.

Dari beberapa penelitian tersebut, penelitian ini difokuskan pada dua hal. Pertama, *YOLOv11m* dan *YOLOv12m* dibandingkan pada domain plat nomor kendaraan Indonesia dengan ukuran model yang sama-sama berada pada varian *medium*. Kedua, perbandingan tidak berhenti pada metrik deteksi. Hasil deteksi dari kedua model juga digunakan sebagai masukan *EasyOCR*, kemudian dibandingkan menggunakan *detection rate*, *fuzzy matching*, *exact match*, dan *Character Error Rate* (*CER*). Dengan cara ini, perbedaan pada tahap deteksi dapat dilihat sampai pengaruhnya terhadap pembacaan karakter.

Penelitian ini bertujuan untuk: (1) membandingkan kinerja deteksi *YOLOv11m* dan *YOLOv12m* menggunakan *Precision*, *Recall*, *F1-Score*, *mAP@0.5*, *mAP@0.5:0.95*, dan waktu inferensi; (2) membandingkan hasil *EasyOCR* pada

JUTEI Edisi Volume. 10 No.2 Oktober 2026
ISSN 2579-3675, e-ISSN 2579-5538
DOI 10.21460/jutei.2026.102.530

ROI *original* dan *preprocessed* yang dihasilkan kedua model; serta (3) menentukan model yang memberikan keseimbangan kinerja lebih baik pada konfigurasi pengujian yang digunakan.

II. LANDASAN TEORI

A. *Arsitektur YOLOv11m dan YOLOv12m*

You Only Look Once (YOLO) merupakan kerangka deteksi objek *single-stage* yang memetakan piksel citra masukan langsung ke koordinat *bounding box* dan probabilitas kelas dalam satu kali propagasi maju [13], [15]. Versi YOLOv11m memperkenalkan perbaikan struktural pada *backbone* dan *neck* dengan memanfaatkan blok C3k2 (*Cross Stage Partial with kernel variation*) yang dipadukan dengan *Spatial Pyramid Pooling Fast* (SPPF) untuk menangkap fitur multi-skala secara efisien [9], [16]. Di sisi lain, YOLOv12m menyematkan mekanisme *Area Attention* yang memungkinkan model memusatkan perhatian pada dependensi spasial global dan fitur kontekstual objek kecil tanpa menimbulkan beban komputasi kuadratik seperti pada *vision transformer* konvensional [8], [17], [18].

B. *Automatic License Plate Recognition (ALPR)*

Sistem ALPR secara umum beroperasi melalui *pipeline* bertahap yang mencakup akuisisi citra, pelokalisasian plat nomor kendaraan, ekstraksi *Region of Interest* (ROI), prapemrosesan citra, segmentasi karakter, dan pengenalan karakter [1], [5]. Kualitas *bounding box* dari tahap deteksi menentukan resolusi dan keutuhan area ROI yang akan diproses oleh tahap pengenalan karakter.

C. *Karakteristik Plat Nomor Kendaraan Indonesia*

Plat nomor kendaraan bermotor di Indonesia (TNKB) memiliki struktur alfanumerik dua baris standar kepolisian [1]. Baris atas memuat tiga elemen informasi: kode wilayah registrasi (1–2 huruf), nomor polisi (1–4 angka), dan seri wilayah (1–3 huruf). Baris bawah memuat masa berlaku (2 digit bulan dan 2 digit tahun). Warna dasar plat bervariasi antara hitam/putih (pribadi), kuning (umum), merah (pemerintah), dan aksen biru (kendaraan listrik).

D. *Optical Character Recognition (EasyOCR)*

EasyOCR adalah pustaka pengenalan karakter berbasis *deep learning* yang mengintegrasikan arsitektur *Character Region Awareness for Text Detection* (CRAFT) sebagai detektor teks dan model *Convolutional Recurrent Neural Network* (CRNN) dengan dekoder *Connectionist Temporal Classification* (CTC) sebagai pengenal teks [1], [19], [20]. CRAFT mendeteksi probabilitas wilayah karakter (*region score*) dan keterkaitan antar karakter (*affinity score*) secara efektif pada citra natural.

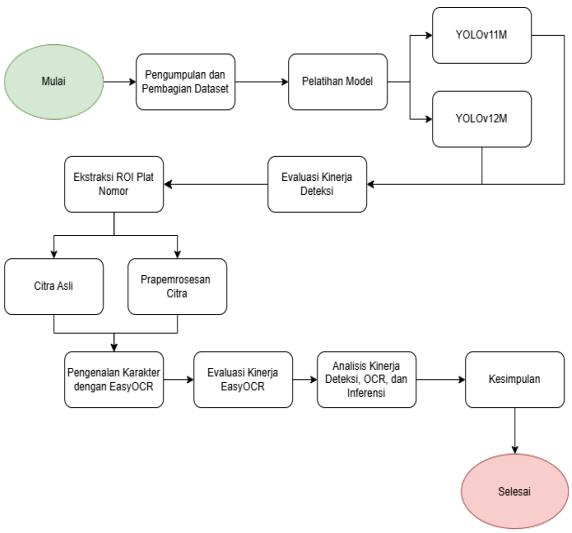
E. *Metrik Evaluasi Kinerja*

Evaluasi deteksi plat nomor diukur menggunakan *True Positive* (TP), *False Positive* (FP), *False Negative* (FN), *Precision* (P), *Recall* (R), *F1-Score*, *mean Average Precision* (mAP@0.5 dan mAP@0.5:0.95), serta waktu inferensi (ms) [8], [21]. Pada tahap OCR, evaluasi diukur menggunakan *Detection Rate* (proporsi citra dengan plat yang berhasil terdeteksi), *Fuzzy Matching Similarity* (derajat kemiripan *string*), *Exact Match Accuracy* (kesesuaian 100% karakter), dan *Character Error Rate* (CER) berbasis *Levenshtein Distance* [1], [22].

III. METODOLOGI PENELITIAN

A. *Alur Penelitian*

Penelitian ini dilakukan melalui serangkaian tahapan yang disusun untuk membandingkan kinerja YOLOv11m dan YOLOv12m dalam mendeteksi plat nomor kendaraan Indonesia serta mengevaluasi pengaruh hasil deteksi terhadap proses pengenalan karakter menggunakan EasyOCR. Tahapan penelitian dimulai dari pengumpulan dan pembagian data menjadi data latih, validasi, dan uji, kemudian dilanjutkan dengan proses pelatihan kedua model menggunakan konfigurasi yang sama agar hasil perbandingan dapat dilakukan secara konsisten. Setelah proses pelatihan, masing-masing model dievaluasi berdasarkan kinerja deteksi plat nomor sebelum hasil deteksi digunakan untuk mengekstraksi area *Region of Interest* (ROI). Area ROI tersebut selanjutnya diuji dalam dua kondisi, yaitu citra asli dan citra yang telah melalui tahap prapemrosesan, sebelum dilakukan pengenalan karakter menggunakan EasyOCR. Hasil dari setiap tahap kemudian digunakan sebagai dasar untuk membandingkan kinerja deteksi, OCR, dan waktu inferensi kedua model. Alur penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar. 1. Diagram alur desain penelitian

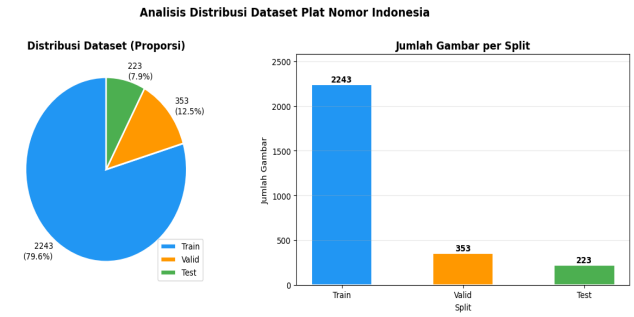
Berdasarkan Gambar 1, penelitian diawali dengan pengumpulan data yang kemudian dibagi menjadi data latih, validasi, dan uji. Data latih digunakan untuk melatih YOLOv11m dan YOLOv12m dengan konfigurasi pelatihan yang sama. Selanjutnya, kinerja kedua model dievaluasi untuk mengetahui kemampuan masing-masing model dalam mendeteksi plat nomor. Area plat nomor hasil deteksi kemudian diekstraksi sebagai *Region of Interest* (ROI) dan diuji dalam dua kondisi, yaitu citra asli dan citra yang telah melalui prapemrosesan. Kedua kondisi citra tersebut digunakan sebagai masukan pada proses pengenalan karakter menggunakan EasyOCR. Hasil evaluasi deteksi dan OCR selanjutnya dianalisis bersama dengan waktu inferensi untuk

membandingkan kinerja kedua model dan menentukan model dengan keseimbangan kinerja yang lebih baik.

B. Pengumpulan dan Pembagian Dataset

Dataset yang digunakan untuk pelatihan dan evaluasi model deteksi diperoleh dari proyek *Indonesia License Plate Detection* pada Roboflow Universe versi 1 dengan lisensi CC BY 4.0 [23]. *Dataset* tersebut terdiri dari 2.819 citra kendaraan dengan variasi kondisi pengambilan gambar, seperti sudut pandang, jarak objek, latar belakang, dan pencahayaan. Berdasarkan konfigurasi anotasinya, *dataset* memiliki satu kelas objek, yaitu plat nomor kendaraan (license-plate). Jenis kendaraan yang terdapat pada citra tidak digunakan sebagai kelas anotasi maupun target prediksi. Dengan demikian, pengelompokan mobil pribadi, sepeda motor, bus, dan truk tidak menjadi bagian dari skema kelas penelitian karena model difokuskan pada deteksi lokasi plat nomor kendaraan.

Dataset telah tersusun menjadi tiga subset, yaitu 2.243 citra data latih (79,6%), 353 citra data validasi (12,5%), dan 223 citra data uji (7,9%). Data latih digunakan untuk melatih YOLOv11m dan YOLOv12m, sedangkan data validasi digunakan untuk mengevaluasi kinerja model selama proses pelatihan. Data uji digunakan untuk mengukur kemampuan deteksi model pada citra yang tidak digunakan dalam pelatihan. Distribusi jumlah citra pada setiap subset ditunjukkan pada Gambar 2.



Gambar. 2. Distribusi citra pada data latih, validasi, dan uji



Gambar. 3. Contoh citra dan anotasi bounding box pada area plat nomor

Anotasi pada *dataset* menggunakan *bounding box* dalam format YOLO untuk menunjukkan lokasi plat nomor kendaraan pada citra yang memuat objek tersebut. Anotasi tersebut merepresentasikan posisi objek melalui koordinat pusat serta lebar dan tinggi kotak yang dinormalisasi terhadap ukuran citra. Informasi *bounding box* digunakan sebagai *ground truth* pada proses pelatihan dan evaluasi model sehingga model dapat mempelajari lokasi objek plat nomor pada citra. Pada tahap ini, *bounding box* merupakan anotasi lokasi objek dan bukan proses prapemrosesan citra untuk OCR. Contoh citra beserta anotasi *bounding box* pada area plat nomor ditunjukkan pada Gambar 3.

C. Konfigurasi Lingkungan dan Pelatihan Model

Eksperimen pelatihan dan evaluasi dijalankan pada lingkungan komputasi Google Colaboratory yang dilengkapi GPU NVIDIA Tesla T4 (VRAM ~15,64 GB), CUDA 12.8, PyTorch 2.10.0, dan *framework* Ultralytics YOLO 8.4.37. Kedua model (YOLOv11m dan YOLOv12m) dilatih menggunakan konfigurasi *hyperparameter* identik selama 50 *epoch* dengan resolusi masukan 640×640 piksel, ukuran batch 24, *optimizer* AdamW, *learning rate* awal (lr0) 0,002, *momentum* 0,9, bobot peluruhan (*weight decay*) 0,0005, patience *early stopping* 20 *epoch*, dan *Automatic Mixed Precision* (AMP) aktif.

Setelah pelatihan selesai, pengujian dibagi menjadi evaluasi deteksi dan evaluasi OCR. Evaluasi deteksi menggunakan data validasi dan data uji yang tidak digunakan sebagai data latih. Pada data validasi, model dibandingkan berdasarkan precision, recall, *mAP@0.5*, *mAP@0.5:0.95*, dan waktu inferensi. Data uji digunakan sebagai pengujian lanjutan dengan *confidence threshold* 0,70 dan *IoU threshold* 0,50. Pada bagian ini dicatat nilai TP, FP, FN, precision, recall, *F1-Score*, dan waktu inferensi. Pemisahan data validasi dan uji digunakan agar hasil model tidak hanya dilihat dari satu subset data.

D. Prapemrosesan Citra dan Pengujian EasyOCR

Untuk menguji pengaruh kualitas ROI terhadap kinerja EasyOCR, disiapkan *subset* evaluasi primer berisi 31 citra plat nomor kendaraan Indonesia dengan anotasi *ground truth* karakter lengkap. Area ROI hasil deteksi YOLOv11m dan YOLOv12m diekstraksi dan diuji dalam dua mode: (1) *Mode Original* (citra RGB hasil *cropping* tanpa modifikasi piksel) dan (2) *Mode Preprocessed* (rangkaian 6 operasi: *resize* 640×320, konversi *grayscale*, reduksi derau *Gaussian blur kernel* 5×5, peningkatan kontras adaptif CLAHE dengan *clip limit* 2,0 dan *grid size* 8×8, binarisasi *Otsu thresholding*, serta penipisan karakter melalui erosi morfologi *kernel* 2×2). Tahapan visual prapemrosesan diperlihatkan pada Gambar 4.

Untuk evaluasi OCR digunakan data yang berbeda karena dataset Roboflow hanya menyediakan anotasi lokasi plat dalam bentuk bounding box dan tidak menyediakan ground truth teks plat nomor untuk seluruh citra. Pengujian OCR karena itu menggunakan 31 citra primer yang telah memiliki ground truth karakter. Hasil deteksi YOLOv11m dan YOLOv12m pada setiap citra digunakan untuk menentukan Region of Interest (ROI). ROI kemudian dipotong dan diteruskan ke EasyOCR, sehingga hasil OCR tetap bergantung pada keluaran detektor yang sedang diuji.

Pada tahap ini tidak dilakukan pemilihan satu model deteksi terlebih dahulu. Hasil deteksi dari *YOLOv11m* dan *YOLOv12m* sama-sama diteruskan ke *EasyOCR*. Cara ini dipakai agar pengaruh keluaran masing-masing detektor terhadap OCR dapat dibandingkan secara langsung. Jika hanya model dengan hasil deteksi terbaik yang diteruskan ke

JUTEI Edisi Volume. 10 No.2 Oktober 2026
ISSN 2579-3675, e-ISSN 2579-5538
DOI 10.21460/jutei.2026.102.530

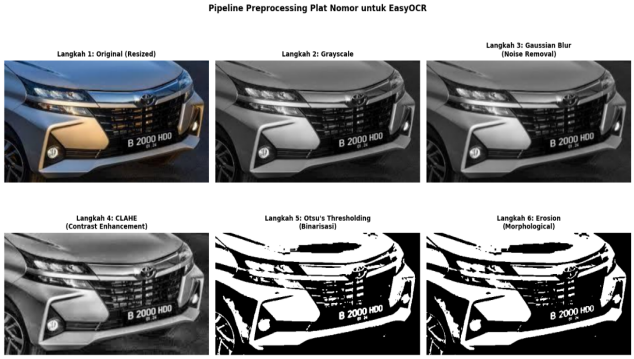
OCR, perbandingan pada tahap pengenalan karakter tidak lagi berada pada kondisi yang sama. Karena itu, setiap model mengikuti alur pengujian yang sama mulai dari deteksi, ekstraksi ROI, sampai pembacaan karakter.

Setiap ROI diuji dalam dua kondisi. Pada *mode original*, hasil *cropping* RGB langsung digunakan sebagai masukan *EasyOCR*. Pada *mode preprocessed*, ROI melalui enam tahap, yaitu *resize* 640×320 piksel, *grayscale*, *Gaussian blur*, *CLAHE*, *Otsu thresholding*, dan erosi morfologi. Perbandingan dua kondisi tersebut digunakan untuk melihat apakah rangkaian prapemrosesan yang dipakai pada penelitian ini membantu atau justru menurunkan hasil pembacaan *EasyOCR*.

Ekstraksi ROI dilakukan dengan prosedur yang sama untuk kedua model. Perbedaannya hanya berasal dari lokasi dan ukuran *bounding box* yang dihasilkan oleh masing-masing detektor. Setelah ROI diperoleh, citra diproses menggunakan parameter *EasyOCR* yang sama. Pengaturan ini digunakan untuk mengurangi perbedaan yang berasal dari proses setelah deteksi. Dengan demikian, ketika hasil OCR antara *YOLOv11m* dan *YOLOv12m* berbeda, perbedaan tersebut dapat dibaca bersama dengan karakteristik hasil deteksi yang masuk ke tahap OCR.

Hasil OCR dinilai menggunakan *detection rate*, *fuzzy matching*, *exact match accuracy*, *CER*, dan rata-rata *confidence*. Detection rate menunjukkan proporsi citra yang berhasil menghasilkan area plat untuk diproses lebih lanjut. Fuzzy matching memberikan nilai kemiripan terhadap *ground truth* ketika masih terdapat perbedaan karakter, sedangkan *exact match* hanya bernilai benar jika seluruh karakter sama. *CER* menghitung kesalahan pada tingkat karakter melalui substitusi, penghapusan, dan penyisipan. Metrik-metrik tersebut digunakan bersama karena masing-masing menggambarkan bagian yang berbeda dari hasil pembacaan OCR.

Hasil deteksi, OCR, dan waktu inferensi kemudian dibaca bersama. Nilai mAP saja tidak digunakan untuk menentukan model terbaik karena plat yang tidak terdeteksi tidak akan masuk ke tahap OCR. Karena itu, recall dan *detection rate* menjadi penting untuk melihat keberhasilan alur deteksi sampai pembacaan karakter. *Precision* dan *mAP@0.5:0.95* tetap digunakan untuk melihat ketepatan deteksi dan lokalisasi. Penilaian akhir didasarkan pada keseimbangan hasil dari ketiga aspek tersebut.



Gambar. 4. Tahapan pipeline prapemrosesan citra plat nomor

E. Formulasi Matematis Metrik Evaluasi

Kinerja deteksi dan pengenalan karakter dihitung menggunakan persamaan matematis berikut:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (1)$$

di mana *Precision* menyatakan rasio prediksi positif yang benar; TP (*True Positive*) adalah jumlah plat nomor yang terdeteksi dengan benar dan memenuhi ambang batas IoU; serta FP (*False Positive*) adalah jumlah deteksi salah (latar belakang yang keliru dideteksi sebagai plat nomor).

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

di mana *Recall* menyatakan kemampuan model mendeteksi seluruh objek plat nomor yang sebenarnya; dan FN (*False Negative*) adalah jumlah plat nomor aktual yang tidak terdeteksi (terlewat) oleh model.

$$\text{F1} - \text{Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

di mana *F1-Score* merupakan rata-rata harmonik (harmonic mean) antara *Precision* dan *Recall* untuk memberikan gambaran keseimbangan performa deteksi.

$$\text{AP} = \sum_{k=1}^{N} (R_k - R_{k-1}) \times P_{\text{interp}}(R_k) \quad (4)$$

di mana *AP* (*Average Precision*) adalah luas area di bawah kurva *Precision-Recall* yang diinterpolasi pada setiap tingkat *Recall R_k*; dan *P_interp(R_k)* adalah nilai *Precision* maksimum untuk nilai *Recall* yang lebih besar atau sama dengan *R_k*.

$$\text{mAP} = \frac{1}{C} \sum_{c=1}^{C} \text{AP}_c \quad (5)$$

di mana *mAP* (*mean Average Precision*) adalah rata-rata nilai AP pada seluruh kelas objek C (pada tugas deteksi plat nomor, *C = 1* yaitu kelas *license_plate*). mAP@0.5 dihitung pada ambang batas IoU = 0,50, sedangkan mAP@0.5:0.95 dihitung sebagai rata-rata nilai mAP pada rentang IoU 0,50 hingga 0,95 dengan kenaikan langkah (step) 0,05.

$$\text{CER} = \frac{S + D + I}{N_{\text{ground truth}}} \quad (6)$$

di mana *CER* (*Character Error Rate*) mengukur tingkat kesalahan pengenalan karakter berbasis *Levenshtein Distance*; S adalah jumlah substitusi karakter (karakter salah ganti); D adalah jumlah penghapusan karakter (karakter terlewat); I adalah jumlah penyisipan karakter (karakter tambahan yang tidak ada); serta *N_ground truth* adalah total jumlah karakter pada string teks plat nomor referensi asli.

$$\text{Fuzzy Similarity} = \frac{2 \times M}{|T_{\text{pred}}| + |T_{\text{true}}|} \quad (7)$$

di mana *Fuzzy Similarity* mengukur derajat kemiripan teks hasil prediksi OCR dengan referensi (skala 0,00 hingga 1,00); M adalah jumlah karakter yang cocok secara berurutan; serta |*T_pred*| dan |*T_true*| masing-masing merupakan panjang string teks hasil prediksi OCR dan teks *ground truth*.

IV. HASIL DAN PEMBAHASAN

A. Kompleksitas dan Efisiensi Arsitektur Model

Tabel 1 merangkum perbandingan profil komputasi dan kompleksitas arsitektur antara YOLOv11m dan YOLOv12m setelah proses fusi lapisan.

TABEL I
PERBANDINGAN KARAKTERISTIK ARSITEKTUR MODEL

Model	Lapisan *Fused*	Jumlah Parameter	GFLOPs	Ukuran Bobot
YOLOv11m	126	20.030.803	67,6	40,5 MB
YOLOv12m	169	20.105.683	67,1	40,8 MB

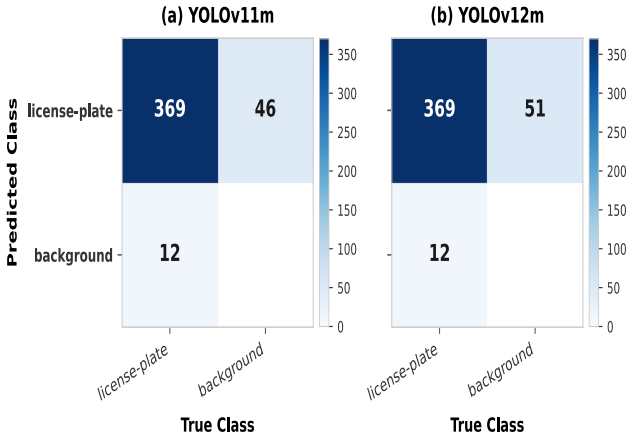
Berdasarkan Tabel 1, jumlah parameter kedua model hampir sama, yaitu sekitar 20,03 juta pada *YOLOv11m* dan 20,10 juta pada *YOLOv12m*. Kebutuhan komputasinya juga berdekatan, masing-masing 67,6 dan 67,1 GFLOPs. Perbedaan yang lebih terlihat terdapat pada jumlah lapisan. *YOLOv12m* memiliki 169 lapisan, sedangkan *YOLOv11m* memiliki 126 lapisan. Perbedaan ini berkaitan dengan penggunaan modul *Area Attention* pada *YOLOv12m*.

B. Evaluasi Kinerja Deteksi pada Data Validasi

Evaluasi kuantitatif kemampuan generalisasi deteksi plat nomor pada 353 citra data validasi disajikan pada Tabel 2 dan visualisasi *confusion matrix* ditampilkan pada Gambar 5.

TABEL II
KINERJA DETEKSI OBJEK PADA DATA VALIDASI

Model	*Precision*	*Recall*	mAP@0.5	mAP@0.5:0.95	Inferensi (ms)
YOLOv11m	0,9172	0,9554	0,9782	0,6671	24,58
YOLOv12m	0,9483	0,9160	0,9783	0,6748	26,09



Gambar. 5. Confusion matrix hasil validasi YOLOv11m dan YOLOv12m

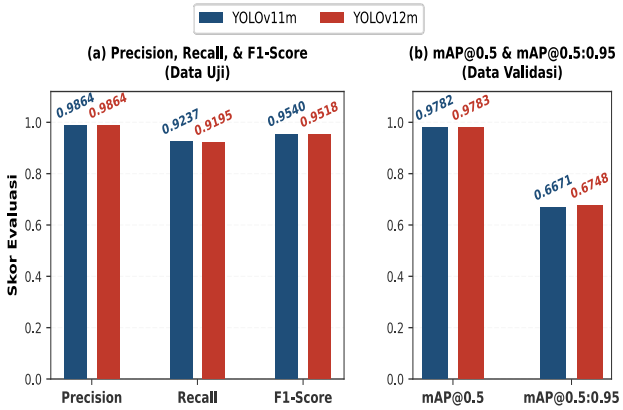
Berdasarkan Tabel 2 dan Gambar 5, nilai *mAP@0.5* kedua model hampir sama, yaitu 0,9782 pada *YOLOv11m* dan 0,9783 pada *YOLOv12m*. Perbedaannya terlihat pada precision dan recall. *YOLOv11m* memperoleh recall 0,9554 dengan waktu inferensi 24,58 ms, sedangkan *YOLOv12m* memperoleh recall 0,9160 dengan waktu inferensi 26,09 ms. Sebaliknya, precision *YOLOv12m* lebih tinggi, yaitu 0,9483 dibandingkan 0,9172 pada *YOLOv11m*. Nilai *mAP@0.5:0.95 YOLOv12m* juga sedikit lebih tinggi, yaitu 0,6748 dibandingkan 0,6671. Hasil ini menunjukkan bahwa *YOLOv11m* lebih banyak menemukan objek yang ada, sedangkan *YOLOv12m* sedikit lebih baik pada ketepatan prediksi dan lokalisasi pada ambang IoU yang lebih ketat.

C. Evaluasi Kinerja Deteksi pada Data Uji

Pengujian lebih lanjut dilakukan pada 223 citra data uji independen dengan *confidence threshold* 0,70 dan *IoU threshold* 0,50, sebagaimana terangkum pada Tabel 3 dan divisualisasikan pada Gambar 6.

TABEL III
HASIL EVALUASI KINERJA DETEKSI PADA DATA UJI

Model	TP	FP	FN	*Precision*	*Recall*	*F1-Score*	Inferensi (ms)
YOLOv11m	218	3	18	0,9864	0,9237	0,9540	32,47
YOLOv12m	217	3	19	0,9864	0,9195	0,9518	32,61



Gambar. 6. Grafik perbandingan kinerja deteksi YOLOv11m dan YOLOv12m

Pada data uji, kedua model memperoleh *Precision* 0,9864 dan masing-masing menghasilkan 3 *False Positive*. *YOLOv11m* mendeteksi 218 *True Positive* dengan *F1-Score* 0,9540, sedangkan *YOLOv12m* mendeteksi 217 *True Positive* dengan *F1-Score* 0,9518. Selisih waktu inferensi juga kecil, yaitu 32,47 ms pada *YOLOv11m* dan 32,61 ms pada *YOLOv12m*. Hasil data uji memperlihatkan pola yang sama dengan data validasi, yaitu *YOLOv11m* sedikit lebih unggul pada recall dan *F1-Score*.

Waktu inferensi pada data uji lebih tinggi daripada waktu inferensi pada data validasi untuk kedua model. Pada data validasi, waktu yang tercatat sebesar 24,58 ms untuk *YOLOv11m* dan 26,09 ms untuk *YOLOv12m*, sedangkan pada data uji nilainya menjadi 32,47 ms dan 32,61 ms. Perbedaan tersebut tidak diikuti perubahan arsitektur atau parameter model. Pengujian dijalankan pada sesi *Google Colaboratory* yang dapat memiliki kondisi *runtime* dan beban *GPU* yang berbeda. Karena kedua model tetap diuji pada lingkungan yang sama pada masing-masing tahap, angka tersebut digunakan untuk membandingkan kecepatan relatif kedua model, bukan sebagai ukuran waktu inferensi yang berlaku untuk semua perangkat.

Jika hasil validasi dan data uji dibaca bersama, nilai mAP@0.5 kedua model pada data validasi hampir sama, yaitu 0,9782 pada YOLOv11m dan 0,9783 pada YOLOv12m. Nilai tersebut menunjukkan bahwa keduanya mampu mendeteksi plat nomor dengan baik pada dataset

JUTEI Edisi Volume. 10 No.2 Oktober 2026
ISSN 2579-3675, e-ISSN 2579-5538
DOI 10.21460/jutei.2026.102.530

yang digunakan. Martadinata et al. [2] melaporkan mAP@0.5 sebesar 94,2% pada penelitian YOLOv11 dan EasyOCR. Angka dari kedua penelitian tidak dapat dibandingkan secara langsung karena dataset dan konfigurasi pengujiannya berbeda. Namun, hasil tersebut sama-sama menunjukkan bahwa keluarga YOLO dapat digunakan untuk deteksi plat nomor Indonesia.

Perbedaan kedua model lebih terlihat pada precision dan recall. *YOLOv12m* memiliki precision validasi lebih tinggi, sedangkan *YOLOv11m* memiliki recall lebih tinggi. Pada sistem ALPR, perbedaan ini penting karena plat yang tidak terdeteksi tidak dapat diteruskan ke OCR. Hal tersebut terlihat pada 31 citra primer. *YOLOv11m* mendeteksi seluruh citra, sedangkan *YOLOv12m* melewatkan dua citra. Jadi, precision dan *mAP@0.5:0.95 YOLOv12m* yang sedikit lebih tinggi belum menghasilkan hasil OCR yang lebih baik pada pengujian ini.

D. Pengaruh Kualitas Deteksi terhadap Kinerja EasyOCR

Pengujian OCR dilakukan untuk melihat pengaruh ROI yang dihasilkan masing-masing model terhadap pembacaan *EasyOCR*. Pengujian menggunakan 31 citra primer dan hasilnya dirangkum pada Tabel 4 serta Gambar 7.

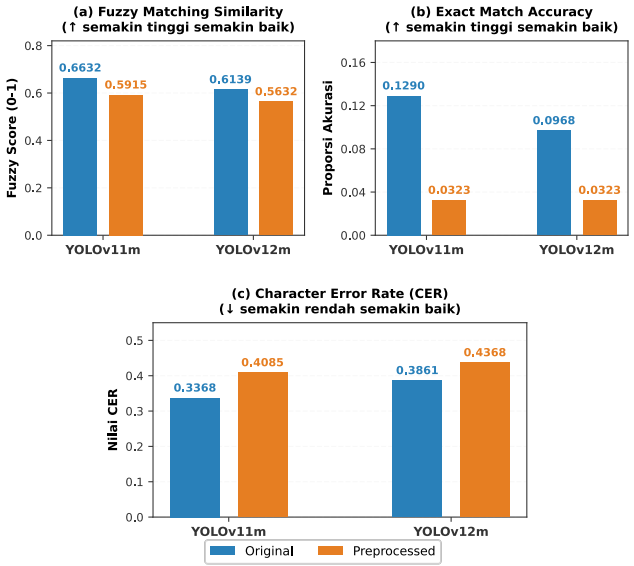
TABEL IV
KINERJA PENGENALAN KARAKTER EASYOCR (*ORIGINAL* VS *PREPROCESSED*)

Model Detektor	*Detection Rate*	Fuzzy (Ori)	Fuzzy (Pre)	Exact (Ori)	Exact (Pre)	CER (Ori)	CER (Pre)	Avg Conf
YOLOv11m	1,0000	0,6632	0,5915	0,1290	0,0323	0,3368	0,4085	0,7903
YOLOv12m	0,9355	0,6139	0,5632	0,0968	0,0323	0,3861	0,4368	0,7291

Berdasarkan Tabel 4 dan Gambar 7, *YOLOv11m* mendeteksi seluruh 31 citra uji sehingga *detection rate*-nya mencapai 100%. Pada *mode original*, model ini menghasilkan *fuzzy matching* 0,6632 dan *Character Error Rate* (*CER*) 0,3368. *YOLOv12m* mendeteksi 29 dari 31 citra atau 93,55%, dengan *fuzzy matching* 0,6139 dan *CER* 0,3861. Dua citra yang tidak terdeteksi oleh *YOLOv12m* tidak menghasilkan teks pada tahap OCR. Pada data uji ini, recall detektor ikut memengaruhi hasil akhir OCR karena objek yang tidak ditemukan tidak dapat diproses pada tahap berikutnya.

Pada hasil OCR, nilai fuzzy matching dan exact match perlu dibaca secara berbeda. Pada mode original, fuzzy score YOLOv11m sebesar 0,6632, sedangkan exact match hanya 0,1290. YOLOv12m memperoleh fuzzy score 0,6139 dan exact match 0,0968. Nilai exact match rendah karena satu kesalahan karakter sudah membuat satu sampel dinilai tidak cocok sepenuhnya. Sebaliknya, fuzzy matching masih memberikan nilai ketika sebagian besar karakter sudah sesuai. CER digunakan sebagai pelengkap untuk menunjukkan banyaknya kesalahan pada tingkat karakter.

Perbedaan kedua metrik tersebut terlihat pada beberapa hasil pembacaan yang hanya salah pada satu karakter. Sebagai contoh, karakter angka dan huruf yang bentuknya mirip dapat tertukar, seperti angka 8 yang terbaca sebagai huruf B. Pada kondisi seperti itu, *exact match* langsung bernilai salah meskipun sebagian besar karakter lain sudah sesuai. Fuzzy matching masih memberikan nilai berdasarkan kemiripan rangkaian teks. Rata-rata *confidence* deteksi pada pengujian OCR juga berbeda, yaitu 0,7903 pada *YOLOv11m* dan 0,7291 pada *YOLOv12m*. Nilai ini tidak digunakan sebagai satu-satunya ukuran keberhasilan OCR, tetapi membantu melihat bahwa ROI yang diteruskan oleh kedua model memiliki tingkat keyakinan deteksi yang berbeda.



Gambar. 7. Kinerja EasyOCR pada mode original dan preprocessed



Gambar. 8. Visualisasi kualitatif hasil deteksi dan pembacaan OCR

E. Analisis Pengaruh Prapemrosesan Citra terhadap EasyOCR

Tabel 4 juga menunjukkan bahwa rangkaian prapemrosesan yang digunakan menurunkan hasil *EasyOCR* pada kedua model. Pada *YOLOv11m*, *fuzzy matching* turun dari 0,6632 menjadi 0,5915 dan *CER* naik dari 0,3368 menjadi 0,4085. Pada *YOLOv12m*, *fuzzy matching* turun dari 0,6139 menjadi 0,5632 dan *CER* naik dari 0,3861 menjadi 0,4368. Perbandingan hasil pembacaan pada kedua kondisi ditampilkan pada Gambar 8.

Salah satu kemungkinan penyebab penurunan tersebut adalah perubahan detail karakter setelah prapemrosesan. *EasyOCR* menggunakan CRAFT pada tahap deteksi teks dan bekerja pada citra dengan informasi visual yang masih lengkap. Pada rangkaian yang diuji, *Otsu thresholding* dan erosi dapat mengurangi bagian tipis pada karakter, sedangkan perubahan ke *grayscale* dan binarisasi menghilangkan sebagian informasi warna dan gradien. Hasil pengujian menunjukkan bahwa, untuk data dan rangkaian prapemrosesan yang digunakan pada penelitian ini, ROI RGB *original* memberikan hasil OCR yang lebih baik.

Hasil ini juga menunjukkan bahwa peningkatan kualitas citra secara visual belum tentu meningkatkan hasil OCR. Setelah prapemrosesan, *fuzzy matching YOLOv11m* turun dari 0,6632 menjadi 0,5915 dan *CER* naik dari 0,3368 menjadi 0,4085. Pola yang sama terjadi pada *YOLOv12m*. Sutikno et al. [7] menggunakan *CLAHE* sebagai bagian dari peningkatan kualitas citra dan memperoleh manfaat pada konfigurasi penelitian mereka. Pada penelitian ini, *CLAHE* digunakan bersama *grayscale*, *Gaussian blur*, *Otsu thresholding*, dan erosi. Karena rangkaian operasinya berbeda, hasil akhirnya juga tidak harus sama.

Hasil tersebut hanya berlaku untuk rangkaian prapemrosesan yang diuji dalam penelitian ini. Penurunan kinerja tidak berarti bahwa seluruh bentuk prapemrosesan selalu merugikan *EasyOCR*. Enam operasi diterapkan secara berurutan, sehingga pengaruh masing-masing tahap tidak diukur secara terpisah. Karena itu, belum dapat ditentukan apakah penurunan terbesar berasal dari *grayscale*, blur, thresholding, erosi, atau kombinasi beberapa tahap. Pengujian lanjutan dapat memisahkan setiap operasi agar pengaruhnya terhadap pembacaan karakter dapat diukur satu per satu.

F. Analisis Keseimbangan (Trade-off) Akurasi, OCR, dan Waktu Inferensi

Tabel 5 menyajikan matriks evaluasi multi-kriteria untuk membandingkan keunggulan menyeluruh antara YOLOv11m dan YOLOv12m.

TABEL V
MATRIKS PERBANDINGAN KINERJA MENYELURUH

Dimensi Evaluasi	Metrik Kunci	YOLOv11m	YOLOv12m	Model Unggul
Akurasi Deteksi	mAP@0.5 (Validasi)	0,9782	0,9783	Setara
Akurasi Deteksi	*Precision* (Validasi)	0,9172	0,9483	YOLOv12m
Akurasi Deteksi	*Recall* (Validasi)	0,9554	0,9160	YOLOv11m
Akurasi Deteksi	*F1-Score* (Uji)	0,9540	0,9518	YOLOv11m
Kinerja OCR	*Detection Rate*	1,0000	0,9355	YOLOv11m
Kinerja OCR	*Fuzzy Score* (*Original*)	0,6632	0,6139	YOLOv11m
Kinerja OCR	CER (*Original*)	0,3368	0,3861	YOLOv11m
Efisiensi Waktu	Inferensi Validasi (ms)	24,58	26,09	YOLOv11m

Hasil penelitian ini sejalan dengan Suharto et al. [1] dalam hal adanya hubungan antara tahap deteksi dan hasil OCR. Perbedaannya, penelitian ini menggunakan *YOLOv11m* dan *YOLOv12m* varian *medium*, kemudian menguji ROI dari kedua model pada dua kondisi citra. Pada data yang digunakan, *YOLOv11m* memberikan hasil yang lebih seimbang karena recall dan *detection rate* lebih tinggi, *F1-Score* sedikit lebih tinggi, dan waktu inferensi sedikit lebih rendah. Selisih *mAP@0.5* kedua model sendiri sangat kecil.

G. Implikasi Praktis dan Rekomendasi Penerapan

Pada aplikasi yang lebih mementingkan agar plat nomor tidak terlewat, hasil penelitian ini lebih mendukung penggunaan *YOLOv11m*. Model tersebut memiliki recall lebih tinggi dan mendeteksi seluruh 31 citra pada pengujian OCR. Waktu inferensinya juga sedikit lebih rendah. Rekomendasi ini tetap berlaku untuk *dataset*, perangkat, dan parameter pengujian yang digunakan pada penelitian ini, sehingga pengujian tambahan tetap diperlukan sebelum diterapkan pada lingkungan yang berbeda.

YOLOv12m tetap dapat dipertimbangkan ketika sistem lebih menekankan precision dan ketelitian lokalisasi. Pada data validasi, precision *YOLOv12m* sebesar 0,9483 dan *mAP@0.5:0.95* sebesar 0,6748, sedikit lebih tinggi daripada *YOLOv11m*. Karena itu, pemilihan model perlu disesuaikan dengan kebutuhan sistem. Sistem yang lebih sensitif terhadap objek terlewat akan lebih memerlukan recall tinggi, sedangkan sistem yang lebih sensitif terhadap deteksi positif yang salah dapat lebih mempertimbangkan precision.

Pada tahap OCR, ROI *original* memberikan hasil yang lebih baik daripada ROI *preprocessed* untuk rangkaian pengujian yang digunakan. Penambahan enam tahap prapemrosesan tidak meningkatkan *fuzzy matching* maupun *CER*. Artinya, rangkaian tersebut belum memberikan manfaat pada *EasyOCR* untuk data yang diuji. Pengembangan berikutnya lebih tepat diarahkan pada peningkatan kualitas deteksi, penyesuaian mesin OCR, atau pengujian metode prapemrosesan lain yang dievaluasi secara terpisah.

Dari sisi implementasi, hasil ini juga menunjukkan bahwa alur yang lebih panjang belum tentu memberi hasil yang lebih baik. Mode *original* hanya memerlukan hasil *cropping* dari detektor sebelum diteruskan ke *EasyOCR*, sedangkan *mode preprocessed* menambahkan enam operasi citra. Pada pengujian ini, tambahan proses tersebut tidak disertai peningkatan hasil OCR. Karena itu, jika konfigurasi

JUTEI Edisi Volume. 10 No.2 Oktober 2026
ISSN 2579-3675, e-ISSN 2579-5538
DOI 10.21460/jutei.2026.102.530

yang digunakan tetap sama, *mode original* lebih sederhana untuk diterapkan. Kesimpulan ini tetap perlu diuji kembali jika mesin OCR, jenis kamera, atau karakteristik citra yang digunakan berubah.

V. KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan hasil pengujian, *YOLOv11m* dan *YOLOv12m* sama-sama mampu mendeteksi plat nomor kendaraan Indonesia dengan baik pada *dataset* yang digunakan. Pada data validasi, *mAP@0.5* keduanya hampir sama, yaitu 0,9782 pada *YOLOv11m* dan 0,9783 pada *YOLOv12m*. *YOLOv11m* memperoleh recall 0,9554, *F1-Score* data uji 0,9540, dan waktu inferensi validasi 24,58 ms. *YOLOv12m* memperoleh precision 0,9483 dan *mAP@0.5:0.95* sebesar 0,6748. Hasil tersebut menunjukkan bahwa *YOLOv11m* lebih baik dalam menemukan objek yang ada, sedangkan *YOLOv12m* sedikit lebih baik pada precision dan lokalisasi pada ambang IoU yang lebih ketat.

Perbedaan hasil deteksi juga terlihat pada pengujian OCR. Dari 31 citra primer, *YOLOv11m* mencapai *detection rate* 100% dengan *fuzzy matching* 0,6632 dan *CER* 0,3368. *YOLOv12m* mencapai *detection rate* 93,55%, *fuzzy matching* 0,6139, dan *CER* 0,3861. Pada kedua model, *mode preprocessed* menghasilkan *fuzzy matching* lebih rendah dan *CER* lebih tinggi daripada *mode original*. Dengan rangkaian prapemrosesan yang digunakan pada penelitian ini, ROI *original* memberikan hasil *EasyOCR* yang lebih baik.

Jika hasil deteksi, OCR, dan waktu inferensi dibaca bersama, *YOLOv11m* memberikan keseimbangan kinerja yang lebih baik pada konfigurasi penelitian ini. Keunggulannya terutama berada pada recall, *detection rate* pengujian OCR, *F1-Score*, dan waktu inferensi yang sedikit lebih rendah. Perbedaan *mAP@0.5* kedua model sangat kecil. Hasil ini juga menunjukkan bahwa pemilihan model ALPR perlu mempertimbangkan hasil pada tahap OCR, bukan hanya metrik deteksi.

B. Saran

Sebagai catatan untuk pengembangan berikutnya, pengujian OCR pada penelitian ini menggunakan 31 citra primer karena dataset Roboflow yang digunakan untuk deteksi tidak menyediakan ground truth teks plat nomor. Jumlah tersebut masih terbatas jika dibandingkan dengan variasi plat nomor dan kondisi pengambilan gambar di lapangan. Kondisi malam hari, hujan, kabut, motion blur, jarak kamera yang lebih jauh, dan sudut pengambilan yang lebih ekstrem belum diuji secara khusus dalam jumlah yang besar.

Eksperimen deteksi juga menggunakan satu sumber *dataset* utama dan hanya membandingkan *YOLOv11m* dengan *YOLOv12m* pada varian *medium*. Hasilnya karena itu belum dapat digunakan untuk mewakili seluruh ukuran model YOLO atau *dataset* plat nomor dengan distribusi yang berbeda. Pada tahap pengenalan karakter, penelitian ini hanya menggunakan *EasyOCR*. *PaddleOCR*, *Tesseract*, atau mesin OCR lain dapat memberikan hasil yang berbeda pada ROI yang sama.

Keterbatasan lain terdapat pada anotasi untuk evaluasi OCR. Ground truth teks pada 31 citra primer disiapkan agar hasil prediksi dapat dibandingkan pada tingkat karakter. Dataset *Roboflow* tetap digunakan untuk pelatihan dan evaluasi deteksi karena menyediakan anotasi *bounding box*, sedangkan citra primer digunakan untuk tahap yang memerlukan teks referensi. Pemisahan sumber data ini memungkinkan evaluasi OCR dilakukan, tetapi jumlah citra primer yang lebih besar tetap diperlukan agar variasi format, kondisi fisik plat, dan kondisi pengambilan gambar dapat tercakup dengan lebih baik.

Seluruh eksperimen dijalankan pada Google Colaboratory dengan GPU NVIDIA Tesla T4. Waktu inferensi yang dilaporkan menggambarkan lingkungan tersebut dan belum menunjukkan kinerja pada perangkat produksi. Pengujian pada perangkat *edge* seperti NVIDIA Jetson atau Raspberry Pi juga belum dilakukan. Karena itu, nilai waktu inferensi dalam penelitian ini digunakan terutama untuk membandingkan kedua model pada lingkungan yang sama.

Keterbatasan tersebut membatasi ruang generalisasi hasil penelitian. Pengujian berikutnya perlu menggunakan data primer OCR yang lebih besar, kondisi pengambilan gambar yang lebih beragam, mesin OCR lain, dan perangkat target yang berbeda agar hasil perbandingan dapat diuji kembali pada skenario yang lebih luas.

Penelitian selanjutnya dapat memperluas data primer OCR, terutama untuk kondisi malam hari, hujan, kabut, *motion blur*, dan variasi sudut pengambilan. Perbandingan dengan *PaddleOCR* atau *Tesseract* juga dapat dilakukan untuk melihat apakah pola hasil yang sama tetap muncul pada mesin OCR yang berbeda. Selain itu, pengujian pada perangkat *edge* seperti NVIDIA Jetson atau Raspberry Pi diperlukan untuk mengukur waktu inferensi pada perangkat yang lebih dekat dengan kondisi penerapan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Informatika, Fakultas Teknik, Universitas Bengkulu atas dukungan akademik dan fasilitas yang diberikan selama penelitian. Penulis juga mengucapkan terima kasih kepada Ernawati dan Funny Farady Coastera selaku dosen pembimbing atas bimbingan, arahan, dan masukan selama penyusunan penelitian dan artikel ini.

KONFLIK KEPENTINGAN

Para penulis menyatakan tidak ada konflik kepentingan terkait dengan publikasi artikel ini.

PENDANAAN

Penelitian ini tidak mendapatkan dukungan keuangan spesifik dari lembaga pendanaan sektor publik, komersial, atau nirlaba.

DEKLARASI PENGGUNAAN ALAT AI

Selama pelaksanaan penelitian dan penyiapan naskah, penulis menggunakan Google Gemini untuk membantu pengembangan dan peninjauan kode penelitian, serta

ChatGPT untuk membantu penyuntingan bahasa, pemeriksaan konsistensi redaksi, penyempurnaan penyajian teks, dan penyesuaian format naskah. Seluruh kode, hasil eksperimen, interpretasi hasil, dan isi naskah selanjutnya ditinjau dan diverifikasi secara mandiri oleh penulis. Penulis bertanggung jawab penuh atas keseluruhan isi publikasi.

DAFTAR PUSTAKA

[1] R. N. Suharto, M. H. Zajuli Al Faroby, and Y. Setiawan, "Comparative Evaluation of YOLO-based Models for Indonesian License Plate Detection and Recognition with EASY OCR," *Procedia Comput. Sci.*, vol. 269, pp. 943–952, 2025, doi: 10.1016/j.procs.2025.09.037.

[2] F. Martadinata, A. Firdaus, and M. R. T. Amal, "Detection and Identification of Vehicle License Plates in Indonesia Transportation System Based on Deep Learning Using YOLOv11 and Easyocr," *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 14, no. 4, pp. 573–578, 2025, doi: 10.32736/sisfokom.v14i4.2524.

[3] N. A. Kurniawan and C. A. Sari, "Automatic License Plate Detection System with YOLOv11 Algorithm," vol. 9, no. 6, pp. 3097–3109, 2025.

[4] N. Salsabila and S. Sriani, "Enhancing Automated Vehicle License Plate Recognition with YOLOv8 and EasyOCR," *J. Inf. Syst. Informatics*, vol. 6, no. 3, pp. 1577–1597, 2024, doi: 10.51519/journalisi.v6i3.848.

[5] P. Meesad and W. Thumthong, "Advanced deep learning techniques for automated license plate recognition," *Sci. Rep.*, vol. 15, no. 1, pp. 1–23, 2025, doi: 10.1038/s41598-025-24967-9.

[6] E. R. Syihabuddin, W. Angela, M. Naufal, and R. A. Pramunendar, "PENGENALAN PLAT NOMOR KENDARAAN DENGAN YOLOv8 DAN PADDLEOCR," *J. Comput. Sci. Technol.*, vol. 5, no. 2, pp. 66–72, 2025, doi: 10.54840/jcstech.v5i2.374.

[7] Sutikno, A. Sugiharto, and R. Kusumaningrum, "Enhanced Automatic License Plate Detection and Recognition using CLAHE and YOLOv11 for Seat Belt Compliance Detection," *Eng. Technol. Appl. Sci. Res.*, vol. 15, no. 1, pp. 20271–20278, 2025, doi: 10.48084/etasr.9629.

[8] V. Hendriko and D. Hermanto, "Performance Comparison of YOLOv10, YOLOv11, and YOLOv12 Models on Human Detection Datasets," *Brill. Res. Artif. Intell.*, vol. 5, no. 1, pp. 440–450, 2025, doi: 10.47709/brilliance.v5i1.6447.

[9] L. He, Y. Zhou, L. Liu, W. Cao, and J. Ma, "Research on object detection and recognition in remote sensing images based on YOLOv11," *Sci. Rep.*, vol. 15, no. 1, p. 14032, 2025, doi: 10.1038/s41598-025-96314-x.

[10] I. Ashari, I. S. M. Negara, and A. S. S. A, "Lightweight YOLO Models for Real-Time Multi-Vehicle Detection," *Sinkron*, vol. 9, no. 3, pp. 1795–1810, 2025, doi: 10.33395/sinkron.v9i3.15071.

[11] V. Agarwal and G. Bansal, "Automatic number plate detection and recognition using YOLO world," *Comput. Electr. Eng.*, vol. 120, p. 109646, 2024, doi: https://doi.org/10.1016/j.compeleceng.2024.109646.

[12] L. Alashrafi, R. Badawood, H. Almagrabi, M. Alrige, F. Alharbi, and O. Almatrafi, "Benchmarking Lightweight YOLO Object Detectors for Real-Time Hygiene Compliance Monitoring," *Sensors*, vol. 25, no. 19, 2025, doi: 10.3390/s25196140.

[13] M. L. Ali and Z. Zhang, "The YOLO Framework: A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection," *Computers*, vol. 13, no. 12, 2024, doi: 10.3390/computers13120336.

[14] Z. Cai, K. Zhou, and Z. Liao, "A Systematic Review of YOLO-Based Object Detection in Medical Imaging: Advances, Challenges, and Future Directions," *Comput. Mater. Contin.*, vol. 85, no. 2, pp. 2255–2303, 2025, doi: https://doi.org/10.32604/cmc.2025.067994.

[15] N. A. Megantara and E. Utami, "Object Detection using YOLOv8 : A Systematic Review," *Sistemasi*, vol. 14, no. 3, p. 1186, 2025, doi: 10.32520/stmsi.v14i3.5081.

[16] I. D. Mienye and T. G. Swart, "A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications," *Information*, vol. 15, no. 12, 2024, doi: 10.3390/info15120755.

[17] M. Nazeem, R. Anitha, S. Navaneeth, and others, "Open-source OCR libraries: A comprehensive study for low resource language," in *Proceedings of the 21st International Conference on Natural Language Processing (ICON)*, 2024, pp. 416–421.

[18] R. Sapkota *et al.*, "YOLO advances to its genesis: a decadal and comprehensive review of the You Only Look Once (YOLO) series," *Artif. Intell. Rev.*, vol. 58, no. 9, 2025, doi: 10.1007/s10462-025-11253-3.

[19] C. Tian *et al.*, "A survey on deep learning fundamentals," *Artif. Intell. Rev.*, vol. 58, no. 12, p. 381, 2025, doi: 10.1007/s10462-025-11368-7.

[20] D. R. Vedhaviyassh, R. Sudhan, S. Gangadhara Moorthy, S. Iqubal, and D. Arun, "Comparative Analysis of EasyOCR and TesseractOCR for Automatic License Plate Recognition using Deep Learning Algorithm," 2022, pp. 966–971. doi: 10.1109/ICECA55336.2022.10009215.

[21] H. Wang, Y. Liu, W. Li, and Z. Yang, "Multi-Agent Deep Reinforcement Learning-Based Fine-Grained Traffic Scheduling in Data Center Networks," *Futur. Internet*, vol. 16, no. 4, 2024, doi: 10.3390/fi16040119.

[22] Z. Xiuling, W. Huijuan, S. Yu, C. Gang, Z. Suhua, and Y. Quanbo, "Starting from the structure: A review of small object detection based on deep learning," *Image Vis. Comput.*, vol. 146, p. 105054, 2024, doi: https://doi.org/10.1016/j.imavis.2024.105054.

[23] R. N. S, "Indonesia License Plate Detection Dataset," Apr. 2025, *Roboflow*. [Online]. Available: https://universe.roboflow.com/rendika-nurhartanto-s/indonesia-license-plate-detection

JUTEI Edisi Volume. 10 No.2 Oktober 2026
ISSN 2579-3675, e-ISSN 2579-5538
DOI 10.21460/jutei.2026.102.530