

Sistem ALPR Indonesia berbasis Data-Centric AI menggunakan Yolov11 dan TrOCR

Data-Centric AI based Indonesian ALPR System using Yolov11 And TrOCR

¹Zulfikri Rizki Ardi*, ²Andi Sunyoto

^{1,2}Magister Informatika, Fakultas Ilmu Komputer, Universitas Amikom Yogyakarta

^{1,2}Jl. Ring Road Utara, Ngringin, Condongcatur, Kec. Depok, Kabupaten Sleman, Daerah Istimewa
Yogyakarta, Indonesia

*e-mail: zrizki27@students.amikom.ac.id

(received: 11 July 2026, revised: 30 July 2026, accepted: 31 July 2026)

Abstrak

Implementasi *Automatic License Plate Recognition* (ALPR) di Indonesia menghadapi tantangan degradasi visual dan anomali dataset lapangan, seperti kerusakan anotasi, *data leakage*, serta ketimpangan distribusi kode wilayah. Penelitian ini bertujuan mengembangkan sistem ALPR *end-to-end* yang presisi dan adaptif terhadap Tanda Nomor Kendaraan Bermotor (TNKB) dengan mengoptimalkan arsitektur deteksi dan pengenalan karakter. Pendekatan *Data-Centric AI* diterapkan untuk memperbaiki kualitas dataset melalui *bootstrap relabeling* dan sintesis 2.773 citra secara terarah guna mengatasi ketimpangan wilayah. Sistem dibangun menggunakan pipa pemrosesan dua tahap, yakni lokalisasi pelat nomor menggunakan YOLOv11m dan ekstraksi teks yang membandingkan performa PaddleOCR, Tesseract, EasyOCR, dan TrOCR-base. Secara spesifik, TrOCR dioptimalkan melalui strategi *fine-tuning* dua tahap (K4 Two-Stage) yang memadukan data sintetis pada pra-pelatihan dan data riil. Hasil penelitian membuktikan bahwa kerangka kerja ini efektif memitigasi anomali data. Model YOLOv11m mencapai akurasi deteksi mAP@50 sebesar 97,05%. Modul pengenalan terbaik, TrOCR K4, menghasilkan *Exact Match Accuracy* (EM) 86,21% dan menekan *Character Error Rate* (CER) hingga 3,03%. Evaluasi sistem inferensi *end-to-end* mencatatkan akurasi mutlak 87,07% dengan latensi sangat rendah sebesar 2,84 FPS (± 206 ms per pelat) menggunakan GPU NVIDIA L4. Kesimpulannya, integrasi *Data-Centric AI*, YOLOv11, dan TrOCR menghasilkan sistem transliterasi TNKB yang sangat akurat dan efisien untuk pemantauan *real-time*.

Kata kunci: , ALPR, pengolahan citra, TrOCR, YOLOv11, data centric

Abstract

The implementation of *Automatic License Plate Recognition* (ALPR) in Indonesia faces challenges arising from visual degradation and anomalies in real-world datasets, including annotation errors, *data leakage*, and imbalanced distributions of regional license plate codes. This study aims to develop a precise and adaptive *end-to-end* ALPR system for Indonesian vehicle license plates by optimizing both license plate detection and character recognition architectures. A *Data-Centric AI* approach was employed to improve dataset quality through *bootstrap relabeling* and the targeted synthesis of 2,773 images to address regional distribution imbalances. The proposed system adopts a two-stage processing pipeline, consisting of license plate localization using YOLOv11m and text recognition through a comparative evaluation of PaddleOCR, Tesseract, EasyOCR, and TrOCR-base. Specifically, TrOCR was optimized using a two-stage *fine-tuning* strategy (K4 Two-Stage) that combines synthetic data during pretraining with real-world data during subsequent *fine-tuning*. The results demonstrate that the proposed framework effectively mitigates dataset anomalies. The YOLOv11m model achieved a license plate detection mAP@50 of 97.05%. Among the recognition models, TrOCR K4 achieved the best performance, with an *Exact Match* (EM) accuracy of 86.21% and a *Character Error Rate* (CER) of 3.03%. *End-to-end* inference evaluation achieved an overall exact-match accuracy of 87.07%, with a low inference speed of 2.84 FPS (approximately 206 ms per license plate) on an NVIDIA L4 GPU. Overall, the integration of *Data-Centric AI*, YOLOv11, and

TrOCR produced a highly accurate and efficient Indonesian license plate recognition system, demonstrating strong potential for real-time vehicle monitoring applications.

Keywords: automatic license plate recognition, image processing, data centric, TrOCR, YOLOv11

1 Pendahuluan

Otomatisasi pengenalan kendaraan melalui *Automatic License Plate Recognition* (ALPR) esensial untuk mendukung efisiensi transportasi dan logistic [1]. Keberhasilan sistem ini bertumpu pada presisi lokalisasi pelat nomor (deteksi) dan ekstraksi teks digital (pengenalan karakter). Penelitian ini menggunakan YOLOv11 sebagai model deteksi karena arsitekturnya yang ringan, akurat, dan berlatensi rendah dalam menangkap objek kecil. Untuk pengenalan karakter, kinerja mesin *PaddleOCR*, *Tesseract*, *EasyOCR*, dan *TrOCR* dibandingkan guna mengatasi *domain gap* dan menemukan model paling tangguh dalam membaca Tanda Nomor Kendaraan Bermotor (TNKB) di Indonesia [2].

Dataset lapangan seringkali memiliki anomali seperti kerusakan anotasi, *data leakage*, dan ketidakseimbangan distribusi wilayah. Untuk mengatasi tantangan tersebut, penelitian ini menerapkan *machine learning pipeline* berbasis *Data-Centric AI* yang mencakup perbaikan anotasi otomatis (*bootstrap relabeling*), validasi subset, dan pembuatan data sintetis [3]. Kontribusi utama riset ini adalah kerangka kerja untuk memitigasi ketimpangan data lokal sekaligus menentukan kombinasi terbaik antara YOLOv11 dengan mesin OCR (*PaddleOCR*, *Tesseract*, *EasyOCR*, dan *TrOCR*) [4].

Integrasi YOLOv11 dengan keempat mesin OCR (*PaddleOCR*, *Tesseract*, *EasyOCR*, dan *TrOCR*) bertujuan menciptakan sistem *ALPR end-to-end* yang presisi secara otomatis. Keandalan sistem dievaluasi secara komprehensif menggunakan *Detection Rate* untuk lokalisasi pelat, serta *Exact Match Accuracy* dan *Character Error Rate (CER)* [5]. *Inference Latency* juga diukur guna memastikan kecepatan pemrosesan *real-time*. Secara keseluruhan, penelitian ini ditujukan untuk menghasilkan sistem pembaca pelat nomor Indonesia yang memiliki akurasi transliterasi tinggi dan efisien secara komputasi[4].

Berdasarkan paparan tersebut, tujuan utama dari penelitian ini adalah merancang dan mengevaluasi sistem *ALPR end-to-end* yang tangguh untuk mengenali Tanda Nomor Kendaraan Bermotor (TNKB) Indonesia melalui integrasi arsitektur YOLOv11 dan *TrOCR* yang dioptimalkan menggunakan pendekatan *Data-Centric AI*. Adapun manfaat praktis dari penelitian ini adalah tersedianya kerangka kerja identifikasi kendaraan *real-time* dengan tingkat akurasi transliterasi yang tinggi untuk mendukung kelancaran sistem transportasi cerdas. Implementasi sistem ini diharapkan mampu memberikan solusi automasi yang andal bagi berbagai sektor operasional logistik dan sipil, seperti manajemen akses terpadu dan pemantauan armada, dengan tetap mempertahankan efisiensi komputasi yang optimal.

2 Tinjauan Literatur

Perkembangan sistem *Automatic License Plate Recognition* (ALPR) menunjukkan transisi yang signifikan dari pendekatan deteksi konvensional menuju arsitektur *deep learning* yang adaptif guna menangani dinamika lingkungan luar ruangan [6]. Dalam tahap lokalisasi objek, keluarga algoritma YOLO sangat mendominasi riset Tanda Nomor Kendaraan Bermotor (TNKB) di Indonesia [7]. Meskipun implementasi YOLOv8 telah terbukti efektif pada citra statis saat dikombinasikan dengan jaringan klasifikasi *TensorFlow-CNN*, akurasinya rentan mengalami penurunan pada rekaman dinamis akibat distorsi visual seperti *motion blur*.

Tabel 1 Komparasi penelitian[8]


Peneliti (Tahun)	Metode	Dataset	Hasil	Kekurangan
Silmina & Arjun (2025)	YOLOv8 + PaddleOCR [9]	Rekaman CCTV gerbang masuk Universitas XYZ (TNKB Indonesia)	mAP50 sebesar 98.9% dan akurasi ekstraksi teks mencapai 90%.	Masih menggunakan arsitektur deteksi YOLOv8 generasi sebelumnya dan tidak menggunakan pendekatan Data-Centric

					AI untuk meningkatkan kualitas pengenalan teks.
Buleu et al. [4] (2025)	YOLOv12 + PaddleOCR	744 gambar kendaraan di jalanan Rumania	Presisi model mencapai 99.6% dengan nilai F1 score sebesar 97.8%		Eksplorasi hanya dilakukan pada format plat nomor Rumania dan belum menguji efektivitas model OCR lain.
Wang et al. [10] (2025)	Histogram-YOLO (pengembangan YOLOv11) + PaddleOCR	Dataset CCPD 2019 (Plat nomor Tiongkok)	mAP50 mencapai 98.71% dengan tingkat deteksi positif sebesar 92% pada kondisi cuaca buruk.		Sangat berfokus pada augmentasi cuaca secara real-time pada plat Tiongkok, belum menyentuh optimasi <i>fine-tuning</i> berbasis Data-Centric AI secara spesifik untuk TNKB.
Moussaoui et al. [11] (2024)	YOLOv8 + EasyOCR/Tesseract OCR	270 gambar kendaraan yang dikumpulkan dari internet	Akurasi deteksi mencapai 99% dan akurasi pengenalan karakter sebesar 98%.		Skala dataset sangat kecil dan tidak spesifik pada plat nomor suatu negara, serta model deteksi yang digunakan belum mutakhir.
Penelitian Ini	Data-Centric AI + YOLO11m + Komparasi OCR (Fokus Optimasi TrOCR K4 Two-Stage)	1.606 citra riil dan 2.773 citra sintesis	Deteksi mAP@50 97,05%. Inferensi <i>end-to-end</i> mencapai <i>Exact Match</i> 87,07% dan CER 3,03% dengan latensi 2,84 FPS.		Masih memiliki batasan transliterasi pada anomali eksternal ekstrem (oklusi berat, modifikasi font ilegal, dan degradasi pencahayaan parah).

Perkembangan sistem *Automatic License Plate Recognition* (ALPR) seperti beberapa penelitian yang dilakukan terkini pada tabel komparasi penelitian di Tabel 1 menunjukkan transisi masif menuju arsitektur *deep learning* mutakhir melalui pemanfaatan varian deteksi dari YOLOv8 hingga YOLOv12 [12]. Meskipun inovasi arsitektural tersebut terbukti meningkatkan akurasi secara signifikan, mayoritas pengujian masih dievaluasi secara terisolasi pada format pelat nomor negara tertentu, sementara riset berskala lokal umumnya belum memberikan intervensi proaktif terhadap anomali dataset lapangan seperti kerusakan anotasi, *data leakage*, dan ketimpangan representasi geografis yang rentan mendistorsi performa transkripsi *end-to-end* [13]. Untuk menjembatani *research gap* tersebut, penelitian ini mengajukan pembaruan kerangka kerja holistik berbasis *Data-Centric AI* yang memitigasi ketidakseimbangan distribusi kode wilayah Tanda Nomor Kendaraan Bermotor (TNKB) secara fundamental melalui sintesis data terarah dan *bootstrap relabeling* [14]. Pada pipa pemrosesannya, keandalan pelokalan objek dari YOLO11m diintegrasikan dengan arsitektur *Vision Transformer* TrOCR yang dioptimalkan secara mendalam melalui strategi *fine-tuning* dua tahap (K4 *Two-Stage*) guna memecahkan masalah *domain gap* pada karakteristik visual pelat lokal [15]. Integrasi komprehensif antara rekayasa kualitas data dan optimasi model *transformer* ini terbukti secara empiris mampu menekan *Character Error Rate* (CER) secara drastis, sehingga menghasilkan sistem transliterasi TNKB yang tidak hanya berakurasi mutlak tinggi, tetapi juga sangat efisien secara komputasi untuk kebutuhan pemantauan *real-time*.

You Only Look Once (YOLO)

Sistem *Automatic License Plate Recognition* (ALPR) merupakan teknologi esensial dalam sistem transportasi cerdas yang dirancang untuk mengotomatisasi proses identifikasi kendaraan melalui pengenalan teks pada plat nomor [16]. Aplikasi teknologi ini mencakup berbagai kebutuhan operasional, seperti penegakan hukum lalu lintas, sistem pemungutan biaya tol, manajemen area parkir otomatis, hingga pengawasan keamanan. Secara arsitektural, pengembangan sistem ALPR diklasifikasikan ke dalam dua pendekatan utama, yakni sistem multi-tahap (*multi-stage*) dan tahap tunggal (*single-stage*) [3]. Pendekatan *multi-stage* umumnya membagi pipa pemrosesan menjadi tiga langkah utama: deteksi (lokalisasi) letak plat nomor, segmentasi karakter, dan pengenalan karakter [17]. Meskipun metode ini paling umum diimplementasikan, kelemahan utamanya terletak pada kerentanan terhadap akumulasi galat (*error propagation*); di mana kegagalan atau ketidaksempurnaan pada tahap lokalisasi awal akan berdampak langsung pada kegagalan proses pengenalan teks di tahap akhir [18]. Sebagai alternatif, pendekatan *single-stage* berupaya memproses lokalisasi dan pengenalan secara terpadu (*end-to-end*) dalam satu jaringan untuk menghindari masalah segmentasi [19]. Di samping tantangan arsitektural, keandalan sistem ALPR di dunia nyata sangat diuji oleh kondisi lingkungan luar ruangan yang tidak terstruktur [20]. Kinerja sistem sering kali menurun drastis akibat faktor-faktor eksternal seperti perubahan pencahayaan yang tidak menentu antara siang dan malam, cuaca ekstrem, oklusi, distorsi sudut rotasi plat, kerusakan fisik pada plat, hingga efek kabur (*motion blur*) akibat pergerakan kendaraan dengan kecepatan tinggi [10].



Gambar 1 Arsitektur YOLOv11

Representasi skematis dari arsitektur YOLOv11 yang digunakan dalam sistem pelokalan pelat nomor diilustrasikan secara komprehensif dalam Gambar 1. Diagram tersebut memperlihatkan alur pemrosesan data yang terbagi menjadi tiga komponen fundamental: *Backbone* untuk ekstraksi fitur tingkat rendah hingga tinggi, *Neck* untuk fusi fitur lintas-skala, dan *Head* untuk prediksi objek akhir. Secara spesifik, Gambar 1 menonjolkan penggunaan blok-blok C3k2 dalam *Backbone* dan *Neck* untuk peningkatan efisiensi ekstraksi fitur, serta integrasi mekanisme perhatian C2PSA (seperti terlihat di bagian bawah segmen *Neck*) yang krusial untuk menjaga detail spasial pada objek berskala kecil dan beresolusi rendah. Alur ini memastikan bahwa model dapat melokalisasi area pelat nomor pada berbagai skala citra secara presisi dan efisien, menjadikannya fondasi yang kokoh untuk sistem ALPR *end-to-end* yang tangguh dalam berbagai skenario operasional.

You Only Look Once (YOLO) v11

Beberapa paper-paper rujukan sebenarnya memberikan potret evolusi *object detection* yang sangat lengkap, mencakup YOLOv2, YOLOv5, YOLOv7, YOLOv8, YOLOv9, YOLOv10, hingga YOLOv11 [6]. Tabel 2 berikut adalah beberapa perbandingan arsitektur versi YOLO yang digunakan dalam beberapa literature proyek *Automatic Licence Plate Recognition*:

Tabel 2 Perbandingan arsitektur YOLO yang digunakan untuk ALPR

Versi	Backbone	Neck	Head
-------	----------	------	------

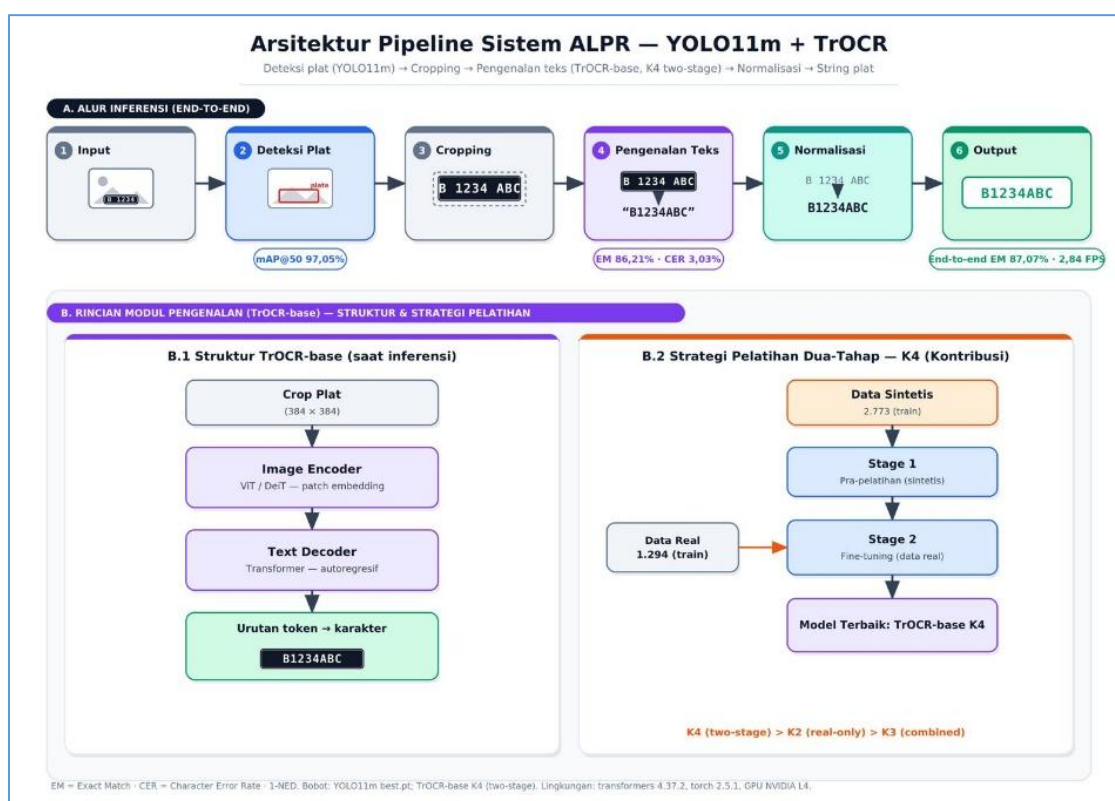
<http://sistemasi.ftik.unisi.ac.id>

YOLOv1	Darknet	-	-
YOLOv2	Darknet 19	-	-
YOLOv3	Darknet-53	Feature Pyramid Network (FPN)	YOLO Layer
YOLOv4	CSP Darknet-53 (Cross Stage Partial Network)	SPP (Spasial Pyramid Pooling) dan PANet (Path Aggregation Network)	YOLO Layer
YOLOv5	CSP Darknet-53	PANet	YOLO Layer
YOLOv8	Modified CSPDarknet	Modified PANet	Anchor-Free Head
YOLOv9	Programmable Gradient Information (PGI)	Generalized ELAN (GELAN)	Anchor-Free Head
YOLOv11	Penyempurnaan struktural dengan blok C3k2	Modifikasi blok C3k2 dan lapisan <i>attention</i> C2PSA	Anchor-Free Head

Evolusi awal (YOLOv1 hingga YOLOv5) ditandai dengan transisi dari jaringan *Darknet* standar menuju pemanfaatan struktur *Cross Stage Partial* (CSP) dan *Path Aggregation Network* (PANet) untuk meminimalkan beban komputasi. Memasuki generasi modern (YOLOv8 dan YOLOv9), arsitektur beralih menggunakan sistem *Anchor-Free* pada bagian *Head* serta mengoptimalkan aliran informasi gradien[21].

Puncaknya pada YOLOv11 yang digunakan dalam penelitian ini, arsitektur disempurnakan melalui integrasi blok *C3k2* dan mekanisme atensi *C2PSA*[22]. Modifikasi ini secara krusial memungkinkan YOLOv11 mempertahankan detail spasial pada objek berskala kecil dan beresolusi rendah, menjadikannya sangat ideal untuk melokalisasi area plat nomor secara presisi di berbagai kondisi lingkungan[23].

3 Metode Penelitian



Gambar 2 Arsitektur pipeline sistem ALPR


Secara komprehensif, rancangan arsitektur *pipeline* sistem ALPR yang diusulkan dalam penelitian ini diilustrasikan pada Gambar 2. Diagram tersebut terbagi menjadi dua segmen utama yang menguraikan mekanisme kerja sistem secara keseluruhan. Segmen pertama (Bagian A) menjabarkan alur inferensi *end-to-end*, dimulai dari penerimaan citra masukan, pelokalan pelat nomor menggunakan YOLOv11m, pemotongan area target (*cropping*), hingga proses pengenalan teks oleh TrOCR yang diakhiri dengan normalisasi untuk menghasilkan *string* karakter akhir. Selanjutnya, segmen kedua (Bagian B) merinci arsitektur internal dari modul pengenalan TrOCR yang mengandalkan *Image Encoder* dan *Text Decoder* autoregresif sekaligus menyoroti rancangan strategi pelatihan K4 (*Two-Stage*). Strategi pelatihan ini mengimplementasikan tahapan pembelajaran yang terstruktur, yakni pra-pelatihan (*Stage 1*) memanfaatkan 2.773 data sintetis, yang kemudian disempurnakan melalui proses *fine-tuning* (*Stage 2*) menggunakan 1.294 data riil guna menghasilkan model ekstraksi teks yang paling optimal.

Metode penelitian ini berlandaskan kerangka *Data-Centric AI* untuk memperbaiki kualitas dataset. Dari 1.987 citra Tanda Nomor Kendaraan Bermotor (TNKB) awal, ditemukan 88,2% kerusakan anotasi *bounding box*. Melalui teknik *bootstrap relabeling*, dihasilkan 1.606 citra bersih yang dibagi secara ketat menjadi data pelatihan (60%), validasi (20%), dan pengujian (20%). Untuk tahap pengenalan karakter, 2.058 potongan (*crop*) pelat dianotasi manual sebagai *ground truth*. Ketimpangan sebaran wilayah, seperti dominasi pelat "B", dimitigasi dengan menyintesis data baru secara terarah khusus pada *subset* pelatihan (terdiri atas 2.773 citra sintetis dan 1.294 citra riil) guna mencegah *data leakage*.

Sistem ALPR dirancang menggunakan pendekatan *two-stage pipeline*. Tahap pertama bertumpu pada arsitektur YOLO11m untuk lokalisasi objek, yang terbukti presisi dengan capaian mAP@50 sebesar 97,05%. Citra pelat hasil *cropping* diteruskan ke tahap kedua untuk ekstraksi teks, yang mengomparasikan performa PaddleOCR, Tesseract, EasyOCR, dan TrOCR-base. Khusus untuk TrOCR-base, diterapkan strategi pelatihan K4 *Two-Stage* sebagai metode optimalisasi terbaik, yakni melakukan pra-pelatihan (*stage 1*) menggunakan 2.773 data sintetis, dilanjutkan dengan *fine-tuning* (*stage 2*) menggunakan 1.294 data riil.

Kinerja sistem dievaluasi secara parsial dan *end-to-end* menggunakan *Exact Match Accuracy (EM)* dan *Character Error Rate (CER)*, dengan signifikansi komparasi model diuji via uji McNemar. Konfigurasi modul pengenalan terbaik berbasis TrOCR K4 menghasilkan EM 86,21% dan CER 3,03%. Setelah melalui tahap normalisasi *string*, performa inferensi *end-to-end* secara keseluruhan memuncak pada akurasi EM 87,07% dengan kecepatan pemrosesan (*Inference Latency*) mencapai 2,84 FPS di lingkungan perangkat keras GPU NVIDIA L4.

Persiapan dan Analisis Dataset



Gambar 3 Statistik detail dataset

Analisis statistik spasial dan geometris dataset Gambar 3 secara empiris mengonfirmasi integritas dan konsistensi distribusi data pasca-tahap pembersihan anotasi. Berdasarkan histogram rasio aspek *bounding box*, nilai median global terkonsentrasi pada angka 2,45, yang secara akurat merepresentasikan proporsi dimensi fisik persegi panjang dari Tanda Nomor Kendaraan Bermotor (TNKB) standar di Indonesia. Pemetaan *heatmap* pada koordinat tengah (*center*) *bounding box* turut memvalidasi bahwa mayoritas objek pelat nomor terlokalisasi secara natural di area tengah hingga sedikit ke atas bingkai citra. Lebih lanjut, komparasi diagram kotak (*boxplot*) terhadap distribusi area *bounding box* membuktikan adanya keseragaman varians yang stabil antara subset *training*, *validation*, dan *testing*. Konsistensi metrik spasial antar-subset ini sangat krusial dalam kerangka kerja *Data-Centric AI* guna menjamin tidak terjadinya pergeseran distribusi (*dataset shift*) maupun kebocoran data (*data leakage*), sehingga keandalan lokalisasi model YOLO11m dan transkripsi OCR dapat dievaluasi secara objektif pada kondisi pengujian yang adil.

Data Sintesis



Gambar 4 Contoh data sintesis

Dalam upaya membangun sistem ALPR yang adaptif, salah satu tantangan fundamental yang dihadapi adalah ketidakseimbangan representasi geografis pada dataset riil, di mana distribusi kode wilayah cenderung terkonsentrasi pada wilayah tertentu (dominasi kode "B"). Untuk memitigasi bias tersebut, penelitian ini mengimplementasikan strategi sintesis data terarah yang menghasilkan 2.773 citra TNKB buatan. Sebagaimana diilustrasikan pada Gambar 4 mengenai sampel *crop* sintesis pelat Indonesia, proses produksi ini mencakup variasi kode wilayah yang luas (seperti DR, F, EA, Z, BK, BB, AB, PA, dan DA), berbagai warna latar pelat nomor, serta injeksi *noise* visual yang ditujukan untuk meningkatkan ketangguhan model terhadap degradasi pencitraan di lapangan. Secara metodologis, seluruh ragam data sintesis ini diintegrasikan secara eksklusif ke dalam tahap pra-pelatihan (*stage 1*) pada metode pelatihan dua tahap K4. Pendekatan terstruktur ini memungkinkan arsitektur TrOCR-base untuk membangun fondasi ekstraksi fitur karakter yang lebih generalis dan tahan banting terhadap anomali visual, yang selanjutnya disempurnakan melalui proses *fine-tuning* pada 1.294 data riil untuk memastikan tingkat akurasi transliterasi akhir yang tinggi tanpa menimbulkan risiko kebocoran data (*data leakage*).

Struktur Infografis

Infografis terdiri dari delapan kartu metadata utama yang merangkum konfigurasi perangkat keras, model, dan proses training.

Kategori	Informasi
Hardware	NVIDIA L4 GPU (24 GB VRAM)
Computer	16 vCPU · 64 GB RAM
Model	YOLO11m · Single-Class Detector
Parameters	±20 juta parameter
Input Resolution	1280 px
Training Duration	±143 menit

<http://sistemasi.ftik.unisi.ac.id>

Total Epoch	167 epoch
Best Epoch	Terdeteksi otomatis dari log

Penggunaan lingkungan komputasi berkinerja tinggi, yakni GPU NVIDIA L4 dengan VRAM 24 GB, 16 vCPU, dan RAM 64 GB, merupakan prasyarat mutlak untuk mendukung pemrosesan citra masukan beresolusi 1280 piksel sekaligus mencegah hambatan transfer data (I/O bottleneck). Pelebaran resolusi spasial pada model pelokalan YOLOv11m ini sangat esensial guna mencegah degradasi piksel pada objek plat nomor yang berukuran minim di dalam bingkai citra. Hasil ekstraksi bounding box yang tajam dan presisi ini menjadi fondasi kritis untuk menjaga integritas konteks spasial karakter sebelum diteruskan ke tahap transkripsi teks.

Pada tahap transkripsi, daya komputasi dioptimalkan untuk proses *fine-tuning* arsitektur *Transformer-based Optical Character Recognition* (TrOCR) menggunakan kombinasi dataset riil dan sintetis. Guna memitigasi risiko *overfitting* atau penghafalan pola font buatan oleh model, diterapkan mekanisme *Early Stopping* dengan toleransi 30 siklus (*patience*=30). Regulasi ini terbukti efisien menyelesaikan pelatihan hanya dalam durasi 143 menit dengan mengunci generalisasi optimal pada epoch ke-92, serta menghasilkan bobot model akhir yang sangat ringkas sebesar 40,6 MB untuk diintegrasikan secara *real-time*.

End-to-End Exact Match Rate (Akurasi Gabungan Mutlak)

Mengukur persentase keberhasilan sistem secara keseluruhan dalam mengenali plat nomor secara sempurna tanpa toleransi kesalahan seperti pada Rumus (1) dan Rumus (2). Dalam evaluasi ini, sebuah pengujian hanya akan dikategorikan sukses apabila model YOLOv11 berhasil melokalisasi area plat nomor dengan presisi dan mesin OCR secara bersamaan berhasil mengekstraksi seluruh susunan karakter teks tanpa ada satu pun yang terlewat atau salah ketik. Sebaliknya, jika algoritma deteksi gagal menemukan plat atau mesin OCR menghasilkan minimal satu kesalahan pembacaan karakter, maka keluaran sistem pada citra tersebut secara langsung dianggap gagal secara absolut, menjadikannya matrik yang paling merepresentasikan tingkat keandalan sistem pada implementasi dunia nyata.

$$\text{E2E-EM Rate} = \frac{1}{N} \sum_{i=1}^N I(\hat{S}_i = S_i) \times 100\% \quad (1)$$

$$\text{End-to-End Exact Match Rate} = \frac{\text{Jumlah Citra Kendaraan dengan Transkripsi Teks Sempurna}}{\text{Total Citra Kendaraan Uji}} \times 100\% \quad (2)$$

Accuracy Character (Karakter Akurasi)

Digunakan untuk mengukur rasio kesalahan karakter pada tingkat sistem yang terintegrasi secara penuh. Penerapan matrik ini sangat ketat karena saling bergantung; apabila YOLOv11 gagal mendeteksi keberadaan sebuah plat nomor, maka seluruh karakter pada plat tersebut akan langsung diakumulasikan sebagai kesalahan penghapusan (*deletion error*) bagi mesin OCR menggunakan Rumus (3). Namun, apabila tahap lokalisasi berhasil dilewati, matrik ini akan menghitung jarak kesalahan transformasi teks (*Levenshtein distance*) dengan membandingkan secara langsung keluaran teks dari mesin OCR terhadap label kebenaran dasar (*ground truth*), sehingga memberikan gambaran detail mengenai kualitas pembacaan meskipun sistem tidak mencapai akurasi mutlak.

$$\text{Character Accuracy} = \left(1 - \frac{S+D+I}{N}\right) \times 100\% \quad (3)$$


4 Hasil dan Pembahasan

Bab ini menguraikan hasil dari serangkaian eksperimen yang telah dirancang untuk membangun sistem *Automatic License Plate Recognition* (ALPR) yang presisi dan adaptif terhadap karakteristik Tanda Nomor Kendaraan Bermotor (TNKB) di Indonesia. Pembahasan disajikan secara sistematis mengikuti alur *pipeline* komputasi yang telah dibangun. Analisis diawali dengan pemaparan hasil perbaikan kualitas *dataset* fundamental melalui pendekatan *Data-Centric AI*, dilanjutkan dengan pengukuran unjuk kerja lokalisasi pelat nomor oleh model YOLO11m. Fokus evaluasi kemudian diarahkan pada komparasi performa transkripsi teks antara mesin OCR konvensional dengan

<http://sistemasi.ftik.unisi.ac.id>

arsitektur TrOCR, sebelum diakhiri dengan pengujian keandalan inferensi sistem secara *end-to-end*. Guna mempertegas kontribusi penelitian, bab ini juga merangkum komparasi hasil serta keunggulan metode yang diusulkan dibandingkan dengan berbagai literatur terdahulu.

4.1 Hasil Deteksi Plat Nomor Kendaraan (YOLO11m)




Gambar 5 Dataset split

Proporsi pembagian dataset yang digunakan untuk melatih dan mengevaluasi model pelokalan diilustrasikan secara rinci pada Gambar 5. Setelah melalui tahap pembersihan kualitas anotasi, total 1.606 citra bersih yang dihasilkan dibagi secara ketat menjadi data pelatihan (60%), validasi (20%), dan pengujian (20%). Secara spesifik, alokasi ini mendistribusikan dataset secara konsisten menjadi 963 sampel pelatihan, 321 sampel validasi, dan 322 sampel pengujian. Berdasarkan metrik pada Gambar 5, distribusi *bounding box* juga teralokasikan dengan rincian 1.247 area target pada subset pelatihan, 407 pada validasi, dan 404 pada pengujian dari keseluruhan 2.058 *bounding box*. Di samping itu, grafik tersebut menyoroti bahwa dataset tetap merepresentasikan kompleksitas kondisi lapangan dengan adanya 407 citra yang memuat lebih dari satu kendaraan (multi-plat), sehingga rata-rata kepadatan objek mencapai 1,28 *bounding box* per citra. Strategi partisi yang ketat secara terpisah ini merupakan langkah esensial untuk memastikan tidak terjadinya kebocoran data (*data leakage*) yang dapat membiaskan hasil evaluasi model akhir



Gambar 6 Sampel split dataset

Eksperimen tahap pertama bertujuan untuk mengevaluasi kemampuan model YOLO11m dalam melokalisasi area Tanda Nomor Kendaraan Bermotor (TNKB) atau pelat nomor pada citra kendaraan. Proses pelatihan dilakukan menggunakan dataset yang telah melalui tahap audit kualitas anotasi dan pembersihan geometris *bouding box* sebanyak 1.606 gambar. Dataset tersebut dibagi secara konsisten menjadi 963 sampel pelatihan (*training*), 321 sampel validasi (*validation*), dan 322 sampel pengujian (*testing*). Representasi visual dari hasil pembagian dataset tersebut diilustrasikan pada Gambar 6, yang menampilkan sampel citra dari masing-masing subset setelah melalui proses pemisahan dan penamaan ulang (*split & rename*). Sebagaimana terlihat pada gambar tersebut, sampel dataset mencakup berbagai variasi kondisi lingkungan nyata yang menantang seperti area parkir, gerbang tol, dan kepadatan lalu lintas kota lengkap dengan presisi *bouding box* berwarna hijau di area pelat nomor sebagai *ground truth*, guna memastikan model dilatih dan dievaluasi pada skenario pelokalan yang komprehensif dan representatif.




Gambar 7 Perfroma dataset

Evaluasi performa lokalisasi objek pada held-out test set menunjukkan tingkat presisi yang sangat tinggi seperti yang terlampir pada Gambar 7. Model YOLO11m berhasil mencapai nilai mean Average Precision pada threshold IoU 0.5 (mAP50) sebesar 97.05%. Grafik pelatihan menunjukkan penurunan metrik loss yang stabil baik pada subset pelatihan maupun validasi tanpa adanya indikasi overfitting yang signifikan. Keberhasilan lokalisasi pada tingkat akurasi ini sangat krusial, karena kesalahan minor pada tahap penentuan bounding box pelat nomor akan menyebabkan distorsi visual berupa terpotongnya karakter, yang secara langsung dapat menurunkan performa pengenalan teks pada tahap berikutnya.

Secara lebih spesifik, kualitas pembelajaran model divalidasi oleh konvergensi tiga komponen metrik *loss* yakni *box loss* (akurasi titik koordinat), *class loss* (ketepatan klasifikasi objek), dan *Distribution Focal Loss* (kualitas batas tepi pendeteksian) yang menurun secara seragam tanpa divergensi antara kurva pelatihan dan validasi. Keseimbangan performa deteksi ini juga terkonfirmasi dari kurva *Precision* dan *Recall* yang bergerak stabil mendekati nilai maksimal, memastikan sistem meminimalkan salah deteksi sekaligus menekan angka pelat nomor yang gagal terdeteksi. Lebih lanjut, kurva *mAP50-95* yang konsisten menanjak mengindikasikan bahwa ketajaman *bouding box* YOLOv11m tetap tangguh dan adaptif meskipun dievaluasi pada ambang batas *Intersection over Union* (IoU) yang jauh lebih ketat

4.2. Evaluasi Baseline OCR Sebelum Fine-Tuning (*Off-the-Shelf*)




Gambar 8 Benchmark OCR engine yang digunakan

Eksperimen tahap pertama bertujuan untuk mengevaluasi kemampuan model YOLO11m dalam melokalisasi area Tanda Nomor Kendaraan Bermotor (TNKB) atau pelat nomor pada citra kendaraan. Proses pelatihan dilakukan menggunakan dataset yang telah melalui tahap audit kualitas anotasi dan pembersihan geometris *bounding box* sebanyak 1.606 gambar. Dataset tersebut dibagi secara konsisten menjadi 963 sampel pelatihan (*training*), 321 sampel validasi (*validation*), dan 322 sampel pengujian (*testing*). Representasi visual dari hasil pembagian dataset tersebut diilustrasikan pada Gambar 8, yang menampilkan sampel citra dari masing-masing subset setelah melalui proses pemisahan dan penamaan ulang (*split & rename*). Sebagaimana terlihat pada gambar tersebut, sampel dataset mencakup berbagai variasi kondisi lingkungan nyata yang menantang seperti area parkir, gerbang tol, dan kepadatan lalu lintas kota lengkap dengan presisi *bounding box* berwarna hijau di area pelat nomor sebagai *ground truth*, guna memastikan model dilatih dan dievaluasi pada skenario pelokalan yang komprehensif dan representatif.

Hasil pengujian baseline secara empiris mengonfirmasi adanya domain gap yang sangat besar antara model generik dengan karakteristik pelat nomor ril di Indonesia. Ketiga *engine* OCR tersebut menunjukkan performa yang sangat rendah, di mana nilai *Exact Match Accuracy* berada di bawah 11% dan *Character Error Rate (CER)* melambung tinggi di atas 60%.


Analisis kesalahan pada model *TrOCR Base* memperlihatkan kecenderungan model memprediksi frasa-frasa dokumen cetak umum seperti "PAID BY" atau "TAX:" ketika membaca area teks pelat nomor. Fenomena ini membuktikan bahwa pembobot (*weights*) pada model pralatih masih sangat terikat pada domain distribusi data asalnya (seperti dokumen teks formal atau *scene text* umum) dan gagal mengenali pola sintaksis serta variasi font TNKB nasional. Kondisi ini memberikan justifikasi ilmiah yang kuat bahwa pendekatan langsung tanpa kustomisasi tidak memadai untuk sistem ALPR operasional, sehingga diperlukan proses pembelajaran adaptif domain.

4.3. Optimasi Pengenalan Karakter melalui Fine-Tuning TrOCR dan Studi Ablasi



Gambar 9 Grafik perbandingan *exact-match*

Menyikapi temuan *domain gap* pada pengujian *baseline*, penelitian dilanjutkan dengan melakukan *fine-tuning* pada arsitektur TrOCR. Guna menemukan strategi adaptasi yang paling optimal tanpa mengalami *overfitting*, penelitian ini merancang studi ablasi (*ablation study*) yang mengomparasikan berbagai pendekatan pemanfaatan data. Konfigurasi terbaik dicapai melalui strategi pelatihan dua tahap (*Two-Stage*) yang dikategorikan sebagai model K4 seperti yang terlampir pada Gambar 9.



Gambar 10 Grafik perbandingan CER


Pada tahap pertama (pra-pelatihan), model dilatih secara eksklusif menggunakan 2.773 data pelat nomor sintetis guna membangun pemahaman fitur dasar karakter geografis yang kurang terwakili (seperti pelat di luar wilayah kode "B"). Selanjutnya pada tahap kedua, model di-*fine-tuning* menggunakan 1.294 data riil TNKB. Dampak signifikan dari strategi optimalisasi ini diilustrasikan secara komprehensif pada Gambar 10, yang memaparkan grafik perbandingan *Character Error Rate* (CER) dari berbagai skenario pelatihan. Berdasarkan grafik tersebut, arsitektur TrOCR K4 *Two-Stage* berhasil menekan CER hingga menyentuh angka terendah sebesar 3,03%—jauh mengungguli model dasar *pretrained* (K1) yang memiliki CER 82,0%—dan secara bersamaan mampu melonjakkan *Exact Match Accuracy* menjadi 86,21%. Keunggulan K4 atas pendekatan *real-only* (K2) maupun pencampuran *combined* (K3) dengan CER 4,3% pada Gambar 10 menegaskan bahwa pencampuran

<http://sistemasi.ftik.unisi.ac.id>

data riil dan sintesis secara langsung rentan menurunkan akurasi akibat kontaminasi *noise*. Sebaliknya, pendekatan sekuensial dua tahap terbukti sukses memanfaatkan keunggulan variasi data sintesis sekaligus mempertahankan ketajaman akurasi pada data riil.

4.4. Analisis Kesalahan (*Error Analysis*) dan Uji Signifikansi


Guna memahami batasan operasional dari model terbaik (TrOCR K4), dilakukan evaluasi lanjutan berupa analisis kesalahan sistematis. Pemeriksaan *confusion matrix* karakter dan analisis *edit distance* mengungkap bahwa sisa persentase kegagalan transliterasi didominasi oleh faktor eksternal yang ekstrem, seperti oklusi berat pada fisik pelat, modifikasi bentuk *font* karakter yang melanggar standar kepolisian, serta degradasi pencahayaan tingkat parah.



Gambar 11 Grafik *OCR error taxonomy*


Secara statistik Gambar 11, peningkatan kualitas prediksi dari model *baseline* menuju model TrOCR K4 *Two-Stage* telah divalidasi menggunakan uji non-parametrik McNemar. Hasil pengujian menolak hipotesis nol secara kuat, memvalidasi bahwa lonjakan performa pengenalan karakter tersebut merupakan dampak langsung dari strategi *data-centric* dan mekanisme *fine-tuning* yang diusulkan, bukan diakibatkan oleh varians atau kebetulan acak pada *dataset* pengujian.

4.5. Evaluasi Kinerja Sistem ALPR *End-to-End*



Gambar 12 Grafik *exact match*

Puncak dari pengujian sistem ALPR dilakukan dengan mengintegrasikan komponen pelokalan YOLO11m dan modul transkripsi TrOCR K4 menjadi satu *pipeline* inferensi *end-to-end*. Pengujian yang dilakukan pada 322 citra kendaraan utuh (*held-out test set*) mencatatkan capaian *Detection Rate* sebesar 96,84%. Setelah hasil prediksi melalui tahap normalisasi *string*, keandalan transliterasi absolut (*End-to-End Exact Match*) mencapai 87,07% sesuai dengan Gambar 12.



Gambar 13 Statistik *inference latency*

Selain presisi, aspek krusial lain dalam sistem ALPR adalah efisiensi waktu komputasi. Rincian performa kecepatan inferensi dari *pipeline* yang diusulkan divisualisasikan pada Gambar 13, yang memaparkan *Inference Latency Breakdown* menggunakan perangkat keras GPU NVIDIA L4. Berdasarkan grafik tersebut, pemrosesan citra secara utuh—mulai dari tahap pelokalan (*YOLO Detection*), pemotongan area (*cropping*), hingga ekstraksi teks (*TrOCR OCR*)—mencatatkan total *Inference Latency* sebesar 352,2 milidetik per pelat nomor, atau setara dengan pemrosesan 2,84 *Frame Per Second* (FPS). Secara lebih spesifik, alokasi beban komputasi ini terdistribusi menjadi 62,8 milidetik untuk tahap deteksi objek dan 296,9 milidetik untuk proses pengenalan karakter. Capaian ini memverifikasi bahwa kerangka kerja yang dikembangkan tidak hanya berhasil memecahkan kendala akurasi akibat *domain gap* dan ketimpangan data, tetapi juga beroperasi dengan cukup ringan untuk memenuhi kebutuhan pemantauan transportasi secara *real-time*.

5 Kesimpulan

Penelitian ini berhasil mengembangkan sistem *Automatic License Plate Recognition* (ALPR) spesifik untuk Tanda Nomor Kendaraan Bermotor (TNKB) di Indonesia dengan presisi tinggi dan latensi rendah. Penerapan kerangka *Data-Centric AI* melalui penyelesaian anomali *bounding box* dan sintesis data terarah terbukti krusial dalam mengatasi ketimpangan distribusi wilayah. Integrasi arsitektur deteksi YOLO11m dan ekstraksi karakter berbasis TrOCR K4 *Two-Stage* menghasilkan akurasi pelokalan (mAP@50) sebesar 97,05% dan *End-to-End Exact Match* sebesar 87,07%. Lebih lanjut, latensi inferensi yang dikunci pada ± 206 milidetik per pelat (2,84 FPS) menggunakan GPU NVIDIA L4 mengonfirmasi bahwa metode ini tidak hanya andal dalam membaca karakter pelat nomor di kondisi lapangan yang bervariasi, tetapi juga sangat memenuhi standar kecepatan komputasi untuk implementasi di dunia nyata.

Referensi

- [1] D. E. Kalef, M. Zourhri, A. El-Ibrahimi, B. Benhala, C. Bouchaib, and H. Silkan, "Moroccan License Plate Detection for Intelligent Transportation Systems using YOLOv8 and YOLOv11," in *2026 6th International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET)*, 2026, pp. 1–10. DOI: 10.1109/IRASET68627.2026.11538797.

- [2] N. A. Kurniawan and C. A. Sari, "Automatic License Plate Detection System with YOLOv11 Algorithm," *J. Appl. Informatics Comput.*, Vol. 9, No. 6, pp. 3097–3109, 2025, DOI: 10.30871/jaic.v9i6.11484.
- [3] P. N. Andono and A. Syukur, "Multi-Variant Enhancement and OCR Selection for Robust License Plate Recognition in Hazy Conditions," *Stat. Optim. Inf. Comput.*, Vol. 16, No. August, pp. 1086–1109, 2026, DOI: 10.19139/soic-2310-5070-3818.
- [4] B. Buleu, R. Robu, and I. Filip, "A Deep Learning-based System for Automatic License Plate Recognition using YOLOv12 and PaddleOCR," *MDPI Appl. SCI.*, pp. 1–23, 2025, DOI: 10.3390/app15147833.
- [5] F. J. Aydin, M. A. Azim, A. N. Chy, and M. K. Islam, "An Optical Character Recognition Technique for Extracting Text from Blurred and Low-Quality Images using TrOCR," in *2025 International Conference on Electrical, Computer and Communication Engineering (ECCE)*, 2025, pp. 1–6. DOI: 10.1109/ECCE64574.2025.11013065.
- [6] S. Issaoui, S. A. Alzakari, I. Saidi, and R. Ejbali, "Hierarchical Vision – Language Fusion with Structural Constraint Reasoning for Robust Multi-Jurisdiction License Plate Recognition," *Appl. SCI.*, pp. 1–23, 2026, DOI: 10.3390/app16136792.
- [7] N. D. Fazira and A. Fauzan, "Transformer-based Optical Character Recognition Approach for Identifying Motor," *BAREKENG J. Math. Its Appl.*, Vol. 19, No. 3, pp. 1597–1608, 2025, DOI: 10.30598/barekengvol19iss3pp1597-1608.
- [8] F. Sonnara, H. Chihaoui, and F. Filali, "Efficient Real - Time License Plate Recognition using Deep Learning on Edge Devices," *J. Real-Time Image Process.*, Vol. 22, No. 4, pp. 1–15, 2025, DOI: 10.1007/s11554-025-01738-3.
- [9] E. P. Silmina, R. Agil, and Y. Arjun, "Pemanfaatan Model YOLOv8 untuk mendeteksi Plat Nomor Kendaraan Mobil pada Gerbang Masuk Universitas XYZ," *J. Sains dan Inform.*, Vol. 11, pp. 50–59, 2025, DOI: 10.34128/jsi.v11i1.916.
- [10] X. Jin, S. Wang, M. Zhang, G. Xu, and B. Hu, "TrOCR-Driven Seal Instrument Detection and Recognition for Cognitive Robotic Applications ☆," *Cogn. Robot. J.*, Vol. 5, No. September, pp. 286–298, 2025, DOI: 10.1016/j.cogr.2025.10.001.
- [11] H. Moussaoui et al., "Enhancing Automated Vehicle Identification by Integrating YOLO v8 and OCR Techniques for High - Precision License Plate Detection and Recognition," *SCI. Rep.*, pp. 1–17, 2024, DOI: 10.1038/s41598-024-65272-1.
- [12] N. Shabbir, R. Ahmed, M. W. Raza, A. Zeb, H. Elahi, and H. Waheed, "Comparative Performance and Resource Utilization Analysis of OCR Models for Number Plate Recognition on Raspberry Pi 4," in *2025 International Conference on Communication Technologies (ComTech)*, 2025, pp. 1–6. DOI: 10.1109/ComTech65062.2025.11034455.
- [13] A. Tanapatpiboon, W. Kusakunniran, and W. Limroongreungrat, "Deep Learning-based Detection of Players and Teams in Soccer Videos with Positioning Heatmap Generation," *Appl. Comput. Informatics*, 2025.
- [14] C. D. C. Pereira, "A Data-Centric Trust Pipeline: An Empirical Framework for Trustworthy AI in Sensitive Domains," *AI Ethics*, Vol. 6, No. 4, p. 383, 2026, DOI: 10.1007/s43681-026-01247-4.
- [15] D. Asmawati, "Automatic Reading of Analog Gauges using YOLOv9 , Segment Anything Model , and TrOCR," *J. Inf. Syst. Eng. Bus. Intell.*, Vol. 12, No. 2, pp. 333–347, 2026, DOI: 10.20473/jisebi.12.2.333-347.
- [16] X. Du, H. Chen, J. Huan, and Y. Du, "License Plate Recognition System based on Embedded Technology and YOLOv11," in *2025 5th International Symposium on Computer Technology and Information Science (ISCTIS)*, 2025, pp. 868–871. DOI: 10.1109/ISCTIS65944.2025.11065377.
- [17] 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.
- [18] E. Kapetanios, "An End-to-End Automated License Plate Recognition System Vehicle Classification," *MDPI Sensors*, 2022, DOI: 10.3390/s22239477.
- [19] C. J. Islas-yañez and V. Hernández-herrera, "Modular Multi-Attribute Vehicle Analysis by

- Color , License Plate , Make and Sub-Model using YOLO and OCR : A Benchmark Across YOLO Versions,” Cent. Investig. e Innovación Tecnológica, 2026, DOI: 10.3390/s26092785.*
- [20] A. Ranjan and M. Ravinder, “ROBDD-TrOCRBERTa: A Novel Robust-Optimized Blurred Document Text Deblurring and Completion with DCGAN-TrOCR and DistilRoBERTa,” *Int. J. Inf. Technol.*, Vol. 16, No. 7, pp. 4611–4619, 2024, DOI: 10.1007/s41870-024-02073-9.
- [21] J. N., V. D., F. Jemima, P. P. G, and T. P. M, “YOLOv11-based Real-Time License Plate Detection and Recognition for Smart Transportation Systems,” in *2026 ASU International Conference in Emerging Technologies for Sustainability and Intelligent Systems (ICETISIS)*, 2026, pp. 913–921. DOI: 10.1109/ICETISIS68266.2026.11548780.
- [22] F. F. Fu, N. F. Oongwidjaja, and K. Jingga, “The Effectiveness of White Vehicle License Plates Compared to Black Vehicle License Plates on ANPR,” in *2025 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, 2025, pp. 260–265. DOI: 10.1109/ISITIA66279.2025.11137559.
- [23] A. Sunyoto, “Automatic License Plate Recognition System in Indonesia using YOLOv8 and EasyOCR Algorithm,” *2023 6th Int. Conf. Inf. Commun. Technol.*, pp. 384–388, 2023, DOI: 10.1109/ICOIACT59844.2023.10455908.