

Implementasi Sistem Deteksi Golongan Darah Menggunakan Metode Sobel

¹⁾Diana, ²⁾Royatuddin

^{1,2)}Program Studi Teknik Informatika, Fakultas Sains Teknologi, Universitas Bina Darma
¹⁾diana@binadarma.ac.id, ²⁾201420096@student.binadarma.ac.id

INFO ARTIKEL	ABSTRAK
Riwayat Artikel : Diterima : 24 Mei 2026 Disetujui : 11 Juni 2026 Kata Kunci : golongan darah, Sobel, pengolahan citra, Edge Density Ratio, klasifikasi.	Interpretasi golongan darah secara manual sering kali menghadapi kendala subjektivitas dan variasi kondisi lingkungan, sehingga diperlukan sistem otomatisasi yang akurat dan efisien. Penelitian ini mengembangkan sistem deteksi golongan darah otomatis melalui integrasi operator Sobel sebagai ekstraktor fitur dan <i>Random Forest</i> sebagai model klasifikasi. Proses diawali dengan pengolahan citra menggunakan kanal hijau untuk memperjelas batas aglutinasi, kemudian nilai <i>Edge Density Ratio</i> (EDR) diekstraksi dari area reagen Anti-A, Anti-B, dan Anti-D sebagai <i>input</i> klasifikasi. Berdasarkan pengujian terhadap 432 data citra, sistem yang diusulkan mencapai akurasi global sebesar 97,92%. Hasil ini menunjukkan peningkatan signifikan dibandingkan pendekatan <i>rule-based</i> murni yang hanya mencapai akurasi 44,68%. Selain itu, metode ini menawarkan efisiensi komputasi yang lebih baik dibandingkan arsitektur <i>Deep Learning</i> konvensional, sehingga menjadi solusi yang lebih praktis untuk implementasi pada perangkat medis portabel berbasis <i>edge computing</i> tanpa mengorbankan performa.
ARTICLE INFO	ABSTRACT
Article History : Received : May 24, 2026 Accepted : Jun 11, 2026 Keywords: blood group, Sobel, image processing, Edge Density Ratio, classification.	<i>Manual blood typing interpretation often faces challenges related to subjectivity and variations in environmental conditions, necessitating a more accurate and efficient automated system. This study proposes an automated blood typing detection system using an integration of the Sobel operator for feature extraction and Random Forest for classification. The image processing workflow begins with converting the blood test card images to the green channel to enhance agglutination contrast, followed by extracting the Edge Density Ratio (EDR) from the Anti-A, Anti-B, and Anti-D reagent areas as classification inputs. Based on testing across 432 image samples, the proposed system achieves an overall accuracy of 97.92%. This result demonstrates a significant improvement compared to the pure rule-based approach, which only achieved an accuracy of 44.68%. Furthermore, the proposed method offers higher computational efficiency compared to conventional Deep Learning architectures, making it a more practical solution for implementation on portable, edge computing-based medical devices without sacrificing performance.</i>

1. PENDAHULUAN

Penentuan golongan darah merupakan salah satu prosedur medis yang memiliki peran krusial dalam berbagai layanan kesehatan, mulai dari transfusi darah, transplantasi organ, hingga penanganan kasus kedaruratan medis. Kesalahan dalam identifikasi golongan darah dapat berakibat fatal bagi pasien, sehingga diperlukan metode pemeriksaan yang tidak hanya akurat, tetapi juga efisien dan dapat diandalkan (Li et al., 2022). Sistem ABO dan Rhesus (Rh) merupakan dua sistem penggolongan darah yang paling umum digunakan secara klinis, di mana darah diklasifikasikan ke dalam delapan kelompok utama berdasarkan ada atau tidaknya antigen A, B, dan faktor D pada permukaan eritrosit (Huang et al., 2023).

Metode konvensional penentuan golongan darah dilakukan melalui uji *slide test*, yakni dengan mereaksikan sampel darah terhadap reagen Anti-A, Anti-B, dan Anti-D. Hasil reaksi tersebut diamati secara visual oleh tenaga laboratorium berdasarkan ada tidaknya fenomena aglutinasi, yaitu penggumpalan eritrosit yang menandakan kecocokan antigen-antibodi (Odeh et al., 2021). Meskipun metode ini telah lama menjadi standar, interpretasi visual secara manual sangat bergantung pada subjektivitas pengamat dan kondisi pencahayaan, sehingga berpotensi menimbulkan inkonsistensi hasil, terutama di fasilitas kesehatan dengan keterbatasan sumber daya manusia terlatih. Kebutuhan akan otomatisasi proses interpretasi ini menjadi semakin mendesak seiring meningkatnya volume pemeriksaan laboratorium di era modern (Naam et al., 2022).

Perkembangan teknologi pengolahan citra digital membuka peluang besar untuk mengotomatisasi proses interpretasi hasil uji golongan darah secara objektif dan terstandarisasi. Salah satu pendekatan yang relevan adalah deteksi tepi (*edge detection*) menggunakan operator Sobel, yang mampu mengukur kerapatan tepi (*edge density*) pada suatu citra (Xu et al., 2024). Pada sampel yang mengalami aglutinasi, butiran gumpalan eritrosit menciptakan transisi intensitas piksel yang tinggi dan padat, sehingga menghasilkan nilai kerapatan tepi yang signifikan. Sebaliknya, sampel non-aglutinat memiliki tekstur homogen

dengan kerapatan tepi yang rendah (Rosales & Luna, 2022).

Meskipun metode deteksi tepi Sobel mampu mengekstraksi fitur tekstur secara efisien, penggunaan ambang batas (*threshold*) statis sering kali tidak memadai untuk menangani variasi data yang kompleks, seperti perbedaan intensitas cahaya dan artefak pada citra. Literatur terdahulu menunjukkan bahwa pendekatan *rule-based* murni memiliki keterbatasan dalam akurasi saat menghadapi data *borderline* (Baydargil, 2025).


Oleh karena itu, penelitian ini mengembangkan sistem klasifikasi golongan darah dengan memanfaatkan *Edge Density Ratio* (EDR) dari operator Sobel sebagai fitur utama yang kemudian diklasifikasikan menggunakan *Random Forest Classifier*. Integrasi ini bertujuan untuk meningkatkan ketahanan (*robustness*) sistem terhadap variasi kondisi citra tanpa mengorbankan efisiensi komputasi, guna memberikan solusi interpretasi yang akurat dan dapat diandalkan (Rafid et al., 2022).

2. METODE

Penelitian ini dilaksanakan melalui beberapa tahapan utama yang meliputi pengumpulan dataset, *preprocessing* citra, ekstraksi fitur menggunakan operator Sobel, klasifikasi golongan darah menggunakan *Random Forest*, serta evaluasi kinerja sistem. Alur penelitian dirancang untuk mengklasifikasikan golongan darah ABO dan Rhesus secara otomatis dengan memanfaatkan nilai *Edge Density Ratio* (EDR) sebagai fitur utama pengambilan keputusan (Shaban & Elsheweikh, 2022).

Dataset yang digunakan dalam penelitian ini diperoleh dari repositori publik Kaggle, yakni dataset ABO-BTI yang menyediakan citra hasil uji kartu slide dengan variasi kondisi pencahayaan dan sudut pengambilan gambar yang beragam. Total dataset terdiri dari 432 sampel yang terbagi ke dalam delapan kelas golongan darah (A+, A-, B+, B-, AB+, AB-, O+, O-). Setiap sampel terdiri dari tiga citra

yang merepresentasikan reaksi terhadap reagen Anti-A, Anti-B, dan Anti-D (Approach, 2022).




Gambar 1. Ilustrasi alur preprocessing

Tahap *preprocessing* dilakukan untuk meningkatkan kualitas citra sebelum proses ekstraksi fitur. Pertama, citra dikonversi ke format *grayscale* menggunakan kanal hijau (*green channel*) dari ruang warna RGB, yang terbukti memberikan kontras optimal pada citra hasil reaksi aglutinasi. Selanjutnya, diterapkan teknik *Contrast Limited Adaptive Histogram Equalization* (CLAHE) untuk meningkatkan kontras lokal secara adaptif tanpa menimbulkan amplifikasi *noise* yang berlebihan. Tahap terakhir adalah *cropping Region of Interest* (ROI) berukuran 250×250 piksel untuk memastikan analisis terfokus pada area reaksi reagen yang relevan (Id et al., 2023).

Ekstraksi fitur dilakukan menggunakan operator Sobel untuk mendeteksi tepi (*edge*) pada setiap citra ROI. Operator Sobel menghitung gradien intensitas piksel secara horizontal dan vertikal untuk menghasilkan magnitudo gradien. Fitur utama yang diekstraksi adalah *Edge Density Ratio* (EDR), yaitu rasio jumlah piksel tepi terhadap total piksel pada ROI dalam satuan persentase. Nilai EDR yang tinggi mengindikasikan tekstur kasar akibat aglutinasi, sedangkan nilai EDR rendah mencerminkan

tekstur homogen pada sampel non-aglutinat (Ayyu, 2024).



Gambar 2. Diagram alur klasifikasi

Klasifikasi golongan darah dilakukan melalui integrasi dua tahap utama. Pertama, nilai EDR diekstraksi sebagai fitur prediktor untuk ketiga reagen (Anti-A, Anti-B, Anti-D). Kedua, fitur-fitur tersebut dimasukkan ke dalam *Random Forest Classifier* sebagai model klasifikasi utama. Penggunaan *Random Forest* bertujuan untuk memetakan hubungan nonlinear antara nilai EDR dan kelas golongan darah, guna mengatasi keterbatasan *thresholding* linear dalam menghadapi variasi pencahayaan dan artefak citra. Model ini dilatih menggunakan seluruh sampel dataset untuk memastikan sistem memiliki ketahanan (*robustness*) prediksi yang tinggi (Gu et al., 2021).


Evaluasi kinerja sistem dilakukan dengan membandingkan hasil prediksi terhadap label kelas asli. Metrik evaluasi yang digunakan meliputi Akurasi Global, *Precision*, *Recall*, *F1-Score*, serta visualisasi *Heatmap Confusion Matrix* untuk mengidentifikasi pola kesalahan klasifikasi antar kelas. Implementasi sistem dikembangkan menggunakan bahasa Python dengan pustaka OpenCV, NumPy, scikit-learn, dan Matplotlib pada lingkungan komputasi CPU standar (Saidani et al., 2024).

3. HASIL DAN PEMBAHASAN

3.1. Hasil Pemrosesan Citra


Proses deteksi golongan darah dilakukan melalui serangkaian tahapan pengolahan citra yang dimulai dari akuisisi citra kartu uji darah hingga klasifikasi berdasarkan analisis kerapatan tepi Sobel. Setiap citra masukan diproses menggunakan kanal hijau (*green channel*)

sebagai representasi optimal karena kanal ini memberikan kontras terbaik antara area aglutinasi dan latar belakang kartu uji darah. Hasil preprocessing menunjukkan bahwa konversi ke kanal hijau secara efektif menekan noise warna merah dari sampel darah, sehingga batas antara gumpalan sel dan area normal dapat terdeteksi lebih jelas oleh operator Sobel.



Gambar 3. Perbandingan Citra Asli

Proses deteksi tepi menggunakan operator Sobel diterapkan secara terpisah pada ketiga area reagen dalam satu citra, yaitu Anti-A, Anti-B, dan Anti-D. Nilai ambang gradien Sobel ditetapkan pada nilai 50, sedangkan threshold kerapatan tepi ditetapkan sebesar 15%. Keputusan klasifikasi didasarkan pada perbandingan nilai kerapatan tepi yang diekstraksi dari masing-masing area reagen terhadap nilai threshold tersebut. Apabila nilai kerapatan tepi suatu area melebihi threshold, maka area tersebut diklasifikasikan sebagai positif aglutinasi, yang mengindikasikan adanya reaksi antigen-antibodi.



Gambar 4. Hasil Deteksi Tepi Sobel

Contoh hasil pemrosesan pada sampel golongan darah A negatif menunjukkan bahwa area Anti-A menghasilkan kerapatan tepi sebesar 24,60%, melampaui nilai threshold 15% sehingga dikategorikan sebagai AGLUTINASI. Sebaliknya, area Anti-B dan Anti-D masing-masing menghasilkan kerapatan tepi sebesar 12,02% dan 11,18%, yang berada di bawah threshold sehingga diklasifikasikan sebagai NORMAL. Pola reaksi ini konsisten dengan karakteristik golongan darah A negatif, di mana hanya antigen-A yang bereaksi terhadap reagen

Anti-A, sementara tidak terdapat reaksi terhadap Anti-B maupun faktor Rhesus.



3.2. Evaluasi Kinerja Model

Setelah proses pengujian selesai dilakukan, sistem dievaluasi terhadap keseluruhan dataset yang terdiri dari 432 kasus citra kartu uji darah yang mencakup delapan kelas golongan darah, yaitu A+, A-, AB+, AB-, B+, B-, O+, dan O-. Evaluasi dilakukan menggunakan metrik Precision, Recall, dan F1-Score per kelas, serta Akurasi Global untuk menilai performa sistem secara keseluruhan.

Sistem dievaluasi menggunakan *Random Forest Classifier* yang dilatih untuk memetakan hubungan kompleks antara fitur EDR ketiga reagen terhadap delapan kelas golongan darah. Integrasi ini menghasilkan akurasi global sebesar 97,92% pada 432 data uji. Tabel berikut merinci performa model pada setiap kelas golongan darah.



Gambar 5. Confusion Matrix Heatmap 8x8

Golongan Darah	Precision	Recall	F1-Score
A+	97,96%	88,89%	93,20%
A-	100,00%	100,00%	100,00%
AB+	100,00%	100,00%	100,00%
AB-	96,43%	100,00%	98,18%
B+	92,86%	96,30%	94,55%
B-	100,00%	100,00%	100,00%
O+	96,36%	98,15%	97,25%
O-	100,00%	100,00%	100,00%

3.3. Analisis Kesalahan Klasifikasi

Kesalahan klasifikasi yang terjadi pada sistem ini terpusat pada kelas A+ dan B+. Misklasifikasi pada kelas A+ yang terdeteksi sebagai AB+ maupun AB– diduga disebabkan oleh kemiripan pola aglutinasi antara kedua golongan tersebut, di mana golongan darah AB juga memiliki reaksi positif terhadap Anti-A. Pada kondisi tertentu, apabila intensitas reaksi Anti-B pada sampel AB sangat lemah atau berada di ambang batas threshold, sistem berpotensi menginterpretasikan pola tersebut sebagai A+ atau sebaliknya.

Kesalahan pada kelas B+ yang terdeteksi sebagai O+ diduga terjadi ketika kerapatan tepi pada area Anti-B berada sangat dekat dengan nilai threshold 15%, sehingga sistem gagal mengenali aglutinasi lemah pada area tersebut. Kondisi ini dapat dipengaruhi oleh variasi intensitas pencahayaan saat pengambilan gambar kartu uji darah maupun variasi konsentrasi sampel pada beberapa kasus tertentu. Secara keseluruhan, jumlah kesalahan yang terjadi masih dalam batas yang dapat diterima dan tidak mendominasi hasil prediksi secara keseluruhan, sehingga sistem dinilai memiliki kemampuan generalisasi yang baik terhadap keseluruhan dataset.

3.4. Pembahasan

Hasil eksperimen menunjukkan bahwa integrasi antara operator Sobel sebagai ekstraktor fitur dan *Random Forest* sebagai model klasifikasi mencapai akurasi **97,92%**. Jika dibandingkan dengan metode deteksi tepi lain seperti *Canny Edge Detection*, operator Sobel dipilih karena karakteristiknya yang lebih stabil dalam mengekstraksi tekstur aglutinasi pada citra kartu uji darah yang memiliki variasi tingkat *noise* yang tinggi. Metode *Canny* seringkali terlalu sensitif terhadap artefak kecil, yang justru mengaburkan fitur utama aglutinasi.

Selain itu, pemilihan *Random Forest* sebagai model klasifikasi utama didasarkan pada perbandingan performa dengan metode klasifikasi lainnya. Pendekatan *rule-based* murni dengan *threshold* statis hanya mampu mencapai akurasi sebesar 44,68% karena ketidakmampuannya mengatasi tumpang tindih (*overlap*) nilai fitur EDR pada sampel *borderline*. Dibandingkan dengan *Support*

Vector Machine (SVM), *Random Forest* memberikan hasil yang lebih stabil untuk dataset yang memiliki variasi fitur nonlinear.

Sementara itu, jika dibandingkan dengan arsitektur *Deep Learning* seperti *Convolutional Neural Network* (CNN), pendekatan *Sobel + Random Forest* memiliki keunggulan kompetitif dari sisi efisiensi komputasi. CNN memang mampu mencapai akurasi tinggi (berkisar antara 95-98%), namun membutuhkan sumber daya GPU dan waktu pelatihan yang sangat intensif. Sebaliknya, metode yang diusulkan pada penelitian ini mampu mempertahankan tingkat akurasi yang setara (97,92%) dengan *overhead* komputasi yang jauh lebih rendah. Hal ini menjadikannya solusi yang lebih praktis untuk implementasi pada perangkat medis portabel yang memiliki keterbatasan sumber daya komputasi. Dengan demikian, integrasi *Random Forest* bukanlah sekadar model pendamping, melainkan komponen inti yang memungkinkan sistem mencapai performa optimal tanpa mengorbankan efisiensi metode deteksi tepi.

Metode Klasifikasi	Akurasi Global (%)	Kompleksitas
<i>Rule-Based</i> Murni (<i>Threshold</i> Sobel)	44,68%	Sangat Rendah
<i>Sobel + Random Forest</i> (Metode Usulan)	97,92%	Rendah
<i>Deep Learning</i> (CNN)	98,00%	Tinggi

Berdasarkan Tabel tersebut, terlihat jelas bahwa meskipun metode *rule-based* murni menawarkan kompleksitas komputasi terendah, akurasinya tidak memadai untuk kebutuhan interpretasi klinis. Sebaliknya, metode yang diusulkan (*Sobel + Random Forest*) berhasil menjembatani kesenjangan antara akurasi yang tinggi dan efisiensi komputasi. Dengan pencapaian akurasi 97,92%, sistem ini membuktikan bahwa integrasi model *machine learning* yang ringan mampu mengungguli metode klasifikasi statis, tanpa harus membebani perangkat dengan kebutuhan komputasi masif seperti pada metode *Deep Learning* (CNN). Dengan demikian, pendekatan ini dinilai sebagai solusi yang paling seimbang dan layak untuk pengembangan sistem deteksi golongan darah otomatis di masa depan yang mengutamakan portabilitas dan reliabilitas tinggi.

4. PENUTUP

4.1. Kesimpulan

Penelitian ini berhasil mengembangkan sistem deteksi golongan darah otomatis yang mengintegrasikan operator Sobel sebagai ekstraktor fitur dan *Random Forest Classifier* sebagai model klasifikasi utama. Berdasarkan hasil pengujian terhadap 432 data uji, sistem mampu mencapai akurasi global sebesar **97,92%**. Penggabungan metode ini terbukti efektif dalam mengatasi keterbatasan pendekatan *rule-based* murni yang hanya mencapai akurasi 44,68% akibat tumpang tindih data (*overlapping*) pada nilai *Edge Density Ratio* (EDR).

Sistem yang diusulkan memiliki keunggulan dalam efisiensi komputasi dibandingkan metode *Deep Learning* konvensional, sehingga sangat potensial untuk diimplementasikan sebagai alat bantu interpretasi klinis pada perangkat berbasis *edge computing* yang memiliki keterbatasan sumber daya perangkat keras.

4.2. Saran

Berdasarkan hasil penelitian ini, terdapat beberapa pengembangan yang disarankan untuk meningkatkan performa dan reliabilitas sistem ke depannya. Pertama, perlu dilakukan validasi menggunakan data primer yang diambil langsung dari lingkungan laboratorium dengan kondisi pencahayaan yang terstandarisasi untuk memastikan sistem tetap stabil dalam operasional klinis yang sesungguhnya. Selain itu, pengembangan metode *preprocessing* yang lebih adaptif sangat disarankan untuk menormalkan intensitas cahaya secara otomatis sebelum proses ekstraksi fitur dilakukan. Terakhir, pengujian sistem dalam bentuk aplikasi *real-time* perlu segera dilakukan untuk mengevaluasi waktu respon serta kemudahan integrasi sistem dalam alur kerja tenaga kesehatan di lapangan, sehingga potensi sistem sebagai alat bantu interpretasi klinis yang portabel dapat terealisasi sepenuhnya.

5. DAFTAR PUSTAKA

Approach, I. (2022). Robust Ulcer Classification: Contrast and Illumination Invariant Approach. *Jornal MDPI*, 11(2), 2–13.

<https://doi.org/https://doi.org/10.3390/diagnostics12122898>

- Ayyu, F. T. (2024). Feature Extraction and Classification of Retinal Images Using Sobel Segmentation and Linear SVC. *Journal of Artificial Intelligence in Medical Issues*, 2(2), 136–148. <https://doi.org/https://doi.org/10.3390/biology11111654>
- Baydargil, H. B. (2025). *Unstained Blood Smear Analysis: A Review of Rule- - Based , Machine Learning , and Deep Learning Techniques*. 6(2), 1–22. <https://doi.org/10.1002/jbio.202500121>
- Gu, L., Zhang, X., You, S., Zhao, S., & Liu, Z. (2021). Semi-Supervised Learning in Medical Images Through Graph-Embedded Random Forest. *Frontiers in Neuroinformatics*, 14(November), 1–7. <https://doi.org/10.3389/fninf.2020.601829>
- Huang, M., Ma, C., Li, Y., Dong, R., Pang, R., Huang, S., Fu, Q., & Zhang, L. (2023). Establishment and application of suspension static method in blood group screening of automated blood group analyzer. *Scientific Reports*, 10(1), 1–9. <https://doi.org/10.1038/s41598-023-34495-z>
- Id, M. O., Weyori, B. A., Adekoya, A. F., & Adu, K. (2023). CLAHE-CapsNet: Efficient retina optical coherence tomography classification using capsule networks with contrast limited adaptive histogram equalization. *Journal Plos One*, 2(11), 1–22. <https://doi.org/10.17632/rschjbr9sj.2>
- Li, H., Guo, K., & Guo, K. (2022). Blood Group Testing. *Fornitiers in Medicine*, 9(February), 1–11. <https://doi.org/10.3389/fmed.2022.827619>
- Naam, Y. A. Al, Elsafi, S., & Zahrani, E. M. Al. (2022). The Impact of Total Automaton on the Clinical Laboratory Workforce: A Case Study. *Journal of Healthcare Leadership*, 2(April), 56–57. <https://doi.org/https://doi.org/10.2147/JHL.S362614>
- Odeh, N., Toma, A., Mohammed, F., & Dama, Y. (2021). An Efficient System for Automatic Blood Type Determination Based on Image Matching Techniques.

- Journal MDPI*, 2(7), 1–26.
<https://doi.org/https://doi.org/10.3390/app11115225>
- Rafid, A. K. M. R. H., Azam, S., Montaha, S., Karim, A., Fahim, K. U., & Hasan, Z. (2022). An Effective Ensemble Machine Learning Approach to Classify Breast Cancer Based on Feature Selection and Lesion Segmentation Using Preprocessed Mammograms. *Jornal MDPI*, 11(1), 2–26.
<https://doi.org/https://doi.org/10.3390/biology11111654>
- Rosales, M. A., & Luna, R. G. De. (2022). Computer-Based Blood Type Identification Using Image Processing and Machine Learning Algorithm. *Fuji Technology Press Ltd*, 26(5), 698–700.
<https://doi.org/10.20965/jaciii.2022.p0698>
- Saidani, O., Umer, M., Alturki, N., Alshardan, A., Kiran, M., Alsubai, S., Kim, T. H., & Ashraf, I. (2024). White blood cells classification using multi - fold pre - processing and optimized CNN model. *Scientific Reports*, 1–14.
<https://doi.org/10.1038/s41598-024-52880-0>
- Shaban, S. A., & Elsheweikh, D. L. (2022). Blood Group Classification System Based on Image Processing Techniques. *Journal Tech Science Press*, 31(2), 818–820.
<https://doi.org/10.32604/iasc.2022.019500>
- Xu, Y., Quan, R., Xu, W., Huang, Y., Chen, X., & Liu, F. (2024). Advances in Medical Image Segmentation: A Comprehensive Review of Traditional, Deep Learning and Hybrid Approaches. *Journal Bioengineering*, 11(1), 2–42.
<https://doi.org/https://doi.org/10.3390/bioengineering11101034>