

# Evaluasi Performa Yolov8 Dalam Deteksi Objek Di Depan Kendaraan Dengan Variasi Kondisi Lingkungan

<sup>1</sup>Taufiqurrahman, <sup>2</sup>Aji Prasetya Hadi, <sup>3</sup>Rully Emirza Siregar  
<sup>1, 2, 3</sup>Politeknik Wilmar Bisnis Indonesia

[taufiq@wbi.ac.id](mailto:taufiq@wbi.ac.id), [aji.prasetya.hadi@wbi.ac.id](mailto:aji.prasetya.hadi@wbi.ac.id), [rully.emirza.siregar@wbi.ac.id](mailto:rully.emirza.siregar@wbi.ac.id)

## ABSTRAK

Keselamatan berlalu lintas adalah isu global yang membutuhkan perhatian serius mengingat tingginya angka kecelakaan setiap tahun. Penelitian ini bertujuan mengevaluasi performa YOLOv8, algoritma deteksi objek berbasis deep learning, dalam mendeteksi elemen-elemen penting lalu lintas seperti kendaraan, pejalan kaki, dan rambu lalu lintas. Dataset yang digunakan terdiri dari video jalan biasa dan jalan tol, direkam pada enam waktu berbeda (08:00, 10:00, 12:00, 18:00, 20:00, dan 22:00) untuk menangkap variasi pencahayaan dan kepadatan lalu lintas. Tiga varian YOLOv8, yaitu YOLOv8n, YOLOv8s, dan YOLOv8m, diuji untuk menganalisis akurasi, jumlah deteksi, dan performa dalam berbagai kondisi lingkungan. Hasil penelitian menunjukkan bahwa YOLOv8m memiliki performa terbaik dengan rata-rata *confidence score* tertinggi, khususnya pada kondisi pencahayaan optimal di siang hari. YOLOv8s menawarkan keseimbangan antara efisiensi dan akurasi, sedangkan YOLOv8n menunjukkan keterbatasan dalam mendeteksi objek pada kondisi pencahayaan rendah dan kompleksitas lingkungan yang tinggi. Jalan tol, dengan lingkungan yang lebih terstruktur, memberikan hasil deteksi yang lebih konsisten dibandingkan jalan biasa yang menghadirkan tantangan berupa variasi objek dan pencahayaan. Kesimpulannya, YOLOv8m adalah model yang paling efektif untuk aplikasi berbasis keselamatan lalu lintas, sementara YOLOv8n cocok untuk perangkat keras dengan sumber daya terbatas. Penelitian selanjutnya diharapkan dapat mengoptimalkan deteksi pada objek kecil dan meningkatkan performa di kondisi pencahayaan rendah melalui pelatihan ulang model menggunakan *dataset* yang lebih kompleks.

**Kata Kunci:** Keselamatan Lalu Lintas, Deteksi Objek, YOLOv8, Deep Learning, Variasi Pencahayaan, Model Pretrained.

## PENDAHULUAN

Keselamatan berlalu lintas merupakan isu global yang terus menjadi perhatian serius, mengingat tingginya angka kecelakaan yang memberikan dampak besar pada kehidupan manusia. Berdasarkan data *World Health Organization* (WHO), kecelakaan lalu lintas menyebabkan lebih dari 1,3 juta kematian setiap tahunnya, menjadikannya salah satu penyebab utama kematian di dunia. Di Indonesia, data Korlantas Polri pada tahun 2021 menunjukkan terdapat 103.645 kasus kecelakaan lalu lintas yang mengakibatkan 25.266 korban meninggal dunia, 10.553 korban luka berat, dan 117.913 korban luka ringan. Kerugian material akibat kecelakaan ini mencapai 246.653 juta rupiah (Mardikawati et al., 2023). Tingginya angka kecelakaan ini mencerminkan perlunya solusi yang lebih baik untuk meningkatkan keselamatan berlalu lintas, terutama melalui teknologi yang mampu mendeteksi objek secara cepat dan akurat.

*Deep learning* telah menjadi salah satu terobosan teknologi yang menjanjikan dalam mendeteksi objek secara otomatis dan *real-time* (Afandi et al., 2024; Rahman et al., 2023;

Wakhidah et al., 2023). Algoritma YOLO (*You Only Look Once*) merupakan salah satu pendekatan terdepan yang dikenal karena keunggulannya dalam mendeteksi objek dengan efisiensi tinggi (Maulana et al., 2024; Zophie & Triharminto, 2023). Berbeda dengan algoritma deteksi objek lainnya yang membutuhkan beberapa tahap pemrosesan, YOLO mampu mendeteksi dan mengklasifikasikan objek dalam satu langkah, sehingga jauh lebih cepat tanpa mengorbankan akurasi. Kecepatan ini membuat YOLO sangat cocok untuk aplikasi *real-time*, seperti deteksi objek dalam sistem bantuan pengemudi atau kendaraan otonom. Selain itu, arsitektur YOLO dirancang untuk bekerja secara efisien pada perangkat keras dengan sumber daya terbatas (Ravi & El-Sharkawy, 2022; Zhang et al., 2022), menjadikannya relevan untuk diimplementasikan pada perangkat di kendaraan.

Keunggulan lain dari YOLO adalah kemampuannya untuk mendeteksi berbagai jenis objek secara simultan, bahkan dalam kondisi lingkungan yang kompleks. YOLO telah terbukti unggul dalam mendeteksi objek kecil (Pham et al., 2020), objek yang tumpang tindih (Jiang et al., 2022), serta dalam menangani variasi pencahayaan (Mirhaji et al., 2021). Fleksibilitas ini menjadikannya pilihan utama untuk sistem yang membutuhkan deteksi objek pada skenario dunia nyata, seperti jalan raya dengan variasi lalu lintas dan kondisi pencahayaan yang berbeda. Selain itu, YOLO dirancang untuk mendeteksi objek pada seluruh area gambar (*global detection*), sehingga memiliki cakupan yang lebih luas dibandingkan dengan metode deteksi berbasis *region proposals*.

Penelitian ini menggunakan dataset yang terdiri dari video jalan biasa dan jalan tol yang diambil pada enam waktu berbeda, yaitu pukul 08.00, 10.00, 12.00, 18.00, 20.00, dan 22.00, untuk menangkap variasi pencahayaan dan kepadatan lalu lintas. *Dataset* ini digunakan untuk menguji kemampuan YOLO dalam mendeteksi objek-objek yang relevan dengan keselamatan berkendara, seperti kendaraan lain, pejalan kaki, dan rambu lalu lintas. Fokus penelitian ini adalah mengevaluasi performa YOLO dalam kondisi dunia nyata dan menganalisis kemampuannya dalam mendeteksi objek pada berbagai skenario.

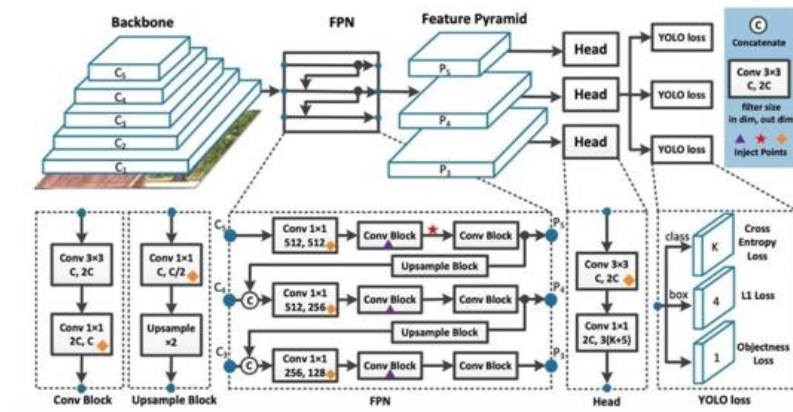
Meskipun teknologi YOLO telah diaplikasikan secara luas, masih terdapat tantangan dalam penerapannya pada kondisi dunia nyata. YOLO mampu mendeteksi objek dengan kecepatan tinggi, tetapi akurasinya dapat menurun pada kondisi lingkungan yang kompleks (Krišto et al., 2020). YOLOv4 menunjukkan peningkatan akurasi deteksi, namun model ini masih menghadapi kesulitan dalam mendeteksi objek kecil atau dalam kondisi pencahayaan rendah (Chen et al., 2022). Penelitian ini bertujuan untuk mengevaluasi kemampuan YOLO dalam mengatasi tantangan tersebut dan memberikan wawasan tentang keunggulan serta keterbatasannya.

Tujuan utama penelitian ini adalah untuk mengevaluasi performa YOLO dalam mendeteksi objek secara akurat pada video kendaraan dari dua jenis jalan, yaitu jalan biasa dan jalan tol, dengan mempertimbangkan variasi kondisi lingkungan. Penelitian ini juga bertujuan untuk memberikan kontribusi nyata dalam pengembangan teknologi keselamatan berkendara berbasis deteksi objek yang dapat diimplementasikan pada sistem transportasi cerdas di masa depan.

## TINJAUAN PUSTAKA

### YOLO (*You Only Look Once*)

*Framework* yang digunakan dalam penelitian ini adalah algoritma YOLO (*You Only Look Once*), yang merupakan salah satu metode deteksi objek berbasis *deep learning* dengan keunggulan utama dalam hal kecepatan dan akurasi. YOLO dirancang untuk mendeteksi objek dalam satu langkah pemrosesan, berbeda dengan metode deteksi objek tradisional yang memerlukan beberapa tahap, seperti seleksi wilayah (*region proposals*) dan klasifikasi (Aziz et al., 2020; Wu et al., 2020). Pendekatan ini memungkinkan YOLO untuk mendeteksi berbagai jenis objek secara efisien dalam satu gambar atau *frame* video, menjadikannya ideal untuk aplikasi *real-time* seperti sistem keselamatan kendaraan. Keunggulan YOLO meliputi kecepatan pemrosesan yang tinggi, kemampuan mendeteksi objek secara global dalam satu gambar, akurasi yang baik bahkan dalam kondisi lingkungan kompleks, serta efisiensi yang memungkinkan implementasi pada perangkat keras dengan sumber daya terbatas.



Gambar 1. Arsitektur YOLOv8.

Dalam penelitian ini, tiga varian YOLO digunakan, yaitu YOLOv8n (*nano*), YOLOv8s (*small*), dan YOLOv8m (*medium*). Ketiga varian ini dipilih untuk mengevaluasi performa deteksi objek pada berbagai skenario dunia nyata. YOLOv8n menawarkan efisiensi tinggi dengan konsumsi sumber daya rendah, YOLOv8s memberikan keseimbangan antara efisiensi dan akurasi, sedangkan YOLOv8m menawarkan akurasi yang lebih tinggi dengan kebutuhan komputasi yang lebih besar. Penelitian ini menggunakan *pretrained* model yang telah dilatih pada *dataset* berskala besar untuk memanfaatkan pengetahuan awal model, sehingga memungkinkan pengujian langsung pada *dataset* video tanpa perlu pelatihan ulang. Proses deteksi dilakukan dengan menerapkan model pada setiap *frame* video, menghasilkan anotasi berupa *bounding box*, label kelas, dan nilai *confidence score* untuk setiap objek yang terdeteksi. Pendekatan ini memastikan bahwa performa deteksi dapat dievaluasi secara efisien pada berbagai kondisi lingkungan.

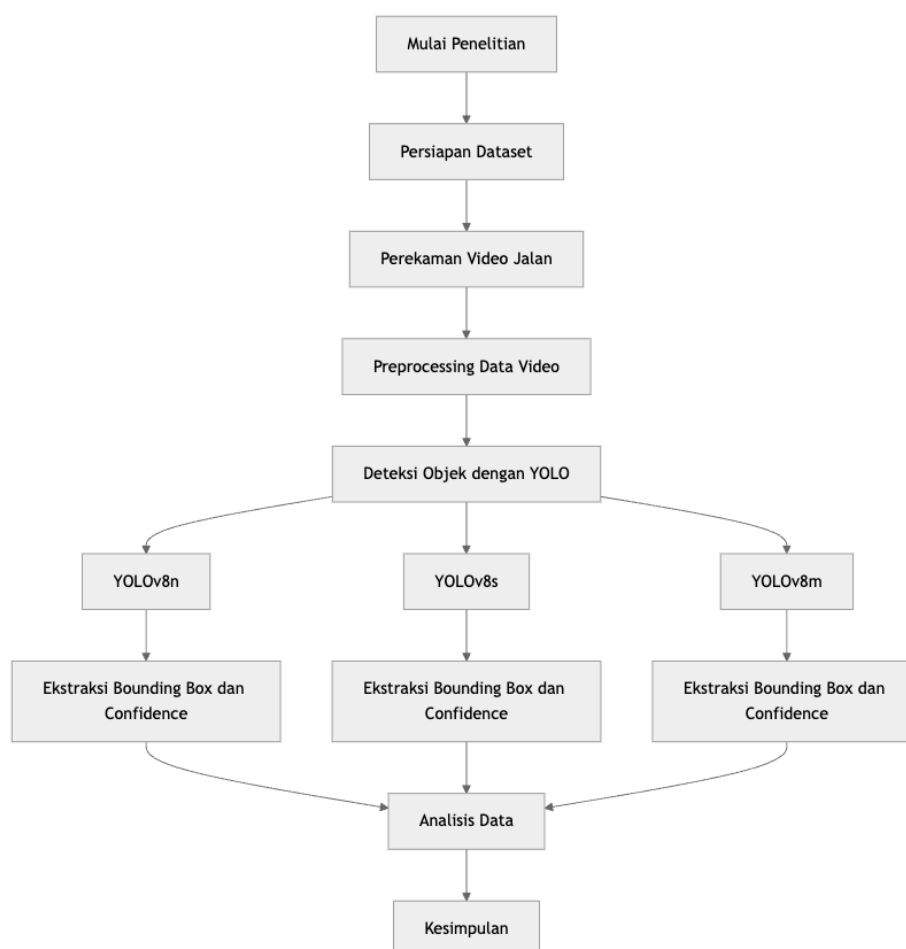
Tabel 1. Spesifikasi teknis model YOLOv8, termasuk ukuran *input*, akurasi deteksi (mAPval 50-95), kecepatan pemrosesan pada *CPU* dan *GPU*, serta *parameter* dan kompleksitas komputasi (*FLOPs*), untuk berbagai varian model (Sumber: *Ultralytics YOLOv8 Documentation*).

<i>Model</i>	<i>size</i>	<i>mAP</i>	<i>Speed CPU ONNX</i>	<i>Speed A100 TensorRT</i>	<i>params</i>	<i>FLOPs</i>
<a href="#">YOLOv8n</a>	640	37.3	80.4	0.99	3.2	08.07
<a href="#">YOLOv8s</a>	640	44.9	128.4	1.20	11.2	28.6
<a href="#">YOLOv8m</a>	640	50.2	234.7	1.83	25.9	78.9
<a href="#">YOLOv8l</a>	640	52.9	375.2	2.39	43.7	165.2
<a href="#">YOLOv8x</a>	640	53.9	479.1	3.53	68.2	257.8

Dalam penelitian ini, model YOLOv8n, YOLOv8s, dan YOLOv8m dipilih berdasarkan keseimbangan antara efisiensi dan akurasi yang sesuai untuk pengujian pada video dengan resolusi 640 piksel. Model YOLOv8n digunakan untuk evaluasi efisiensi pada perangkat keras dengan kapasitas rendah, YOLOv8s untuk aplikasi dengan kebutuhan keseimbangan, sedangkan YOLOv8m dievaluasi untuk performa akurasi yang lebih tinggi meskipun membutuhkan waktu pemrosesan lebih besar. Penelitian ini memanfaatkan *pretrained model* YOLOv8 yang telah dilatih pada *dataset* berskala besar untuk mengoptimalkan waktu pengujian tanpa pelatihan ulang. Proses deteksi dilakukan dengan menerapkan model pada setiap *frame* video, menghasilkan anotasi berupa *bounding box*, label kelas, dan nilai *confidence score* untuk setiap objek yang terdeteksi. Pendekatan ini memastikan bahwa performa deteksi dapat dievaluasi secara efisien pada berbagai kondisi lingkungan.

## METODE PENELITIAN

Penelitian ini bertujuan untuk mengevaluasi performa model deteksi objek dalam mendeteksi elemen-elemen penting pada jalan raya menggunakan video yang direkam dalam berbagai kondisi. Proses penelitian mencakup pengumpulan data, implementasi sistem deteksi objek, dan evaluasi model berdasarkan parameter tertentu. *Dataset* yang digunakan dirancang untuk merepresentasikan kondisi dunia nyata, sementara sistem deteksi objek dikembangkan dengan pendekatan berbasis deep learning menggunakan algoritma YOLO.



Gambar 2. Diagram alur metode penelitian

### Dataset dan Lingkup Penelitian

Penelitian ini menggunakan dataset berupa video yang direkam secara langsung di dua jenis jalan, yaitu jalan biasa dan jalan tol, untuk mencerminkan variasi kondisi lingkungan yang umumnya dihadapi pengendara. Jalan biasa dipilih karena mewakili lingkungan perkotaan dengan tingkat interaksi yang tinggi antara kendaraan, pejalan kaki, dan rambu lalu lintas, sedangkan jalan tol merepresentasikan kondisi lalu lintas dengan kecepatan tinggi yang berfokus pada interaksi antar kendaraan dan rambu lalu lintas. Perekaman dilakukan pada enam waktu berbeda, yaitu pukul 08.00, 10.00, 12.00, 18.00, 20.00, dan 22.00, untuk menangkap variasi pencahayaan mulai dari kondisi terang di pagi dan siang hari, pencahayaan redup menjelang malam, hingga kondisi malam hari dengan pencahayaan buatan seperti lampu jalan dan lampu kendaraan. Selain itu, variasi waktu ini juga membantu menangkap tingkat kepadatan lalu lintas yang berbeda, mulai dari kondisi jalan yang ramai pada pagi dan sore hari hingga kondisi yang lebih sepi di malam hari.



Gambar 3. Kumpulan video pengambilan data pada berbagai waktu dan kondisi di jalan biasa dan jalan tol.

Setiap video memiliki durasi 1 menit dengan resolusi Full HD (1920x1080) untuk memastikan kualitas visual yang memadai bagi proses deteksi objek. Kamera ditempatkan di posisi tetap pada dashboard kendaraan untuk mereplikasi sudut pandang pengemudi, dengan tujuan mendekati kondisi dunia nyata yang akan dihadapi oleh sistem deteksi objek dalam kendaraan. Fokus deteksi dalam dataset ini mencakup tiga kategori utama, yaitu kendaraan lain, pejalan kaki, dan rambu lalu lintas. Kendaraan lain meliputi mobil, sepeda motor, bus, dan truk yang merupakan elemen utama dalam interaksi lalu lintas. Pejalan kaki menjadi objek penting terutama pada jalan biasa yang sering melibatkan interaksi langsung dengan kendaraan. Rambu lalu lintas juga menjadi elemen krusial karena memberikan informasi dan peringatan kepada pengemudi, seperti rambu peringatan, larangan, dan informasi. Dataset ini dirancang untuk menguji kemampuan model dalam mendeteksi objek dengan akurasi tinggi pada berbagai skenario, termasuk pencahayaan redup, kondisi objek yang saling tumpang tindih, dan kecepatan kendaraan yang bervariasi.

### Evaluasi Performa

Evaluasi performa model deteksi objek dilakukan untuk menilai akurasi dan kualitas deteksi pada berbagai skenario dunia nyata. Parameter utama yang digunakan adalah akurasi deteksi, yang diukur berdasarkan nilai *confidence score* yang dihasilkan oleh model untuk setiap objek yang terdeteksi. Nilai *confidence score* menunjukkan tingkat keyakinan model terhadap hasil deteksi, yang kemudian dianalisis secara statistik untuk menggambarkan performa masing-masing model. Statistik deskriptif seperti rata-rata, median, nilai minimum, dan maksimum digunakan untuk memberikan gambaran menyeluruh tentang distribusi *confidence score* antar model. Untuk

memvisualisasikan perbandingan performa, *boxplot* digunakan untuk menggambarkan variabilitas *confidence score* pada setiap model, sehingga mempermudah interpretasi dan evaluasi antar model dalam mendeteksi objek pada berbagai kondisi.

Selain itu, evaluasi juga dilakukan dengan menghitung rata-rata *confidence score* untuk setiap jenis objek, seperti kendaraan lain, pejalan kaki, dan rambu lalu lintas. Rata-rata ini dianalisis untuk menilai kemampuan model dalam mendeteksi berbagai kategori objek secara spesifik. Grafik batang (*bar chart*) digunakan untuk memvisualisasikan rata-rata *confidence score* per objek untuk masing-masing model, memberikan gambaran lebih mendetail mengenai perbedaan performa dalam mendeteksi objek tertentu.

Perbandingan hasil deteksi juga dilakukan secara visual untuk menilai kualitas *bounding box*, label kelas, dan kesesuaian deteksi pada video yang telah dianotasi. Hasil deteksi dari setiap model dibandingkan secara kualitatif untuk mengidentifikasi kelebihan dan kekurangan masing-masing model dalam kondisi yang melibatkan pencahayaan berbeda dan kepadatan lalu lintas yang bervariasi. Data hasil evaluasi, termasuk statistik *confidence score* dan rata-rata per objek, disimpan dalam *file CSV* untuk dokumentasi dan pelaporan lebih lanjut. Proses evaluasi ini dirancang untuk memberikan analisis komprehensif terhadap keunggulan dan keterbatasan masing-masing model deteksi objek, sehingga dapat menjadi dasar dalam menentukan model terbaik untuk mendukung aplikasi keselamatan berkendara.

## HASIL DAN PEMBAHASAN

Bagian hasil dan pembahasan dalam penelitian ini bertujuan untuk menganalisis performa model deteksi objek pada berbagai skenario dunia nyata, yaitu jalan biasa dan jalan tol, yang direkam pada enam waktu berbeda (08:00, 10:00, 12:00, 18:00, 20:00, dan 22:00). Analisis dilakukan untuk mengevaluasi kemampuan model YOLOv8n, YOLOv8s, dan YOLOv8m dalam mendeteksi elemen-elemen penting lalu lintas seperti kendaraan, pejalan kaki, dan rambu lalu lintas.


Penelitian ini memanfaatkan data hasil deteksi berupa jumlah objek yang terdeteksi, nilai rata-rata *confidence score*, serta distribusi *confidence score* untuk setiap model. Analisis dilakukan baik secara global, yaitu perbandingan performa model secara keseluruhan pada setiap waktu, maupun secara spesifik berdasarkan jenis objek yang terdeteksi. Evaluasi dilakukan untuk memahami pola deteksi yang terjadi pada kondisi pencahayaan yang berbeda, mulai dari pagi hingga malam hari, serta untuk mengidentifikasi kelebihan dan kekurangan masing-masing model pada lingkungan jalan biasa dan jalan tol.

Diskusi dalam bagian ini juga mencakup perbandingan hasil antara model pada dua lokasi penelitian. Jalan biasa mewakili skenario dengan tingkat interaksi yang lebih kompleks, seperti adanya pejalan kaki dan elemen jalan lainnya, sedangkan jalan tol merepresentasikan lalu lintas dengan kecepatan tinggi yang didominasi oleh kendaraan besar. Dengan pendekatan ini, penelitian ini bertujuan untuk menentukan model terbaik yang mampu memberikan akurasi deteksi tinggi dan konsistensi performa di berbagai kondisi lingkungan.

### Hasil Berdasarkan Lokasi dan Waktu

#### Jalan Biasa 08:00


Pada skenario jalan biasa pukul 08:00, hasil evaluasi menunjukkan bahwa YOLOv8m menghasilkan jumlah deteksi objek tertinggi dengan 18.389 deteksi, diikuti oleh YOLOv8s sebanyak 15.967 deteksi, dan YOLOv8n sebanyak 13.080 deteksi. Rata-rata *confidence score* tertinggi dicapai oleh YOLOv8m sebesar 0,566, diikuti oleh YOLOv8s sebesar 0,541, dan YOLOv8n sebesar 0,501. YOLOv8m menunjukkan distribusi skor yang stabil dengan standar deviasi 0,179, lebih rendah dibandingkan YOLOv8s (0,180). Pada analisis berdasarkan jenis objek, YOLOv8m menunjukkan performa terbaik untuk kendaraan (*car*) dengan rata-rata *confidence score* 0,601 dan bus (*bus*) sebesar 0,522.

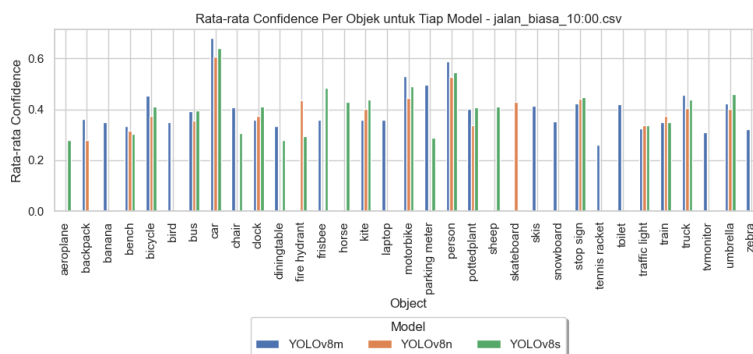


Gambar 4. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan biasa pukul 08:00.

### Jalan Biasa 10:00

Pada pukul 10:00, YOLOv8m kembali menunjukkan performa terbaik dengan 15.387 deteksi dan rata-rata *confidence score* sebesar 0,599. YOLOv8s mendeteksi 14.644 objek dengan rata-rata skor 0,559, sementara YOLOv8n menghasilkan 10.964 deteksi dengan rata-rata skor 0,545. Distribusi *confidence score* lebih merata pada YOLOv8m dengan standar deviasi 0,205 dibandingkan YOLOv8n (0,199). Model YOLOv8m menunjukkan keunggulan dalam mendeteksi objek kendaraan seperti bus dan mobil dengan *confidence score* masing-masing 0,678 dan 0,608. Pencahayaan pagi yang lebih cerah pada pukul 10:00 mendukung peningkatan performa deteksi, terutama pada objek dengan ukuran besar.






Gambar 5. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan biasa pukul 10:00.

### Jalan Biasa 12:00

Pada siang hari pukul 12:00, pencahayaan yang optimal memungkinkan deteksi objek yang lebih baik. YOLOv8m menghasilkan 24.330 deteksi dengan rata-rata confidence score sebesar 0,581, sedangkan YOLOv8s menghasilkan 21.680 deteksi dengan skor rata-rata 0,562. YOLOv8n mencatatkan 16.632 deteksi dengan rata-rata skor 0,504. Distribusi confidence score menunjukkan bahwa YOLOv8m memiliki performa stabil dengan standar deviasi 0,192. Model ini unggul dalam mendeteksi kendaraan (car: 0,608) dan pejalan kaki (person: 0,622). Pencahayaan siang hari memberikan keuntungan signifikan dalam mendeteksi elemen jalan yang lebih kecil seperti rambu lalu lintas.




Gambar 6. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan biasa pukul 12:00.

### Jalan Biasa 18:00

Pada pukul 18:00, ketika cahaya mulai berkurang, performa deteksi menurun dibandingkan


siang hari. YOLOv8m mendeteksi 12.597 objek dengan rata-rata *confidence score* sebesar 0,576, diikuti oleh YOLOv8s dengan 10.384 deteksi dan skor rata-rata 0,531, serta YOLOv8n dengan 7.915 deteksi dan skor rata-rata 0,492. YOLOv8m menunjukkan keunggulan dalam mendeteksi kendaraan seperti mobil dengan rata-rata skor 0,584. Tantangan utama pada waktu ini adalah transisi pencahayaan, yang menyebabkan beberapa model mengalami penurunan akurasi dalam mendeteksi objek kecil.



Gambar 7. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan biasa pukul 18:00.

### Jalan Biasa 20:00

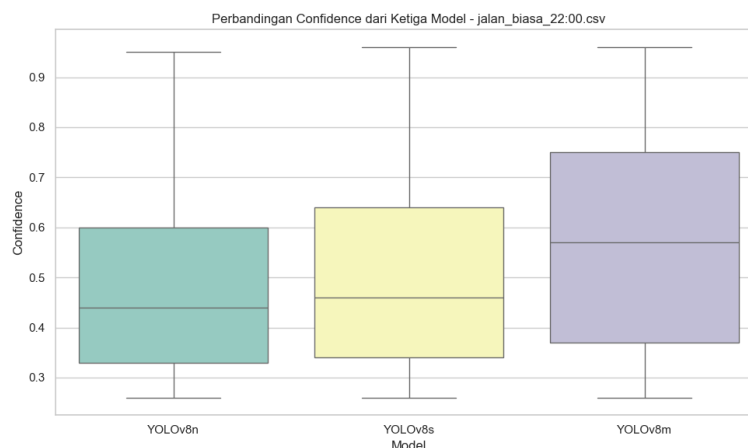
Pada malam hari pukul 20:00 dengan pencahayaan buatan, YOLOv8m kembali mencatatkan performa terbaik dengan 18.713 deteksi dan rata-rata *confidence score* sebesar 0,587. YOLOv8s mendeteksi 16.287 objek dengan rata-rata skor 0,541, sedangkan YOLOv8n menghasilkan 12.817 deteksi dengan rata-rata skor 0,503. YOLOv8m menunjukkan performa unggul pada deteksi kendaraan besar seperti bus (*confidence score*: 0,631) dan mobil (*confidence score*: 0,632). Namun, tantangan utama tetap pada objek kecil seperti rambu lalu lintas dan pejalan kaki, yang cenderung sulit terdeteksi dengan baik dalam kondisi cahaya rendah.

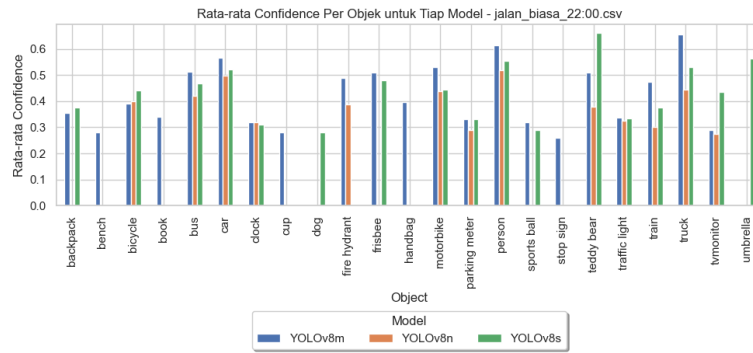


Gambar 8. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan biasa pukul 20:00.

### Jalan Biasa 22:00

Pada pukul 22:00, kondisi malam hari memberikan tantangan besar bagi deteksi objek. YOLOv8m menghasilkan 11.872 deteksi dengan rata-rata *confidence score* sebesar 0,567, diikuti oleh YOLOv8s dengan 10.867 deteksi dan skor rata-rata 0,502. YOLOv8n mencatatkan 7.600 deteksi dengan rata-rata skor 0,481. YOLOv8m menunjukkan performa terbaik dalam mendeteksi kendaraan (*car*: 0,568) dan pejalan kaki (*person*: 0,614). Penurunan akurasi deteksi terlihat pada objek kecil seperti rambu lalu lintas, akibat keterbatasan pencahayaan.






Gambar 9. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan biasa pukul 22:00.

### Jalan Tol 08:00

Pada pukul 08:00 di jalan tol, YOLOv8m menunjukkan performa terbaik dengan 4.349 deteksi objek dan rata-rata *confidence score* sebesar 0,646. YOLOv8s mendeteksi 4.059 objek dengan rata-rata skor 0,602, sedangkan YOLOv8n mencatatkan 3.455 deteksi dengan skor rata-rata 0,548. YOLOv8m menunjukkan keunggulan dalam mendeteksi kendaraan seperti bus (*confidence score*: 0,660) dan mobil (*confidence score*: 0,655). Namun, YOLOv8n mengalami kesulitan mendeteksi beberapa objek kecil seperti rambu lalu lintas. Pencahayaan pagi yang masih redup menjadi tantangan dalam meningkatkan akurasi deteksi.




Gambar 10. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan tol pukul 08:00.

### Jalan Tol 10:00

Pada pukul 10:00, performa YOLOv8m tetap unggul dengan 3.712 deteksi dan rata-rata *confidence score* sebesar 0,638. YOLOv8s mencatatkan 3.292 deteksi dengan skor rata-rata 0,614, sedangkan YOLOv8n menghasilkan 2.103 deteksi dengan skor rata-rata 0,548. YOLOv8m menunjukkan stabilitas dalam mendeteksi kendaraan besar seperti bus (*confidence score*: 0,628)

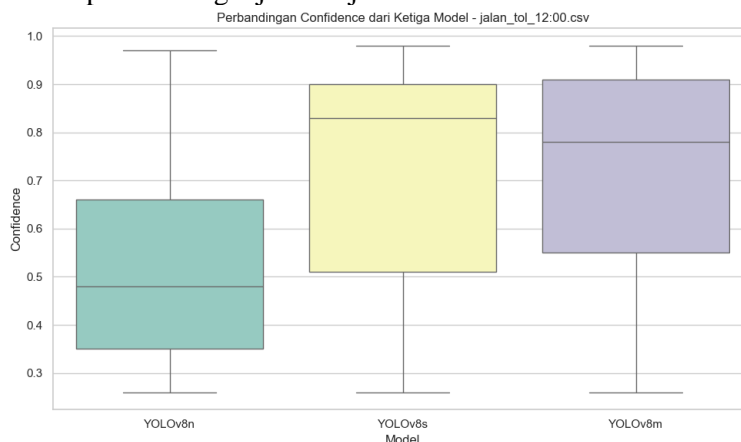
dan truk (*confidence score*: 0,762). Pencahayaan yang lebih baik pada waktu ini mendukung peningkatan akurasi deteksi.




Gambar 11. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan tol pukul 10:00.

### Jalan Tol 12:00

Pada siang hari pukul 12:00, YOLOv8m mencapai performa puncak dengan 7.238 deteksi dan rata-rata *confidence score* sebesar 0,714. YOLOv8s menghasilkan 7.159 deteksi dengan skor rata-rata 0,712, sedangkan YOLOv8n mencatatkan 5.942 deteksi dengan skor rata-rata 0,516. YOLOv8m dan YOLOv8s menunjukkan kemampuan deteksi yang hampir setara, terutama pada kendaraan besar seperti truk (*confidence score*: 0,790). Pencahayaan optimal pada siang hari mendukung akurasi deteksi pada berbagai jenis objek.






Gambar 12. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan tol pukul 12:00.

### Jalan Tol 18:00


Pada pukul 18:00, YOLOv8m tetap unggul dengan 7.691 deteksi dan rata-rata *confidence score* sebesar 0,654, diikuti oleh YOLOv8s dengan 7.537 deteksi dan skor rata-rata 0,619, serta YOLOv8n dengan 6.403 deteksi dan skor rata-rata 0,546. Tantangan transisi pencahayaan mulai terasa, dengan penurunan akurasi pada YOLOv8n. YOLOv8m menunjukkan performa stabil pada deteksi kendaraan (*confidence score* untuk mobil: 0,655).



Gambar 13. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan tol pukul 18:00.

### Jalan Tol 20:00

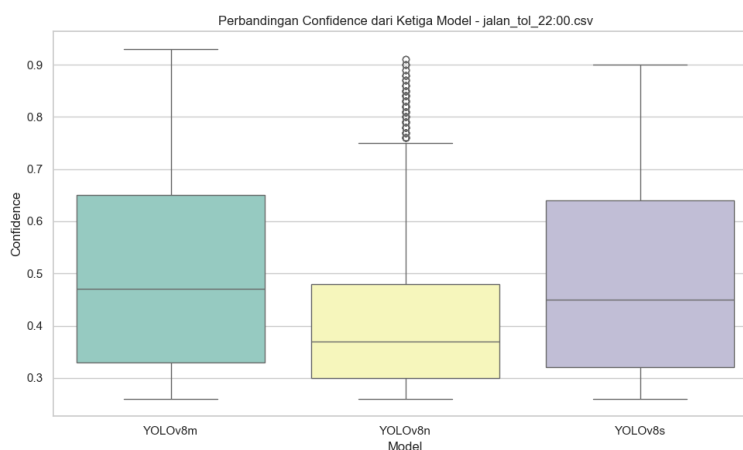
Pada pukul 20:00, kondisi malam hari menyebabkan penurunan performa YOLOv8n yang hanya mencatatkan rata-rata *confidence score* sebesar 0,374 dari 3.716 deteksi. YOLOv8m menghasilkan skor rata-rata tertinggi sebesar 0,500 dari 4.501 deteksi, sedangkan YOLOv8s mencapai skor rata-rata 0,422 dari 4.665 deteksi. Tantangan utama adalah pencahayaan buatan yang tidak merata, yang memengaruhi deteksi objek kecil seperti rambu lalu lintas.




Gambar 14. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan tol pukul 20:00.

### Jalan Tol 22:00

Pada pukul 22:00, YOLOv8m mencatatkan 3.210 deteksi dengan rata-rata *confidence score* sebesar 0,500, sedangkan YOLOv8s menghasilkan 2.941 deteksi dengan skor rata-rata 0,490. YOLOv8n memiliki performa terendah dengan 2.546 deteksi dan skor rata-rata 0,419. YOLOv8m tetap unggul dalam mendeteksi kendaraan besar seperti truk (*confidence score*: 0,551). Tantangan utama pada waktu ini adalah pencahayaan minim yang memperbesar kemungkinan kesalahan deteksi.





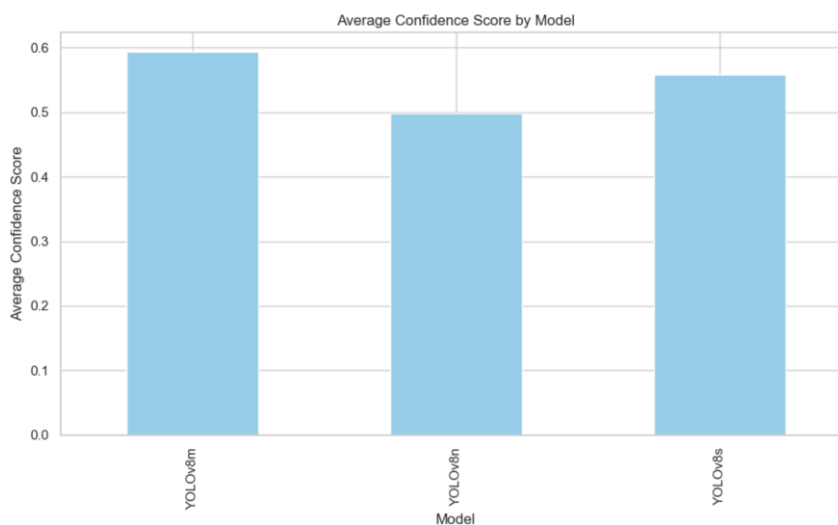
Gambar 15. Perbandingan performa model YOLOv8n, YOLOv8s, dan YOLOv8m pada skenario jalan tol pukul 22:00.

### Pengaruh Waktu Terhadap Performa

Waktu memiliki pengaruh signifikan terhadap performa deteksi objek oleh model YOLOv8 (YOLOv8m, YOLOv8s, dan YOLOv8n). Pada pagi hari (08:00 dan 10:00), pencahayaan yang mulai meningkat namun masih menimbulkan bayangan memberikan tantangan tersendiri, terutama dalam mendeteksi objek kecil seperti rambu lalu lintas. Namun, kendaraan besar seperti bus dan mobil tetap dapat terdeteksi dengan baik oleh YOLOv8m, yang menunjukkan performa superior dibandingkan model lainnya. Pada siang hari (12:00), pencahayaan optimal mendukung deteksi objek dengan akurasi yang lebih tinggi, terutama pada YOLOv8m dan YOLOv8s, yang menunjukkan performa hampir setara dalam mendeteksi kendaraan besar dan elemen jalan. Ketika sore menjelang malam (18:00), transisi pencahayaan mulai memengaruhi akurasi deteksi, terutama pada YOLOv8n yang mencatatkan penurunan *confidence score* yang lebih signifikan dibandingkan model lainnya. Pada malam hari (20:00 dan 22:00), pencahayaan buatan yang tidak merata menjadi tantangan utama. Semua model mengalami penurunan akurasi, terutama dalam mendeteksi objek kecil seperti rambu lalu lintas dan pejalan kaki. Namun, YOLOv8m tetap unggul dengan rata-rata *confidence score* yang lebih tinggi, menunjukkan kemampuannya untuk beradaptasi dengan kondisi pencahayaan minim. Secara keseluruhan, waktu memengaruhi tingkat keberhasilan deteksi dengan siang hari sebagai periode optimal dan malam hari sebagai tantangan terbesar bagi semua model.

### Perbandingan Model YOLOv8

Perbandingan antara model YOLOv8m, YOLOv8s, dan YOLOv8n menunjukkan perbedaan yang signifikan dalam performa deteksi objek, yang mencakup jumlah deteksi, *confidence score*, serta kemampuan menangani kondisi lingkungan. Model YOLOv8m secara konsisten menunjukkan performa terbaik di seluruh skenario waktu dan lokasi, dengan jumlah deteksi dan rata-rata *confidence score* yang lebih tinggi dibandingkan model lainnya. Model ini unggul dalam mendeteksi kendaraan besar seperti bus dan mobil, terutama pada kondisi pencahayaan optimal di siang hari. Selain itu, YOLOv8m juga menunjukkan stabilitas dengan distribusi *confidence score* yang lebih rendah, yang mengindikasikan kemampuan yang lebih konsisten dalam berbagai kondisi.



Gambar 16. Grafik rata-rata confidence score per model (YOLOv8m, YOLOv8n, dan YOLOv8s) menunjukkan bahwa YOLOv8m memiliki skor rata-rata tertinggi, diikuti oleh YOLOv8s, dan terakhir YOLOv8n. Data ini mengindikasikan bahwa YOLOv8m memiliki akurasi deteksi yang lebih konsisten dibandingkan model lainnya.

Model YOLOv8s menawarkan keseimbangan antara akurasi dan efisiensi. Meskipun performanya sedikit di bawah YOLOv8m, model ini tetap mampu menghasilkan jumlah deteksi yang signifikan dengan *confidence score* yang mendekati YOLOv8m, terutama pada siang hari. Namun, performa YOLOv8s sedikit menurun dalam kondisi pencahayaan rendah, seperti malam hari atau transisi sore ke malam, yang menunjukkan keterbatasannya dalam menangani objek kecil dan elemen jalan dengan pencahayaan minim.

Sementara itu, YOLOv8n, sebagai model yang paling ringan dan efisien, menunjukkan keterbatasan dalam mendeteksi objek pada kondisi kompleks. Jumlah deteksi dan rata-rata *confidence score* pada YOLOv8n secara konsisten lebih rendah dibandingkan dua model lainnya. Model ini lebih rentan terhadap penurunan performa pada kondisi pencahayaan rendah dan kesulitan dalam mendeteksi objek kecil seperti rambu lalu lintas. Namun, YOLOv8n tetap menjadi pilihan yang baik untuk aplikasi dengan kebutuhan komputasi real-time atau perangkat keras yang terbatas, di mana efisiensi lebih diprioritaskan daripada akurasi.

Secara keseluruhan, model YOLOv8m adalah pilihan terbaik untuk skenario yang memerlukan akurasi tinggi dan stabilitas deteksi dalam berbagai kondisi. YOLOv8s dapat digunakan sebagai alternatif yang seimbang antara kecepatan dan akurasi, sedangkan YOLOv8n lebih cocok untuk aplikasi dengan keterbatasan perangkat keras yang memerlukan kecepatan tinggi meski dengan akurasi yang lebih rendah.

### Pengaruh Lokasi Terhadap Performa

Lokasi memiliki pengaruh yang signifikan terhadap performa deteksi objek oleh model YOLOv8, khususnya dalam hal jumlah deteksi, rata-rata *confidence score*, dan stabilitas deteksi. Pada skenario jalan biasa, performa model dipengaruhi oleh elemen-elemen lingkungan yang kompleks, seperti kehadiran berbagai jenis objek (pejalan kaki, kendaraan, dan rambu lalu lintas) serta variasi pencahayaan alami. YOLOv8m, sebagai model dengan performa terbaik, secara konsisten mampu menangani kompleksitas ini dengan deteksi yang akurat, terutama pada kendaraan besar seperti bus dan mobil. Namun, tantangan seperti bayangan dari pohon atau bangunan pada pagi hari dan minimnya pencahayaan pada malam hari menyebabkan penurunan akurasi, terutama pada YOLOv8n.



Gambar 17. Visualisasi hasil deteksi objek menggunakan YOLOv8 pada berbagai kondisi waktu dan lokasi.

Sebaliknya, pada skenario jalan tol, lingkungan yang lebih terstruktur dengan objek yang didominasi oleh kendaraan memberikan keuntungan bagi semua model. YOLOv8m dan YOLOv8s menunjukkan peningkatan *confidence score* yang lebih tinggi dibandingkan skenario jalan biasa, terutama pada siang hari dengan pencahayaan optimal. Deteksi kendaraan besar seperti truk dan bus lebih konsisten di jalan tol, karena objek-objek ini lebih mudah dikenali tanpa adanya gangguan visual seperti pejalan kaki atau rambu kecil. Namun, kondisi malam hari tetap menjadi tantangan utama, di mana pencahayaan buatan di jalan tol terkadang tidak merata, menyebabkan penurunan *confidence score*, terutama pada YOLOv8n.

Secara keseluruhan, lokasi jalan tol memberikan lingkungan yang lebih kondusif untuk deteksi objek, terutama bagi model yang lebih kompleks seperti YOLOv8m dan YOLOv8s. Namun, pada jalan biasa, variasi elemen lingkungan dan kompleksitas objek memberikan tantangan yang lebih besar, yang menguji kemampuan model dalam mendeteksi objek kecil dan menangani variasi pencahayaan. Hal ini menunjukkan bahwa lokasi memengaruhi tingkat keberhasilan deteksi, dengan jalan tol sebagai lingkungan yang lebih ideal untuk aplikasi deteksi berbasis YOLOv8.

## KESIMPULAN

Penelitian ini berhasil mengevaluasi performa tiga varian model YOLOv8 (*nano*, *small*, dan *medium*) dalam mendeteksi elemen-elemen lalu lintas penting, yaitu kendaraan, pejalan kaki, dan rambu lalu lintas, pada video yang direkam di jalan biasa dan jalan tol dengan variasi kondisi pencahayaan dan kepadatan lalu lintas. Hasil penelitian menunjukkan bahwa model YOLOv8m secara konsisten memberikan hasil deteksi terbaik dalam berbagai kondisi dengan rata-rata *confidence score* tertinggi dan distribusi yang lebih stabil dibandingkan varian lainnya. Model ini

menunjukkan kemampuan yang unggul terutama pada kendaraan besar seperti bus dan mobil, khususnya pada kondisi siang hari dengan pencahayaan optimal.

Model YOLOv8s menunjukkan performa yang mendekati YOLOv8m dengan keseimbangan antara akurasi dan efisiensi, tetapi mengalami penurunan performa pada kondisi pencahayaan rendah. Sementara itu, YOLOv8n, meskipun efisien dan cocok untuk perangkat keras terbatas, menunjukkan keterbatasan signifikan dalam deteksi objek kecil dan kondisi lingkungan kompleks. Performa deteksi juga dipengaruhi oleh lokasi, di mana jalan tol memberikan lingkungan yang lebih terstruktur sehingga mendukung akurasi deteksi yang lebih tinggi dibandingkan jalan biasa yang memiliki variasi elemen dan kompleksitas yang lebih besar.

Penelitian ini dapat dikembangkan lebih lanjut dengan menyesuaikan model YOLO untuk meningkatkan akurasi pada objek kecil dan kondisi pencahayaan rendah. Selain itu, integrasi model ini ke dalam sistem kendaraan cerdas berbasis *Internet of Things* dapat menjadi solusi nyata untuk meningkatkan keselamatan berlalu lintas di dunia nyata.

### REFERENSI

- Afandi, M. A., Kinanti, A., Permatasari, I., & Tarigan, N. Y. (2024). Deteksi Objek Bahasa Isyarat Alfabet BISINDO Menggunakan Deep Learning dan Arsitektur YOLO. *Techno.Com*, 23(2), 411–419. <https://doi.org/10.62411/tc.v23i2.9889>
- Aziz, L., Haji Salam, M. S. Bin, Sheikh, U. U., & Ayub, S. (2020). Exploring Deep Learning-Based Architecture, Strategies, Applications and Current Trends in Generic Object Detection: A Comprehensive Review. *IEEE Access*, 8, 170461–170495. <https://doi.org/10.1109/ACCESS.2020.3021508>
- Chen, Y., Sun, X., Xu, L., Ma, S., Li, J., Pang, Y., & Cheng, G. (2022). Application of YOLOv4 Algorithm for Foreign Object Detection on a Belt Conveyor in a Low-Illumination Environment. *Sensors*, 22(18). <https://doi.org/10.3390/s22186851>
- Jiang, C., Ren, H., Ye, X., Zhu, J., Zeng, H., Nan, Y., Sun, M., Ren, X., & Huo, H. (2022). Object detection from UAV thermal infrared images and videos using YOLO models. *International Journal of Applied Earth Observation and Geoinformation*, 112, 102912. <https://doi.org/https://doi.org/10.1016/j.jag.2022.102912>
- Krišto, M., Ivacic-Kos, M., & Pobar, M. (2020). Thermal Object Detection in Difficult Weather Conditions Using YOLO. *IEEE Access*, 8, 125459–125476. <https://doi.org/10.1109/ACCESS.2020.3007481>
- Mardikawati, B., Suartawan, P. E., & Mulyaningtyas, D. O. (2023). Pelatihan Keselamatan Berlalu Lintas sebagai Upaya Preventif Menurunkan Angka Kecelakaan. *Empowerment: Jurnal Pengabdian Masyarakat*, 2(4), 169–180. <https://doi.org/10.55983/empjcs.v2i4.414>
- Maulana, A. Q., Suherman, M., Masruriyah, A. F. N., & Novita, H. Y. (2024). PENERAPAN ALGORITMA CNN MENGGUNAKAN FRAMEWORK YOLO UNTUK DETEKSI OBJEK PRODUK DI PERUSAHAAN MANUFAKTUR. *INTI Nusa Mandiri*. <https://api.semanticscholar.org/CorpusID:267493566>
- Mirhaji, H., Soleymani, M., Asakereh, A., & Abdanan Mehdizadeh, S. (2021). Fruit detection and load estimation of an orange orchard using the YOLO models through simple approaches in different imaging and illumination conditions. *Computers and Electronics in Agriculture*, 191, 106533. <https://doi.org/https://doi.org/10.1016/j.compag.2021.106533>
- Pham, M. T., Courtrai, L., Friguet, C., Lefèvre, S., & Baussard, A. (2020). YOLO-fine: One-stage detector of small objects under various backgrounds in remote sensing images. *Remote Sensing*, 12(15), 1–26. <https://doi.org/10.3390/RS12152501>
- Rahman, M. R., Kusumawati, R., & Fatimah, F. (2023). Deteksi Objek Menghitung Pohon Kelapa Sawit Menggunakan Metode Deep Learning Object Detection Tree Counting Palm Oil using Deep Learning Method. *Bina: Jurnal Pembangunan Daerah*, 2(1), 45–51. <http://binajurnal.id/index.php/bina/article/download/51/32>
- Ravi, N., & El-Sharkawy, M. (2022). Real-Time Embedded Implementation of Improved Object Detector for Resource-Constrained Devices. *Journal of Low Power Electronics and Applications*, 12(2). <https://doi.org/10.3390/jlpea12020021>

- Wakhidah, N., Pungkasanti, P. T., & Pinem, A. P. R. (2023). Deteksi Objek menggunakan Deep Learning untuk Mengetahui Tingkat Kerumunan Mahasiswa. *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*. <https://api.semanticscholar.org/CorpusID:270643239>
- Wu, X., Sahoo, D., & Hoi, S. C. H. (2020). Recent advances in deep learning for object detection. *Neurocomputing*, 396, 39–64. <https://doi.org/https://doi.org/10.1016/j.neucom.2020.01.085>
- Zhang, Z., Mahmud, M. A. P., & Kouzani, A. Z. (2022). Resource-constrained FPGA implementation of YOLOv2. *Neural Computing and Applications*, 34(19), 16989–17006. <https://doi.org/10.1007/s00521-022-07351-w>
- Zophie, J., & Triharminto, H. H. (2023). . Implemetasi Algoritma You Only Look Once (YOLO) menggunakan Web Camera untuk Mendeteksi Objek Statis dan Dinamis. *TNI Angkatan Udara*. <https://api.semanticscholar.org/CorpusID:269050709>