

Model Deteksi Objek Menggunakan Yolov5 untuk Pengendalian Pengaturan Lalu Lintas

I Wayan Adi Artha Wiguna¹⁾, Roy Rudolf Huizen²⁾, Gede Angga Pradipta³⁾

Program Studi Magister Sistem Informasi
Institut Teknologi dan Bisnis STIKOM Bali
Denpasar, Indonesia

e-mail: 222012018@stikom-bali.ac.id¹⁾, roy@stikom-bali.ac.id²⁾, angga_pradipta@stikom-bali.ac.id³⁾

Abstrak

Penelitian ini bertujuan untuk menganalisis dan mengevaluasi kinerja model YOLOv5 dalam mengendalikan lampu merah secara dinamis dalam pengaturan lalu lintas. Studi ini mencoba menjawab urgensi penanganan masalah kemacetan lalu lintas dan peningkatan efisiensi lalu lintas di perkotaan. Dengan memanfaatkan kemampuan deteksi objek secara real-time dari model YOLOv5, penelitian ini berusaha mengintegrasikan model pengendalian lampu lalu lintas yang responsif dan adaptif. Tujuan utama adalah mengembangkan model pengaturan lampu lalu lintas yang dapat mendeteksi volume lalu lintas dan beradaptasi dengan kondisi lalu lintas secara dinamis. Model ini akan mengubah durasi lampu merah dan hijau berdasarkan jumlah kendaraan yang terdeteksi, sehingga mengurangi waktu tunggu dan meningkatkan aliran lalu lintas. Selain itu, penelitian ini juga bertujuan untuk mengevaluasi akurasi deteksi objek oleh model YOLOv5 dalam berbagai kondisi pencahayaan, termasuk pencahayaan rendah dan tinggi, untuk memastikan kinerja optimal model pengaturan lampu lalu lintas dalam situasi yang beragam. Hasil dari penelitian ini diharapkan memberikan panduan untuk penerapan teknologi terkini dalam meningkatkan pengaturan lampu lalu lintas di perkotaan, serta menyumbang pada pemahaman kinerja deteksi objek dari model YOLOv5 dalam konteks lalu lintas yang beragam. Harapannya, penelitian ini dapat membantu mengurangi kemacetan lalu lintas, meningkatkan efisiensi transportasi perkotaan, dan mengurangi emisi gas buang, memberikan manfaat bagi masyarakat dan lingkungan.

Kata kunci: YOLOv5, Pengaturan Lalu Lintas Dinamis, Deteksi Objek, Lampu Merah

1. Pendahuluan

Kemacetan lalu lintas merupakan salah satu masalah perkotaan yang paling menantang di era modern. Di banyak kota besar di seluruh dunia, jalan-jalan seringkali tersumbat oleh deretan kendaraan yang panjang, menyebabkan tidak hanya keterlambatan dan ketidaknyamanan bagi pengendara, tetapi juga berdampak negatif terhadap ekonomi dan lingkungan. Kemacetan ini seringkali diperparah oleh sistem pengaturan lampu lalu lintas yang statis, di mana siklus lampu merah dan hijau tidak menyesuaikan dengan kondisi lalu lintas yang dinamis dan terus berubah [1].

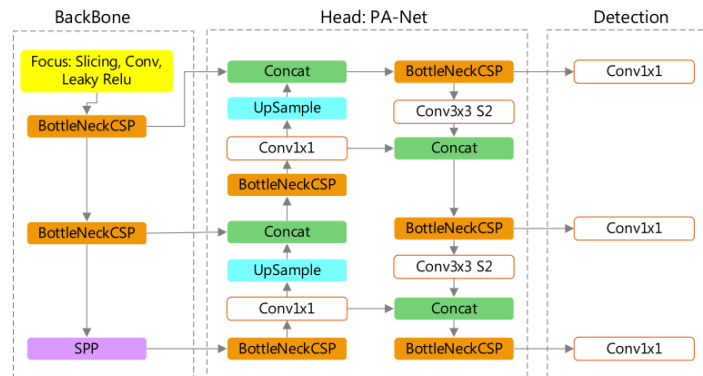
Teknologi kecerdasan buatan, terutama dalam bidang pengenalan pola dan pemrosesan citra digital, menawarkan solusi yang inovatif untuk masalah ini. YOLOv5, sebagai salah satu algoritma deteksi objek yang telah mendemonstrasikan kemampuannya dalam mengidentifikasi kendaraan dan objek lainnya dalam berbagai kondisi lalu lintas dengan cepat dan akurat. Penggunaan YOLOv5 dalam sistem pengendalian lalu lintas memungkinkan untuk analisis kondisi lalu lintas secara *real-time*, yang dapat digunakan untuk mengoptimalkan siklus lampu lalu lintas [3]. Adam *Optimizer*, dikenal karena kemampuannya dalam mempercepat konvergensi pelatihan dan menangani masalah optimasi non-stasioner, telah terbukti efektif dalam berbagai studi terkait YOLOv5. Misalnya, Liu et al. menerapkan Adam *Optimizer* dalam pengembangan model YOLOv5s-MobileNetV2 untuk deteksi rambu lalu lintas, menghasilkan peningkatan signifikan dalam akurasi dan efisiensi komputasi [4]. Demikian pula, Isa et al. menunjukkan peningkatan prestasi YOLOv5 dalam deteksi bawah air dengan penggunaan Adam *Optimizer* [5].

Integrasi Adam *Optimizer* dalam pengembangan model YOLOv5 Anda tidak hanya akan mempercepat proses pelatihan tetapi juga meningkatkan akurasi deteksi dalam kondisi lalu lintas yang kompleks. Dengan demikian, penelitian Anda "Model Deteksi Objek Menggunakan YOLOv5 Untuk Pengendalian Pengaturan Lalu Lintas" akan mengambil manfaat dari kemajuan terkini dalam teknologi AI untuk mengatasi masalah kemacetan lalu lintas akibat sistem pengaturan lampu lalu lintas yang kaku, bergerak menuju era baru pengelolaan lalu lintas yang lebih cerdas dan responsif.

2. Metode Penelitian

2.1. YOLOv5

Model YOLOv5 terdiri dari tiga komponen penting: backbone, head, dan deteksi. Backbone, yang berfungsi sebagai jaringan saraf konvolusional (CNN), memiliki tugas utama untuk mengekstraksi dan membentuk fitur gambar pada tingkat detail yang berbeda. Head, terdiri dari beberapa lapisan, berperan dalam mengintegrasikan fitur gambar untuk proses prediksi. Sedangkan komponen deteksi menggunakan fitur yang diperoleh dari head untuk melakukan prediksi kotak dan kelas bisa dilihat pada gambar 1. [14].



Gambar 1. Arsitektur YOLOv5

YOLOv5 menggunakan fungsi aktivasi Sigmoid-weighted Linear Units (SiLU) pada persamaan berikut.

$$\alpha_k(z_k) = z_k \sigma(z_k) \quad (1)$$

$$z_k = \sum_i \omega_{ik} S_i + b_k \quad (2)$$

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (3)$$

Dimana z_k adalah input hidden unit k $\sigma(\cdot)$ merupakan fungsi sigmoid, ω_{ik} adalah beban penghubung dan hidden unit k dan b_k beban bias untuk hidden unit (1)(2)(3).

Fokus utama penelitian ini adalah mengembangkan pengaturan lampu lalu lintas yang dinamis dengan menggunakan analisis dan evaluasi performa model YOLOv5. Ini meliputi bagaimana model YOLOv5 dapat digunakan untuk mendeteksi volume kendaraan secara real-time dan bagaimana informasi ini kemudian dapat dimanfaatkan untuk mengoptimalkan aliran lalu lintas dan mengurangi kemacetan.

Perbedaan kunci dari penelitian ini dibandingkan dengan studi lainnya adalah bahwa penelitian ini mengeksplorasi potensi YOLOv5 dalam konteks pengaturan lalu lintas perkotaan yang adaptif, bukan hanya untuk deteksi dan klasifikasi kendaraan. Ini merupakan langkah maju dalam pemanfaatan teknologi AI untuk menciptakan solusi lalu lintas yang lebih cerdas dan efisien, dengan menyeroi bagaimana data lalu lintas dapat digunakan secara strategis untuk mengelola infrastruktur lalu lintas perkotaan.

2.2. Pengembangan Model YOLOv5

2.2.1. Sumber Data

Penggunaan dataset dari Roboflow Universe untuk keperluan pelatihan dan pengujian model, memanfaatkan dataset yang dikumpulkan oleh FSMVU dan tersedia di Roboflow Universe. Dataset ini, yang terdiri dari 8.693 gambar kendaraan yang telah dianotasi secara rinci, berformat .jpg dengan resolusi 512x512 piksel. Kualitas anotasi yang tinggi dan resolusi yang sesuai dari dataset ini memastikan data yang kaya untuk pengembangan dan validasi model YOLOv5. Contoh citra yang ada pada dataset yang akan digunakan pada penelitian ini terdapat pada gambar 2.[6].



Gambar 2. Contoh Gambar Dataset

2.2.2. Preprocessing

Proses preprocessing mencakup penyesuaian ukuran gambar menjadi 256x256 piksel serta pembagian dataset ke dalam tiga bagian utama, yakni set pelatihan, validasi, dan pengujian. Rasio pembagian dataset antara bagian utama adalah 87% untuk set pelatihan, 9% untuk validasi, dan 4% untuk pengujian.

2.2.3. Training Phase

Pada tahap pelatihan, model YOLOv5 diterapkan dengan modifikasi pada lapisan-lapisan yang ada. Proses ini termasuk penambahan, penghapusan, atau penyesuaian lapisan untuk meningkatkan kualitas model. Gambar 2. menerangkan citra input berukuran 448 x 448 piksel dengan 3 channel warna (RGB) diproses melalui lapisan convolutional network, menghasilkan output dengan dimensi 7 x 7 x 30. Padding zero-padding dan stride digunakan selama proses konvolusi. Optimizer Adam juga ditambahkan untuk meningkatkan efisiensi dan efektivitas model, dengan mengatur learning rate secara adaptif [15].

3. Hasil dan Pembahasan

3.1 Sumber Dataset

Objek pada penelitian ini merupakan kendaraan bermotor yang ada di persimpangan jalan. Objek dataset yang digunakan merupakan dataset publik dari *Roboflow Universe* yang dikumpulkan oleh Fsmvu. *Dataset* ini terdiri dari 8.693 gambar kendaraan yang telah dianotasi dengan baik, dengan format .jpg dan dengan resolusi berbagai ukuran.

3.2 Train Model

Sebelum menguji model, penulis melakukan beberapa eksperimen dengan metode YOLO menggunakan beberapa konfigurasi. Semua percobaan dilakukan menggunakan optimizer Adam. Sebagai langkah awal, *batch_size* diatur menjadi 32 sesuai dengan standar umum dari penelitian sebelumnya. Penentuan nilai ini juga dipengaruhi oleh keterbatasan GPU dalam penelitian, di mana semakin besar nilai *batch_size*, semakin banyak komputasi yang dibutuhkan. Untuk stabilitas dan kemudahan implementasi, penulis membandingkan *batch_size* 32 dengan *batch_size* 16, dan kemudian mengevaluasi hasilnya, seperti yang terlihat dalam tabel di bawah ini.

Tabel 1. Evaluasi Training dan Validation Model

batch_size	lr	Training		Validation	
		Acc	Loss	Acc	Loss
32	0.1	0.687	1.23	0.62	1.13
32	0.01	0.758	0.11	0.623	0.22
32	0.001	0.876	0.0230	0.87561	0.0200
16	0.1	0.523	2.58	0.454	2.68
16	0.01	0.655	1.36	0.645	1.58


16	0.001	0.754	0.2	0.6	0.255
----	-------	-------	-----	-----	-------

Semua langkah dilakukan dengan melakukan pelatihan selama 50 epoch terlebih dahulu, dan kemudian melakukan penyesuaian *hyperparameter* dengan 50 epoch tambahan untuk mencapai hasil yang optimal dan stabil. Pada tabel 1. dapat dilihat rata-rata waktu yang dibutuhkan untuk melatih setiap konfigurasi adalah 90 menit. Hasil akhir terbaik diperoleh dengan menggunakan *batch_size* 32 dan *learning_rate* 0.001 dengan tingkat akurasi rata-rata sebesar 87.60% selama pelatihan dan 87.56% selama validasi.

3.3 Evaluasi Performa

3.3.1 Confusion Matrix

Confusion matrix dari hasil pengujian akhir, yang ditunjukkan dalam gambar dibawah ini, mengilustrasikan distribusi prediksi yang benar dan salah. Dari matrix tersebut, bisa dilihat bahwa warna yang lebih gelap menandakan akurasi yang lebih tinggi pada kelas tertentu. Semua prediksi yang benar diplot pada garis diagonal matrix, yang menunjukkan bahwa model sangat akurat dalam mengenali 'bus' dan 'car'. Di sisi lain, keliru dalam prediksi dapat dilihat pada sel yang terletak di luar diagonal, yang menandakan bahwa kelas 'person' dan 'truck' memerlukan perhatian lebih karena masing-masing memiliki akurasi 55% dan 79%.



Gambar 3. Confusion matrix

4. Kesimpulan

Salah satu kunci keberhasilan penelitian ini terletak pada efektivitas Adam Optimizer dalam meningkatkan proses konvergensi dan akurasi deteksi model YOLOv5. Penggunaan dataset Roboflow Universe juga menunjukkan pentingnya kualitas data yang baik dalam mengembangkan model kecerdasan buatan yang handal. Dengan akurasi deteksi yang mencapai 87.6% selama pelatihan dan 87.56% selama validasi, model ini menawarkan solusi yang sangat menjanjikan untuk manajemen lalu lintas yang lebih efisien.

Daftar Pustaka

- [1] M. M. Rahman, P. Najaf, M. G. Fields, and J. C. Thill, "Traffic congestion and its urban scale factors: Empirical evidence from American urban areas," *Int. J. Sustain. Transp.*, vol. 16, no. 5, pp. 406–421, 2022, doi: 10.1080/15568318.2021.1885085.
 - [2] Z. Zheng, Z. Wang, L. Zhu, and H. Jiang, "Determinants of the congestion caused by a traffic accident in urban road networks," *Accid. Anal. Prev.*, vol. 136, no. May 2019, p. 105327, 2020, doi: 10.1016/j.aap.2019.105327.
 - [3] S. Jin and L. Sun, "Application of Enhanced Feature Fusion Applied to YOLOv5 for Ship Detection," in *2021 33rd Chinese Control and Decision Conference (CCDC)*, 2021, pp. 7242–7246. doi: 10.1109/CCDC52312.2021.9602100.
 - [4] X. Liu and others, "Traffic sign recognition algorithm based on improved YOLOv5," in *2021 International Conference on Control, Automation and Information Sciences (ICCAIS)*, 2021, pp. 980–985.
 - [5] I. S. Isa, M. S. A. Rosli, U. K. Yusof, M. I. F. Maruzuki, and S. N. Sulaiman, "Optimizing the Hyperparameter Tuning of YOLOv5 for Underwater Detection," *IEEE Access*, vol. 10, pp. 52818–52831, 2022, doi: 10.1109/ACCESS.2022.3174583.
 - [6] FSMVU, "Street View Dataset," *Roboflow Universe*. Roboflow, Sep. 2023. [Online]. Available: <https://universe.roboflow.com/fsmvu/street-view-gdogo>
 - [7] E. Husni *et al.*, "Microclimate investigation of vehicular traffic on the urban heat island through IoT-Based device," *Heliyon*, vol. 8, no. 11, p. e11739, 2022, doi: 10.1016/j.heliyon.2022.e11739.
 - [8] D. M. Tan and L. M. Kieu, "TRAMON: An automated traffic monitoring system for high density, mixed and lane-free traffic," *IATSS Res.*, vol. 47, no. 4, pp. 468–481, 2023, doi: 10.1016/j.iatssr.2023.10.001.
 - [9] C. Yu and Y. Shin, "SAR ship detection based on improved YOLOv5 and BiFPN," *ICT Express*, no. xxxx, 2023, doi: 10.1016/j.icte.2023.03.009.
 - [10] C. Jiang *et al.*, "Object detection from UAV thermal infrared images and videos using YOLO models," *Int. J. Appl. Earth Obs. Geoinf.*, vol. 112, no. October 2021, p. 102912, 2022, doi: 10.1016/j.jag.2022.102912.
 - [11] S. Ujianto, "Pengendalian Traffic Light Berbasis Logika Fuzzy pada Kasus Persimpangan Dalam Kota dengan Satu Jalur Kepadatan yang Dinamik Traffic Light Control Based on Fuzzy Logic on The Case of Intersection in The City with One Dynamic Density Lane," *78 Telekontran*, vol. 10, no. 1, 2022.
 - [12] R. Dwiyanto, D. W. Widodo, and P. Kasih, "Implementasi Metode You Only Look Once (YOLOv5) Untuk Klasifikasi Kendaraan Pada CCTV Kabupaten Tulungagung," *Semin. Nas. Inov. Teknol.*, vol. 1, no. 1, pp. 102–104, 2022.
 - [13] S. A. Syifa and I. A. Dewi, "Arsitektur Resnet-152 dengan Perbandingan Optimizer Adam dan RMSProp untuk Mendeteksi Penyakit Paru-Paru," *J. MIND J. / ISSN*, vol. 7, no. 2, pp. 139–150, 2022, [Online]. Available: <https://doi.org/10.26760/mindjournal.v7i2.139-150>
 - [14] J. Ieamsaard, S. N. Charoensook, and S. Yammen, "Deep Learning-based Face Mask Detection Using YoloV5," *Proceeding 2021 9th Int. Electr. Eng. Congr. iEECON 2021*, pp. 428–431, 2021, doi: 10.1109/iEECON51072.2021.9440346.
 - [15] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 779–788, 2019, doi: 10.1109/CVPR.2016.91.
 - [16] M. H. Ashar and D. Suarna, "KLIK: Kajian Ilmiah Informatika dan Komputer Implementasi Algoritma YOLOv5 dalam Mendeteksi Penggunaan Masker Pada Kantor Biro Umum Gubernur Sulawesi Barat," *Media Online*, vol. 3, no. 3, pp. 298–302, 2022, [Online]. Available: <https://djournals.com/klik>
 - [17] D. Soydaner, "A Comparison of Optimization Algorithms for Deep Learning," *Int. J. Pattern Recognit. Artif. Intell.*, vol. 34, no. 13, 2020, doi: 10.1142/S0218001420520138.
-