

Peramalan Kepadatan Lalu Lintas Berbasis Video Menggunakan YOLOX dan *Long Short-Term Memory* (LSTM)

1st Maoreen Damar Safira Subakti
Program Studi Teknologi Informasi
Universitas Telkom, Kampus Surabaya
Surabaya, Jawa Timur, Indonesia
maoreendsafiraa@student.telkomuniversity.ac.id

2nd Mustafa Kamal
Program Studi Teknologi Informasi
Universitas Telkom, Kampus Surabaya
Surabaya, Jawa Timur, Indonesia
mustafakamal@telkomuniversity.ac.id

3rd Fandisyah Rahman
Program Studi Informatika
Universitas Telkom, Kampus Surabaya
Surabaya, Jawa Timur, Indonesia
fandisyah@telkomuniversity.ac.id

Abstrak — Kepadatan lalu lintas di kawasan perkotaan menjadi tantangan serius dalam pengelolaan transportasi modern karena dampaknya terhadap kemacetan, pemborosan waktu, dan polusi udara. Untuk mengatasi permasalahan ini, dibutuhkan pendekatan prediktif berbasis teknologi guna mendukung pengambilan keputusan yang cepat dan adaptif. Penelitian ini bertujuan mengembangkan sistem prediksi kepadatan lalu lintas berbasis video dengan mengintegrasikan algoritma YOLOX sebagai detektor kendaraan dan *Long Short-Term Memory* (LSTM) sebagai model peramalan. Data dikumpulkan melalui rekaman video lalu lintas dari Jembatan Penyeberangan Orang (JPO), yang kemudian diolah melalui ekstraksi *frame* dan pelabelan *bounding box*. Model YOLOX digunakan untuk mendeteksi jumlah kendaraan per *frame*, sedangkan hasil deteksi menjadi input bagi model LSTM untuk meramalkan jumlah kendaraan dalam lima menit ke depan. Evaluasi menunjukkan bahwa YOLOX mencapai performa deteksi tinggi dengan $mAP@50$ sebesar 98,5% dan $mAP@75$ sebesar 91,6%, sementara LSTM menunjukkan akurasi prediksi yang baik dengan MAE sebesar 0,0905 dan RMSE sebesar 0,1173. Sistem ini telah diimplementasikan dalam bentuk aplikasi web untuk mempermudah pengguna mengunggah video dan memperoleh hasil prediksi secara visual. Temuan ini menunjukkan potensi sistem dalam mendukung pengelolaan lalu lintas berbasis data secara efisien di lingkungan perkotaan.

Kata kunci— YOLOX, LSTM, peramalan, lalu lintas, video, *deep learning*.

I. PENDAHULUAN

Pertumbuhan jumlah kendaraan bermotor di Indonesia meningkat pesat setiap tahunnya, dengan lebih dari 150 juta unit tercatat pada tahun 2023 [1]. Peningkatan ini memberikan dampak besar terhadap kepadatan lalu lintas, yang tidak hanya menyebabkan kemacetan dan membuang waktu, tetapi juga menurunkan kenyamanan pengguna jalan dan meningkatkan polusi udara. Kepadatan lalu lintas, yang diukur dalam jumlah kendaraan per satuan panjang jalan [2], sangat dipengaruhi oleh berbagai faktor seperti waktu, jumlah kendaraan, dan lebar jalan, terutama pada jam sibuk [3]. Kondisi ini menuntut solusi inovatif yang mampu mengelola arus kendaraan secara lebih efisien. Salah satu

pendekatan yang menjanjikan adalah pemanfaatan teknologi informasi untuk mengumpulkan dan menganalisis data lalu lintas secara langsung guna mendukung pengambilan keputusan yang lebih cepat dan adaptif.

Dalam beberapa tahun terakhir, *deep learning* telah menjadi salah satu teknologi yang banyak digunakan dalam berbagai aplikasi, termasuk di bidang transportasi [4]. Salah satu algoritma *deep learning* yang unggul dalam menangani data sekuensial adalah *Long Short-Term Memory* (LSTM). LSTM terbukti efektif dalam peramalan deret waktu karena mampu menangkap pola data jangka pendek maupun jangka panjang. Selain itu, deteksi objek dalam video juga memainkan peran penting dalam memperoleh data lalu lintas yang akurat. YOLOX, sebagai pengembangan terbaru dari keluarga YOLO, menunjukkan kinerja tinggi dalam mendeteksi objek pada kondisi kompleks, termasuk kendaraan kecil, latar belakang padat, dan objek yang saling tumpang tindih [5]. Beberapa penelitian sebelumnya telah berhasil menunjukkan performa unggul dari YOLOX dalam tugas deteksi serta efektivitas LSTM dalam peramalan arus lalu lintas, namun masih sedikit studi yang menggabungkan keduanya dalam satu sistem terintegrasi untuk keperluan prediksi kepadatan lalu lintas berbasis video [6].

Berdasarkan kondisi tersebut, permasalahan utama yang hendak dipecahkan dalam penelitian ini adalah bagaimana membangun sistem berbasis video yang mampu mendeteksi kendaraan dari rekaman secara otomatis dan melakukan prediksi arus lalu lintas secara akurat dalam jangka pendek. Lebih jauh lagi, penting untuk mengevaluasi efektivitas masing-masing algoritma dalam konteks data lalu lintas nyata serta memastikan hasil prediksi dapat dimanfaatkan secara langsung untuk mendukung pengambilan keputusan berbasis data di lingkungan perkotaan.

Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem prediksi kepadatan lalu lintas berbasis video dengan menggabungkan algoritma YOLOX untuk deteksi kendaraan dan LSTM untuk peramalan. Sistem ini dirancang agar mampu mendeteksi jumlah kendaraan dari video lalu lintas secara akurat, lalu menggunakan data tersebut untuk memprediksi kondisi lalu lintas dalam jangka pendek. Dengan implementasi ini, diharapkan sistem yang

dihasilkan mampu menjadi solusi praktis dalam pengelolaan lalu lintas yang lebih efisien dan responsif terhadap dinamika di lapangan.

II. KAJIAN TEORI

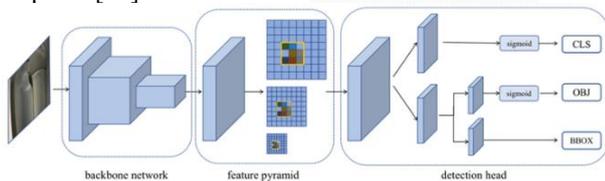
Kajian teori bertujuan untuk menjelaskan landasan konseptual dan ilmiah yang mendasari penelitian ini. Teori-teori yang dibahas meliputi konsep-konsep utama yang berkaitan dengan peramalan kepadatan lalu lintas, deteksi objek pada citra video, serta teknologi yang digunakan dalam implementasi sistem.

A. Peramalan

Peramalan (*forecasting*) adalah proses memperkirakan nilai atau kondisi di masa depan berdasarkan data historis [7]. Dalam konteks transportasi, peramalan digunakan untuk memprediksi volume kendaraan atau kepadatan lalu lintas guna mendukung pengambilan keputusan yang lebih efektif. Metode peramalan umumnya digunakan dalam analisis deret waktu (*time series*) untuk mendeteksi pola yang berulang dari waktu ke waktu [8].

B. YOLOX

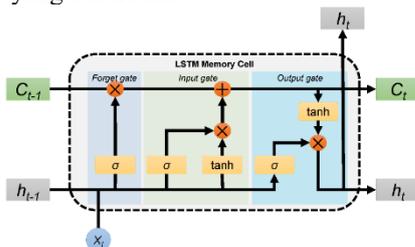
YOLOX (You Only Look Once Extended) merupakan algoritma deteksi objek berbasis *deep learning* yang dikembangkan dari arsitektur YOLO [9]. YOLOX mengusung pendekatan *anchor-free* dan terdiri dari tiga komponen utama: CSPDarknet sebagai *backbone* untuk ekstraksi fitur, PAFPN untuk penggabungan fitur multiskala, dan *prediction head* untuk klasifikasi serta regresi *bounding box*. Algoritma ini unggul dalam mendeteksi objek secara cepat dan akurat, termasuk dalam kondisi visual yang kompleks [10].



GAMBAR 1
ARSITEKTUR YOLOX

C. LSTM

LSTM (Long Short-Term Memory) adalah model *deep learning* yang digunakan untuk memproses data berurutan, seperti data lalu lintas dari waktu ke waktu [11]. LSTM dapat mengingat informasi penting dari waktu sebelumnya dan melupakan yang tidak perlu, sehingga cocok untuk memprediksi data *time series* [12]. Model ini sering digunakan karena mampu mengenali pola yang berubah-ubah dalam data yang berurutan.



GAMBAR 2
ARSITEKTUR LSTM

D. Evaluasi Model

Evaluasi kinerja dilakukan menggunakan metrik yang disesuaikan dengan tugas masing-masing model. Untuk YOLOX yang digunakan dalam deteksi objek kendaraan, digunakan *mean Average Precision* (mAP) dengan dua ambang batas, yaitu mAP@50 dan mAP@75. Sedangkan untuk model LSTM yang digunakan dalam peramalan jumlah kendaraan, digunakan *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE). Penjelasan masing-masing metrik disertai rumusnya sebagai berikut:

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

Metrik ini digunakan untuk mengukur seberapa baik model mendeteksi objek berdasarkan presisi dan *recall* pada setiap kelas [13]. N adalah jumlah kelas objek, dan AP_i adalah nilai *Average Precision* untuk kelas ke- i . Dalam penelitian ini, objek yang dideteksi adalah mobil dan motor.

$$IoU = \frac{\text{Luas area tumpang tindih}}{\text{Luas area gabungan}} \quad (2)$$

IoU digunakan untuk menentukan apakah suatu deteksi dianggap benar atau salah dalam perhitungan mAP. Pada mAP@50, deteksi dianggap benar jika $IoU \geq 0.50$, sedangkan mAP@75 menetapkan ambang lebih ketat yaitu $IoU \geq 0.75$ [14].

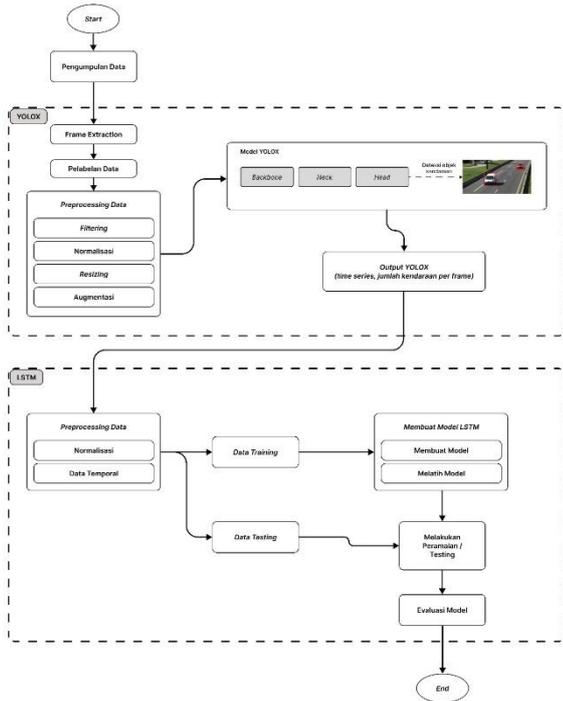
$$RMSE = \sqrt{\frac{1}{n} \sum_i^n (\hat{y}_i - y_i)^2} \quad (3)$$

Dengan \hat{y}_i adalah nilai hasil prediksi, y_i adalah nilai aktual, dan n adalah jumlah data. RMSE digunakan untuk mengukur akar dari rata-rata kuadrat selisih antara nilai prediksi dan nilai aktual [15].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

MAE mengukur rata-rata selisih absolut antara prediksi dan nilai aktual, tanpa memperhitungkan arah kesalahan. Nilai yang lebih kecil menunjukkan tingkat kesalahan prediksi yang rendah [16].

III. METODE



GAMBAR 3
SISTEMATIKA PENYELESAIAN MASALAH

Penelitian ini mengembangkan sistem peramalan kepadatan lalu lintas berbasis *deep learning* dengan memanfaatkan dua model utama. Model YOLOX digunakan untuk mendeteksi jumlah kendaraan dalam setiap *frame* video secara otomatis, sedangkan model LSTM diterapkan untuk meramalkan jumlah kendaraan pada 5 menit ke depan berdasarkan data historis yang diperoleh. Integrasi kedua model ini dirancang untuk menghasilkan proses deteksi dan peramalan kepadatan lalu lintas secara berurutan dan terstruktur.

A. Pengumpulan Data

Data primer dalam penelitian ini diperoleh melalui perekaman video secara langsung di Jalan Wonokromo, Surabaya, dengan sudut pengambilan sekitar 45°–60° dari atas jembatan penyeberangan orang (JPO). Jumlah video yang dikumpulkan sebanyak 14 kali, dengan durasi tiap video berkisar antara 30 hingga 600 dan waktu pengambilan pada pagi dan siang hari. Kondisi lalu lintas yang terekam mencakup kategori 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*, dengan interval satu *frame* setiap lima detik untuk mewakili isi video secara merata. Gambar-gambar tersebut digunakan dalam proses pelabelan, pelatihan, dan pengujian model, dengan pengaturan yang disesuaikan agar efisien dan sesuai dengan kebutuhan representasi data dalam penelitian ini.

C. Pelabelan Data

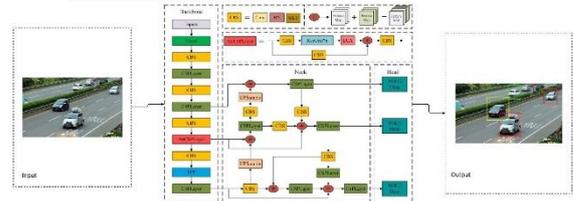
Pelabelan data dilakukan secara manual menggunakan *platform* Supervisely dengan menambahkan anotasi *bounding box* pada setiap kendaraan dalam gambar. Objek diklasifikasikan ke dalam dua kelas, yaitu motor dan mobil, dan hasil pelabelan disimpan dalam format .json sebagai *ground truth* untuk pelatihan model YOLOX.

D. *Preprocessing* Data

Proses *preprocessing* data dalam penelitian ini mencakup dua bagian, yaitu untuk model YOLOX dan LSTM. Untuk YOLOX, dilakukan penyesuaian ukuran gambar menjadi 640×640, pemberian *padding* agar berbentuk persegi, normalisasi piksel, serta penyaringan anotasi yang tidak valid. Augmentasi gambar diterapkan melalui teknik seperti *Mosaic*, *RandomAffine*, *MixUp*, perubahan HSV, dan *flipping horizontal* untuk memperkaya variasi data pelatihan. Sementara itu, *preprocessing* data LSTM melibatkan pembersihan data, seleksi fitur kendaraan, normalisasi, pembentukan urutan waktu, dan penetapan label target untuk lima menit ke depan. Pembagian data dilakukan secara kronologis (urut) tanpa pengacakan, dengan rasio 80% untuk pelatihan, 10% validasi, dan 10% pengujian guna menjaga integritas data *time series*.

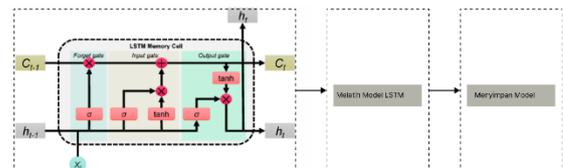
E. Pembuatan Model

Model dikembangkan dengan pendekatan gabungan antara YOLOX dan LSTM. YOLOX digunakan untuk mendeteksi kendaraan pada setiap *frame* video dengan arsitektur CSPDarknet sebagai *backbone*, FPN sebagai *neck*, dan *head* untuk menghasilkan *bounding box* serta klasifikasi objek.



GAMBAR 4
MODEL YOLOX

Sementara itu, model LSTM dibangun dengan satu lapisan LSTM (*single-layer*) yang dirancang untuk mengenali pola dalam data *time series*. Model ini digunakan untuk meramalkan jumlah kendaraan lima menit ke depan berdasarkan hasil deteksi dari YOLOX. Kedua model berjalan secara terpisah, namun saling terintegrasi dalam alur sistem untuk menghasilkan prediksi kondisi lalu lintas berdasarkan data input video.



GAMBAR 5
MODEL LSTM

F. Melakukan Peramalan

Setelah model LSTM selesai dilatih, proses peramalan dilakukan menggunakan data uji (*testing*) yang telah dipisahkan sebelumnya. Input berupa jumlah kendaraan pada rentang waktu tertentu digunakan untuk menghasilkan prediksi jumlah kendaraan lima menit ke depan. Hasil prediksi kemudian melalui proses denormalisasi untuk mengembalikan nilai ke skala aslinya agar lebih mudah dibaca dan diinterpretasikan sesuai konteks analisis lalu lintas.

G. Evaluasi Model

Evaluasi dilakukan untuk menilai akurasi model setelah pelatihan dan peramalan. Kinerja model YOLOX dievaluasi menggunakan *mean Average Precision* (mAP), yang mengukur tingkat ketepatan deteksi objek dibandingkan dengan *ground truth*. Sementara itu, Model LSTM dievaluasi menggunakan dua metrik utama, yaitu *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE), yang bersama-sama memberikan gambaran menyeluruh mengenai rata-rata kesalahan dan sensitivitas terhadap *outlier*. Hasil evaluasi divisualisasikan dalam bentuk grafik untuk memperjelas perbandingan antara data aktual dan prediksi.

H. Implementasi Sistem dan Uji Coba

Model yang telah dikembangkan kemudian diimplementasikan ke dalam sebuah *website* menggunakan bahasa pemrograman Python dan JavaScript [17]. *Website* ini dirancang untuk menjalankan fungsi utama sistem, yaitu mendeteksi kendaraan dan memprediksi kepadatan lalu lintas berdasarkan input video. Sistem berjalan secara lokal melalui *localhost* dan memungkinkan pengguna untuk mengunggah video serta melihat hasil deteksi dan peramalan secara visual, sehingga mendukung uji coba sistem dalam konteks nyata.



GAMBAR 6
RANCANGAN WEBSITE 1



GAMBAR 7
RANCANGAN WEBSITE 2

IV. HASIL DAN PEMBAHASAN

Bagian ini memuat keluaran dari proses pengembangan sistem deteksi dan prediksi kepadatan lalu lintas menggunakan model YOLOX dan LSTM. Uraian difokuskan pada performa model dalam mendeteksi kendaraan serta ketepatan hasil peramalan yang diperoleh. Selain itu, dijelaskan pula implementasi sistem ke dalam platform berbasis web serta interpretasi terhadap hasil yang diperoleh untuk menilai efektivitas pendekatan yang digunakan.

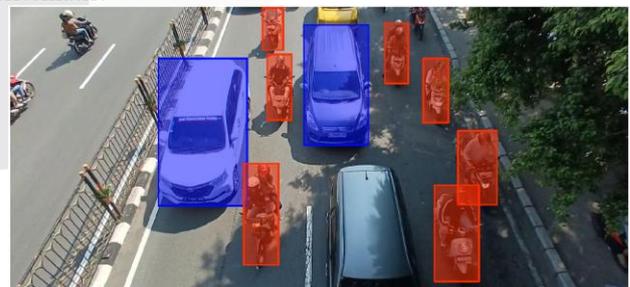
A. Pengumpulan dan Pengolahan Data

Data primer diperoleh melalui perekaman video secara langsung di Jalan Wonokromo, Surabaya, menggunakan sudut pengambilan 45° – 60° dari atas jembatan penyeberangan orang (JPO). Sebanyak 14 video berdurasi 60 hingga 600 detik diambil dan kemudian diekstraksi menjadi 1.559 gambar menggunakan interval 5 detik per *frame*.



GAMBAR 8
HASIL DARI EKSTRAKSI FRAME

Gambar hasil ekstraksi digunakan dalam proses pelabelan menggunakan platform Supervisely, dengan anotasi berupa bounding box untuk dua kelas objek: motor dan mobil. Seluruh data selanjutnya dibagi menjadi 80% untuk pelatihan, 10% validasi, dan 10% pengujian, guna mendukung proses pengembangan dan evaluasi model secara sistematis.



GAMBAR 9
PROSES PELABELAN PADA OBJEK

B. Pelatihan dan Evaluasi Model YOLOX

Pelatihan model deteksi kendaraan dilakukan menggunakan arsitektur YOLOX-s dengan variasi konfigurasi *hyperparameter* seperti *batch size* dan *base learning rate*. Sebanyak delapan eksperimen dijalankan, seluruhnya menggunakan 50 *epoch*, *optimizer* SGD, serta menerapkan *early stopping* untuk mencegah *overfitting*.

TABEL 1
KONFIGURASI DAN HASIL EKSPERIMEN MODEL YOLOX

Eksperimen	Epoch	Batch Size	Base LR	Early Stopping	mAP
1.	50	8	0.001	Ya	0.716
2.	50	16	0.001	Ya	0.669
3	50	8	0.005	Ya	0.633
4	50	16	0.005	Ya	0.724
5	50	8	0.01	Ya	0.648
6	50	16	0.01	Ya	0.660
7	50	8	0.05	Ya	0.751
8	50	16	0.05	Ya	0.749

Selanjutnya, evaluasi awal dilakukan berdasarkan nilai mAP pada data validasi, dengan tiga model terbaik (eksperimen ke-4, ke-7, dan ke-8) dipilih untuk diuji lebih lanjut pada data uji.

TABEL 2
HASIL EVALUASI EKSPERIMEN MODEL YOLOX

Eksperimen	mAP (val)	mAP (test)	mAP@50 (test)	mAP@75 (test)
4	0.724	0.730	0.980	0.887
7	0.751	0.750	0.982	0.943
8	0.749	0.765	0.985	0.916

Hasil evaluasi menunjukkan bahwa model dari eksperimen ke-7 mencapai mAP tertinggi sebesar 0.751. Visualisasi *training loss* dan *validation mAP* mengindikasikan proses pelatihan yang stabil dan konvergen, dengan peningkatan bertahap pada mAP@50 dan mAP@75 yang menunjukkan peningkatan ketepatan dalam deteksi objek, terutama pada data dengan ukuran kendaraan yang kecil. Model terbaik kemudian digunakan sebagai model akhir untuk proses inferensi.

C. Pelatihan dan Evaluasi Model LSTM

Pelatihan model LSTM dilakukan untuk meramalkan jumlah kendaraan berdasarkan data deret waktu, dengan menggunakan delapan kombinasi eksperimen yang mencakup variasi jumlah unit LSTM (32 dan 64), nilai *dropout* (0.0 dan 0.2), serta *learning rate* (0.0001 dan 0.0005). Seluruh eksperimen yang dilakukan menggunakan *epoch* 100, *batch size* 32, dan *optimizer* Adam.

TABEL 3
KONFIGURASI DAN HASIL EKSPERIMEN MODEL LSTM

No.	LSTM Units	Dropout	Learning Rate	MAE (val mae)	RMSE (val loss)
1.	32	0.0	0.0001	0.0870	0.0115
2.	32	0.2	0.0001	0.0867	0.0116
3.	64	0.0	0.0001	0.0866	0.0115
4.	64	0.2	0.0001	0.0868	0.0114
5.	32	0.0	0.0005	0.0893	0.0118
6.	32	0.2	0.0005	0.0901	0.0120
7.	64	0.0	0.0005	0.0924	0.0124
8.	64	0.2	0.0005	0.0898	0.0119

Dari delapan eksperimen tersebut, tiga model terbaik (eksperimen ke-4, ke-7, dan ke-8) dipilih untuk diuji lebih lanjut pada data uji guna menilai kemampuan generalisasi.

TABEL 4
HASIL EVALUASI EKSPERIMEN MODEL LSTM

Eksperimen	Val Loss (MSE)	Val MAE	Test MAE	Test RMSE
1	0.0113	0.0870	0.098	0.120
3	0.0115	0.0870	0.099	0.122
4	0.0115	0.0864	0.0979	0.1203

Dari hasil evaluasi, model terbaik diperoleh pada eksperimen ke-4 dengan nilai tertera pada Tabel 4. Model dengan performa paling stabil dan akurat kemudian ditetapkan sebagai model akhir yang digunakan untuk peramalan jumlah kendaraan lima menit ke depan.

D. Analisis Kinerja LSTM

Sub bab ini menyajikan hasil evaluasi terhadap model LSTM yang telah dilatih, guna mengetahui sejauh mana akurasi model dalam melakukan peramalan jumlah kendaraan berdasarkan data deret waktu. Evaluasi dilakukan menggunakan metrik MAE dan RMSE pada data uji untuk mengukur performa prediksi secara menyeluruh dan mendalam.

TABEL 5
HASIL METRIK EVALUASI LSTM

Metrik	Nilai
MAE	0.0905
RMSE	0.1173

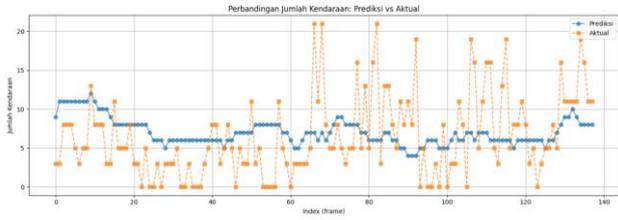
Berdasarkan Tabel 5, analisis kinerja model LSTM menunjukkan bahwa model mampu melakukan peramalan jumlah kendaraan lima menit ke depan dengan akurasi yang baik. Berdasarkan evaluasi menggunakan metrik MAE dan RMSE, diperoleh nilai MAE sebesar 0.0905 dan RMSE sebesar 0.1173, yang menunjukkan bahwa rata-rata kesalahan prediksi tergolong rendah dan tidak didominasi oleh *error* ekstrem. Model ini menggunakan enam titik data historis (30 detik sebelumnya) sebagai input untuk memprediksi jumlah kendaraan pada jendela waktu berikutnya, dan hasil evaluasi mengindikasikan bahwa model cukup andal dalam menangkap pola pergerakan lalu lintas secara konsisten.

E. Analisis Hasil Peramalan

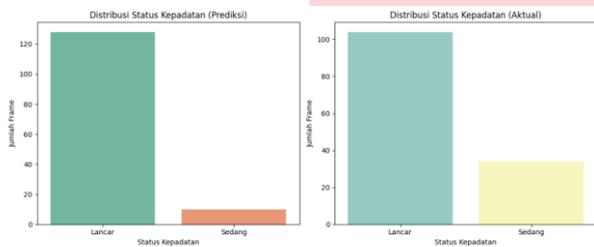
Setelah model LSTM selesai dilatih, hasil peramalan jumlah kendaraan pada setiap *frame* diuji dan dikembalikan ke skala aslinya melalui proses denormalisasi agar dapat dibandingkan langsung dengan data aktual. Nilai prediksi dan aktual tersebut kemudian diklasifikasikan ke dalam tiga kategori tingkat kepadatan lalu lintas yaitu Lancar, Sedang, dan Padat berdasarkan ambang batas yang telah ditentukan. Proses ini bertujuan mengevaluasi akurasi model tidak hanya dari sisi kuantitatif jumlah kendaraan, tetapi juga dari aspek klasifikasi kondisi lalu lintas.

	y_prediksi_denorm	status_prediksi	y_aktual_denorm	status_aktual
0	9	Lancar	3	Lancar
1	11	Sedang	3	Lancar
2	11	Sedang	8	Lancar
3	11	Sedang	8	Lancar
4	11	Sedang	8	Lancar

GAMBAR 10
TABEL HASIL DENORMALISASI



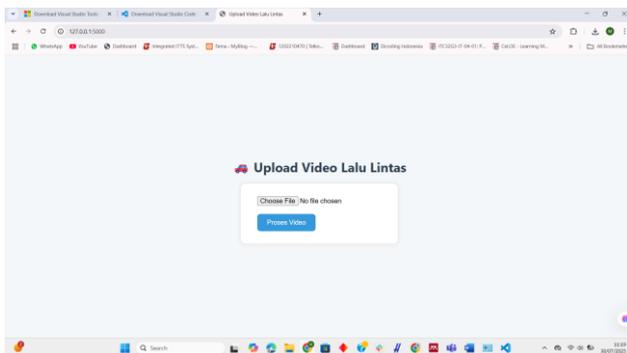
GAMBAR 11
GRAFIK HASIL PERBANDINGAN



GAMBAR 12
DIAGRAM BATANG DISTRIBUSI STATUS KEPADATAN

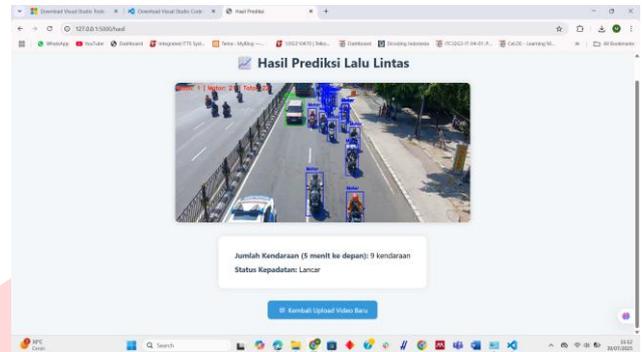
Hasil peramalan disajikan melalui tabel, grafik garis, dan diagram batang untuk memperjelas evaluasi performa model. Tabel memperlihatkan perbandingan nilai prediksi dan aktual jumlah kendaraan, disertai klasifikasi tingkat kepadatan berdasarkan ambang batas tertentu. Grafik garis menunjukkan bahwa model LSTM mampu mengikuti pola umum jumlah kendaraan aktual, namun masih terdapat deviasi terutama saat terjadi lonjakan mendadak. Sementara itu, diagram batang mengindikasikan bahwa model cenderung mengklasifikasikan lalu lintas ke dalam kategori kepadatan yang lebih ringan dibandingkan kondisi sesungguhnya. Secara keseluruhan, model cukup efektif dalam menangkap tren lalu lintas, namun masih perlu peningkatan pada sensitivitas terhadap kondisi ekstrem untuk menghasilkan prediksi yang lebih akurat.

F. Implementasi Sistem Pada Website



GAMBAR 13
TAMPILAN HOME PADA WEBSITE

Implementasi sistem dalam bentuk aplikasi web memungkinkan pengguna untuk mengunggah video lalu lintas, memprosesnya secara otomatis, dan menampilkan hasil deteksi serta peramalan jumlah kendaraan secara visual. Antarmuka awal menyediakan *form* unggah video .mp4 dan tombol untuk memulai analisis.



GAMBAR 14
TAMPILAN HASIL OUTPUT PREDIKSI PADA WEBSITE

Setelah diproses, halaman hasil menampilkan cuplikan *frame* hasil deteksi YOLOX dengan *bounding box* berwarna sesuai jenis kendaraan, serta prediksi jumlah kendaraan dan status kepadatan dari model LSTM. Sistem memisahkan informasi aktual dan prediktif agar pengguna memperoleh gambaran lalu lintas secara menyeluruh dan mudah dipahami.

V. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa sistem deteksi dan peramalan lalu lintas berbasis video berhasil dikembangkan dengan mengintegrasikan algoritma YOLOX dan LSTM. Model YOLOX digunakan untuk mendeteksi kendaraan dalam setiap frame hasil ekstraksi video, sedangkan model LSTM digunakan untuk meramalkan jumlah kendaraan berdasarkan data hasil deteksi tersebut. Proses pengumpulan data dilakukan secara langsung di lapangan, yaitu di Jalan Wonokromo, dan melewati tahapan penting seperti ekstraksi frame, pelabelan objek, serta preprocessing sebelum pelatihan model. Hasil pelatihan menunjukkan bahwa model YOLOX mampu mencapai performa deteksi tinggi dengan nilai mAP@50 sebesar 98,5% dan mAP@75 sebesar 91,6% pada data uji. Di sisi lain, model LSTM terbaik yang diperoleh dari eksperimen keempat menghasilkan nilai MAE sebesar 0.0864 pada data validasi, serta MAE sebesar 0.0979 dan RMSE sebesar 0.1203 pada data uji, yang menunjukkan tingkat akurasi numerik yang cukup baik dalam memprediksi jumlah kendaraan.

Sistem ini juga telah berhasil diimplementasikan dalam bentuk aplikasi web yang memungkinkan pengguna mengunggah video, memprosesnya secara otomatis, dan memperoleh hasil deteksi serta prediksi dalam bentuk visual dan teks. Meskipun performa numerik model menunjukkan hasil yang menjanjikan, analisis visual mengindikasikan bahwa model LSTM masih cenderung kurang responsif terhadap lonjakan ekstrem jumlah kendaraan, sehingga perbaikan model masih diperlukan. Secara keseluruhan, sistem ini telah mampu menjawab tujuan penelitian dan menghasilkan *prototipe* fungsional yang dapat digunakan sebagai dasar pengembangan sistem pemantauan lalu lintas yang lebih adaptif dan akurat.

REFERENSI

- [1] B. P. S. Indonesia, "Jumlah Kendaraan Bermotor Menurut Provinsi dan Jenis Kendaraan (unit), 2023 [Online]." Online. Accessed: Dec. 10, 2024. [Online]. Available: <https://www.bps.go.id/id/statistics-table/3/VjJ3NGRGa3dkRk5MTIU1bVNFOTVVbmQyVURSTVFUMDkjMw==/jumlah-kendaraan-bermotor-menurut-provinsi-dan-jenis-kendaraan--unit--2023.html>
- [2] Y. P. W. Prasetyo, "Evaluasi Dampak Kegiatan Sekolah Terhadap Pola Lalu Lintas Dan Mobilitas Kota," *Jurnal Sains dan Teknologi (JSIT)*, vol. 4, no. 1, pp. 53–61, 2024, doi: 10.47233/jsit.v4i1.1519.
- [3] 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: 10.1016/j.jtte.2017.12.002.A.
- [4] S. Afandizadeh, S. Abdolahi, and H. Mirzahosseini, "Deep Learning Algorithms for Traffic Forecasting: A Comprehensive Review and Comparison with Classical Ones," *J Adv Transp*, vol. 2024, pp. 1–30, 2024, doi: 10.1155/2024/9981657.
- [5] Z. Liu, W. Han, H. Xu, K. Gong, Q. Zeng, and X. Zhao, "Research on vehicle detection based on improved YOLOX S," *Sci Rep*, vol. 13, no. 1, pp. 1–21, 2023, doi: 10.1038/s41598-023-50306-x.
- [6] S. A. Azan, Y. Darma, F. N. Akla, and A. Putri, "Pemrosesan Jumlah Dan Jenis Kendaraan Berdasarkan Video Images (Studi Kasus: Jln. T. Nyak Arief Jeulingke, Kota Banda Aceh)," *Jurnal Arsip Rekayasa Sipil dan Perencanaan*, vol. 6, no. 4, pp. 216–224, 2023, doi: 10.24815/jarsp.v6i4.35607.
- [7] T. Tajrin, Y. Kuswoyo, and R. A. Ginting, "Implementasi Metode Forecasting Dengan Menggunakan Algoritma Time Series Dalam Memprediksi Permintaan Cetak Cv. Grand Grafika," *Djtechno: Jurnal Teknologi Informasi*, vol. 5, no. 2, pp. 184–194, 2024, doi: 10.46576/djtechno.v5i2.4563.
- [8] R. Rahmawati, Z. Azhar, and N. Marpaung, "Penerapan Metode Weight Moving Average Untuk Peramalan Persediaan Kosmetik Pada Toko Robin," *Seminar Nasional Informatika (SENATIKA)*, no. 2021: Prosiding SENATIKA, pp. 449–453, 2021, [Online]. Available: <https://ejournal.pelitaindonesia.ac.id/ojs32/index.php/SENATIKA/article/view/1201>
- [9] M. Khairul Imam, S. Sai, A. Yuliananda Mabrur, and Y. P. Manaha, "Pemanfaatan Algoritma You Only Look Once (Yolo) Untuk Mendukung Sistem Informasi Lalu Lintas Berbasis Geospasial Traffic Dashboard," *Prosiding SEMSINA*, vol. 4, no. 2, pp. 256–262, 2024, doi: 10.36040/semsina.v4i2.8070.
- [10] 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, pp. 1–22, 2023, doi: 10.1371/journal.pone.0294709.
- [11] S. Zahara and Sugianto, "Peramalan Data Indeks Harga Konsumen Berbasis Time Series Multivariate Menggunakan Deep Learning," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 24–30, 2021, doi: 10.29207/resti.v5i1.2562.
- [12] S. H. Rafi, N. Al-Masood, S. R. Deeba, and E. Hossain, "A short-term load forecasting method using integrated CNN and LSTM network," *IEEE Access*, vol. 9, pp. 32436–32448, 2021, doi: 10.1109/ACCESS.2021.3060654.
- [13] T. Hai *et al.*, "A Deep Learning-Based Approach to Apple Tree Pruning and Evaluation with Multi-Modal Data for Enhanced Accuracy in Agricultural Practices," *Agronomy*, vol. 15, no. 5, pp. 1–23, 2025, doi: 10.3390/agronomy15051242.
- [14] H. Lin *et al.*, "A Study on Data Selection for Object Detection in Various Lighting Conditions for Autonomous Vehicles," *J Imaging*, vol. 10, no. 7, pp. 1–18, 2024, doi: 10.3390/jimaging10070153.
- [15] Y. Xu, S. Zou, and X. Lu, "Short-Term Load Forecasting Based on Feature Selection and Combination Model," *Zhongguo Dianli/Electric Power*, vol. 55, no. 7, pp. 121–127, 2022, doi: 10.11930/j.issn.1004-9649.202111045.
- [16] R. F. Syam and F. Aziz, "PERAMALAN TRAFIK UNTUK ALOKASI BANDWIDTH JARINGAN SELULER 4G MENGGUNAKAN MODEL HYBRID ARIMA-LSTM Pendahuluan," vol. 2, no. 2, pp. 78–84, 2024.
- [17] K. K. K. Dewi, L. Gd. R. Budiarta, and P. K. Nitiasih, "The development of website games as learning media for 4th-grade elementary students," *Jurnal Inovasi dan Teknologi Pembelajaran*, vol. 10, no. 3, p. 259, 2023, doi: 10.17977/um031v10i32023p259.