



Deteksi Rambu Lalu Lintas Indonesia Menggunakan Transfer Learning

Anini Nihayah^{1*}, Ghazi Murtadho², Ika Marlisa Raharjo³

¹Institut Teknologi dan Bisnis Adias, Indonesia

²Universitas Dian Nuswantoro, Indonesia

³Universitas Siber Muhammadiyah, Indonesia

*Penulis Korespondensi: anininihayah02@gmail.com

Abstract. *This study aims to develop an Indonesian traffic sign detection system using a transfer learning approach to improve road safety and traffic efficiency. The dataset was obtained from Kaggle and consists of 2,100 images across 21 traffic sign classes. The research stages include data collection, preprocessing to reduce noise and normalize image brightness, object detection using YOLOv5, and classification based on transfer learning with ResNet, VGG-16, and MobileNet architectures. Model performance was evaluated using accuracy, precision, recall, and F1-score metrics. Experimental results indicate that the YOLOv5 model is capable of detecting traffic sign objects; however, the classification performance remains relatively low, with a mean Average Precision (mAP) value of 0.17. These findings suggest that further optimization is required in data preprocessing, dataset quality, and model parameter tuning to achieve better performance. This study demonstrates that transfer learning has significant potential for developing computer vision-based traffic sign detection systems, although further improvements are necessary to ensure robustness under real-world Indonesian traffic conditions.*

Keywords: *Computer Vision; Deep Learning; Indonesian Traffic Signs; Transfer Learning; YOLOv5.*

Abstrak. Penelitian ini bertujuan untuk mengembangkan sistem deteksi rambu lalu lintas Indonesia menggunakan pendekatan transfer learning guna meningkatkan keselamatan dan efisiensi lalu lintas. Dataset yang digunakan bersumber dari Kaggle dan terdiri dari 2.100 citra dengan 21 kelas rambu lalu lintas. Tahapan penelitian meliputi pengumpulan data, preprocessing untuk mengurangi noise dan menyeragamkan kecerahan citra, deteksi objek menggunakan YOLOv5, serta klasifikasi berbasis transfer learning dengan arsitektur ResNet, VGG-16, dan MobileNet. Evaluasi model dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score. Hasil pengujian menunjukkan bahwa model YOLOv5 mampu mendeteksi objek rambu dengan baik, namun performa klasifikasi masih rendah dengan nilai mAP sebesar 0,17. Hal ini menunjukkan perlunya optimasi lebih lanjut pada preprocessing, kualitas dataset, serta penyetelan parameter model. Penelitian ini menegaskan bahwa pemanfaatan transfer learning memiliki potensi dalam pengembangan sistem deteksi rambu lalu lintas berbasis visi komputer, namun masih memerlukan perbaikan untuk mencapai performa yang optimal pada kondisi lingkungan nyata di Indonesia.

Kata kunci: Pembelajaran Mendalam; Pembelajaran Transfer; Rambu Lalu Lintas; Visi Komputer; YOLOv5.

1. LATAR BELAKANG

Proyek deteksi rambu lalu lintas Indonesia menggunakan transfer learning berada dalam domain kecerdasan buatan, khususnya dalam pembelajaran mesin, visi komputer, dan pengolahan citra digital. Melibatkan analisis citra dan video, proyek ini bertujuan untuk meningkatkan keselamatan lalu lintas dengan mendeteksi dan mengenali berbagai jenis rambu di lingkungan jalan raya Indonesia. Dengan memanfaatkan transfer learning, model yang telah dilatih pada data yang lebih luas dapat disesuaikan untuk mengatasi kompleksitas variasi kondisi lingkungan, jenis rambu, dan situasi lalu lintas yang unik di Indonesia (Girshick, 2015; Ren et al., 2015). Dalam pengembangan perangkat lunak, optimisasi kinerja model, dan fokus pada sistem pemrosesan data real-time, proyek ini diharapkan dapat memberikan solusi efektif

yang dapat diimplementasikan untuk meningkatkan efisiensi dan keselamatan lalu lintas di jalan raya Indonesia (Liu et al., 2016; Lin et al., 2017).

Dalam konteks proyek deteksi rambu lalu lintas Indonesia menggunakan transfer learning, pemahaman bisnis (*Business Understanding*) mencakup pengidentifikasian masalah dan tujuan yang ingin dicapai melalui implementasi teknologi deteksi rambu lalu lintas. (Krizhevsky, A., Sutskever, I., & Hinton, 2012) Secara khusus, proyek ini diinisiasi untuk meningkatkan keselamatan lalu lintas di Indonesia dengan memanfaatkan kecerdasan buatan. Dengan melibatkan teknologi deteksi rambu lalu lintas, tujuan bisnisnya adalah memberikan solusi yang dapat secara akurat dan cepat mendeteksi berbagai jenis rambu di jalan raya (Krizhevsky, A., Sutskever, I., & Hinton, 2012). Manfaatnya termasuk memberikan informasi yang diperlukan kepada pengemudi, mencegah pelanggaran aturan lalu lintas, dan mengurangi risiko kecelakaan. Pemahaman bisnis juga mencakup aspek ekonomi, di mana implementasi solusi ini diharapkan dapat mengurangi biaya kecelakaan dan membantu meningkatkan efisiensi lalu lintas secara keseluruhan.

Proyek deteksi rambu lalu lintas di Indonesia menggunakan transfer learning menghadapi beberapa tantangan kritis (Howard, A. G., 2017). Variabilitas yang kompleks dalam kondisi lingkungan, termasuk perubahan cuaca dan pencahayaan, menjadi kendala utama dalam deteksi akurat. Keanekaragaman jenis rambu lalu lintas di Indonesia, baik dari segi bentuk, warna, maupun simbol, memerlukan kemampuan model untuk mengklasifikasikan rambu dengan akurasi tinggi. Ketidakpastian dalam situasi lalu lintas yang dinamis dan kebutuhan untuk mengoptimalkan kinerja model agar merespons secara real-time merupakan tantangan tambahan. Terdapat pula keterbatasan pada dataset yang mencakup variasi kondisi dan jenis rambu lalu lintas yang dapat mempengaruhi kemampuan model dalam mengenali rambu di situasi dunia nyata (Tan, M., & Le, 2019). Selain itu, integrasi solusi dengan infrastruktur lalu lintas yang ada dan dampak positif terhadap angka kecelakaan dan pelanggaran menjadi aspek penting yang harus diperhatikan dalam pengembangan proyek ini.

Tujuan dari proyek deteksi rambu lalu lintas Indonesia menggunakan transfer learning adalah mengembangkan sistem deteksi yang dapat meningkatkan keselamatan lalu lintas dan efisiensi jalan raya di Indonesia (Redmon, J., Divvala, S., Girshick, R., & Farhadi, 2016). Fokusnya adalah mencapai tingkat akurasi dan klasifikasi yang tinggi dalam mengenali berbagai jenis rambu lalu lintas, sekaligus mempertimbangkan variabilitas kondisi lingkungan yang kompleks. Proyek ini bertujuan untuk memberikan informasi yang akurat dan respons real-time kepada pengemudi, mengoptimalkan alur lalu lintas, serta menyelaraskan solusi dengan infrastruktur lalu lintas yang sudah ada di Indonesia. Melalui pencapaian tujuan ini,

proyek diharapkan dapat berkontribusi signifikan dalam menurunkan angka kecelakaan dan pelanggaran lalu lintas, menciptakan lingkungan lalu lintas yang lebih aman dan efisien di seluruh wilayah Indonesia.


Solusi dari proyek deteksi rambu lalu lintas Indonesia menggunakan transfer learning mencakup penerapan teknik transfer learning untuk meningkatkan kinerja model deteksi, memastikan kemampuan adaptasi yang optimal terhadap variabilitas kondisi lingkungan dan keanekaragaman jenis rambu lalu lintas di Indonesia. Dengan mengoptimalkan arsitektur dan parameter model, proyek ini bertujuan untuk mencapai akurasi tinggi dan respons real-time dalam situasi lalu lintas yang dinamis (Stallkamp, J., Schlipsing, M., Salmen, J., & Igel, 2012). Pengembangan dataset representatif yang mencakup berbagai kondisi lalu lintas di Indonesia menjadi fokus untuk memastikan pelatihan model yang handal. Solusi juga melibatkan integrasi dengan infrastruktur lalu lintas yang sudah ada dan pengembangan antarmuka pengguna yang informatif. Dengan demikian, proyek ini bersifat holistik, menghadirkan solusi inovatif yang beradaptasi dengan kebutuhan khusus Indonesia dan diharapkan memberikan dampak positif dalam meningkatkan keselamatan dan efisiensi lalu lintas.

2. KAJIAN TEORITIS

Pemahaman data (Data Understanding) dalam konteks proyek deteksi rambu lalu lintas Indonesia menggunakan transfer learning melibatkan analisis mendalam terhadap dataset yang akan digunakan untuk melatih dan menguji model deteksi. Dataset ini harus mencakup gambar rambu lalu lintas dari berbagai lokasi di Indonesia dengan variasi kondisi cuaca, pencahayaan, dan latar belakang visual (Bochkovskiy, A., Wang, C. Y., & Liao, 2020). Proses ini mencakup eksplorasi terhadap jumlah dan variasi kategori rambu lalu lintas, serta penanganan ketidakseimbangan kelas jika ada. Pemahaman juga harus mencakup evaluasi terhadap kualitas dan kebersihan data, termasuk identifikasi potensi anomali atau ketidaksesuaian yang mungkin mempengaruhi pelatihan model (Zhu, Z., Liang, D., Zhang, S., Huang, X., Li, B., & Hu, 2016). Selain itu, penelitian tentang metadata, seperti lokasi dan waktu pengambilan gambar, dapat memberikan wawasan tambahan terkait dengan konteks dan karakteristik dataset. Dengan pemahaman data yang mendalam, proyek dapat memastikan bahwa dataset yang digunakan mencerminkan dengan baik variasi kondisi di lapangan, sehingga dapat melatih model deteksi rambu lalu lintas dengan baik dan menghasilkan hasil yang dapat diandalkan.

3. METODE PENELITIAN

Metode yang diusulkan pada penelitian ini ditunjukkan pada Gambar 1. Metode ini terdiri dari koleksi dataset, *preprocessing*, penyusunan algoritma dan evaluasi model.



Gambar 1. Alur metode yang diusulkan.

a. Koleksi Dataset

Dataset yang digunakan pada penelitian ini bersumber dari *Indonesia traffic sign* yang didownload dari situs *Kaggle*. Dataset merupakan kumpulan rambu lalu lintas di Indonesia yang terdiri dari 21 kelas.

b. *Data Preprocessing*

Data citra rambu pada dataset masih terdapat *noise* dan tingkat kecerahan yang berbeda pada tiap citra. Pada tahap *preprocessing* ini coba dilakukan penghilangan *noise* dengan memfokuskan citra hanya pada bagian rambu lalu lintas dan penyeragaman kecerahan citra (Pan, S. J., & Yang, 2010). *Data preprocessing* dilakukan guna memudahkan sistem komputasi pada tahapan selanjutnya dan meningkatkan hasil kinerja sistem.

c. Algoritma Klasifikasi


Klasifikasi yang dilakukan pada penelitian ini menggunakan algoritma *transfer learning*. Algoritma yang digunakan adalah ResNet, VGG-16 dan Mobilenet. Ketiga model ini akan dibandingkan hasil kinerjanya dalam mengenali rambu lalu lintas di Indonesia (He, K., Zhang, X., Ren, S., & Sun, 2016).

d. Evaluasi Model

Hasil akhir sistem yang diusulkan akan dievaluasi dengan menggunakan matrik evaluasi berupa, akurasi, *recall*, *precision* dan *f1-score*. Matriks evaluasi ini digunakan untuk membandingkan kinerja pada tiga model transfer learning yang

diusulkan.

Dataset yang digunakan merupakan data yang bersumber dari Kaggle. Adapun tampilan data yang terdapat pada dataset ditunjukkan pada Gambar 1.



Gambar 2. Contoh data yang terdapat pada dataset, (a) larangan belok kiri, (b) larangan parkir, (c) lampu kuning, dan (d) perintah masuk jalur kiri.

Dataset rambu lalu lintas ini terdiri dari 2100 data dan 21 kelas, dengan detail sebagai berikut,

- a. Data *train* terdiri 1470 data dari 21 kelas, tiap kelas terdapat 70 gambar rambu.
- b. Data *test* terdiri 840 data dari 21 kelas, tiap kelas terdapat 40 gambar rambu.
- c. Format gambar: .jpg
- d. Kelas pada dataset:
 - 1) Lampu-hijau
 - 2) Lampu-kuning
 - 3) Lampu-merah
 - 4) Larangan-belok-kanan
 - 5) Larangan-belok-kiri
 - 6) Larangan-berhenti
 - 7) Larangan-berjalan-terus-wajib-berhenti-sesaat
 - 8) Larangan-masuk-bagi-kendaraan-bermotor-dan-tidak-bermotor
 - 9) Larangan-memutar-balik
 - 10) Larangan-parkir
 - 11) Peringatan-alat-pemberi-isyarat-lalu-lintas
 - 12) Peringatan-banyak-pejalan-kaki-menggunakan-zebra-cross
 - 13) Peringatan-penegasan-rambu-tambahan
 - 14) Peringatan-pintu-perlintasan-kereta-api
 - 15) Peringatan-simpang-tiga-sisi-kiri
 - 16) Perintah-masuk-jalur-kiri
 - 17) Perintah-pilihan-memasuki-salah-satu-jalur

- 18) Petunjuk-area-parkir
- 19) Petunjuk-lokasi-pemberhentian-bus
- 20) Petunjuk-lokasi-putar-balik
- 21) Petunjuk-penyeberangan-pejalan-kaki

Data yang digunakan masih terdapat banyak *noise* latar belakang. Perlu dilakukan preprocessing berupa objek deteksi terlebih dahulu pada data rambu lalu lintas. Penggunaan deteksi rambu lalu lintas ini berguna untuk mengetahui letak rambu dan memudahkan proses klasifikasi selanjutnya. Model deteksi yang digunakan pada percobaan ini adalah YOLOv5 yang bersumber dari repository: [YOLOv5 for traffic sign detection](#)

4. HASIL DAN PEMBAHASAN

Hasil akhir pelatihan model YOLO v5 yang digunakan menunjukkan nilai mAP yang masih sangat rendah dengan nilai 0,17. Pada Gambar 2 juga ditunjukkan bahwa model mampu mendeteksi objek dengan baik namun masih buruk dalam memprediksi kelas data. Hasil pengujian model deteksi objek menggunakan YOLOv5 menunjukkan bahwa sistem mampu melakukan lokalisasi rambu lalu lintas dengan cukup baik, namun masih mengalami kelemahan dalam proses klasifikasi kelas. Nilai mean Average Precision (mAP) yang diperoleh sebesar 0,17 mengindikasikan bahwa performa model secara keseluruhan masih rendah. Hasil dari percobaan deteksi objek rambu lalu lintas menggunakan YOLOv5 ditunjukkan pada Gambar 3.



Gambar 3. Hasil prediksi deteksi pada objek rambu lalu lintas di Indonesia.

Secara visual, bounding box pada beberapa citra telah mengarah pada posisi rambu yang benar, tetapi kesalahan prediksi label kelas masih sering terjadi. Hal ini menunjukkan bahwa model telah mampu mengenali pola umum objek rambu, namun belum optimal dalam membedakan karakteristik visual antar kelas yang memiliki kemiripan bentuk dan warna. Kompleksitas tugas deteksi yang mencakup lokalisasi dan klasifikasi secara simultan turut mempengaruhi capaian performa tersebut (Everingham et al., 2010).

Rendahnya nilai mAP dipengaruhi oleh beberapa faktor, antara lain keterbatasan jumlah dataset, variasi kondisi pencahayaan dan latar belakang, serta kemiripan visual antar rambu seperti kategori larangan dan perintah. Dengan total 2100 gambar untuk 21 kelas, jumlah data pelatihan masih relatif terbatas untuk kebutuhan object detection berbasis deep learning. Selain itu, variasi sudut pengambilan gambar, occlusion, dan noise latar belakang turut menurunkan kemampuan generalisasi model. Oleh karena itu, diperlukan peningkatan jumlah data, penerapan augmentasi citra, serta optimasi hyperparameter agar performa deteksi dapat meningkat secara signifikan dan lebih layak untuk implementasi pada sistem lalu lintas berbasis kecerdasan buatan di Indonesia (Shorten & Khoshgoftaar, 2019; Goodfellow et al., 2016; Russakovsky et al., 2015).

5. KESIMPULAN DAN SARAN

Kesimpulan dari proyek deteksi rambu lalu lintas Indonesia menggunakan YOLOv5 adalah bahwa metode ini menawarkan solusi inovatif dan adaptif dalam meningkatkan keselamatan dan efisiensi lalu lintas. Pemahaman mendalam terhadap data, termasuk representativitas dan variasi dataset, merupakan kunci kesuksesan dalam pelatihan model deteksi. Penggunaan *transfer learning* memberikan keunggulan dalam meningkatkan kinerja model, dengan memanfaatkan pengetahuan yang telah ada dari dataset yang lebih luas. Pelatihan preprocessing yang telah dilakukan dengan menggunakan *object detection* berbasis YOLOv5 masih kurang baik. Perlu dilakukannya pengecekan ulang kode dan dataset sebelum dilatih agar hasil yang diperoleh dapat lebih baik. Tahapan selanjutnya untuk melakukan deteksi adalah dengan menggunakan data yang telah disegmentasi berdasarkan bagian penting yang dideteksi dari proses deteksi objek.

DAFTAR PUSTAKA

- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. *arXiv*. <https://arxiv.org/abs/2004.10934>
- Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J., & Zisserman, A. (2010). The Pascal Visual Object Classes (VOC) challenge. *International Journal of Computer Vision*, 88, 303–338. <https://doi.org/10.1007/s11263-009-0275-4>
- Girshick, R. (2015). Fast R-CNN. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)* (pp. 1440–1448). <https://doi.org/10.1109/ICCV.2015.169>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 770–778). <https://doi.org/10.1109/CVPR.2016.90>
- Howard, A. G., et al. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv*. <https://arxiv.org/abs/1704.04861>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems (NeurIPS)* (Vol. 25).
- Lin, T.-Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2017). Focal loss for dense object detection. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)* (pp. 2980–2988). <https://doi.org/10.1109/ICCV.2017.324>
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016). SSD: Single shot multibox detector. In *Proceedings of the European Conference on Computer Vision (ECCV)* (pp. 21–37). https://doi.org/10.1007/978-3-319-46448-0_2
- Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 779–788). <https://doi.org/10.1109/CVPR.2016.91>
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. In *Advances in Neural Information Processing Systems (NeurIPS)* (Vol. 28).
- Russakovsky, O., et al. (2015). ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*, 115, 211–252. <https://doi.org/10.1007/s11263-015-0816-y>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6, Article 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Stallkamp, J., Schlipsing, M., Salmen, J., & Igel, C. (2012). Man vs. computer: Benchmarking machine learning algorithms for traffic sign recognition. *Neural Networks*, 32, 323–332. <https://doi.org/10.1016/j.neunet.2012.02.016>
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. In *Proceedings of the International Conference on Machine Learning (ICML)* (pp. 6105–6114).
- Zhu, Z., Liang, D., Zhang, S., Huang, X., Li, B., & Hu, S. (2016). Traffic sign detection and recognition using fully convolutional network. *IEEE Transactions on Intelligent Transportation Systems*, 17(7), 2021–2032. <https://doi.org/10.1109/TITS.2016.2552441>