

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Pertumbuhan volume kendaraan di perkotaan, termasuk Indonesia, menyebabkan kemacetan lalu lintas yang parah, berdampak pada mobilitas dan produktivitas (Wang et al., 2021; Almassar dan Girsang, 2022). Data BPS menunjukkan bahwa jumlah kendaraan bermotor di Indonesia meningkat rata-rata 5,43% per tahun antara 2015–2022, dengan total pertumbuhan 44,69%, termasuk mobil penumpang, bus, barang, dan sepeda motor. Pertumbuhan kendaraan yang cepat tanpa peningkatan kapasitas jalan berkontribusi pada kemacetan dan meningkatnya risiko kecelakaan, dengan pertumbuhan rata-rata kecelakaan 5,21% per tahun (BPS, 2023).

Prediksi tingkat kemacetan lalu lintas secara akurat menjadi penting untuk mengoptimalkan kapasitas jalan dan mengurangi dampak ekonomi (Huang et al., 2022). Hal ini sangat krusial, terutama mengingat ketidakseimbangan antara kapasitas jalan dan pertumbuhan jumlah kendaraan, yang merupakan salah satu penyebab utama kemacetan (Shi dan Du, 2022). Salah satu sumber data yang banyak digunakan adalah rekaman CCTV lalu lintas, dengan fokus pada deteksi objek kendaraan. Namun, deteksi objek bergerak secara *real-time* menghadapi tantangan signifikan, termasuk hilangnya objek, deteksi palsu, dan kesulitan melacak banyak objek secara simultan (Zheng et al., 2022). Untuk itu, integrasi metode *computer vision* dan *deep learning* diperlukan agar prediksi kemacetan lebih akurat dengan memanfaatkan data *real-time* dari CCTV.

Deteksi objek merupakan salah satu tugas utama dalam bidang *computer vision* (Wang et al., 2022). Algoritma YOLO (*You Only Look Once*) telah menjadi standar untuk deteksi objek *real-time* karena keseimbangan kecepatan dan akurasi, memungkinkan identifikasi objek yang cepat dan andal dalam satu *frame* (Terven dan Cordova-esparza, 2023). Versi terbaru, YOLOv7, menunjukkan peningkatan performa *real-time* dibanding versi sebelumnya,

sedangkan YOLOv8 lebih efisien dalam pemrosesan *frame* secara *real-time*, menjadikannya ideal untuk aplikasi prediksi kemacetan berbasis CCTV (Wang et al., 2022; Ngo, 2023).

Implementasi metode *Bidirectional Long Short-Term Memory* (Bi-LSTM), sebuah teknik *deep learning* yang dirancang untuk memproses urutan data, dapat meningkatkan kinerja deteksi objek dengan menyediakan informasi kontekstual yang melibatkan tugas-tugas terkait. Metode Bi-LSTM sangat relevan dalam konteks sistem prediksi kemacetan lalu lintas, termasuk dalam segmentasi *frame*, deteksi objek, dan klasifikasi (Benjelloun et al., 2020).

Penggunaan Bi-LSTM dalam analisis data kemacetan lalu lintas didukung oleh berbagai penelitian yang menunjukkan keunggulan dan ketepatan prediksi model berbasis Bi-LSTM. Secara umum, penelitian menunjukkan bahwa Bi-LSTM lebih unggul dibandingkan metode *Long Short-Term Memory* (LSTM) konvensional dalam pengembangan model prediksi aliran lalu lintas (Zhai et al., 2022). Keunggulan ini memberikan dasar yang kuat untuk memilih Bi-LSTM sebagai metode utama dalam membangun model prediksi kemacetan lalu lintas, terutama karena ketepatan prediksi aliran lalu lintas merupakan faktor krusial dalam manajemen dan pencegahan kemacetan.

Sebagai contoh, sebuah penelitian mengembangkan model prediksi kemacetan lalu lintas cerdas dengan mengintegrasikan *Seasonal Auto-Regressive Integrated Moving Average* (SARIMA) dan Bi-LSTM (Chahal et al., 2023). Model gabungan SARIMA dan Bi-LSTM terbukti mampu menghasilkan nilai terendah untuk *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE), masing-masing sebesar 0,499, 0,337, 0,58, dan 0,03 (Chahal et al., 2023). Hasil penelitian ini menunjukkan bahwa penggunaan Bi-LSTM secara efektif dapat meningkatkan akurasi dan ketepatan prediksi dalam analisis data kemacetan lalu lintas.

Untuk lebih meningkatkan akurasi prediksi lalu lintas, teknik *sliding window* dapat diterapkan untuk menangkap pola temporal dalam data secara lebih efektif. Teknik ini bekerja dengan membagi data menjadi segmen-segmen

berurutan, memungkinkan model untuk memahami hubungan antarwaktu dalam prediksi lalu lintas (Yang et al., 2024; D. Yu et al., 2024; Thapaliya et al., 2025; Papageorgiou dan Tjortjis, 2025). Kombinasi Bi-LSTM dan teknik *sliding window* memberikan keunggulan dalam mengidentifikasi pola lalu lintas dari dua arah, baik dari masa lalu ke masa depan maupun sebaliknya, sehingga meningkatkan kemampuan model dalam menangkap pola kompleks dalam data lalu lintas (Ounoughi dan Ben Yahia, 2024; Bui Tien et al., 2024; Xiaoqiao Huang et al., 2022). Dengan pendekatan ini, sistem prediksi kemacetan lalu lintas dapat menghasilkan hasil yang lebih akurat dan lebih adaptif terhadap perubahan kondisi jalan raya.

Meskipun Bi-LSTM merupakan salah satu model *deep learning* yang banyak digunakan dalam prediksi arus lalu lintas, tantangan utama yang dihadapi adalah optimasi parameter untuk memastikan bahwa model dapat mencapai performa terbaik (Redhu dan Kumar, 2023). Untuk mengatasi tantangan ini, berbagai teknik optimasi telah dikembangkan. Salah satunya adalah Modified *Firefly Optimization Algorithm* (MFOA), yang diterapkan dalam MFOA-Bi-LSTM untuk menyempurnakan parameter Bi-LSTM (Naheliya et al., 2024). Selain itu, optimasi pada LSTM juga telah dilakukan dengan pendekatan *framework hybrid* FD-Markov-LSTM, yang mengintegrasikan model statistik *Markov* dengan LSTM untuk meningkatkan akurasi prediksi (Pan et al., 2024).

Pendekatan lain yang digunakan adalah CAM-LSTM, yang memanfaatkan mekanisme perhatian (*attention mechanism*) untuk meningkatkan performa jaringan *Recurrent Neural Network* (RNN), termasuk LSTM (Chauhan dan Kumar, 2024a). Kombinasi algoritma *Prophet* dan LSTM dengan *tuning* parameter yang signifikan, yang dikenal dengan sebutan *Hyper-Flophet*, juga menunjukkan performa akurasi prediksi yang menjanjikan (Zaraket et al., 2024). Semua model ini dirancang untuk mengatasi tantangan dalam prediksi arus lalu lintas, seperti pola non-linear dan stokastik, serta memberikan solusi prediksi yang lebih akurat dan efisien dalam berbagai skenario lalu lintas. Pada penelitian ini akan digunakan algoritma Komodo Mlipir (KMA) untuk mengoptimasi Bi-LSTM.

KMA merupakan algoritma optimasi metaheuristik yang terinspirasi dari gabungan dua fenomena unik: perilaku biologis naga Komodo yang hidup di Nusa Tenggara Timur (NTT), Indonesia, dan gaya berjalan dalam budaya Jawa yang disebut *mlipir* (Suyanto et al., 2022a). Algoritma ini bekerja dengan membagi populasi individu (kandidat solusi) ke dalam tiga kelompok berdasarkan kualitasnya (nilai objektif), yaitu: Komodo Jantan Besar (*Big Males*), Komodo Betina (*Female*), dan Komodo Jantan Kecil (*Small Males*) (Kusuma et al., 2023). Algoritma KMA terbukti efektif dalam meningkatkan akurasi prediksi arus lalu lintas dengan menyesuaikan parameter model Bi-LSTM secara adaptif, sebagaimana ditunjukkan pada pendekatan SW-KMA-Bi-LSTM yang menghasilkan kesalahan prediksi (RMSE dan MAE) lebih rendah dibandingkan Bi-LSTM standar maupun Bi-LSTM yang dioptimasi dengan algoritma metaheuristik lain seperti GA, PSO, FOA, CWO, SOA, dan AOOA (Syafei et al., 2025).

Dengan berfokus pada perkembangan teknologi terkini, seperti *computer vision* dan metode *deep learning*, serta menggabungkan kekuatan deteksi objek *real-time* dengan analisis pola waktu, sistem prediksi kemacetan lalu lintas yang dikembangkan dapat memberikan kontribusi signifikan dalam mengatasi tantangan kompleks yang dihadapi oleh kondisi lalu lintas jalan perkotaan yang selalu berubah. Optimasi prediksi dapat ditingkatkan lebih lanjut dengan menerapkan teknik *sliding window* sebagai metode temporal untuk menangkap pola perubahan lalu lintas secara lebih akurat, serta menggunakan algoritma metaheuristik Komodo Mlipir untuk mengoptimalkan parameter *deep learning*, sehingga meningkatkan performa model dalam memprediksi kemacetan.

1.2. Identifikasi Masalah

Berdasarkan hasil kajian literatur dan analisis terhadap penelitian terdahulu, dapat diidentifikasi beberapa permasalahan utama sebagai berikut:

1. Deteksi kendaraan berbasis YOLO telah banyak digunakan, tetapi akurasi model masih menurun signifikan pada kondisi lalu lintas padat, malam hari, atau pencahayaan tidak stabil, yang menunjukkan perlunya pendekatan adaptif terhadap variasi kondisi visual.
2. Model *Bidirectional Long Short-Term Memory* (Bi-LSTM) mampu mempelajari pola deret waktu lalu lintas, namun hasil prediksinya sangat bergantung pada kombinasi *hyperparameter*, yang pada sebagian besar studi sebelumnya masih ditentukan secara manual atau menggunakan algoritma optimasi seperti PSO, GA, dan *Firefly*.
3. Belum ada penelitian yang mengadopsi Algoritma Komodo Mlipir (KMA) sebagai mekanisme optimasi otomatis dan adaptif dalam penyetelan parameter Bi-LSTM untuk konteks prediksi lalu lintas berbasis data visual.
4. Penerapan teknik *sliding window* dua arah untuk menangkap pola pergerakan kendaraan dari arah masuk dan keluar secara simultan juga belum banyak dieksplorasi, padahal hal ini penting untuk representasi temporal yang lebih akurat.

1.3. Perumusan Masalah

Perumusan masalah pada penelitian ini adalah bagaimana mengembangkan model cerdas berbasis *computer vision* dan *deep learning* yang mampu mendeteksi serta memprediksi tingkat kemacetan lalu lintas perkotaan secara *real-time* melalui analisis visual dari kamera pengawas (CCTV) dengan tingkat akurasi dan keandalan yang lebih baik dibandingkan model-model sebelumnya.

1.4. Maksud dan Tujuan Penelitian

Tujuan penelitian ini adalah untuk mengembangkan model cerdas berbasis *computer vision* dan *deep learning* yang mampu mendeteksi serta memprediksi tingkat kemacetan lalu lintas perkotaan secara *real-time* melalui analisis visual dari kamera pengawas (CCTV), dengan fokus pada peningkatan akurasi dan keandalan dibandingkan model-model sebelumnya.

1.5. Kebaruan (*Novelty*)

Penelitian ini memiliki beberapa kebaruan signifikan dalam pengembangan sistem prediksi lalu lintas *real-time*. Pertama, integrasi YOLO dengan Bi-LSTM dilakukan secara *end-to-end* dan *real-time*, sehingga deteksi kendaraan dari rekaman video dan prediksi kepadatan lalu lintas dilakukan dalam satu alur sistem yang terpadu, berbeda dengan banyak penelitian sebelumnya yang hanya menggabungkan deteksi dan prediksi secara terpisah menggunakan algoritma optimasi klasik seperti PSO, GA, atau *Firefly*. Kedua, penggunaan Algoritma Komodo Mlipir (KMA) untuk optimasi *hyperparameter* Bi-LSTM menghadirkan metode tuning yang adaptif dan jarang diterapkan dalam konteks prediksi lalu lintas berbasis *deep learning*, memberikan keunggulan dalam peningkatan akurasi model dibandingkan optimasi konvensional. Ketiga, penerapan *sliding window* dua arah memungkinkan sistem menganalisis pergerakan lalu lintas secara simultan dari arah masuk dan keluar, sehingga pola kepadatan dapat dipantau secara lebih dinamis dan menyeluruh. Secara keseluruhan, penelitian ini menghadirkan sistem prediksi lalu lintas yang *real-time*, adaptif, dan lebih akurat, dengan pendekatan optimasi dan analisis dua arah yang membedakannya dari studi-studi sebelumnya.

1.6. Manfaat Penelitian

Penelitian ini memberikan kontribusi baru dalam integrasi metode *computer vision* dan *deep learning* untuk membangun sistem prediksi kemacetan secara *real-time* pada kondisi lalu lintas padat dan pencahayaan yang tidak optimal. Integrasi model deteksi YOLO dan model prediktif Bi-LSTM menjadi pendekatan yang inovatif untuk menangani tantangan visual dan temporal dalam sistem transportasi cerdas. Manfaat lainnya adalah memberikan alternatif solusi berbasis optimasi dengan mengimplementasikan Algoritma Komodo Mlipir untuk menyetel parameter Bi-LSTM secara otomatis, sehingga meningkatkan stabilitas dan akurasi prediksi. Penerapan pendekatan ini memberikan kontribusi dalam pengembangan sistem monitoring lalu lintas cerdas berbasis video *surveillance*, khususnya dalam menghadapi tantangan *real-time prediction* di lingkungan perkotaan yang kompleks.

1.7. Pembatasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Penelitian ini hanya mendeteksi kendaraan bermotor, yaitu sepeda motor, mobil, bus, dan truk.
2. Deteksi objek secara *real-time* dilakukan menggunakan algoritma YOLO versi *Ultralytics*.
3. Prediksi tingkat kemacetan dilakukan menggunakan algoritma Bi-LSTM yang dioptimasi dengan pendekatan metaheuristik berbasis *deep learning*.
4. Prediksi tingkat kemacetan dilakukan untuk jangka waktu 30 menit ke depan dengan interval pembaruan setiap 5 menit.
5. Status kemacetan diklasifikasikan ke dalam tiga kategori, yaitu *Free Flow* (F), *Stable* (S), dan *Jammed* (J).
6. Model hanya diterapkan pada area pengamatan dengan kamera CCTV statis yang menyorot langsung ke arah kendaraan, tanpa halangan visual, bukan di area persimpangan, dan tanpa kendaraan terparkir di badan jalan.
7. Prediksi kemacetan hanya didasarkan pada indikator kecepatan kendaraan, okupansi jalan, dan jumlah kendaraan hasil estimasi model, tanpa mempertimbangkan faktor eksternal non-visual seperti cuaca, kecelakaan, atau rekayasa lalu lintas insidental.

1.8. Sistematika Penulisan

Sistematika penulisan dalam penelitian ini disusun secara runtut untuk mempermudah pemahaman terhadap keseluruhan isi. Bab 1 berisi pendahuluan yang mencakup latar belakang, identifikasi dan perumusan masalah, tujuan, kebaruan, batasan, serta sistematika penulisan. Bab 2 menyajikan kajian pustaka yang membahas teori-teori terkait seperti kemacetan lalu lintas, deteksi objek berbasis *computer vision*, algoritma YOLO, model Bi-LSTM, teknik *sliding window*, dan optimasi dengan Algoritma Komodo Mlipir. Bab 3 menguraikan metodologi penelitian, termasuk pengumpulan data, *preprocessing*, desain arsitektur model, skenario pengujian, dan metrik evaluasi. Bab 4 memaparkan hasil eksperimen, analisis performa model, serta pembahasan dampaknya

terhadap prediksi lalu lintas. Terakhir, Bab 5 berisi kesimpulan dan saran untuk pengembangan lebih lanjut.



SEKOLAH PASCASARJANA