

Optimasi Deteksi Nomor Lambung Truk Tambang Menggunakan YOLOv11 Berbasis Augmentasi Data

Optimization Of Mining Truck Hull Number Detection Using YOLOv11 Based on Data Augmentation

Tri Prianto¹, Muhammad Sobirin², Jemie Muliadi³

^{1,2,3} Program Studi Teknik Elektro, Fakultas Teknik dan Informatika, Universitas 17 Agustus 1945 Jakarta

^{1,2,3} Jl, Sunter Permai Raya, Sunter Agung, Kec. Tanjung Priok, Jakarta Utara,

Daerah Khusus Ibukota Jakarta 14350, Indonesia

email : ^{*}¹triprianto2271060006@gmail.com, ²muhammad.sobirin@uta45jakarta.ac.id,

³jemie.muliadi@uta45jakarta.ac.id

Informasi Artikel

Diajukan, 5 Januari 2026

Diterima, 17 Februari 2026

Diterbitkan, 5 Juni 2026

Kata Kunci :

YOLOv11, deteksi objek, augmentasi data, truk tambang, computer vision

ABSTRAK

Identifikasi nomor lambung truk tambang secara manual masih banyak diterapkan pada operasi tambang terbuka dan rentan terhadap kesalahan manusia akibat debu, pencahayaan tidak stabil, serta sudut pandang kamera yang tidak ideal. Penelitian ini bertujuan mengoptimalkan deteksi nomor lambung truk menggunakan algoritma *You Only Look Once* versi 11 (YOLOv11) melalui tahapan *preprocessing* dan *data augmentation*. *Preprocessing* meliputi *Auto-Orient* dan *Resize* (Stretch to 640×640), sedangkan *data augmentation* menggabungkan manipulasi fotometrik (*brightness*, *noise*) dan geometrik (*blur*) untuk meningkatkan generalisasi model. Dataset sebanyak 11.664 citra dilatih menggunakan *pretrained weights* dengan *batch size* 16 dan 100 *epochs*. Hasil eksperimen menunjukkan bahwa augmentasi gabungan memberikan kinerja terbaik dengan mAP@0.5 sebesar 0,931, *precision* 0,868, dan *recall* 0,890. Implementasi pada Raspberry Pi 5 menggunakan citra dan video uji secara *offline* menunjukkan sistem mampu mendeteksi dan membaca nomor lambung melalui integrasi EasyOCR serta pengiriman data ke Google Sheet dengan kecepatan rata-rata 3,1 *frames per second* (FPS). Hasil ini menunjukkan bahwa strategi *preprocessing* dan *data augmentation* berperan penting dalam meningkatkan akurasi dan ketangguhan YOLOv11, serta mendukung penerapan sistem berbasis *computer vision* pada perangkat *edge computing* sebagai prototipe awal menuju implementasi *real-time* di lingkungan tambang terbuka.

ABSTRACT

Manual identification of mining truck hull numbers remains common in open-pit mining operations and is prone to human error due to dust, unstable lighting, and non-ideal camera angles. This study aims to optimize hull number detection using the *You Only Look Once* version 11 (YOLOv11) algorithm through *preprocessing* and *data augmentation*. The preprocessing stage includes *Auto-Orient and Resize* (Stretch to 640×640), while data augmentation combines photometric (*brightness*, *noise*) and geometric (*blur*) transformations to improve model generalization. A dataset of 11,664 images was trained using *pretrained weights* with a batch size of 16 and 100 epochs. Experimental results show that the combined augmentation scenario achieved the best performance with an mAP@0.5 of 0.931, precision of 0.868, and recall of 0.890. Implementation on a Raspberry Pi 5 using offline images and videos demonstrates that the system can detect and recognize hull numbers through EasyOCR integration and automatic data transmission to Google Sheets with an average inference speed of 3.1 frames per second (FPS). These results indicate that preprocessing and data augmentation significantly enhance YOLOv11's robustness and support the feasibility of deploying a computer vision-based prototype system on edge computing devices toward real-time implementation in open-pit mining environments.

Keyword :

YOLOv11, object detection, data augmentation, mining truck, computer vision

1. PENDAHULUAN

Di era *Revolusi Industri 4.0*, sektor pertambangan dituntut untuk mengadopsi teknologi digital guna meningkatkan efisiensi operasional dan keselamatan kerja, khususnya dalam pengelolaan armada truk tambang di tambang terbuka. Proses identifikasi nomor lambung truk secara manual yang masih banyak diterapkan di lapangan rentan terhadap kesalahan manusia (*human error*), seperti salah baca atau salah catat, terutama pada kondisi lingkungan ekstrem berupa debu tebal, lumpur, fluktuasi pencahayaan, dan curah hujan tinggi. Kondisi tersebut menyebabkan inkonsistensi data logistik dan produksi, antrean panjang pada pos penimbangan serta stasiun pengisian bahan bakar, hingga penurunan produktivitas secara keseluruhan. Oleh karena itu, otomatisasi identifikasi nomor lambung berbasis *computer vision* menjadi kebutuhan mendesak untuk mendukung konsep *smart mining* [1], [2].

Perkembangan pesat algoritma deteksi objek berbasis *deep learning*, khususnya keluarga *You Only Look Once (YOLO)*, telah menghasilkan performa tinggi dalam berbagai aplikasi *real-time*. *YOLOv11* sebagai generasi terbaru menawarkan efisiensi komputasi dan akurasi yang lebih baik dibandingkan pendahulunya melalui arsitektur *anchor-free*, mekanisme *attention spasial (C2PSA)*, dan *Spatial Pyramid Pooling Fast (SPPF)* [3]. Beberapa penelitian terkini berhasil menerapkan *YOLOv11* untuk pengenalan *tarpaulin* truk barang di jalan raya [4], deteksi serta segmentasi objek di lokasi konstruksi dengan *mAP* hingga 0,93 [5], dan deteksi truk batubara di area transportasi tambang dengan *mAP* 0,87 [6]. Namun, mayoritas penerapan tersebut masih berfokus pada lingkungan urban atau semi-terkontrol dengan variasi visual yang relatif rendah.

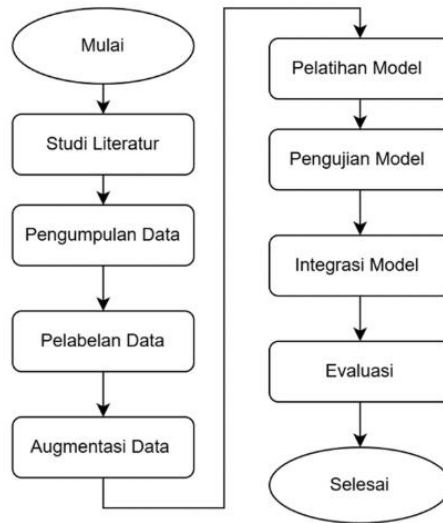
Data augmentation terbukti menjadi strategi efektif untuk meningkatkan ketangguhan model terhadap gangguan visual. Penelitian pada citra penginderaan jauh menunjukkan bahwa augmentasi berupa *noise*, *blur*, rotasi, dan perubahan kontras mampu meningkatkan akurasi deteksi hingga 5–10% pada kondisi pencahayaan buruk dan oklusi parsial [7]. Studi lain pada deteksi anomali kendaraan barang melaporkan peningkatan *precision* sebesar 5,4% setelah augmentasi intensif [8], sementara penerapan kombinasi teknik fotometrik dan geometrik berhasil menjembatani *domain gap* serta meningkatkan generalisasi model di lingkungan dinamis [9]. Temuan ini memperkuat potensi augmentasi data sebagai solusi murah dan efisien untuk meningkatkan generalisasi model di lingkungan yang tidak terprediksi.

Meskipun demikian, masih terdapat kesenjangan penelitian yang signifikan dalam penerapan *YOLOv11* untuk deteksi nomor lambung truk tambang di lingkungan *open-pit* yang ekstrem. Penelitian sebelumnya mayoritas berfokus pada pengenalan plat nomor kendaraan umum di jalan raya atau kampus dengan akurasi mendekati 99% [10], tetapi belum mengakomodasi tantangan spesifik pertambangan seperti oklusi debu tebal, sudut pandang tidak ideal, dan perubahan kondisi cuaca secara drastis. Kebaruan penelitian ini terletak pada optimasi *YOLOv11* melalui augmentasi data yang dirancang khusus untuk simulasi kondisi tambang serta pemanfaatan multi-class detection yang memungkinkan model mendeteksi truk sebagai objek utama terlebih dahulu sebelum memfokuskan lokalisasi pada area nomor lambung yang relatif kecil dan rentan gangguan visual. Integrasi ini dengan modul EasyOCR memungkinkan pembacaan karakter secara otomatis, sehingga menghasilkan solusi yang lebih tangguh dan aplikatif dibandingkan sistem berbasis plat nomor konvensional yang kurang adaptif terhadap kondisi lapangan. Kontribusi ini diharapkan memberikan solusi yang lebih tangguh dan aplikatif dibandingkan sistem berbasis plat nomor konvensional.

Tujuan penelitian ini adalah mengembangkan model *YOLOv11* yang dioptimasi dengan teknik augmentasi data untuk mendeteksi nomor lambung truk tambang secara akurat, menganalisis pengaruh berbagai teknik augmentasi terhadap peningkatan akurasi dan *robustness* model, serta menguji efektivitas model pada kondisi visual yang merepresentasikan lingkungan pertambangan terbuka secara nyata. Penelitian ini penting untuk dilakukan karena akan mendukung transformasi digital manajemen armada tambang, mengurangi ketergantungan pada tenaga manusia, serta meningkatkan akurasi data operasional pada industri pertambangan nasional yang merupakan salah satu pilar ekonomi Indonesia.

2. METODE PENELITIAN

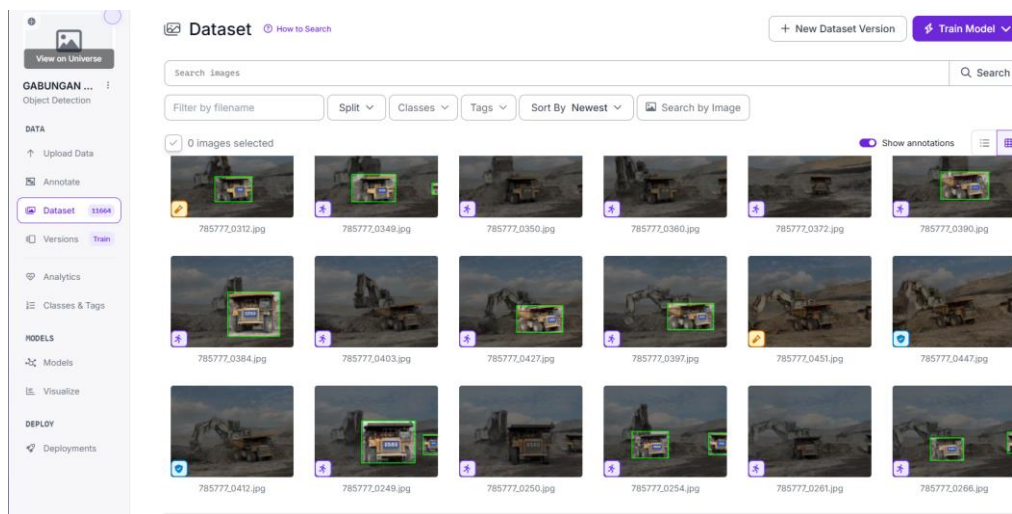
Penelitian ini menerapkan pendekatan eksperimental kuantitatif berbasis *deep learning* untuk mengoptimalkan deteksi nomor lambung truk tambang menggunakan model *YOLOv11* yang dilatih dengan strategi augmentasi data. Proses penelitian dilakukan secara *cloud-based* melalui Google Colab dan Roboflow, mencakup tahapan pengumpulan data, pelabelan, augmentasi, pelatihan, pengujian, integrasi sistem OCR dan google sheets, serta evaluasi performa model berdasarkan metrik *object detection*. Alur metodologis penelitian ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alir Penelitian

2.1. Pengumpulan Data

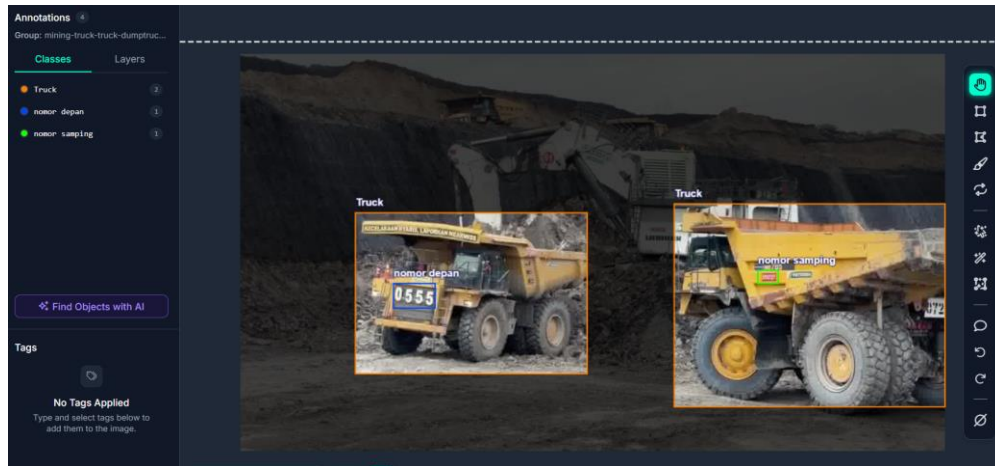
Dataset yang digunakan terdiri atas 11.664 citra hasil kombinasi antara dataset publik *Roboflow Universe* bertema *mining truck* dan *Dump Truck*, serta data sekunder dari video aktivitas truk tambang. Setiap citra mewakili variasi kondisi lingkungan tambang seperti perbedaan pencahayaan, jarak, debu, dan sudut pandang kamera. Contoh dataset ditunjukkan pada Gambar 2



Gambar 2. Dataset *Roboflow*

2.2. Pelabelan Data

Pelabelan dilakukan secara manual menggunakan *Roboflow Annotate* dengan menandai area nomor lambung pada setiap citra dalam bentuk *bounding box*. Proses ini memastikan model mengenali area numerik secara presisi. Setiap label diberi nama kelas “nomor depan, nomor samping, dan truk”. Contoh proses anotasi ditunjukkan pada Gambar 3.



Gambar 3. Proses Anotasi/ Pelabelan Data

2.3. Preprocessing

Tahapan *preprocessing* dilakukan untuk menstandarkan kualitas dan format citra sebelum pelatihan model *YOLOv11*. Dua langkah utama diterapkan, yaitu *Auto-Orient* dan *Resize (Stretch to 640×640)*. Proses *Auto-Orient* menyesuaikan orientasi citra berdasarkan metadata EXIF agar seluruh dataset memiliki arah tampilan yang konsisten. Selanjutnya, citra diubah ukurannya menggunakan metode *stretch* ke resolusi 640×640 piksel tanpa *cropping* atau *padding*, sehingga area citra tetap utuh. Tahapan ini memastikan keseragaman dimensi input, mempercepat konvergensi pelatihan, serta meningkatkan akurasi dan *robustness* model pada proses inferensi *real-time*.

2.4. Augmentasi Data

Untuk meningkatkan ketangguhan model terhadap variasi kondisi operasional di area pertambangan terbuka, proses augmentasi diterapkan secara terarah mengikuti setiap skenario pengujian. Augmentasi mencakup manipulasi fotometrik seperti *brightness* dan *noise*, serta manipulasi geometrik seperti *blur* akibat getaran dan *rotation* pada sudut kamera. Selain itu, disertakan pula skenario gabungan untuk mensimulasikan kondisi ekstrem di lapangan. Seluruh jenis augmentasi yang digunakan dalam penelitian ini ditunjukkan pada Tabel 1.

Tabel 1. Augmentasi

Jenis Augmentasi	Parameter
<i>Brightness</i>	±25%
<i>Noise</i>	5–8%
<i>Blur</i>	1–2 px
Gabungan	Gabungan

Gambar 4 menampilkan perbandingan citra sebelum dan sesudah penerapan augmentasi *brightness*, *noise*, dan *blur* sesuai parameter pada Tabel 1 sebagai validasi visual terhadap simulasi kondisi lapangan.



Gambar 4. Perbandingan Citra Sebelum dan Sesudah Augmentasi

2.5. Pelatihan Model

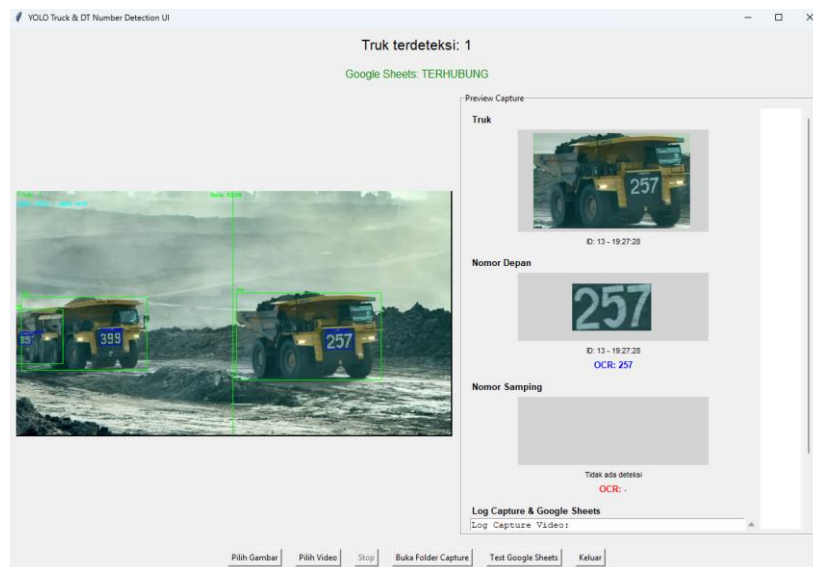
Pelatihan model dilakukan di Google Colab dengan memanfaatkan *pretrained weights YOLOv11*. Parameter utama mencakup *batch size* 16, *epochs* 100, dan ukuran citra input 640×640 piksel, dengan *loss function Complete IoU (CIoU)* untuk konvergensi yang stabil. Proses pelatihan dijalankan sesuai skenario augmentasi pada Tabel 1, di mana model dilatih secara terpisah untuk setiap skenario guna menganalisis pengaruh augmentasi terhadap performa. Hasil pelatihan divisualisasikan melalui grafik konvergensi *loss* dan peningkatan *mAP* per *epoch*, memastikan model mencapai kestabilan setelah 100 *epochs*.

2.6. Pengujian Model

Pengujian model dibagi menjadi dua jenis untuk mengevaluasi kestabilan di berbagai kondisi visual. Pertama, pengujian *offline video* menggunakan rekaman aktivitas truk tambang untuk menguji deteksi terhadap perubahan pencahayaan, sudut kamera, gerakan objek, debu, dan bayangan. Kedua, pengujian citra statis menggunakan citra tunggal dengan tingkat kompleksitas visual berbeda, seperti objek yang tertutup sebagian atau latar belakang rumit. Hasil deteksi ditampilkan dalam bentuk *bounding box* disertai nilai probabilitas sebagai indikator keyakinan model.

2.7. Integrasi Google Sheet dan EasyOCR

Hasil deteksi *bounding box* diteruskan ke modul OCR menggunakan *EasyOCR* untuk membaca karakter angka pada area terdeteksi. Output numerik kemudian dikirim secara otomatis ke *Google Sheets* melalui API sebagai proses pencatatan identitas nomor truk secara langsung tanpa intervensi manual. Integrasi ini dirancang sebagai *proof-of-concept* untuk mendukung sistem *fleet monitoring* di lingkungan pertambangan. Rancangan integrasi sistem deteksi nomor lambung truk tambang ditunjukkan pada Gambar 5



Gambar 5. Sistem Deteksi Nomor Lambung

2.8. Evaluasi Model

Evaluasi performa model dilakukan secara kuantitatif menggunakan metrik standar deteksi objek, yaitu *Precision* (P), *Recall* (R), dan *mean Average Precision* (mAP). *Precision* mengukur proporsi prediksi benar dari total prediksi positif dan dirumuskan pada persamaan (1):

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

di mana TP merupakan *true positive* dan FP merupakan *false positive*. Selanjutnya, *Recall* mengukur proporsi prediksi benar dari total instance positif aktual dan ditunjukkan pada persamaan (2):

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

di mana FN merupakan *false negative*. Adapun mAP dihitung sebagai rata-rata *Average Precision* (AP) di berbagai threshold IoU, yang ditunjukkan pada persamaan (3):

$$mAP = \frac{1}{N} \sum_{i=1}^N Ap_i \quad (3)$$

di mana (N) adalah jumlah kelas (dalam penelitian ini hanya satu kelas, yaitu nomor lambung). Selain evaluasi kuantitatif, pengamatan kualitatif dilakukan melalui visualisasi hasil deteksi untuk mengidentifikasi *false positive* dan *false negative*. Validasi juga dilakukan melalui *cross-validation* dengan pembagian dataset 70% data pelatihan, 20% data validasi, dan 10% data pengujian, serta perbandingan performa model sebelum dan sesudah dilakukan augmentasi data. Rincian pembagian dataset ditunjukkan pada Tabel 2.

Tabel 2. Pembagian Dataset

Jenis Dataset	Jumlah Data	Persentase
<i>Trainset</i>	8167	70%
<i>Validset</i>	2342	20%
<i>Testset</i>	1155	10%
Total	11664	100%

2.9. Implementasi Perangkat Keras

Pengujian sistem dilakukan menggunakan Raspberry Pi 5 sebagai perangkat komputasi utama untuk menjalankan model YOLOv11 beserta integrasi *OCR* dan *Google Sheet*. Perangkat ini berfungsi sebagai unit pemroses inferensi untuk membaca hasil deteksi pada video uji dan citra uji, tanpa menggunakan kamera secara langsung. Raspberry Pi 5 dipilih karena memiliki kemampuan komputasi yang efisien dan portabilitas tinggi, sehingga cocok diterapkan sebagai prototipe sistem berbasis *edge computing* di lingkungan tambang terbuka. Seluruh proses inferensi, pembacaan karakter, serta pengiriman data ke *Google Sheet* dilakukan secara otomatis melalui skrip *Python* yang dijalankan pada perangkat tersebut. Implementasi perangkat keras Raspberry Pi 5 dalam penelitian ini ditunjukkan pada Gambar 6



Gambar 6. Raspberry Pi 5

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil eksperimen serta pembahasan kinerja model YOLOv11 dalam mendeteksi nomor lambung truk tambang berdasarkan berbagai skenario augmentasi data. Analisis dilakukan secara kuantitatif menggunakan metrik *precision*, *recall*, dan *mean Average Precision* (mAP), serta didukung oleh evaluasi kualitatif melalui visualisasi hasil deteksi.

3.1. Evaluasi Hasil Training

Evaluasi dilakukan terhadap lima model pelatihan *YOLOv11* yang menggunakan berbagai jenis *data augmentation*, yaitu tanpa augmentasi, *brightness*, *noise*, *blur*, serta kombinasi dari beberapa teknik tersebut. Tujuan pengujian ini adalah untuk memahami pengaruh masing-masing metode *augmentation* terhadap performa model dalam mendeteksi objek angka secara akurat. Hasil evaluasi performa model berdasarkan metrik *mean Average Precision* pada ambang 0.5 (*mAP@0.5*), *mean Average Precision* pada rentang 0,5 hingga 0,95 (*mAP@0.5:0.95*), *Precision*, dan *Recall* ditunjukkan pada Tabel 3.

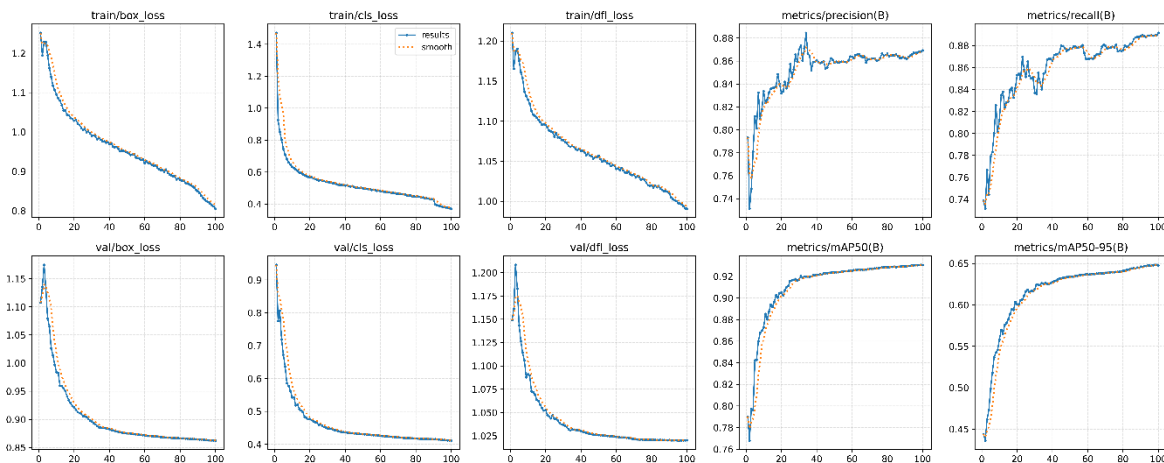
Tabel 3. Hasil Evaluasi Model YOLOv11 Terhadap Augmentasi

No.	Jenis Augmentasi	mAP@0.5	mAP@0.5:0.95	Precision	Recall
1	Tanpa Augmentasi	0,921	0,636	0,866	0,876
2	Brightness	0,927	0,641	0,857	0,897
3	Noise	0,926	0,636	0,883	0,878
4	Blur	0,928	0,646	0,863	0,894
5	Gabungan	0,931	0,648	0,868	0,89

Dari hasil pada Tabel 3 terlihat bahwa penerapan *data augmentation* memberikan dampak positif terhadap peningkatan performa model *YOLOv11*. Model tanpa augmentasi menghasilkan *mAP@0.5* sebesar 0,921 dengan *precision* 0,866 dan *recall* 0,876. Penggunaan augmentasi *brightness* meningkatkan *recall* menjadi 0,897, menunjukkan kemampuan model yang lebih baik dalam mengenali variasi pencahayaan. Penerapan *noise* menghasilkan *precision* tertinggi sebesar 0,883, menandakan bahwa teknik ini efektif dalam memperkuat ketahanan model terhadap gangguan visual atau *image artifacts*. Sementara itu, augmentasi *blur* memberikan hasil *mAP@0.5:0.95* tertinggi di antara augmentasi tunggal, yaitu sebesar 0,646, yang mengindikasikan peningkatan akurasi deteksi pada berbagai tingkat *Intersection over Union (IoU)*. Kombinasi beberapa augmentasi (*gabungan*) memberikan hasil paling optimal dengan *mAP@0.5* sebesar 0,931 dan *mAP@0.5:0.95* sebesar 0,648, serta keseimbangan antara *precision* (0,868) dan *recall* (0,890). Hal ini menunjukkan bahwa kombinasi augmentasi mampu meningkatkan kemampuan generalisasi model *YOLOv11* terhadap berbagai kondisi citra di dunia nyata, sebagaimana berbagai studi terkini pada sistem berbasis deep learning yang menunjukkan bahwa variasi data latih berpengaruh terhadap peningkatan akurasi model [11]. Secara keseluruhan, hasil ini membuktikan bahwa penerapan strategi *data augmentation* yang tepat, terutama kombinasi teknik *brightness*, *noise*, dan *blur*, dapat secara signifikan meningkatkan performa dan ketangguhan model *YOLOv11* dalam tugas deteksi objek.

3.2. Grafik Training Model Yolov11 dengan Augementasi Gabungan


Proses pelatihan model *YOLOv11* dengan penerapan augmentasi gabungan, yang melibatkan transformasi fotometrik (*brightness* dan *noise*) serta transformasi geometrik (*blur*), menghasilkan serangkaian metrik evaluasi yang meliputi *box loss*, *classification loss*, dan *distribution focal loss (DFL)*, diikuti oleh metrik performa utama seperti *precision*, *recall*, *mAP@0.5*, dan *mAP@0.5:0.95*. Grafik yang disajikan pada Gambar 7 mengilustrasikan dinamika konvergensi metrik-metrik tersebut selama 100 *epoch* proses pelatihan.



Gambar 7. Grafik Augmentasi Gabungan

Berdasarkan Gambar 7, terlihat bahwa model *YOLOv11* menunjukkan pola konvergensi yang stabil dan konsisten sepanjang proses pelatihan. Nilai *box loss* dan *DFL loss* mengalami penurunan signifikan pada fase awal (sekitar *epoch* ke-1 hingga ke-20), kemudian menurun secara gradual hingga mencapai kestabilan pada kisaran 0,8–1,0 pada *epoch* ke-100. Tren ini mengindikasikan bahwa model telah mampu menyesuaikan parameter internalnya secara efektif untuk meminimalkan kesalahan prediksi posisi *bounding box* dan distribusi fitur spasial. Sementara itu, *classification loss* menunjukkan pola penurunan yang relatif cepat pada 10 *epoch* pertama dan cenderung konvergen setelahnya, menandakan bahwa model telah berhasil membedakan kelas target secara efisien tanpa mengalami fluktuasi yang berarti. Sumbu X pada grafik merepresentasikan jumlah *epoch* pelatihan, sedangkan sumbu Y menunjukkan nilai metrik evaluasi yang digunakan untuk menilai kinerja model. Kurva hasil pelatihan (berwarna biru) dan validasi (berwarna oranye) memperlihatkan kecenderungan yang searah dan berjarak kecil, yang menunjukkan tidak adanya indikasi *overfitting* maupun *underfitting* yang signifikan. Kestabilan tersebut menegaskan bahwa penerapan augmentasi gabungan berkontribusi terhadap peningkatan kemampuan generalisasi model terhadap data yang tidak pernah dilihat selama proses pelatihan. Dari sisi performa deteksi, peningkatan bertahap terlihat pada metrik *precision* dan *recall*, yang masing-masing mencapai nilai 0,87 dan 0,89 pada akhir proses pelatihan. Nilai ini menunjukkan keseimbangan antara kemampuan model dalam mempertahankan ketepatan prediksi (*true positive rate*) dan kemampuan mendeteksi seluruh objek relevan pada dataset. Lebih lanjut, nilai *mAP@0.5* meningkat secara progresif hingga mencapai 0,93, sedangkan *mAP@0.5:0.95* mencapai 0,65, yang mengindikasikan bahwa model tidak hanya akurat pada ambang *IoU* tunggal tetapi juga konsisten pada berbagai tingkat kesamaan spasial antara prediksi dan *ground truth*.

3.3. Confusion Matrix



Gambar 8. Confusion Matrix

Untuk mengevaluasi performa klasifikasi secara lebih mendalam, digunakan *confusion matrix* yang merepresentasikan hubungan antara label sebenarnya (*ground truth*) dan label hasil prediksi model *YOLOv11*. *Confusion matrix* memberikan gambaran komprehensif mengenai sejauh mana model mampu mengenali setiap kelas objek, sekaligus mengidentifikasi pola kesalahan klasifikasi yang terjadi pada proses inferensi. Berdasarkan hasil *confusion matrix* yang ditampilkan pada Gambar 8, model *YOLOv11* menunjukkan performa klasifikasi yang sangat baik pada sebagian besar kelas, terutama pada kelas truck dan nomor depan. Kelas *truck* memiliki jumlah prediksi benar (*true positive*) tertinggi yaitu sebanyak 7.471 instance, yang menunjukkan bahwa model sangat efektif dalam mendeteksi objek utama dengan ukuran dan bentuk dominan pada citra. Kelas *nomor depan* juga menunjukkan akurasi yang tinggi dengan 2.443 prediksi benar, meskipun masih terdapat 354 instance yang salah diklasifikasikan sebagai latar belakang (*background*) akibat ukuran objek yang kecil serta faktor gambar yang terlihat kondisi ekstrem tambang. Sementara itu, kelas *nomor samping* memiliki jumlah prediksi benar sebesar 175 instance, dengan sebagian kecil kesalahan prediksi menuju kelas *background* dan *nomor depan*. Jumlah *false negative* pada kelas ini relatif lebih tinggi dibandingkan kelas lain, mengindikasikan bahwa model masih menghadapi tantangan dalam mendeteksi nomor lambung samping yang umumnya berukuran kecil dan sering mengalami distorsi akibat sudut pandang kamera atau pencahayaan yang tidak merata.

Pada sisi lain, *background* mengalami kesalahan klasifikasi sebesar 634 instance yang teridentifikasi sebagai *truck* dan 127 instance sebagai *nomor depan*. Pola ini menunjukkan bahwa model sesekali salah menginterpretasikan area latar belakang dengan tekstur atau pola yang menyerupai bentuk numerik atau bagian badan truk. Meskipun demikian, rasio kesalahan tersebut tergolong kecil dibandingkan total prediksi yang dilakukan, sehingga tidak memengaruhi performa keseluruhan secara signifikan. Secara umum, *confusion matrix* memperlihatkan bahwa model *YOLOv11* memiliki kemampuan generalisasi yang baik terhadap variasi data dengan akurasi dominan pada kelas objek utama. Kesalahan klasifikasi yang tersisa cenderung muncul pada kelas dengan karakteristik visual serupa atau area yang terpengaruh oleh kondisi pencahayaan ekstrem dan *noise* tinggi. Fenomena ini juga menegaskan pentingnya augmentasi data dalam memperkuat kemampuan model menghadapi variasi spasial dan fotometrik yang kompleks.

3.4. Perbandingan Hasil dengan Penelitian Sebelumnya

Penelitian ini menunjukkan bahwa model *YOLOv11* yang telah dioptimalkan melalui tahapan *preprocessing* dan *data augmentation* mampu memberikan performa deteksi yang lebih baik pada objek berukuran kecil, seperti nomor lambung truk tambang, dibandingkan penelitian sebelumnya yang menerapkan *YOLOv11-Seg* untuk pemantauan kendaraan tambang [12]. Pada penelitian tersebut diperoleh nilai *mAP@0.5* sebesar 0,87854, sedangkan pada penelitian ini nilai *mAP@0.5* mencapai 0,931. Peningkatan ini menunjukkan bahwa penerapan strategi augmentasi gabungan mampu meningkatkan akurasi deteksi secara signifikan, terutama ketika model diuji pada kondisi lingkungan tambang yang memiliki pencahayaan tidak stabil, debu, serta gangguan visual lainnya.

Penelitian lain yang menggunakan *YOLOv8l* untuk deteksi objek berbasis *Unmanned Aerial Vehicle (UAV)* melaporkan nilai *mAP@0.5* sebesar 0,814 [13]. Jika dibandingkan dengan hasil tersebut, dapat dilihat bahwa arsitektur *YOLOv11* yang lebih baru, serta didukung oleh tahapan *preprocessing* dan augmentasi fotometrik serta geometrik, mampu memberikan kinerja yang lebih baik. Hal ini khususnya terlihat pada kemampuan model dalam mendeteksi objek kecil dengan variasi bentuk dan ukuran yang tinggi, seperti nomor lambung truk tambang. Selain itu, hasil ini juga menunjukkan bahwa strategi augmentasi yang diterapkan berperan penting dalam meningkatkan kemampuan generalisasi model terhadap kondisi visual ekstrem.

Pada penelitian sebelumnya yang menerapkan *YOLOv11* untuk deteksi plat nomor kendaraan, diperoleh nilai *mAP@0.5* sebesar 0,906 dengan nilai *recall* sebesar 0,911 [14]. Meskipun performa yang dihasilkan cukup tinggi, penelitian tersebut dilakukan pada lingkungan yang relatif terkontrol, seperti area kampus dan jalan raya, sehingga tingkat gangguan visual yang dihadapi lebih rendah. Sebaliknya, penelitian ini menggunakan dataset dengan variasi kondisi yang lebih kompleks, seperti adanya debu, oklusi sebagian objek, serta sudut pandang yang ekstrem. Meskipun demikian, model yang diusulkan tetap mampu mencapai nilai *precision* dan *recall* yang kompetitif, sehingga menunjukkan tingkat ketangguhan yang lebih baik untuk diterapkan pada kondisi nyata di area tambang terbuka.

Penelitian lain yang menggabungkan *YOLOv11 Nano* dengan *PaddleOCR* untuk pendeteksian plat nomor kendaraan memperoleh nilai *mAP@0.5* sebesar 0,883 [15]. Nilai tersebut masih berada di bawah hasil yang dicapai pada penelitian ini. Perbedaan performa ini menunjukkan bahwa penggunaan varian *YOLOv11* dengan kapasitas model yang lebih besar, disertai dengan penerapan *Auto-Orient preprocessing* dan augmentasi data gabungan, mampu meningkatkan akurasi deteksi angka yang berukuran kecil dan sering mengalami distorsi visual. Dengan demikian, model yang dikembangkan dalam penelitian ini dinilai lebih sesuai untuk diterapkan pada tugas deteksi numerik di lingkungan tambang yang memiliki tingkat gangguan visual tinggi.

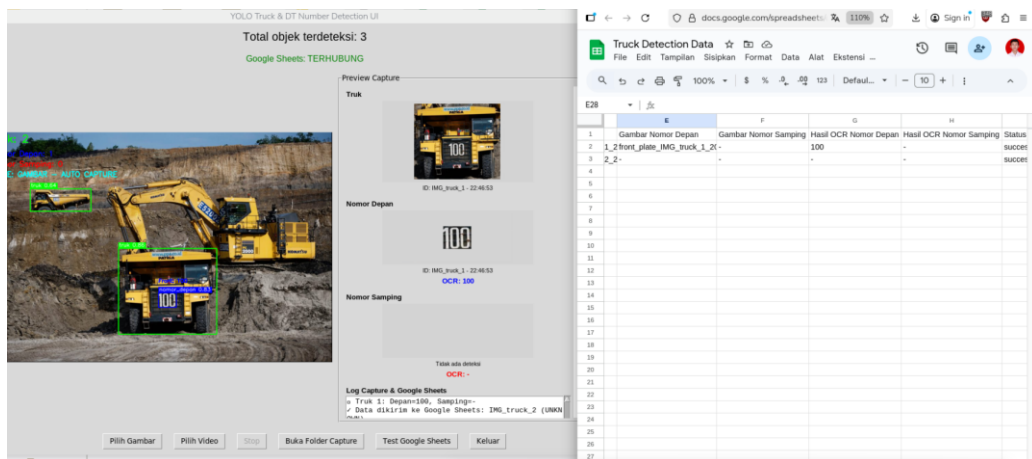
Secara keseluruhan, jika dibandingkan dengan penelitian sebelumnya [11]–[14], model *YOLOv11* yang diusulkan dalam penelitian ini menunjukkan performa yang lebih unggul pada nilai *mAP@0.5*, sekaligus mampu mempertahankan nilai *precision* dan *recall* yang stabil. Hasil ini membuktikan bahwa kombinasi *preprocessing* dan *data augmentation* yang tepat dapat meningkatkan ketahanan model terhadap variasi visual ekstrem, sehingga lebih layak diterapkan sebagai sistem identifikasi truk tambang berbasis *computer vision*. Ringkasan perbandingan hasil dengan penelitian terdahulu ditunjukkan pada Tabel 4.

Tabel 4. Perbandingan Hasil dengan Penelitian Terdahulu

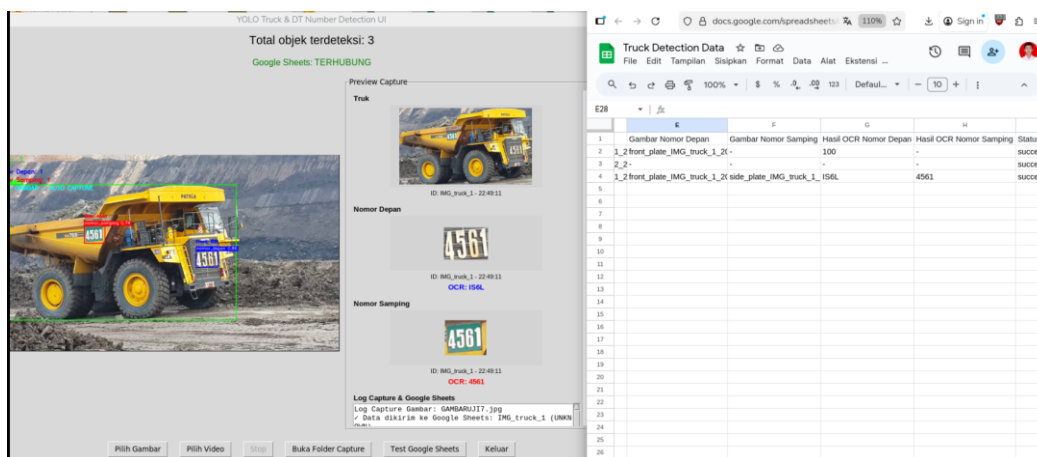
Ref	Metode	mAP@0.5	mAP@0.5:0.95	Precision	Recall
[12]	YOLOv11-Seg (proposed)	0,87854	0,76846	0,85834	0,85985
[13]	YOLOv8l	0,814	0,632	0,92	0,784
[14]	YOLOv11	0,906	0,631	0,891	0,911
[15]	YOLOv11 (Nano) + PaddleOCR	0,883	0,644	0,869	0,886
	Penelitian yang diusulkan	0,931	0,648	0,868	0,89

3.5. Eksperimen Hasil Deteksi Model Yolov11 dengan OCR dan Google Sheet

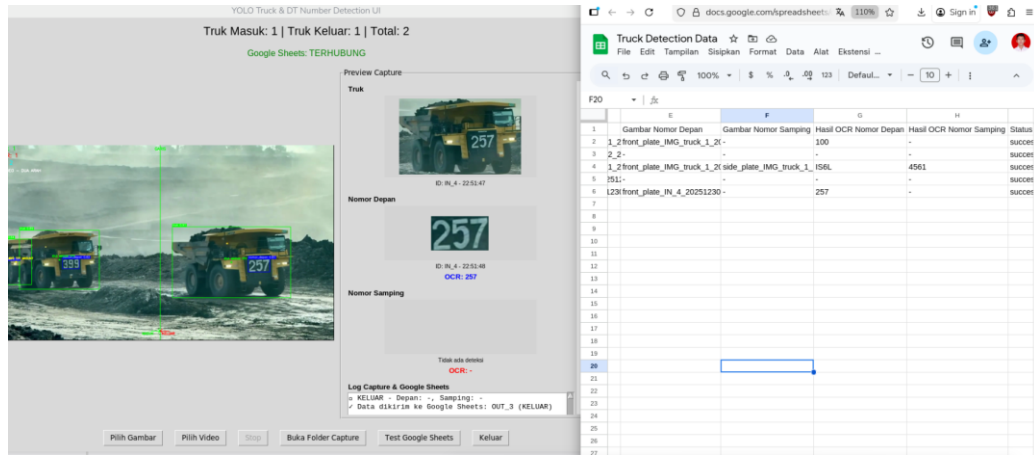
Implementasi hasil deteksi dilakukan dengan menguji model YOLOv11 yang telah dilatih pada perangkat Raspberry Pi 5 untuk mengamati kinerja sistem secara nyata. Model ini diintegrasikan dengan modul *EasyOCR* guna membaca karakter numerik pada area yang terdeteksi dan mengirimkan hasilnya secara otomatis ke *Google Sheet* melalui *API*. Pengujian dilakukan menggunakan beberapa citra truk tambang dengan variasi posisi, pencahayaan, dan kondisi lingkungan untuk menilai keandalan sistem dalam mendeteksi serta mengenali nomor lambung. Hasil pengujian menunjukkan bahwa sistem mampu melakukan proses deteksi dan pengiriman data secara real-time dengan tingkat akurasi yang cukup baik, meskipun masih terdapat beberapa kesalahan pembacaan angka pada citra dengan kualitas rendah. Sistem juga diuji dari sisi kecepatan inferensi dan menghasilkan rata-rata 3,1 *frames per second* (FPS) pada Raspberry Pi 5, yang mencakup proses deteksi, OCR, dan pengiriman data melalui (API). Berikut merupakan hasil uji coba implementasi sistem yang ditampilkan pada Gambar 9(a), (b), dan (c).



(a)



(b)



(c)

Gambar 9. (a),(b),(c) Hasil Pengujian Sistem di Raspberry Pi 5 koneksi ke Google Sheet

Tabel 5. Hasil Eksperimen Pengujian

No	Gambar	Angka Nomor Depan	Angka Nomor Samping	Hasil
1		100	-	Semua Angka Terdeteksi
2		IS6L	4561	3 Angka Nomor Depan Salah Terdeteksi

No	Gambar	Angka Nomor Depan	Angka Nomor Samping	Hasil
3	<p>Preview Capture</p> <p>Truk</p>  <p>ID: IMG_truck_1 - 23.02.53</p> <p>Nomor Depan</p>  <p>ID: IMG_truck_1 - 23.02.53 OCR: 5056</p> <p>Nomor Samping</p>  <p>ID: IMG_truck_1 - 23.02.53 OCR: 65056</p>	5056	65056	1 Angka Nomor Samping Salah Terdeteksi
4	<p>Preview Capture</p> <p>Truk</p>  <p>ID: OUT_2 - 23.08.09</p> <p>Nomor Depan</p>  <p>ID: OUT_2 - 23.08.09 OCR: 0704</p> <p>Nomor Samping</p> <p>Tidak ada deteksi OCR: -</p>	0704	-	Semua Angka Terdeteksi
5	<p>Preview Capture</p> <p>Truk</p>  <p>ID: IN_9 - 23.11.15</p> <p>Nomor Depan</p>  <p>ID: IN_9 - 23.11.15 OCR: 235</p> <p>Nomor Samping</p> <p>Tidak ada deteksi OCR: -</p>	235	-	Semua Angka Terdeteksi

3.6. Pembahasan

Hasil eksperimen implementasi model YOLOv11 pada perangkat Raspberry Pi 5 menunjukkan bahwa sistem deteksi dan pembacaan nomor lambung truk dapat berjalan secara *real-time* dengan integrasi ke *Google Sheet* melalui modul *EasyOCR*. Analisis implementasi sistem dilakukan berdasarkan lima sampel pengujian seperti yang ditunjukkan pada Tabel 5. Dari lima skenario uji tersebut, tiga sampel (60%) berhasil terdeteksi dan terbaca dengan benar tanpa kesalahan angka, sedangkan dua sampel (40%) mengalami kesalahan sebagian pada pembacaan karakter. Kesalahan yang terjadi bukan karena objek tidak terdeteksi, melainkan karena

kesalahan pembacaan angka oleh OCR, sehingga dapat diketahui bahwa model YOLOv11 telah mampu mendeteksi lokasi nomor lambung dengan baik.

Pada sampel kedua, tiga digit nomor depan tidak terbaca dengan benar karena kondisi pencahayaan yang kurang baik dan kontras angka yang rendah terhadap bodi truk. Hal ini menyebabkan bentuk angka menjadi kurang jelas sehingga *EasyOCR* kesulitan mengenali pola karakter secara tepat. Pada sampel ketiga, terjadi kesalahan satu digit pada nomor samping yang diduga dipengaruhi oleh sudut pengambilan gambar yang miring sehingga angka terlihat terdistorsi dan ukurannya relatif kecil pada citra. Jika dikaitkan dengan hasil *confusion matrix* pada Subbab 3.3, kelas “nomor samping” memang memiliki tingkat kesalahan lebih tinggi dibandingkan kelas lainnya. Hal ini menunjukkan bahwa nomor yang berada di samping truk lebih rentan terhadap pengaruh sudut kamera dan jarak pengambilan gambar. Dengan demikian, hasil implementasi ini memperlihatkan bahwa tantangan sistem saat ini lebih dominan pada tahap pembacaan karakter dibandingkan tahap deteksi objek.

4. KESIMPULAN

Penelitian ini berhasil mengoptimalkan deteksi nomor lambung truk tambang menggunakan model YOLOv11 yang dikombinasikan dengan tahapan *preprocessing* dan strategi *data augmentation*. Hasil eksperimen menunjukkan bahwa kombinasi augmentasi fotometrik dan geometrik mampu meningkatkan nilai mAP@0.5 hingga 0,931 dengan precision sebesar 0,868 dan recall sebesar 0,890. Peningkatan ini membuktikan bahwa model memiliki ketahanan yang baik terhadap variasi kondisi visual seperti pencahayaan tidak stabil, debu, serta sudut pandang kamera yang berbeda. Pengujian pada perangkat Raspberry Pi 5 dilakukan menggunakan data citra dan video uji secara *offline*, yang menunjukkan sistem mampu melakukan deteksi dan pembacaan angka secara otomatis dengan integrasi *EasyOCR* dan *Google Sheet*.

Namun demikian, sistem yang dikembangkan pada penelitian ini masih merupakan prototipe awal (*proof-of-concept*) dan belum sepenuhnya diimplementasikan secara langsung di area tambang terbuka. Berdasarkan hasil pembahasan, kendala utama yang masih ditemukan terletak pada tahap pembacaan karakter oleh OCR, terutama pada kondisi refleksi cahaya pada bodi truk, kontras angka yang rendah, serta sudut pengambilan gambar yang menyebabkan distorsi visual. Untuk penelitian selanjutnya, disarankan penggunaan filter fisik pada lensa kamera untuk mengurangi pantulan cahaya yang dapat mengganggu proses OCR. Selain itu, peningkatan kualitas dan jumlah dataset pelatihan, serta pengembangan metode pembacaan angka langsung melalui model YOLO (misalnya dengan mendeteksi setiap digit sebagai kelas tersendiri), dapat menjadi solusi untuk meningkatkan akurasi sistem secara keseluruhan. Dengan pengembangan lebih lanjut, sistem ini berpotensi untuk diterapkan sebagai sistem identifikasi armada truk tambang berbasis *computer vision* yang lebih stabil dan siap digunakan secara *real-time*.

DAFTAR PUSTAKA

- [1] D. Shan, F. Qu, Z. Wang, Y. Ji, and J. Xu, “A Review of the Application of Computer Vision Techniques in Sustainable Engineering of Open Pit Mines,” *Sustain.*, vol. 17, no. 7, pp. 1–16, 2025, doi: 10.3390/su17073051.
- [2] K. Hasözdemir, M. Meral, and M. M. Kahraman, “Revolutionizing Open-Pit Mining Fleet Management: Integrating Computer Vision and Multi-Objective Optimization for Real-Time Truck Dispatching,” *Appl. Sci.*, vol. 15, no. 9, 2025, doi: 10.3390/app15094603.
- [3] M. Kotthapalli, D. Ravipati, and R. Bhatia, “YOLOv1 to YOLOv11: A Comprehensive Survey of Real-Time Object Detection Innovations and Challenges,” pp. 1–13, 2025, [Online]. Available: <http://arxiv.org/abs/2508.02067>
- [4] J. Guo and M. Zhang, “An Improved YOLOv11 Recognition Algorithm for Heavy-Duty Trucks on Highways,” pp. 1–18, 2025.
- [5] L. He, Y. Zhou, L. Liu, and J. Ma, “Research and Application of YOLOv11-Based Object Segmentation in Intelligent Recognition at Construction Sites,” *Buildings*, vol. 14, no. 12, 2024, doi: 10.3390/buildings14123777.
- [6] A. Oktarino, A. Subahi, N. A. Alghanmi, A. B. F. Mansur, A. Tenriawaru, and A. H. Basori, “Deep Learning-Based Generalized Efficient Layer Aggregation Network for the Detection of Coal Trucks,” *TEM J.*, vol. 14, no. 1, pp. 416–428, 2025, doi: 10.18421/TEM141-37.
- [7] X. Hao, L. Liu, R. Yang, L. Yin, L. Zhang, and X. Li, “A Review of Data Augmentation Methods of Remote Sensing Image Target Recognition,” *Remote Sens.*, vol. 15, no. 3, 2023, doi: 10.3390/rs15030827
- [8] H. Jianfeng, G. Cui, J. Du, C. Wang, and L. Zhang, “Enhanced YOLOv11 for Image-Based Anomaly Detection in Freight Train Gate Chains,” *Int. J. Intell. Inf. Technol.*, vol. 21, no. 1, 2024, doi: <https://doi.org/10.4018/IJIT.386138>.
- [9] Z. Yang, R. O. Sinnott, J. Bailey, and Q. Ke, *A survey of automated data augmentation algorithms for deep learning-based image classification tasks*, vol. 65, no. 7. Springer London, 2023. doi: 10.1007/s10115-023-01853-2.
- [10] E. P. Silmina and R. A. Y. Arjun, “Pemanfaatan Model YOLOv8 Untuk Mendeteksi Plat Nomor Kendaraan Mobil Pada Gerbang Masuk Universitas XYZ,” *J. Sains dan Inform.*, vol. 11, no. 1, pp. 50–59, 2025, doi:

- 10.34128/jsi.v11i1.916.
- [11] P. Kaur, "Data Augmentation for Object Detection : A Review," pp. 537–543, 2021.
 - [12] L. He and Y. Zhou, "Real-Time Vision-Based Monitoring of Mining Vehicles for Intelligent Industrial Systems," *SSRN Electron. J.*, 2025, doi: 10.2139/ssrn.5355956.
 - [13] V. Balaska, I. T. Papapetros, K. M. Oikonomou, L. Bampis, and A. Gasteratos, "UAV Object Detection and Positioning in a Mining Industrial Metaverse with Custom Geo-Referenced Data," vol. 14, no. 8, pp. 1–12, 2021.
 - [14] N. A. Kurniawan and C. A. Sari, "Automatic License Plate Detection System with YOLOv11 Algorithm," vol. 9, no. 6, pp. 3097–3109, 2025.
 - [15] M. Yolov and D. Paddleocr, "Sistem Deteksi Dan Pengenalan Plat Nomor Kendaraan," vol. 3, no. 2, pp. 1–6, 2025, doi: 10.26714/jkti.v3i2.18678.