

Implementasi *Random Forest* Untuk Klasifikasi Jenis Kendaraan dengan menggunakan Algoritma *Gamma Correction*

¹Handrie Noprisson, ²Vina Ayumi

¹Fakultas Ilmu Komputer, Universitas Mercu Buana, Indonesia

¹*handrie.noprisson@mercubuana.ac.id*, ²*vina.ayumi@mercubuana.ac.id*,

Article Info

Article history:

Received, 2023-11-23

Revised, 2023-11-24

Accepted, 2023-11-29

Kata Kunci:

*Kendaraan
Random Forest
Gamma Correction*

ABSTRAK

Sistem pengawasan lalu lintas dapat menjadi alat yang berharga untuk mengwasi lalu lintas jalan dengan cara melakukan penghitungan dan pelacakan kendaraan secara real time. Penelitian ini merupakan riset awal pengembangan metode untuk meningkatkan akurasi deteksi dan pengenalan kendaraan. Tujuan penelitian adalah melakukan analisis performa kinerja gamma correction dan random forest untuk meningkatkan akurasi deteksi dan pengenalan kendaraan. Ukuran kinerja yang digunakan dalam penelitian adalah confusion matrix, accuracy, precision, recall, F1-score. Berdasarkan hasil eksperimen, random forest dengan $\text{gamma}=1.5$ mendapatkan akurasi yang paling baik yaitu 85.00%, sedangkan random forest dengan $\text{gamma}=0.5$ mendapatkan akurasi sebesar 81.30%, random forest dengan $\text{gamma}=1.0$ mendapatkan akurasi sebesar 84.00%, random forest dengan $\text{gamma}=2.0$ mendapatkan akurasi sebesar 84.00%.

ABSTRACT

Keywords:

*Vehicle
Random Forest
Gamma Correction*

Traffic control systems can be a valuable tool for monitoring road traffic by counting and tracking vehicles in real time. This research is the initial research into the development of methods to improve the accuracy of vehicle detection and recognition. The purpose of the study was to analyze the performance of gamma correction and random forest performance to improve the accuracy of vehicle detection and recognition. Performance measures used in the study were confusion matrix, accuracy, precision, recall, F1-score. Based on experimental results, random forest with $\text{gamma}=1.5$ got the best accuracy of 85.00%, while random forest with $\text{gamma}=0.5$ got accuracy of 81.30%, random forest with $\text{gamma}=1.0$ got accuracy of 84.00%, random forest with $\text{gamma}=2.0$ got accuracy of 84.00%.

This is an open access article under the CC BY-SA license.



Penulis Korespondensi:

Handrie Noprisson

Fakultas Ilmu Komputer

Universitas Mercu Buana, Indonesia

Email: *handrie.noprisson@mercubuana.ac.id*

1. PENDAHULUAN

Di Indonesia, jalan merupakan fasilitas umum yang paling signifikan untuk mobilitas orang dan transportasi barang. Fasilitas jalan adalah moda transportasi utama untuk berpindah dari satu wilayah ke wilayah lainnya. Setiap tahunnya, fasilitas jalan terus berkembang karena tingkat manfaat yang diberikan bagi masyarakat terhadap infrastruktur jalan cukup tinggi. Perkembangan infrastruktur jalan ini memerlukan kontrol dan analisis lalu lintas jalan agar tidak dapat dimanfaatkan secara optimal [1], [2], [11], [3]–[10].

Sistem pengawasan lalu lintas biasanya didasarkan pada alat kontrol seperti kamera video yang tidak dapat diawasi sepenuhnya oleh manusia. Dengan demikian, banyak masalah muncul di pada jalur

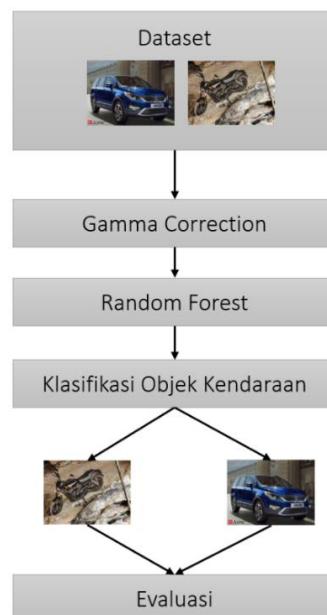
lalu lintas jalan seperti kemacetan dan kecelakaan. Penerapan teknik pengawasan video dalam analisis lalu lintas jalan dapat menjamin hasil yang baik dibandingkan dengan hanya mengandalkan pengawasan manual [12]–[14].

Berdasarkan citra yang diambil dari kamera video, sistem pengawasan ini dapat menjadi alat yang berharga untuk mengelola semua tugas yang terkait dengan lalu lintas jalan. Berdasarkan informasi yang dapat dikumpulkan menggunakan sistem ini, penghitungan dan pelacakan kendaraan secara real time menjadi lebih efisien [15]–[17]. Untuk melakukan klasifikasi objek kendaraan, para peneliti telah mulai menyelidiki penerapan kecerdasan artifisial, seperti algoritma *convolutional neural networks* (CNN) dalam beberapa tahun terakhir. Penelitian Bautista et al. (2016) membahas mengenai sistem deteksi dan klasifikasi kendaraan berbasis CNN menggunakan kamera pemantauan real-time berkualitas rendah[18]. Selanjutnya penelitian oleh Tsai et al. (2018) menggunakan algoritma Faster R-CNN untuk mendeteksi dan mengklasifikasikan kendaraan yang jauh dalam aplikasi real-time [19]. Kinerja desain yang diusulkan dalam penelitian ini dinilai dalam kondisi cuaca yang berbeda. Penelitian oleh Wang, Chen, and Wang (2021) menggunakan metode GAN dan CNN untuk masalah resolusi rendah dalam mengklasifikasikan objek penelitian [20].

Penelitian ini mencoba memberikan kontribusi untuk memecahkan masalah diatas meskipun tidak secara langsung. Tujuan penelitian ini untuk merancang model untuk mendeteksi jenis kendaraan yang ada di jalan berdasarkan citra dari sistem pengawasan video lalu lintas jalan. Hasil yang dihasilkan akan berguna untuk diimplementasikan pada sistem pengawasan lalu lintas yang diintegrasikan dengan modul algoritma lain sehingga kinerja sistem real-time terkait dengan kapasitasnya untuk mendeteksi kendaraan dan mengenali jenisnya dapat bekerja dengan baik. Penelitian ini merupakan riset awal pengembangan metode untuk meningkatkan akurasi deteksi dan pengenalan kendaraan. Metode yang dikembangkan dalam penelitian ini dimulai dengan implementasi *gamma correction* diikuti dengan teknik klasifikasi *random forest*.

2. METODE PENELITIAN

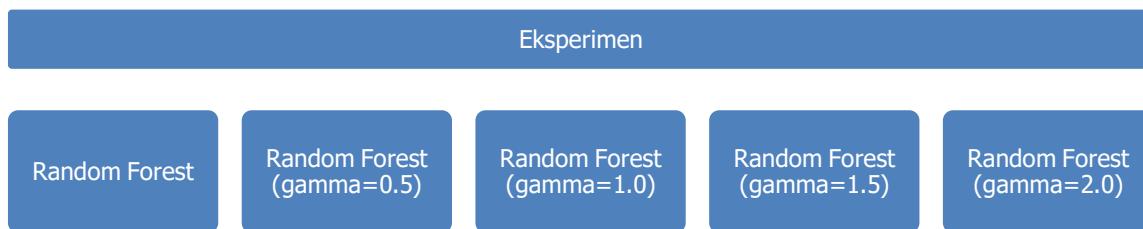
Penelitian ini menggunakan salah satu algoritma klasifikasi *random forest*, untuk membantu klasifikasi objek kendaraan yang digabungkan dengan metode gamma correction. Metode gamma correction ini digunakan untuk meningkatkan kecerahan gambar (*brightness*) pada citra yang ditangkap oleh kamera video pengawasan lalu lintas. Ukuran kinerja yang digunakan dalam penelitian adalah confusion matrix, accuracy, precision, recall, F1-score. Tahapan penelitian ini dapat dilihat pada **Gambar 1**.



Gambar 1 Metodologi Riset

Algoritma *random forest* menggabungkan klasifikasi yang dibuat oleh banyak pohon keputusan (*decision tree*). Untuk pelatihan model jenis ini perlu tidak hanya untuk menentukan dimensi ruang fitur acak, tetapi juga jumlah pohon (tree) yang akan dibangun berdasarkan batas keputusan yang dihasilkan oleh variabel divisi tersebut. Untuk menetapkan nilai optimal dari parameter ini, sejumlah percobaan dilakukan dengan menggunakan jumlah pohon yang berbeda dan jumlah variabel split yang berbeda sehingga akurasi untuk klasifikasi kendaraan dapat menjadi lebih optimal.

Metode *gamma correction* digunakan untuk mengkompensasi perbedaan, karena kecerahan gambar (*brightness*) yang ditampilkan pada monitor berbeda dari informasi input gambar tersebut. Karena hubungan kecerahan (*brightness*) yang ditampilkan pada monitor dengan sinyal input tidak linier, maka diproses sedemikian rupa sehingga nilai output untuk nilai input dikompensasi secara terbalik. Pada eksperimen ini selanjutnya citra diproses oleh *gamma correction* oleh klasifier *random forest* (RF). Penelitian dilakukan sebanyak lima kali eksperimen, yaitu eksperimen dengan menggunakan algoritma *random forest*, *random forest* dengan penambahan $\text{gamma}=0.5$, *random forest* dengan penambahan $\text{gamma}=1.0$, *random forest* dengan penambahan $\text{gamma}=1.5$, *random forest* dengan penambahan $\text{gamma}=2.0$ seperti yang terlihat pada **Gambar 2**.



Gambar 2 Skenario Eksperimen

3. HASIL DAN ANALISIS

Penelitian dilakukan sebanyak lima kali eksperimen, yaitu eksperimen dengan mengimplementasikan algoritma *random forest*, *random forest* dengan penambahan $\text{gamma}=0.5$, *random forest* dengan penambahan $\text{gamma}=1.0$, *random forest* dengan penambahan $\text{gamma}=1.5$, *random forest* dengan penambahan $\text{gamma}=2.0$. Hasil eksperimen pertama yaitu menggunakan algoritma *random forest* berupa *confusion matrix*, *accuracy*, *precision*, *recall*, *F1-score* dapat dilihat pada **Gambar 1**.

Dataset Size: 4000					
Accuracy: 82.90%					
	precision	recall	f1-score	support	
Bike	0.88	0.78	0.83	524	
Car	0.79	0.88	0.83	476	
accuracy			0.83	1000	
macro avg	0.83	0.83	0.83	1000	
weighted avg	0.83	0.83	0.83	1000	
Confusion Matrix					
[[411 113]					
[58 418]]					

Gambar 3 Hasil Eksperimen - Random Forest

Pada eksperimen kedua dilakukan menggunakan *random forest* dengan penambahan $\text{gamma}=0.5$. Metode image enhancement adalah metode yang digunakan untuk membuat citra lebih baik daripada yang asli untuk pemrosesan tertentu. Hasil eksperimen kedua dengan menggunakan *random forest* dengan penambahan $\text{gamma}=0.5$ dalam bentuk *confusion matrix*, *accuracy*, *precision*, *recall*, *F1-score* dapat dilihat pada **Gambar 4**.

Dataset Size: 4000				
Accuracy: 81.30%				
	precision	recall	f1-score	support
Bike	0.86	0.77	0.81	524
Car	0.77	0.86	0.81	476
accuracy			0.81	1000
macro avg	0.82	0.82	0.81	1000
weighted avg	0.82	0.81	0.81	1000
Confusion Matrix				
[[402 122]				
[65 411]]				

Gambar 4 Hasil Eksperimen - Random Forest (gamma=0.5)

Pada eksperimen kedua dilakukan menggunakan *random forest* dengan penambahan gamma=1.0. Untuk meningkatkan kecerahan gambar, perlu untuk akan mengubah nilai gamma (γ). Hasil eksperimen kedua dengan menggunakan Random Forest dengan penambahan gamma=0.5 dalam bentuk *confusion matrix*, *accuracy*, *precision*, *recall*, *F1-score* dapat dilihat pada **Gambar 5**.

Dataset Size: 4000				
Accuracy: 84.00%				
	precision	recall	f1-score	support
Bike	0.87	0.81	0.84	524
Car	0.81	0.87	0.84	476
accuracy			0.84	1000
macro avg	0.84	0.84	0.84	1000
weighted avg	0.84	0.84	0.84	1000
Confusion Matrix				
[[426 98]				
[62 414]]				

Gambar 5 Hasil Eksperimen - Random Forest (gamma=0.5)

Pada eksperimen ketiga dilakukan menggunakan *random forest* dengan penambahan gamma=1.5. Metode *gamma correction* berguna untuk mengubah kontras dan kecerahan pada sebuah citra. Metode ini penting untuk menampilkan gambar pada layar dengan baik, untuk mencegah pemutihan atau penggelapan pada citra. Hasil eksperimen kedua dengan menggunakan Random Forest dengan penambahan gamma=1.5 dalam bentuk *confusion matrix*, *accuracy*, *precision*, *recall*, *F1-score* dapat dilihat pada **Gambar 6**.

Dataset Size: 4000				
Accuracy: 85.00%				
	precision	recall	f1-score	support
Bike	0.88	0.83	0.85	524
Car	0.82	0.87	0.85	476
accuracy			0.85	1000
macro avg	0.85	0.85	0.85	1000
weighted avg	0.85	0.85	0.85	1000
Confusion Matrix				
[[434 90]				
[60 416]]				

Gambar 6 Hasil Eksperimen - Random Forest (gamma=1.5)

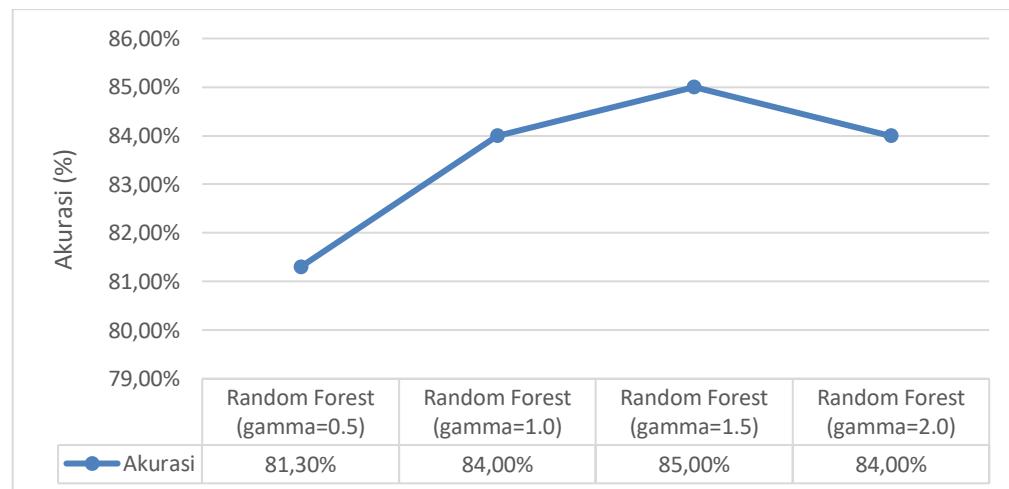
Pada eksperimen ketiga dilakukan menggunakan *random forest* dengan penambahan gamma=2.0. Dengan mengubah nilai *gamma* pada metode *gamma correction*, maka akan memberikan hasil yang

berbeda. Hasil eksperimen kedua dengan menggunakan Random Forest dengan penambahan gamma=2.0 dalam bentuk *confusion matrix*, *accuracy*, *precision*, *recall*, *F1-score* dapat dilihat pada **Gambar 7**.

Dataset Size: 4000				
Accuracy: 84.00%				
	precision	recall	f1-score	support
Bike	0.88	0.81	0.84	524
Car	0.81	0.88	0.84	476
accuracy			0.84	1000
macro avg	0.84	0.84	0.84	1000
weighted avg	0.84	0.84	0.84	1000
Confusion Matrix				
[[423 101]				
[59 417]]				

Gambar 7 Hasil Eksperimen - Random Forest (gamma=2.0)

Penelitian ini menggunakan salah satu metode image enhancement adalah metode *Power-law transformation* atau *gamma correction* yang digabungkan dengan metode *random forest*. Dengan mengubah nilai gamma pada metode *gamma correction*, maka akan memberikan hasil yang berbeda. Jadi koreksi grammar correction adalah proses memilih nilai terbaik untuk gamma agar memiliki gambar keluaran terbaik. Adapun pengaruh nilai gamma correction terhadap hasil klasifikasi dari Random Forest dapat dilihat pada **Gambar 8**.



Gambar 8 Pengaruh Nilai Gamma pada Random Forest

Algoritma gamma correction juga dikenal sebagai Power Law Transform dapat disimpulkan bahwa berpengaruh pada hasil akurasi klasifikasi yang dilakukan oleh algoritma *random forest*. Langkah yang diimplementasikan pada gamma correction dilakukan dengan cara mengatur intensitas piksel gambar menjadi skala [0, 255] hingga [0, 1.0]. Dari pengaturan ini didapatkan gambar keluaran yang dikoreksi dengan menerapkan persamaan $O = \left(\frac{I}{255}\right)^{\frac{1}{G}}$. dimana nilai I adalah gambar input dan G adalah nilai gamma. Gambar keluaran O kemudian diperkecil kembali ke nilai antara [0, 255]. Nilai $G < 1$ akan menggeser gambar ke arah ujung spektrum yang lebih gelap sementara nilai $G > 1$ akan membuat gambar tampak lebih terang. Hasil eksperimen secara keseluruhan pada penelitian ini dapat dilihat pada **Tabel 1**.

Tabel 1 Hasil Eksperimen Penelitian

No	Metode Eksperimen	Parameter	Hasil
1	Random Forest	-	82.90%
2	Random Forest (gamma=0.5)	g=0.5	81.30%
3	Random Forest (gamma=1.0)	g=1.0	84.00%
4	Random Forest (gamma=1.5)	g=1.5	85.00%
5	Random Forest (gamma=2.0)	g=2.0	84.00%

4. KESIMPULAN

Di Indonesia, fasilitas jalan adalah moda transportasi utama untuk berpindah dari satu wilayah ke wilayah lainnya. Penggunaan infrastruktur jalan ini memerlukan kontrol dan analisis lalu lintas jalan agar tidak dapat dimanfaatkan secara optimal. Penelitian ini bertujuan membuat analisis performa kinerja *gamma correction* dan *random forest* untuk meningkatkan akurasi deteksi dan pengenalan kendaraan. Ukuran kinerja yang digunakan dalam penelitian adalah confusion matrix, accuracy, precision, recall, F1-score. Berdasarkan hasil eksperimen, Random Forest dengan gamma=1.5 mendapatkan akurasi yang paling baik yaitu 85.00%, sedangkan Random Forest dengan gamma=0.5 mendapatkan akurasi sebesar 81.30%, Random Forest dengan gamma =1.0 mendapatkan akurasi sebesar 84.00%, Random Forest dengan gamma =2.0 mendapatkan akurasi sebesar 84.00%.

UCAPAN TERIMA KASIH

Terima kasih kepada Biro Penelitian, Pengabdian Masyarakat & Publikasi, Universitas Mercu Buana yang telah mendanai penelitian ini melalui skema Penelitian Internal Kerjasama Dalam Negeri (KDN)

REFERENSI

- [1] R. Hutabarat Lo, “The city as a mirror: Transport, land use and social change in Jakarta,” *Urban Stud.*, vol. 47, no. 3, pp. 529–555, 2010.
- [2] J. Silas, “Toll roads and the development of new settlements: The case of Surabaya compared to Jakarta,” *Bijdr. tot Taal-, Land-en Volkenkd.*, vol. 158, no. 4, pp. 677–689, 2002.
- [3] M. Douglass, “A regional network strategy for reciprocal rural–urban linkages: an agenda for policy research with reference to Indonesia,” in *The Earthscan Reader in Rural–Urban Linkages*, Routledge, 2018, pp. 124–154.
- [4] E. D. Putra, E. Hidayat, and H. Noprisson, “Model Mobile Positioning System Berbasis Android,” vol. III, no. September, pp. 113–121, 2016.
- [5] H. Noprisson, E. Ermataita, A. Abdiansah, V. Ayumi, M. Purba, and M. Utami, “Hand-Woven Fabric Motif Recognition Methods: A Systematic Literature Review,” in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 90–95.
- [6] H. Noprisson, E. Ermataita, A. Abdiansah, V. Ayumi, M. Purba, and H. Setiawan, “Fine-Tuning Transfer Learning Model in Woven Fabric Pattern Classification,” *Int. J. Innov. Comput. Inf. Control*, vol. 18, no. 06, p. 1885, 2022.
- [7] V. Ayumi *et al.*, “Transfer Learning for Medicinal Plant Leaves Recognition: A Comparison with and without a Fine-Tuning Strategy,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 9, 2022.
- [8] V. Ayumi, E. Ermataita, A. Abdiansah, H. Noprisson, M. Purba, and M. Utami, “A Study on Medicinal Plant Leaf Recognition Using Artificial Intelligence,” in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 40–45.
- [9] N. Andi, I. Ilham, D. J. Yudha, and F. Jefry, “Analysis of user satisfaction level on cashcloud. Id system with system usability scale method and Spearman’s rank correlation,” *Int. J. Open Inf. Technol.*, vol. 11, no. 9, pp. 92–99, 2023.
- [10] M. Purba *et al.*, “Effect of Random Splitting and Cross Validation for Indonesian Opinion Mining using Machine Learning Approach,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 9, 2022.
- [11] M. Purba, E. Ermataita, A. Abdiansah, V. Ayumi, H. Noprisson, and A. Ratnasari, “A Systematic Literature Review of Knowledge Sharing Practices in Academic Institutions,” in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 337–342.
- [12] L. Zhang, R. Wang, and L. Cui, “Real-time traffic monitoring with magnetic sensor networks,” *J. Inf. Sci. Eng.*, vol. 27, no. 4, pp. 1473–1486, 2011.
- [13] M. Won, “Intelligent traffic monitoring systems for vehicle classification: A survey,” *IEEE Access*, vol.

- 8, pp. 73340–73358, 2020.
- [14] L. Xiao and Z. Wang, “Internet of things: A new application for intelligent traffic monitoring system,” *J. networks*, vol. 6, no. 6, p. 887, 2011.
 - [15] M. M. Rathore, H. Son, A. Ahmad, and A. Paul, “Real-time video processing for traffic control in smart city using Hadoop ecosystem with GPUs,” *Soft Comput.*, vol. 22, no. 5, pp. 1533–1544, 2018.
 - [16] F. Porikli *et al.*, “Video surveillance: past, present, and now the future [DSP Forum],” *IEEE Signal Process. Mag.*, vol. 30, no. 3, pp. 190–198, 2013.
 - [17] N. K. Jain, R. K. Saini, and P. Mittal, “A review on traffic monitoring system techniques,” *Soft Comput. Theor. Appl.*, pp. 569–577, 2019.
 - [18] C. M. Bautista, C. A. Dy, M. I. Mañalac, R. A. Orbe, and M. Cordel, “Convolutional neural network for vehicle detection in low resolution traffic videos,” in *2016 IEEE Region 10 Symposium (TENSYMP)*, 2016, pp. 277–281.
 - [19] C.-C. Tsai, C.-K. Tseng, H.-C. Tang, and J.-I. Guo, “Vehicle detection and classification based on deep neural network for intelligent transportation applications,” in *2018 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)*, 2018, pp. 1605–1608.
 - [20] X. Wang, X. Chen, and Y. Wang, “Small vehicle classification in the wild using generative adversarial network,” *Neural Comput. Appl.*, vol. 33, pp. 5369–5379, 2021.