

# Klasifikasi Kepadatan Lalu Lintas Berbasis *Deep Learning* Menggunakan YOLOX Dan SegFormer

1<sup>st</sup> Raditya Adi Santoso

Program Studi Teknologi Informasi  
Universitas Telkom, Kampus Surabaya  
Surabaya, Jawa Timur, Indonesia  
radityaadi@student.telkomuniversity.ac.id

2<sup>nd</sup> Mustafa Kamal

Program Studi Teknologi Informasi  
Universitas Telkom, Kampus Surabaya  
Surabaya, Jawa Timur, Indonesia  
mustafakamal@telkomuniversity.ac.id

3<sup>rd</sup> Fandisyah Rahman

Program Studi Informatika  
Universitas Telkom, Kampus Surabaya  
Surabaya, Jawa Timur, Indonesia  
fandisyah@telkomuniversity.ac.id

**Abstrak** — Peningkatan volume lalu lintas menimbulkan tantangan dalam pengelolaan lalu lintas yang efektif. Sistem konvensional sering tidak menyediakan informasi mengenai kondisi kepadatan lalu lintas yang ada. Penelitian ini mengembangkan sistem klasifikasi kepadatan lalu lintas berbasis *deep learning* menggunakan model *hybrid* YOLOX untuk deteksi kendaraan dan SegFormer untuk segmentasi area jalan. Kedua model diintegrasikan menggunakan pendekatan *Fusion Layer*, yang menggabungkan hasil inferensi untuk menghitung rasio area jalan yang tertutupi kendaraan. Sistem ini diimplementasikan dalam bentuk aplikasi *website* yang menerima input langsung dari webcam, serta menampilkan informasi kepadatan secara visual dan numerik. Hasil evaluasi menunjukkan bahwa kombinasi model menghasilkan akurasi klasifikasi sebesar 80%, lebih tinggi dibandingkan penggunaan model secara terpisah. Penelitian ini berhasil mengembangkan sistem klasifikasi kepadatan lalu lintas dan memberikan kemudahan dalam mengakses informasi baik secara visual maupun numerik terkait tingkat kepadatan lalu lintas berdasarkan input langsung dari webcam.

**Kata kunci**— *deep learning*, YOLOX, SegFormer, klasifikasi kepadatan lalu lintas, segmentasi jalan, deteksi kendaraan.

## I. PENDAHULUAN

Peningkatan jumlah kendaraan bermotor di kawasan perkotaan, yang sejalan dengan urbanisasi, telah menciptakan tantangan serius dalam manajemen lalu lintas. Berdasarkan data dari Badan Pusat Statistik tahun 2023, jumlah kendaraan di Indonesia melebihi 150 juta unit [1]. Ketidakseimbangan antara volume kendaraan dan kapasitas jalan menyebabkan kondisi kepadatan yang tinggi, yang dapat berkembang menjadi kemacetan parah jika tidak diatasi [2].

Salah satu pendekatan inovatif dalam mengatasi masalah ini adalah melalui pemanfaatan teknologi informasi berbasis *deep learning*. *Deep learning* telah digunakan secara luas dalam sistem cerdas, termasuk dalam analisis lalu lintas *real-time* [3]. Klasifikasi kepadatan lalu lintas berbasis citra merupakan salah satu penerapan potensial, yang dilakukan dengan mendeteksi objek (kendaraan) dan melakukan segmentasi area jalan pada citra [4], [5].

YOLOX, sebagai salah satu model *object detection* terkini, menawarkan kecepatan dan akurasi tinggi dengan pendekatan *anchor-free* [6]. Di sisi lain, SegFormer

merupakan model segmentasi semantik berbasis arsitektur Transformer yang memiliki kemampuan adaptif dalam menangani kompleksitas citra [7]. Penelitian ini mengintegrasikan keduanya dalam satu sistem *hybrid* untuk melakukan klasifikasi tingkat kepadatan lalu lintas berdasarkan rasio area jalan yang tertutupi kendaraan.


Sistem ini diimplementasikan dalam bentuk aplikasi *web* yang menerima *input* langsung dari webcam, memprosesnya secara otomatis melalui *pipeline* deteksi dan segmentasi, kemudian menghitung rasio area dan mengklasifikasikan kepadatan dalam empat kategori: lengang, lancar, sedang, dan padat. Evaluasi terhadap sistem dilakukan untuk menilai kinerja deteksi, segmentasi, serta akurasi klasifikasi yang dihasilkan.

Penelitian ini bertujuan untuk (1) mengembangkan sistem klasifikasi kepadatan lalu lintas berbasis YOLOX dan SegFormer, (2) mengevaluasi kinerja model, dan (3) menerapkan hasilnya dalam bentuk aplikasi berbasis *web*.

## II. KAJIAN TEORI

### A. Deteksi Objek dan YOLOX

Deteksi objek merupakan proses mengidentifikasi posisi dan jenis objek dalam citra. YOLOX adalah model deteksi terkini yang menggunakan pendekatan *anchor-free* serta *decoupled head* untuk klasifikasi dan regresi, menghasilkan kinerja yang efisien pada *real-time detection* [6].




GAMBAR 1  
ARSITEKTUR YOLOX

### B. Segmentasi dan SegFormer

Segmentasi semantik bertujuan untuk mengelompokkan piksel dalam citra berdasarkan kelas tertentu. SegFormer menggabungkan Transformer *encoder* dengan MLP *decoder*,

menghasilkan segmentasi yang akurat dan efisien dalam berbagai skenario kompleks [7], [8].



GAMBAR 2  
ARSITEKTUR SEGFORMER


### C. Klasifikasi Kepadatan Lalu Lintas

Kepadatan lalu lintas dapat dihitung melalui perbandingan antara area kendaraan dan total area jalan [9], [10]. Rasio ini digunakan untuk mengklasifikasikan tingkat kepadatan [11]. Perhitungan kepadatan lalu lintas menggunakan rumus sebagai berikut:

$$\text{rasio terpakai} = \frac{\sum_{i=1}^n P_{kendaraan,i}}{\sum_{i=1}^n P_{kendaraan,i} + \sum_{j=1}^m P_{jalan,j}} \times 100 \quad (1)$$

### D. Model Hybrid dan Fusion Layer

Model *hybrid* memanfaatkan kelebihan dari beberapa arsitektur dalam satu sistem [12], [13]. Dalam penelitian ini, hasil dari YOLOX dan SegFormer digabungkan melalui *fusion layer* untuk memperoleh informasi rasio area terpakai.



GAMBAR 3  
CONTOH PENERAPAN MODEL HYBRID PADA DL

### E. Evaluasi Kinerja

Evaluasi model dilakukan menggunakan metrik seperti mAP (*mean Average Precision*) untuk deteksi [14], IoU (*Intersection over Union*) untuk segmentasi khusus kelas jalan [15], dan mIoU (*mean Intersection over Union*) untuk segmentasi secara keseluruhan [16]. Selain itu, akurasi

klasifikasi juga menjadi tolok ukur utama dalam sistem ini [17]. Secara berturut-turut metrik evaluasi yang digunakan dapat dilihat sebagai berikut:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (2)$$

Dimana  $N$  adalah jumlah total kelas, dan  $AP_i$  merupakan nilai *Average Precision* untuk kelas ke- $i$ .  $AP$  dihitung berdasarkan area di bawah kurva *Precision-Recall* untuk tiap kelas, yang mencerminkan keseimbangan antara ketepatan dan kelengkapan deteksi.

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

Dimana  $TP$  (*True Positive*) adalah jumlah *pixel* yang benar diklasifikasikan sebagai kelas target,  $FN$  (*False Negative*) adalah *pixel* dari kelas target yang tidak berhasil terdeteksi oleh model, dan  $FP$  (*False Positive*) adalah *pixel* yang salah diklasifikasikan sebagai kelas target.


$$mIoU = \frac{1}{k+1} \sum_{i=0}^k IoU_i \quad (4)$$

Dimana  $IoU_i$  adalah nilai *Intersection over Union* untuk kelas ke- $i$ , dan  $k+1$  merupakan jumlah total kelas.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

Dimana  $TP$  (*True Positive*) adalah jumlah data positif yang berhasil diprediksi dengan benar,  $TN$  (*True Negative*) adalah jumlah data negatif yang juga diprediksi dengan benar,  $FP$  (*False Positive*) adalah data negatif yang salah diklasifikasikan sebagai positif, dan  $FN$  (*False Negative*) adalah data positif yang salah diklasifikasikan sebagai negatif.

## III. METODE



GAMBAR 4  
SISTEMATIKA PENYELESAIAN MASALAH

Penelitian ini mengembangkan sistem klasifikasi kepadatan lalu lintas berbasis deep learning dengan pendekatan dua model, yaitu YOLOX untuk deteksi objek kendaraan dan SegFormer untuk segmentasi area jalan.

Keduanya diintegrasikan melalui *fusion layer* guna menghasilkan klasifikasi kondisi lalu lintas berdasarkan rasio area yang ditempati kendaraan terhadap area jalan.

#### A. Pengumpulan Data

Data diperoleh dari tiga sumber utama: rekaman CCTV publik, *dataset open source*, dan perekaman manual dari jembatan penyeberangan. Perekaman dilakukan selama 14 hari dengan sudut kamera 60 derajat dan waktu pengambilan pada pagi, siang, serta sore hari. Durasi tiap video berkisar antara 30 detik hingga 2 menit. Kondisi lalu lintas yang terekam mencakup kategori lengang, lancar, sedang, dan padat. Pendekatan ini dilakukan untuk memastikan bahwa data mencakup variasi kondisi riil di lapangan, sehingga model dapat belajar secara general terhadap berbagai skenario.

#### B. Ekstraksi *Frame*

Data video yang telah dikumpulkan diubah menjadi kumpulan gambar melalui proses ekstraksi *frame*. Gambar diambil pada interval satu detik per *frame* untuk memastikan representasi temporal yang merata. Gambar-gambar hasil ekstraksi inilah yang digunakan sebagai input dalam proses pelabelan dan pelatihan model deteksi maupun segmentasi.

#### C. Pelabelan Data

Setiap *frame* hasil ekstraksi diberi anotasi sesuai dengan kebutuhan masing-masing model. Untuk YOLOX, anotasi berupa *bounding box* terhadap objek kendaraan seperti mobil, truk, dan motor. Sementara itu, untuk SegFormer digunakan mask segmentasi untuk menandai area jalan, kendaraan, dan trotoar. Proses pelabelan ini dilakukan secara manual menggunakan perangkat lunak Supervisely untuk menjamin ketelitian dan konsistensi label.

#### D. *Preprocessing* Data

Tahapan *preprocessing* mencakup *filtering* untuk menghapus frame buram atau tidak relevan, *resizing* ke resolusi 640×640 (YOLOX) dan 512×512 (SegFormer), serta normalisasi nilai *pixel* ke skala tertentu. Augmentasi dilakukan menggunakan teknik *flipping*, rotasi, *cropping*, dan variasi pencahayaan untuk meningkatkan kemampuan generalisasi model. Data kemudian dibagi menjadi 80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian, berdasarkan hari pengambilan data.

#### E. Pembuatan Model

Model dikembangkan menggunakan pendekatan hybrid. YOLOX digunakan untuk mendeteksi kendaraan dengan arsitektur CSPDarknet53 sebagai backbone, PAFPN sebagai neck, dan head untuk klasifikasi serta regresi bounding box. Di sisi lain, SegFormer digunakan untuk melakukan segmentasi area jalan dengan memanfaatkan patch embedding, blok Transformer, dan MLP pada decoder untuk menghasilkan peta segmentasi. Kedua model bekerja secara terpisah, namun hasilnya disatukan dalam proses inferensi. Berikut visualisasi pembuatan model yang dilakukan:



GAMBAR 5  
MODEL YOLOX




GAMBAR 6  
MODEL SEGFORMER

#### F. Evaluasi Model

Evaluasi dilakukan menggunakan tiga metrik utama: mAP (*mean Average Precision*) untuk mengevaluasi hasil deteksi YOLOX, IoU (*Intersection over Union*) dan mIoU (*Mean Intersection over Union*) untuk mengukur kinerja segmentasi SegFormer, dan akurasi klasifikasi kepadatan lalu lintas. Pendekatan evaluatif ini bertujuan untuk menilai kinerja masing-masing model serta kesesuaian output terhadap kondisi nyata.

#### G. Inferensi Model

Setelah model selesai dilatih, dilakukan proses inferensi pada data uji. Gambar input diproses secara oleh model YOLOX dan SegFormer. YOLOX menghasilkan *bounding box* kendaraan, sementara SegFormer memberikan peta segmentasi area jalan. Proses inferensi ini dilakukan tanpa pelatihan ulang, dan hanya menjalankan model pada data baru.



GAMBAR 7  
INFERENSI MODEL

#### H. *Fusion Layer*

Hasil inferensi dari YOLOX dan SegFormer digabungkan menggunakan *fusion layer*. *Bounding box* dari YOLOX diubah menjadi area *mask (filled box)*, lalu dikombinasikan dengan segmentasi jalan dari SegFormer. Hasil fusi ini memverifikasi apakah kendaraan benar-benar berada di atas area jalan, sebelum digunakan dalam perhitungan kepadatan. Proses ini bertujuan untuk memastikan validitas spasial dalam analisis.

#### I. Klasifikasi Kepadatan

Klasifikasi kepadatan dilakukan dengan menghitung rasio area kendaraan yang menutupi jalan terhadap total area jalan dengan menggunakan rumus dari Persamaan (1). Rasio ini dipetakan ke dalam empat kategori klasifikasi berdasarkan rentang tertentu, sehingga pengukuran ini memungkinkan sistem menentukan tingkat kepadatan lalu lintas secara objektif.

TABEL 1  
KATEGORI KLASIFIKASI

| No | Rentang                                   | Status |
|----|-------------------------------------------|--------|
| 1. | $100\% \geq \text{rasio terpakai} > 49\%$ | Padat  |
| 2. | $49\% \geq \text{rasio terpakai} > 29\%$  | Sedang |
| 3. | $29\% \geq \text{rasio terpakai} > 5\%$   | Lancar |

|    |                                  |        |
|----|----------------------------------|--------|
| 4. | $5\% \geq \text{rasio terpakai}$ | Lengah |
|----|----------------------------------|--------|

#### J. Implementasi Sistem dan Uji Coba

Model yang telah dilatih diimplementasikan dalam bentuk sistem berbasis *web* menggunakan Python dan JavaScript. Pengujian sistem dilakukan menggunakan pendekatan *black-box testing* untuk mengevaluasi fungsionalitas dari sisi pengguna, tanpa melihat struktur kode internal.




GAMBAR 8  
WIREFRAME DESAIN WEBSITE

### IV. HASIL DAN PEMBAHASAN

#### A. Pengumpulan dan Pengolahan Data


Data yang digunakan dalam penelitian ini mencakup 10 rekaman video primer berdurasi 30–120 detik yang diperoleh dari jembatan penyeberangan orang, serta 50 gambar sekunder dari dataset publik. Sebanyak 40 gambar lainnya digunakan sebagai data uji. Ekstraksi frame dilakukan dengan interval 1 detik, menghasilkan total 400 gambar untuk pelabelan dan pelatihan model.



GAMBAR 9  
HASIL EKSTRAKSI FRAME

Pelabelan dilakukan menggunakan Supervisely. Data untuk YOLOX dilabeli dengan *bouding box* untuk setiap

kendaraan, sedangkan data untuk SegFormer dilabeli menggunakan *segmentation mask* untuk area jalan. Seluruh data dibagi menjadi 80% data latih, 10% data validasi, dan 10% data uji.



GAMBAR 10  
PELABELAN DATA

#### B. Pelatihan dan Evaluasi Model YOLOX

Model YOLOX dilatih dengan berbagai kombinasi *batch size* dan *learning rate*, dan dilakukan sebanyak 8 eksperimen

TABEL 2  
HASIL EKSPERIMEN PELATIHAN MODEL YOLOX

| Eksperimen | Epoch | Batch Size | Base LR | Early Stopping | mAP (val) |
|------------|-------|------------|---------|----------------|-----------|
| 1.         | 50    | 8          | 0.001   | Ya             | 0.673     |
| 2.         | 50    | 16         | 0.001   | Ya             | 0.023     |
| 3          | 50    | 8          | 0.005   | Ya             | 0.679     |
| 4          | 50    | 16         | 0.005   | Ya             | 0.721     |
| 5          | 50    | 8          | 0.01    | Ya             | 0.768     |
| 6          | 50    | 16         | 0.01    | Ya             | 0.741     |
| 7          | 50    | 8          | 0.05    | Ya             | 0.776     |
| 8          | 50    | 16         | 0.05    | Ya             | 0.783     |

Delapan eksperimen yang dilakukan, dipilih 3 model hasil eksperimen yang memiliki selisih nilai mAP (val) tertinggi dan selisih paling kecil, yaitu eksperimen ke-5, ke-7, dan ke-8. Dan ketiga hasil eksperimen akan dievaluasi dengan menggunakan data uji untuk mengetahui kemampuan generasilisasi model.

TABEL 3  
HASIL EVALUASI MODEL YOLOX

| Eksperimen | mAP (val) | mAP (test) | mAP@50 (test) | mAP@75 (test) |
|------------|-----------|------------|---------------|---------------|
| 5          | 0.768     | 0.775      | 0.987         | 0.950         |
| 7          | 0.776     | 0.781      | 0.990         | 0.946         |
| 8          | 0.783     | 0.782      | 0.990         | 0.959         |

Dari evaluasi model yang dilakukan hasil terbaik diperoleh dari eksperimen ke-8, dengan perolehan hasil seperti pada Tabel 3.

#### C. Pelatihan dan Evaluasi Model SegFormer

SegFormer dilatih sebanyak 8 eksperimen. Dengan fokus pada *batch size* dan *learning rate*.

TABEL 4  
HASIL EKSPERIMEN PELATIHAN MODEL SEGFORMER

| Eksperimen | Max Iter | Batch Size | Base LR | Early Stopping | mIoU (val) |
|------------|----------|------------|---------|----------------|------------|
| 1.         | 9000     | 8          | 0.01    | Ya             | 0.969      |
| 2.         | 9000     | 16         | 0.01    | Ya             | 0.9549     |



|    |      |    |        |    |        |
|----|------|----|--------|----|--------|
| 3. | 9000 | 8  | 0.005  | Ya | 0.9731 |
| 4. | 9000 | 16 | 0.005  | Ya | 0.9695 |
| 5. | 9000 | 8  | 0.0075 | Ya | 0.9730 |
| 6. | 9000 | 16 | 0.0075 | Ya | 0.6467 |
| 7. | 9000 | 8  | 0.0025 | Ya | 0.9731 |
| 8. | 9000 | 16 | 0.0025 | Ya | 0.9753 |

Selanjutnya, dari proses ini nantinya akan dipilih 3 model hasil eksperimen yang memiliki nilai mIoU (val) yang paling tinggi dan selisih paling kecil, yaitu eksperimen ke-3, ke-7, dan ke-8. Dan ketiga hasil eksperimen akan dievaluasi dengan menggunakan data uji untuk mengetahui kemampuan generalisasi model.


TABEL 5  
HASIL EVALUASI MODEL SEGFORMER

| Eksperimen | mIoU (val) | mIoU (test) | IoU (Jalan) |
|------------|------------|-------------|-------------|
| 3          | 0.9731     | 0.9683      | 0.9796      |
| 7          | 0.9731     | 0.9695      | 0.9803      |
| 8          | 0.9753     | 0.9712      | 0.9814      |

Dari evaluasi model yang dilakukan hasil terbaik diperoleh dari eksperimen ke-8, dengan perolehan hasil seperti pada Tabel 5.

#### D. Inferensi dan Fusion Layer

Model YOLOX menghasilkan *bounding box* kendaraan yang dimodifikasi menjadi *filled box* untuk integrasi spasial. Sementara itu, SegFormer menghasilkan peta segmentasi area jalan. Keduanya digabungkan dalam *fusion layer* menggunakan pendekatan *late fusion*, untuk menghitung rasio area jalan yang ditempati kendaraan.



GAMBAR 11  
PROSES INFERENSI DAN HASIL FUSION LAYER

Sebagai contoh, dari total 263.603 *pixel* jalan, dan sebanyak 145.096 *pixel* adalah kendaraan. Sehingga ketika dihitung menggunakan Persamaan (1) menghasilkan rasio 35,5%, yang diklasifikasikan sebagai “Sedang”.

#### E. Validasi Hasil Klasifikasi

Dilakukan proses verifikasi dan validasi dengan mengukur tingkat akurasi dari hasil klasifikasi yang telah dilakukan. Pengukuran akurasi didasarkan pada *confusion matrix* yang merepresentasikan jumlah prediksi yang benar dan salah oleh model klasifikasi.

TABEL 6  
HASIL KLASIFIKASI GABUNGAN YOLOX+SEGFORMER

|           |         | Actual  |        |        |       |       |
|-----------|---------|---------|--------|--------|-------|-------|
|           |         | Lengang | Lancar | Sedang | Padat | Total |
| Predicted | Lengang | 8       | 2      | 0      | 0     | 10    |
|           | Lancar  | 0       | 7      | 3      | 0     | 10    |
|           | Sedang  | 0       | 1      | 9      | 0     | 10    |
|           | Padat   | 0       | 0      | 2      | 8     | 10    |
|           | Total   | 8       | 10     | 14     | 8     | 40    |

Berdasarkan Tabel 6, maka perhitungan akurasi sebagai berikut:

$$\text{Akurasi Klasifikasi}_{\text{YOLOX+SegFormer}} = \frac{8 + 7 + 9 + 8}{40} = \frac{32}{40} = 0,8 \approx 80\%$$

Hasil perhitungan menunjukkan bahwa akurasi dari penggunaan YOLOX dan SegFormer untuk klasifikasi kepadatan lalu lintas adalah 80%.

#### F. Perbandingan Hasil Klasifikasi

Klasifikasi kepadatan diuji pada 40 citra uji, dengan hasil sebagai berikut:

TABEL 7  
HASIL PERBANDINGAN KLASIFIKASI


| Metode          | Akurasi (%) |
|-----------------|-------------|
| YOLOX           | 50%         |
| SegFormer       | 20%         |
| YOLOX+SegFormer | 80%         |

#### G. Analisis Kesalahan Klasifikasi

Dari 20% kesalahan klasifikasi pada model gabungan YOLOX+SegFormer, sebagian besar terjadi karena kesamaan visual antar kelas, seperti antara “lancar” dan “sedang”. YOLOX saja cenderung mengklasifikasikan lebih rendah karena tidak mempertimbangkan area jalan, sehingga hanya mendapatkan akurasi sebesar 50%. Sedangkan SegFormer cenderung mengklasifikasikan lebih tinggi karena tidak mengenali keberadaan kendaraan, dan hal inilah yang mengakibatkan SegFormer hanya mendapat akurasi sebesar 20%.

#### H. Implementasi Website dan Validasi Fungsionalitas

Model YOLOX dan SegFormer diimplementasikan ke dalam sistem berbasis *web* untuk memungkinkan analisis kepadatan lalu lintas secara *real-time*. *Website* yang dikembangkan mampu menerima *input* video dari webcam, memprosesnya secara langsung, dan menampilkan hasil deteksi kendaraan, jumlah objek, rasio area terpakai, serta status klasifikasi kondisi lalu lintas. Seluruh data diperbarui otomatis dalam interval 100 milidetik, menjadikan sistem ini responsif dan informatif.



GAMBAR 12  
TAMPILAN WEBSITE

Selanjutnya, dilakukan validasi menggunakan *blackbox testing* terhadap enam fitur utama sistem. Lima pengguna menguji sistem melalui skenario nyata, seperti deteksi kendaraan dan klasifikasi kepadatan lalu lintas. Hasil pengujian menunjukkan seluruh fitur berjalan sesuai fungsinya dan sistem berhasil memberikan *output* yang akurat serta mudah dipahami, membuktikan bahwa sistem layak digunakan dan memberikan kemudahan dari perspektif pengguna. Hasil dari pengujian *blackbox testing* ditampilkan pada Tabel berikut:

TABEL 8  
HASIL PENGUJIAN MENGGUNAKAN *BLACKBOX TESTING*

| No | Fitur                              | Input                                                                   | Output                                                                                           | Status       |
|----|------------------------------------|-------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------|--------------|
| 1. | Tampilkan <i>Live Stream</i>       | Sistem dijalankan, webcam aktif                                         | Gambar video dari kamera tampil secara langsung di <i>website</i>                                | Berhasil (✓) |
| 2. | Deteksi Objek Kendaraan            | Kendaraan masuk dalam <i>frame</i>                                      | <i>Bounding box</i> muncul pada kendaraan + label objek dan <i>confidence score</i> ditampilkan  | Berhasil (✓) |
| 3. | Hitung Jumlah Kendaraan            | Beberapa kendaraan terdeteksi                                           | Jumlah kendaraan ditampilkan secara akurat di <i>overlay</i> dan di bagian bawah tampilan        | Berhasil (✓) |
| 4. | Hitung Rasio Area Terpakai         | Kendaraan terdeteksi di area jalan                                      | Persentase area yang tertutup kendaraan dihitung dan ditampilkan                                 | Berhasil (✓) |
| 5. | Klasifikasi Status Lalu Lintas     | Variasi kondisi lalu lintas (lengang / lancar / sedang / padat)         | Status muncul sesuai rasio: Lancar, Lancar, Sedang, dan Padat                                    | Berhasil (✓) |
| 6. | <i>Update Data</i> Secara langsung | Gerakan kendaraan atau objek berubah selama <i>live stream</i> berjalan | Informasi jumlah kendaraan, area terpakai, dan status ikut berubah menyesuaikan kondisi saat ini | Berhasil (✓) |

## V. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi kepadatan lalu lintas berbasis deep learning dengan pendekatan integratif antara model YOLOX dan SegFormer. Sistem mampu mengidentifikasi kepadatan lalu lintas melalui perhitungan rasio area kendaraan terhadap area jalan berdasarkan hasil deteksi dan segmentasi dari kedua model. YOLOX berperan dalam mendeteksi objek kendaraan dengan hasil evaluasi mAP sebesar 0.782, menunjukkan performa deteksi yang akurat. Sementara itu, SegFormer menunjukkan kinerja segmentasi area jalan yang sangat baik dengan nilai mIoU sebesar 0.9712 dan IoU khusus untuk kelas jalan mencapai 0.9814. Gabungan kedua model menghasilkan akurasi klasifikasi sebesar 80%, yang membuktikan bahwa integrasi keduanya dapat saling melengkapi dan meningkatkan keandalan sistem dalam menginterpretasikan kondisi lalu lintas.

Selain dari sisi akurasi model, sistem juga berhasil diimplementasikan dalam bentuk antarmuka website yang mampu menampilkan hasil deteksi, perhitungan rasio, dan klasifikasi status kepadatan secara real-time dari input webcam. Validasi fungsionalitas sistem melalui pengujian *blackbox* dengan melibatkan lima pengguna menunjukkan bahwa seluruh fitur berjalan dengan baik dan antarmuka sistem dapat digunakan secara intuitif. Hal ini membuktikan bahwa sistem yang dikembangkan tidak hanya unggul dari sisi teknis, tetapi juga telah memenuhi aspek keterpakaian dan kenyamanan bagi pengguna akhir.

## REFERENSI

- [1] Badan Pusat Statistik (BPS - Statistics Indonesia), "Jumlah Kendaraan Bermotor Menurut Provinsi dan Jenis Kendaraan (unit), 2023." Accessed: Nov. 19, 2024. [Online]. Available: <https://www.bps.go.id/id/statistics-table/3/Vj3NGRGa3dkRk5MTIU1bVNFOTVVbmQyVURSTVFUMDkjMw==/jumlah-kendaraan-bermotor-menurut-provinsi-dan-jenis-kendaraan--unit--2023.html>
- [2] A. Kurniasari and Jalinas, "Pendeteksian Tingkat Kepadatan Jalan Menggunakan Metode Canny Edge Detection," *Jurnal Ilmiah Teknologi dan Rekayasa*, vol. 25, no. 3, pp. 239–248, 2020, doi: 10.35760/tr.2020.v25i3.3419.
- [3] M. Gupta, H. Miglani, P. Deo, and A. Barhatte, "Real-time traffic control and monitoring," *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, vol. 5, Sep. 2023, doi: 10.1016/j.prime.2023.100211.
- [4] F. Hafifah, S. Rahman, and S. Asih, "Klasifikasi Jenis Kendaraan Pada Jalan Raya Menggunakan Metode Convolutional Neural Networks (CNN)," vol. 2, no. 5, pp. 292–301, Oct. 2021, [Online]. Available: <https://ejurnal.seminar-id.com/index.php/tin>
- [5] D. I. Mulyana, M. F. Lazuardi, and M. B. Yel, "Deteksi Bahasa Isyarat Dalam Pengenalan Huruf Hijaiyah Dengan Metode YOLOV5," *Jurnal Teknik Elektro dan Komputasi (ELKOM)*, vol. 4, no. 2, pp.

- 145–151, Aug. 2022, doi: 10.32528/elkom.v4i2.8145.
- [6] X. Deng, L. Qi, Z. Liu, S. Liang, K. Gong, and G. Qiu, “Weed Target Detection at Seedling Stage in Paddy Fields Based on YOLOX,” *PLoS One*, vol. 18, no. 12, December, Dec. 2023, doi: 10.1371/journal.pone.0294709.
- [7] X. Lin *et al.*, “Semantic Segmentation of China’s Coastal Wetlands Based on Sentinel-2 and Segformer,” *Remote Sens (Basel)*, vol. 15, no. 15, Aug. 2023, doi: 10.3390/rs15153714.
- [8] K. Jiang, U. Afzaal, and J. Lee, “Transformer-Based Weed Segmentation for Grass Management,” *Sensors*, vol. 23, no. 1, Jan. 2023, doi: 10.3390/s23010065.
- [9] Y. P. W. Prasetyo, “Evaluasi Dampak Kegiatan Sekolah Terhadap Pola Lalu Lintas Dan Mobilitas Kota,” *Jurnal Jurnal Sains Dan Teknologi(JSIT)*, vol. 4, no. 1, pp. 53–61, 2024, Accessed: Jan. 10, 2025. [Online]. Available: <https://jurnal.minartaris.com/index.php/jsit/article/view/1519>
- [10] R. E. Wibisono, “Analisa Dampak Lalu Lintas Jalan Tambak Osowilangun Akibat Pembangunan Teluk Lamong Surabaya,” *Ukarst: Jurnal Universitas Kadiri Riset Teknik Sipil*, vol. 4, no. 1, pp. 69–83, 2020, doi: 10.30737/ukarst.v3i2.
- [11] M. Y. Fadhlan, U. B. Hanafi, and M. R. Aulia, “Implementasi Algoritma Pendeteksi Tingkat Kepadatan Lalu Lintas Menggunakan Metode Background Subtraction,” *JITEL (Jurnal Ilmiah Telekomunikasi, Elektronika, dan Listrik Tenaga)*, vol. 1, no. 1, pp. 59–68, 2021, doi: <https://doi.org/10.35313/jitel.v1.i1.2021.59-68>.
- [12] M. U. Salur and I. Aydin, “A Novel Hybrid Deep Learning Model for Sentiment Classification,” *IEEE Access*, vol. 8, pp. 58080–58093, Mar. 2020, doi: 10.1109/ACCESS.2020.2982538.
- [13] D. Wang, J. Guo, and C. Zhang, “A Novel Hybrid Deep Learning Model for Complex Systems: A Case of Train Delay Prediction,” *Advances in Civil Engineering*, vol. 2024, May 2024, doi: 10.1155/2024/8163062.
- [14] I. Ashraf, S. Hur, G. Kim, and Y. Park, “Analyzing Performance of YOLOx for Detecting Vehicles in Bad Weather Conditions,” *Sensors*, vol. 24, no. 2, Jan. 2024, doi: 10.3390/s24020522.
- [15] H. Yu, X. Ye, W. Hong, R. Shi, Y. Ding, and C. Liu, “A Cascading Learning Method with SegFormer for Radiographic Measurement of Periodontal Bone Loss,” *BMC Oral Health*, vol. 24, no. 1, Dec. 2024, doi: 10.1186/s12903-024-04079-y.
- [16] W. M. Elmessery *et al.*, “Semantic Segmentation of Microbial Alterations Based on SegFormer,” *Front Plant Sci*, vol. 15, 2024, doi: 10.3389/fpls.2024.1352935.
- [17] Suwarno, T. Tan, and Jonathan, “MobileNetV3-based Handwritten Chinese Recognition Towards the Effectiveness of Learning Hanzi,” *JURNAL RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 6, pp. 1394–1402, Dec. 2023, doi: <https://doi.org/10.29207/resti.v7i6.5505>.