



Analisa Citra Warna Darah *Reject* Berdasarkan Fitur Histogram Menggunakan KNN

Achhmad Agam¹, Supatman²

¹Department of Informatics, Universitas Mercu Buana Yogyakarta, Indonesia

²Department of Informatics, Universitas Mercu Buana Yogyakarta, Indonesia

Email author: 191110132@student.mercubuana-yogya.ac.id, supatman.fti@gmail.com

Article Info

Article history:

Received September 3, 2025

Revised Desember 3, 2025

Accepted Desember 16, 2025

Keywords:

Platelete Concentrate (TC)

K-Nearest Neighbor (KNN)

Histogram Features

SMOTE

Quality Classification

ABSTRACT

Manual quality assessment of Platelet Concentrate (TC) is highly subjective and inconsistent, necessitating an objective, automated classification system. This study aims to develop a computationally efficient, low-cost model for TC quality classification using Histogram Features extracted from grayscale images combined with the K-Nearest Neighbor (KNN) algorithm. The methodology employed critical preprocessing steps, including StandardScaler for normalization and SMOTE for balancing the training data, followed by optimization across $K=1$ to $K=30$. The optimal model achieved a maximum accuracy of 69.23% at $K=6$, with an F1-Score of 71.43%, confirming robust performance on the imbalanced testing set. The results validate the effectiveness of the Histogram-KNN approach as a consistent and reliable decision support system for rapid TC quality screening in resource-limited settings.

Corresponding Author:

Achhmad Agam

Universitas Mercu Buana Yogyakarta

Jl. Wates Km. 10, Yogyakarta

Email: 191110132@student.mercubuana-yogya.ac.id



1. Pendahuluan

Darah merupakan komponen biologis vital yang mendukung fungsi esensial dari tubuh, mencakup pengiriman oksigen, mediasi respons imun terhadap patogen, dan inisiasi proses pembekuan. Substansi kompleks ini tersusun atas plasma cair yang membawa berbagai unsur padat, termasuk sel darah merah, sel darah putih, dan keping darah (trombosit). Peran utama trombosit adalah menghentikan perdarahan, dengan pembentukan selnya (hematopoiesis) terjadi di sumsum tulang. Meskipun krusial, ketersediaan darah global menghadapi defisit serius; statistik menunjukkan tingginya permintaan transfusi, dengan sekitar satu dari tujuh pasien rawat inap memerlukan suplai. Situasi ini diperparah oleh ketergantungan sebagian besar negara pada donor keluarga atau berbayar. Di Indonesia, kebutuhan tahunan mencapai sekitar 5,1 juta kantong. Namun, pasokan nasional baru dapat mencukupi 4,6 juta kantong dari donasi yang ada, menyisakan kekurangan sekitar setengah juta unit. [1]

Pengawasan mutu TC merupakan langkah krusial dalam menjamin keamanan produk. Sesuai Peraturan Menteri Kesehatan RI, TC harus memenuhi standar ketat, termasuk mempertahankan nilai keasaman (pH) di atas 6,4 dan memiliki jumlah trombosit minimum. Pentingnya stabilitas pH ini terletak pada

hubungannya dengan proses metabolisme, di mana penurunan pH menandakan produksi asam laktat yang berlebihan oleh trombosit. Selain parameter kuantitatif, kualitas TC juga dinilai melalui pemeriksaan visual, yaitu pengamatan *swirling* dan tingkat kekeruhan. Penilaian kekeruhan ini seringkali melibatkan observasi perubahan warna kantong darah sebagai indikator adanya kontaminasi atau kerusakan. Namun, pengendalian pada inspeksi visual dan manual ini seringkali menjadi titik kerentanan utama. Penilaian yang didasarkan pada persepsi mata manusia rentan terhadap inkonsistensi antar-petugas, kelelahan, dan subjektivitas, terutama dalam menentukan gradasi warna yang menunjukkan status '*reject*' (ditolak).[2]

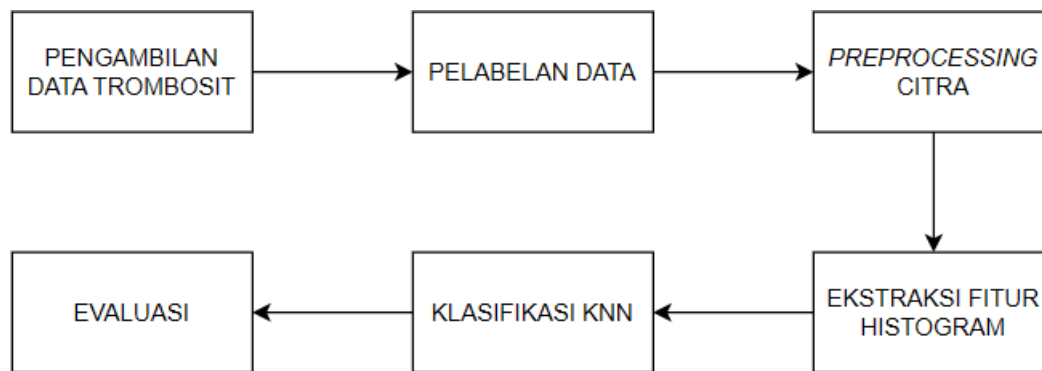
Untuk mengatasi risiko inkonsistensi dan subjektivitas yang melekat pada pemeriksaan visual manual—terutama saat menilai perubahan warna sebagai indikator darah *reject*—penerapan solusi objektif berbasis teknologi menjadi sebuah keharusan. Analisis manual yang memakan waktu dan rentan terhadap variabilitas antar-penilai telah lama menjadi penghambat (*bottleneck*) utama dalam alur kerja Unit Transfusi Darah. Pengenalan pendekatan Kecerdasan Buatan (AI), khususnya Pembelajaran Mesin (*Machine Learning*), menawarkan potensi untuk mengotomatisasi klasifikasi kualitas dan memanfaatkan analisis berdaya-hasil tinggi (*high-throughput*) melalui Pengolahan Citra Digital. Namun, sebagian besar solusi AI mutakhir (seperti *Convolutional Neural Networks/CNN*) menuntut data pelatihan dalam jumlah besar dan memiliki kompleksitas komputasi yang tinggi. Oleh karena itu, penelitian ini hadir untuk mengisi kesenjangan tersebut dengan mengembangkan dan menguji model yang efisien secara komputasi dan praktis untuk Analisa Citra Intensitas Darah *Reject*, sekaligus menguji kelayakan solusi low-cost untuk fasilitas kesehatan dengan sumber daya yang terbatas.[3]

Pemilihan metodologi dalam penelitian ini didasarkan pada efisiensi komputasi dan kesederhanaan implementasi. Algoritma *K-Nearest Neighbor* (KNN) sering digunakan dan populer dalam bidang pengolahan citra dan *machine learning* berkat implementasinya yang sederhana dan kinerja yang efektif. Ide utama KNN adalah menyamakan setiap data baru dengan data dalam set pelatihan melalui perhitungan jarak dalam konteks pengenalan intensitas piksel, metrik *Euclidean distance* umum digunakan untuk mengukur jarak antara atribut fitur statistik. Dalam studi ini, metode ekstraksi fitur histogram intensitas digunakan bersamaan dengan algoritma KNN. Aplikasi ini pertama-tama mengekstraksi histogram dari citra yang dianalisis, dan kemudian klasifikasi dilakukan menggunakan KNN. Perlu diperhatikan, kualitas piksel citra sangat krusial bagi ekstraksi histogram dan klasifikasi yang sukses, karena nilai piksel yang lebih tinggi akan meningkatkan tingkat keberhasilan aplikasi.[4]

Berdasarkan latar belakang masalah, urgensi menjaga kualitas Trombosit Konsentrat (TC), serta adanya kesenjangan dalam pengembangan solusi AI yang efisien, tujuan utama dari studi ini adalah untuk melakukan Analisa Citra Warna Darah *Reject* Berdasarkan Fitur Histogram Menggunakan Algoritma *K-Nearest Neighbor* (KNN). Kontribusi spesifik yang ditawarkan penelitian ini adalah: (1) Mengembangkan dan menguji metodologi Fitur Histogram dan KNN sebagai alternatif berbiaya rendah (*low-cost*) dan efisien secara komputasi terhadap metode kompleks; dan (2) Menyediakan sistem pendukung keputusan yang akurat dan konsisten untuk klasifikasi TC layak dan TC *reject*, yang dapat diimplementasikan menggunakan perangkat umum (seperti kamera *smartphone*) di fasilitas kesehatan dengan sumber daya yang terbatas.

2. Metode Penelitian

Proses analisis dan klasifikasi kualitas Trombosit Konsentrat (TC) dalam penelitian ini dilakukan menggunakan pendekatan komputasi metode *K-Nearest Neighbor* (KNN). Penelitian ini menerapkan serangkaian tahapan dalam pengolahan citra dan machine learning seperti yang ditunjukkan pada gambar 1, untuk mencapai klasifikasi yang objektif.



Gambar 1. Diagram Tahapan KNN

2.1 Pengumpulan Data

Penelitian ini menggunakan citra visual dari Thrombocyte Concentrate (TC) yang telah diproses. Pengumpulan data dilakukan menggunakan kamera bawaan dari perangkat smartphone. Menurut Hunt, Ruiz, dan Pogue, sistem pencitraan berbasis smartphone semakin banyak digunakan dalam aplikasi medis karena perangkat ini memiliki kemampuan pencitraan dan komputasi yang cukup kuat, sekaligus bersifat portabel dan berbiaya rendah.[5] Total data yang dikumpulkan adalah 30 citra TC. Seluruh citra dianonimkan dan diambil dalam kondisi serta jarak pengambilan yang distandarisasi untuk meminimalkan bias eksternal.

2.2 Pelabelan Data

Tahap ini menjelaskan prosedur penentuan Kebenaran Dasar (Ground Truth), suatu langkah fundamental dalam pelatihan model Supervised Learning. Setiap citra Trombosit Konsentrat (TC) diklasifikasikan menjadi dua kelas utama yang diwakili secara numerik: 1 untuk Layak (Kelas Positif) dan 2 untuk Reject (Kelas Negatif).

Pelabelan data ini berdasar pada standar kualitas komponen darah yang diatur dalam Peraturan Menteri Kesehatan Republik Indonesia Nomor 91 Tahun 2015 tentang Standar Pelayanan Darah[6]. Standar baku ini menetapkan persyaratan kuantitatif seperti batasan minimal nilai pH dan suhu penyimpanan TC (20° sampai 24 °). Kriteria kuantitatif tersebut selanjutnya diterjemahkan ke dalam penilaian visual. Perubahan warna pada Trombosit Konsentrat merupakan indikator visual yang andal (reliable indicator) terhadap kegagalan kualitas (pH di bawah batas aman)[7].

Kelas Layak (Kode 1): Citra dikodekan 1 jika menunjukkan kondisi visual yang baik, yaitu tidak adanya kekeruhan dan memiliki warna yang kuning jernih sesuai standar. Adanya fenomena swirling yang tampak pada komponen darah merupakan indikasi integritas dan kualitas yang masih baik[7].

Kelas Reject (Kode 2): Citra dikodekan 2 jika menunjukkan perubahan warna signifikan dan kekeruhan yang mengindikasikan kerusakan trombosit (hemolysis) atau kontaminasi. Kriteria ini didukung oleh studi yang memvalidasi bahwa kekeruhan yang ekstrem dan tidak berubah saat kantong digoyangkan berkorelasi dengan kegagalan kualitas[7].

Dari total 41 citra yang dikumpulkan, komposisi data adalah 19 citra TC layak dan 22 TC reject. Penggunaan data yang seimbang (*balanced dataset*) ini bertujuan untuk meminimalkan bias klasifikasi dalam pelatihan model KNN.

2.3 Preprocessing Data

Tahapan ini fundamental untuk meningkatkan efisiensi dan menghilangkan noise pada citra [8]. Meskipun studi berfokus pada Warna, pra-pemrosesan dioptimalkan ke domain Intensitas karena analisis Histogram *Grayscale* telah terbukti menjadi metode kuantifikasi yang terstandarisasi untuk citra klinis [9].

Langkah standarisasi mencakup konversi citra RGB menjadi Grayscale (satu kanal intensitas) [10], yang merupakan praktik efisien untuk kuantifikasi intensitas.

Selanjutnya, analisis citra dibatasi pada Area Kepentingan (ROI), yaitu area cairan trombosit saja (cropping). Pemilihan ROI yang cermat, mengecualikan area noise atau non-esensial, adalah prosedur klinis wajib untuk menjamin validitas pengukuran [9].

2.4 Ekstraksi Histogram

Sub-bab ini mengubah citra Grayscale yang telah diproses menjadi vektor fitur numerik. Prosesnya berbasis pada Histogram Analisis dari ROI [10]. Metodologi analisis statistik ini telah divalidasi dalam analisis citra medis untuk menghitung distribusi frekuensi voxel dan parameter statistik [9].

Dua belas (12) atribut statistik Grayscale dihitung untuk merepresentasikan karakteristik visual TC. Penggunaan fitur ini mereplikasi pendekatan analisis histogram pada citra medis [9].

Kekeruhan (Mean): Nilai Mean Grayscale (rata-rata intensitas) digunakan untuk kuantifikasi langsung tingkat kekeruhan/kecerahan cairan TC [9]. Swirling (Homogenitas): Diukur oleh fitur dispersi dan bentuk distribusi, termasuk Standard Deviation, Skewness, dan Kurtosis [9]. Vektor fitur ini menjadi input untuk klasifikasi K-Nearest Neighbor (KNN).

2.5 Klasifikasi KNN

K-Nearest Neighbor (KNN) merupakan algoritma pembelajaran terawasi yang mengklasifikasikan sampel berdasarkan mayoritas kelas dari K tetangga terdekat menggunakan Euclidean Distance [11]:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

Proses klasifikasi pada penelitian ini dimulai dengan pembagian data terstratifikasi (70% pelatihan, 30% pengujian) untuk menjaga proporsi kelas tetap seimbang pada kedua subset [15]. Seluruh fitur kemudian distandarisasi menggunakan StandardScaler guna menghindari dominasi fitur berskala besar, karena KNN sensitif terhadap perbedaan skala [12]. Ketidakseimbangan kelas pada data pelatihan diperbaiki menggunakan SMOTE agar distribusi kelas seimbang [13].

Selanjutnya dilakukan optimasi K dengan menguji nilai K dari 1 hingga 30 mengikuti prosedur pencarian nilai K terbaik pada KNN [12]. Kinerja model diukur menggunakan accuracy, precision, recall, dan confusion matrix untuk mengevaluasi hasil prediksi pada data uji [14].

2.6 Evaluasi

Evaluasi digunakan untuk melihat penyajian kinerja model tatanan yang digunakan. Strategi penilaian yang digunakan adalah Matriks Kebingungan (Confusion Matrix) [8]. Pengujian model bertujuan untuk menilai kemampuan generalisasi model pada data yang belum pernah dianalisis [12]. Mengingat data yang berantakan (imbalanced), pengujian model diselesaikan dengan memastikan ketepatan, akurasi, tinjauan (Recall), dan selanjutnya nilai F-Measure [17].

Perhitungan untuk metode Confusion Matrix yaitu nilai skor Accuracy, Precision, Recall, dan F-Measure [20]:

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN}$$

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$\text{F-Measure} = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}}$$

3. Hasil dan Analisis

Penelitian ini terdiri atas beberapa tahapan, yaitu pengumpulan data, pelabelan data, preprocessing citra, ekstraksi fitur histogram, klasifikasi menggunakan algoritma K-Nearest Neighbor (KNN), serta evaluasi performa. Seluruh tahapan ini bertujuan untuk membangun model klasifikasi yang mampu membedakan TC Layak (OK) dan TC Tidak Layak (Reject) secara objektif berdasarkan distribusi intensitas citra.

3.1 Pengumpulan Data

Dataset terdiri dari 42 citra Thrombocyte Concentrate (TC), yaitu 19 citra TC-OK seperti dan 22 citra TC-Reject. Seluruh citra diperoleh dari salah satu Unit Transfusi Darah di Provinsi Yogyakarta menggunakan smartphone redmi note 7. Penggunaan kamera dipilih karena beberapa studi menunjukkan bahwa perangkat ini mampu menghasilkan citra stabil untuk analisis medis berbasis pengolahan citra, sekaligus memberikan keuntungan berupa biaya rendah dan fleksibilitas rendah.

Setiap citra diambil dalam kondisi relatif seragam, terutama dalam hal jarak, pemrosesan, orientasi, dan pencahayaan untuk dilanjutkan ke tahap selanjutnya. Sebelum dilakukan analisis, seluruh citra dianonimkan dan diberi identitas nama file untuk kemudahan dan kerahasiaan dalam pengolahan data. Gambar

2 menunjukkan dataset mentah, sedangkan Gambar 3 menunjukkan proses cropping yang mana menjamin standar dari dataset yang akan diinput.



Gambar 2. TC sebelum proses



Gambar 3. TC setelah proses

3.2 Pelabelan Data

Pelabelan dilakukan secara manual berdasarkan dua parameter visual, yaitu swirling dan kekeruhan, sesuai indikator mutu penyimpanan trombosit konsentrat yang dijelaskan pada studi tahun 2024 [2]. Dalam penelitian tersebut dinyatakan bahwa hilangnya swirl dan meningkatnya kekeruhan merupakan tanda degradasi kualitas penyimpanan.

Hal ini selaras dengan penelitian lokal di Indonesia yang menegaskan bahwa perubahan pH, swirl, dan kekeruhan menjadi dasar penentuan kelayakan TC selama masa simpan [5].

Oleh sebab itu:

- 1) TC-OK diberi label = 1
- 2) TC-*Reject* diberi label = 2

Pelabelan ini digunakan sebagai label target dalam model KNN.

3.3 Preprocessing Citra

Preprocessing dilakukan untuk menyeragamkan citra sebelum diekstraksi fiturnya. Langkah – langkah yang diterapkan:

- 1) Center Cropping

Center Cropping dilakukan untuk menghilangkan latar belakang yang tidak relevan dan menyesuaikan fokus hanya pada area kantong TC. Metode ini memastikan citra memiliki komposisi yang seragam.

- 2) *Resize*

Seluruh citra diseragamkan ukurannya agar menghasilkan histogram intensitas yang dapat dibandingkan antar-citra.

- 3) Konversi ke grayscale

Dalam hal ini peneliti menggunakan fitur berbasis histogram intensitas, seluruh citra dikonversi dari RGB ke grayscale. Histogram grayscale lebih konsisten karena fokus pada distribusi kecerahan dan kekeruhan, bukan warna.

Tahap preprocessing ini menghasilkan kumpulan citra yang sudah siap untuk ekstraksi fitur.

3.4 Eksraksi Fitur Histogram

Ekstraksi fitur dilakukan pada distribusi intensitas grayscale (0-255). Setiap citra menghasilkan 11 fitur statistik, yaitu: Mean, Variance, Standard Deviation, Skewness, Kurtosis, Entropy, Energy, Contrast, Homogeneity, Smoothness, Max Probability.

Tendekatan ini didukung oleh studi Zhu et al., tentang radiomics tahun 2021 yang menyatakan bahwa fitur statistik intensitas efektif untuk klasifikasi biomedis. Serta penelitian Solihin et al., tahun 2023 yang menunjukkan efektivitas histogram grayscale dalam analisis citra medis.

Tabel 1. Nilai intensitas citra


File_name	Mean	Variance	Stddev	Skewness	Kurtosis	Entropy	Energy	Contrast	Homogeneity	Smoothness	Max_probability
IMG_20250509_I53930_1.jpg	165,53	326,17	18,06	1,42	0,44	4,23	0,02	326,17	0,11	1,00	0,02
IMG_20250509_I54013_1.jpg	176,78	300,19	17,33	1,75	1,89	4,21	0,02	300,19	0,12	1,00	0,03
IMG_20250502-0011_1.jpg	145,22	167,40	12,94	3,04	8,26	3,75	0,03	167,40	0,18	0,99	0,05
IMG_20250503-WA0015_1.jpg	122,31	369,12	19,21	2,54	6,07	4,20	0,02	369,12	0,12	1,00	0,04

Tabel 1 menunjukkan nilai intensitas citra TC-OK cenderung lebih tinggi dan lebih homogen dibanding citra TC-Reject, yang sesuai dengan fenomena swirl yang masih terbentuk TC-OK.


3.5 Klasifikasi KNN

Tahap klasifikasi dilakukan menggunakan algoritma K-Nearest Neighbor (KNN). Karena KNN sensitif terhadap skala fitur, maka seluruh fitur dinormalisasi menggunakan StandarScaler, sesuai dengan penelitian yang dilakukan oleh Siregar et al., tahun 2023 yang menyatakan bahwa scaling meningkatkan akurasi KNN secara signifikan.

Data yang tidak seimbang (19:22) diseimbangkan menggunakan SMOTE, mengikuti rekomendasi penelitian feature-based biomedical classification tahun 2024. Pembagian data dilakukan dengan komposisi 70% untuk training dan 30% untuk testing, menggunakan stratified split agar proporsi label tetap konsisten. Dataset kecil rentan akan bias sehingga diperlukan Stratified Split.



Grafik 1. Distribusi Kelas Sebelum SMOTE



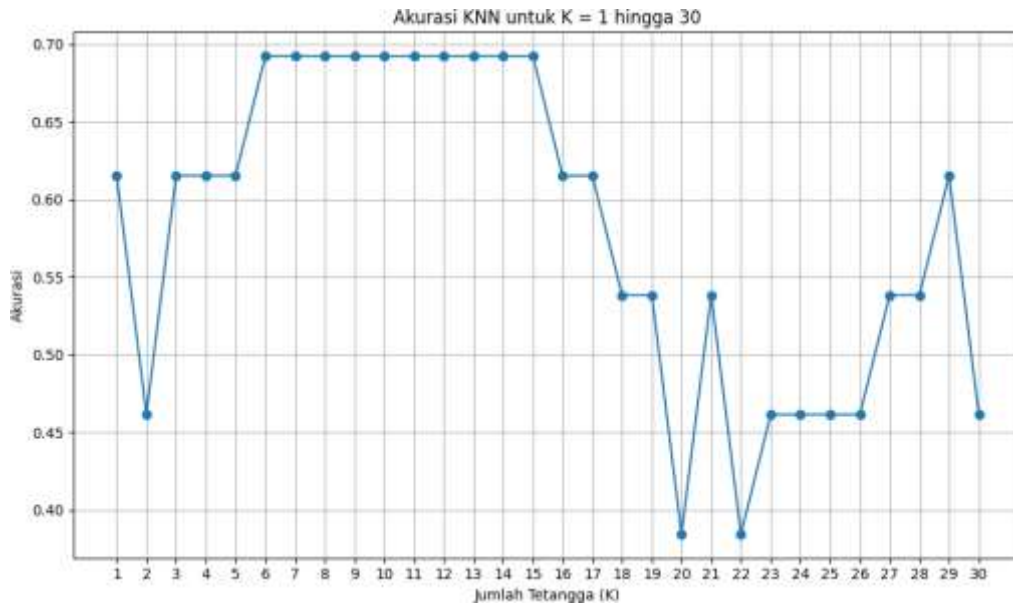
Grafik 2. Distribusi Kelas Setelah SMOTE

1) Optimasi K

K diuji dari K = 1 hingga K = 30. Pemilihan rentang ini sesuai dengan praktik umum dalam pemodelan KNN yang sesuai dengan keterbatasan data yang diperoleh oleh peneliti. Nilai K terbaik adalah yang menghasilkan akurasi tertinggi. Optimasi K dilakukan dengan menguji nilai K dari K = 1 hingga K = 30. Pemilihan rentang ini sesuai dengan praktik umum dalam pemodelan KNN pada dataset kecil. Model terbaik adalah metode yang dapat menghasilkan akurasi tertinggi.

2) Hasil Uji Akurasi KNN

Dari seluruh iterasi yang dijalankan, hasil yang diperoleh adalah nilai K paling optimal adalah K = 6 dengan akurasi 69.23%, sebagaimana yang ditunjukkan pada grafik 3.

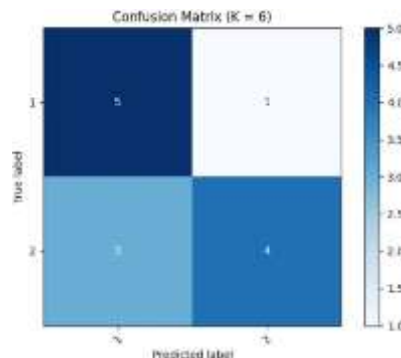


Grafik 3. Hasil Uji Nilai K

3.6 Hasil Evaluasi

Evaluasi dilakukan untuk menilai performa metode K-Nearest Neighbor (KNN) dalam mengklasifikasikan citra trombosit menjadi OK (1) dan Reject (2) menggunakan tiga fitur utama berbasis intensitas histogram: mean, variance, dan standard deviation. Pembagian data menggunakan train-test split 70:30, sementara penentuan parameter terbaik dilakukan melalui pengujian nilai K = 1 hingga K = 30.

Hasil pengujian menunjukkan bahwa nilai terbaik dicapai pada K = 6, dengan akurasi tertinggi sebesar 69,23% dan stabil pada kisaran K menengah. Grafik performa tiap K menjadi dasar pemilihan nilai optimal:



Gambar 4. Hasil Evaluasi K

Selanjutnya dilakukan pengukuran kualitas prediksi menggunakan confusion matrix berikut (K=6):

Tabel 2. Hasil Evaluasi Nilai K

	Prediksi OK	Prediksi Reject
Aktual OK	5 (TP)	1 (FN)
Aktual Reject	3 (FP)	4 (TN)

Dari matriks tersebut diperoleh metrik evaluasi:

○ Accuracy

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} = \frac{5 + 4}{13} = 0,6923 = 69,23\%$$

o **Precision** untuk masing-masing kelas

$$Precision_{OK} = \frac{TP}{TP + FP} = \frac{5}{5 + 3} = 0,625$$

$$Precision_{Reject} = \frac{TN}{TN + FN} = \frac{4}{4 + 1} = 0,800$$

o **Recall / Sensitivity**

$$Recall_{OK} = \frac{TP}{TP + FN} = \frac{5}{6} = 0,8333$$

$$Recall_{Reject} = \frac{TN}{TN + FP} = \frac{4}{7} = 0,5714$$

o **F1-Score (rata-rata harmonik Precision & Recall)**

$$F1_{OK} = 2 \cdot \frac{(0,625 \cdot 0,8333)}{(0,625 + 0,8333)} = 0,714$$

$$F1_{Rejek} = 2 \cdot \frac{(0,800 \cdot 0,5714)}{(0,800 + 0,5714)} = 0,666$$

4. Kesimpulan

Penelitian ini berhasil mencapai tujuan utamanya, yaitu mengembangkan dan menguji metodologi klasifikasi kualitas Trombosit Konsentrat (TC) Layak dan Reject secara objektif, berlandaskan fitur histogram intensitas citra dan algoritma K-Nearest Neighbor (KNN). Metodologi yang diusulkan telah terbukti menjadi solusi berbiaya rendah dan efisien secara komputasi, menjadikannya alternatif yang layak terhadap sistem Kecerdasan Buatan (AI) yang menuntut sumber daya tinggi. Proses pra-pemrosesan yang ketat, meliputi Standardisasi fitur dan penanganan ketidakseimbangan data menggunakan SMOTE, berhasil mengoptimalkan kinerja model. Setelah pengujian iteratif, model menunjukkan kinerja puncak pada nilai K=6, menghasilkan akurasi tertinggi sebesar 69,23% pada testing set. Analisis lebih lanjut menggunakan Matriks Kebingungan mengonfirmasi kualitas dan keandalan sistem; di mana metrik F-Measure yang diperoleh sebesar 71,43% menunjukkan adanya keseimbangan yang kuat antara kemampuan model untuk mengidentifikasi kasus TC Layak (Recall 83,33%) dan keakuratan prediksi positifnya (Precision 62,50%). Secara keseluruhan, penelitian ini memvalidasi efektivitas pendekatan Fitur Histogram intensitas dan algoritma KNN sebagai sistem pendukung keputusan yang konsisten dan akurat untuk penilaian mutu komponen darah.

References

- [1] S. P. Collins *et al.*, “PERBANDINGAN JUMLAH TROMBOSIT PADATHROMBOCYTE CONCENTRATE(TC) YANG SEGERADAN DITUNDA DI HARI KETIGA,” vol. 12, pp. 167–186, 2021.
- [2] I. Print *et al.*, “Jurnal Kesehatan Rajawali Evaluasi Kualitas Thrombocyte Concentrate (TC) berdasarkan Kadar pH , Level,” vol. XIII, pp. 1–4, 2023.
- [3] C. Kempster *et al.*, “Fully automated platelet differential interference contrast image analysis via deep learning,” *Sci. Rep.*, pp. 1–13, 2022, doi: 10.1038/s41598-022-08613-2.
- [4] K. N. Classifier, “Color Recognition Using Color Histogram Feature Extraction and,” 2020.
- [5] B. Hunt, A. J. Ruiz, and B. W. Pogue, “Smartphone-based imaging systems for medical applications : a critical review,” vol. 26, no. April, pp. 1–22, 2021, doi: 10.1117/1.JBO.26.4.040902.
- [6] D. Platelet *et al.*, “Perbandingan Kualitas Trombocyte Concentrate Dari Platelet Rich Plasma Quality Comparison of Platelet Concentrate Prepared by Platelet Rich Plasma and Platelet Apheresis on Platelet Counts and Leukocyte Residues,” vol. 10, pp. 22–28, 2021.
- [7] K. Concentrate, S. Masa, and S. Lima, “Bria, TCH: Kualitas Concentrate,” vol. 7, no. 2, 2024, doi: 10.35990/mk.v7n2.p112-123.
- [8] F. Solihin, M. Syarief, E. Mala, and S. Rochman, “Elinvo (Electronics , Informatics , and Vocational Education) Comparison of Support Vector Machine (SVM), *K-Nearest Neighbor* (K-NN), and Stochastic Gradient Descent (SGD) for Classifying Corn Leaf Disease based on Histogram of Oriented Gradients (HOG) Feature Extraction,” vol. 8, no. 1, pp. 121–129, 2023.
- [9] M. Ali and K. Mohammed, “An intelligent and fast system for detection of grape diseases in RGB , grayscale , YCbCr , HSV and L * a * b * color spaces,” pp. 50381–50399, 2024.
- [10] Q. Zhu, J. Zou, J. Ye, W. Zhu, J. Wu, and W. Chen, “Comparative study of conventional ROI- - based and volumetric histogram analysis derived from CT enhancement in differentiating malignant and benign renal tumors,” no. February, pp. 1–8, 2022.
- [11] K. W. Chandra and H. Irsyad, “Efektifitas SMOTE dalam Mengatasi Imbalanced Class Algoritma K-Nearest Neighbors pada Analisis Sentimen terhadap Starlink,” vol. 4, no. 1, pp. 31–42, 2024.
- [12] M. R. Siregar, D. Hartama, I. Engineering, S. Program, I. Systems, and S. Program, “OPTIMIZING THE KNN ALGORITHM FOR CLASSIFYING CHRONIC,” vol. 10, no. 3, pp. 680–689, 2025, doi: 10.33480/jitk.v10i3.6214.menjadi.
- [13] S. Bishnoi, N. Al-ansari, M. Khan, and S. Heddham, “Classification of Cotton Genotypes with Mixed Continuous and Categorical Variables : Application of Machine Learning Models,” pp. 1–17, 2022.
- [14] F. A. Kusuma, B. Prasetyo, J. I. Komputer, and U. Negeri, “PEMODELAN KLASIFIKASI ANEMIA APLASTIK MENGGUNAKAN TEKNIK OVERSAMPLING DAN K-,” vol. 12, no. 3, 2024.
- [15] M. Sivakumar and S. Parthasarathy, “Trade-off between training and testing ratio in machine learning for medical image processing,” pp. 1–17, 2024, doi: 10.7717/peerj-cs.2245.