

Klasifikasi Sel Darah Putih Berdasarkan Ciri Warna dan Bentuk Menggunakan Metode *K-Nearest Neighbor* (K-NN)

Saga Darmawan^{1*}, Retno Wardhani², Moh. Rosidi Zamroni³

^{1,2,3} Teknik Informatika/Universitas Islam Lamongan

¹Email: sagadarmawann@gmail.com

²Email: retzno.teknik@unisla.ac.id

³Email: rosidizamroni@unisla.ac.id

*) Corresponding Author

ABSTRACT

*Leukocytes, or white blood cells, are essential components of the human immune system that function to fight infections and maintain overall health. Each type of leukocyte has distinct morphological characteristics and specific roles, such as neutrophils, lymphocytes, monocytes, and eosinophils. Automatic classification of leukocyte types from microscopic images plays an important role in supporting medical diagnosis quickly and accurately. This study employed the *k*-Nearest Neighbor (KNN) algorithm as a classification method to identify leukocyte types based on features extracted from images. The KNN algorithm operates by calculating the Euclidean distance between test and training data to determine the class of new data based on its nearest neighbors. The dataset used in this study was obtained from a publicly available collection on the Kaggle platform, consisting of 12,392 images across four leukocyte types: eosinophil, lymphocyte, monocyte, and neutrophil. Experimental results demonstrated that with $K = 3$, the KNN model achieved its best performance, obtaining an accuracy of 71.72%, along with average precision, recall, and F1-score values of 0.70.*

Keywords: Classification, *K-Nearest Neighbor*, Machine learning.

ABSTRAK

*Leukosit atau sel darah putih merupakan komponen penting dalam sistem kekebalan tubuh manusia yang berfungsi melawan infeksi dan menjaga kesehatan tubuh. Setiap jenis leukosit memiliki karakteristik morfologis dan fungsi yang berbeda, seperti neutrophil, lymphocyte, monocyte, dan eosinophil. Klasifikasi otomatis jenis leukosit dari citra mikroskopis berperan penting dalam membantu proses diagnosis medis secara cepat dan akurat. Penelitian ini menggunakan algoritma *k*-Nearest Neighbor (KNN) sebagai metode klasifikasi untuk mengenali jenis sel darah putih berdasarkan fitur yang diekstraksi dari citra. Algoritma KNN bekerja dengan menghitung jarak Euclidean antara data uji dan data latih untuk menentukan kelas data baru berdasarkan tetangga terdekat. Dataset yang digunakan merupakan koleksi citra publik dari platform Kaggle, terdiri dari 12.392 gambar dengan empat jenis leukosit, yaitu eosinophil, lymphocyte, monocyte, dan neutrophil. Hasil pengujian menunjukkan bahwa pada nilai $K = 3$, model KNN menghasilkan performa terbaik dengan akurasi sebesar 71,72%, serta rata-rata precision, recall, dan F1-score masing-masing sebesar 0,70.*

Keywords: Klasifikasi, *K-Nearest Neighbor*, Machine learning.

A. PENDAHULUAN

Sel darah putih atau leukosit merupakan salah satu komponen darah yang berperan penting dalam sistem kekebalan tubuh. Leukosit melindungi tubuh dari infeksi, melawan patogen seperti bakteri, virus, dan parasit, serta mendeteksi dan menghancurkan sel abnormal yang berpotensi membahayakan tubuh [1]. Setiap jenis leukosit memiliki fungsi spesifik, baik dalam respon imun

bawaan maupun adaptif. Ketidakseimbangan jumlah atau fungsi leukosit, seperti leukopenia maupun leukositosis, sering kali menjadi indikator adanya gangguan kesehatan, mulai dari infeksi berat, kelainan autoimun, hingga leukemia[2]. Oleh karena itu, identifikasi jenis leukosit menjadi aspek penting dalam diagnosis medis.

Secara morfologis, leukosit dapat dibedakan melalui pengamatan mikroskopis terhadap bentuk inti, ukuran sel, warna sitoplasma, serta keberadaan granula setelah pewarnaan Wright atau Giemsa [3]. Berdasarkan ciri tersebut, leukosit terbagi menjadi lima jenis utama, yaitu neutrophil, eosinophil, basophil, lymphocyte, dan monocyte [4]. Identifikasi manual menggunakan mikroskop memerlukan waktu, tenaga, dan berpotensi menghasilkan akurasi rendah [5] Hal ini mendorong pengembangan sistem klasifikasi otomatis berbasis pengolahan citra digital.

Sejumlah penelitian sebelumnya telah mengimplementasikan metode klasifikasi yang beragam, seperti Convolutional Neural Network (CNN), Support Vector Machine (SVM), K-means Clustering, serta metode berbasis fitur seperti SIFT, SURF, dan HOG. Meskipun CNN sering menghasilkan akurasi tinggi, metode tersebut memerlukan sumber daya komputasi yang besar. Sebaliknya, algoritma k-Nearest Neighbor (k-NN) menawarkan implementasi yang sederhana, kebutuhan komputasi rendah, serta performa yang kompetitif untuk dataset dengan karakteristik tertentu.

Penelitian ini dilakukan dengan memanfaatkan dataset leukosit publik dari Kaggle. Data citra melalui tahapan praproses meliputi normalisasi ukuran, segmentasi, dan ekstraksi fitur warna, bentuk, serta tekstur. Selanjutnya, fitur digunakan dalam proses klasifikasi dengan algoritma k-NN, dan hasilnya dievaluasi berdasarkan akurasi, precision, recall, dan F1-score.

Berdasarkan uraian diatas rumusan masalah pada penelitian ini Adalah:


- Bagaimana metode k-Nearest Neighbor (K-NN) dapat digunakan untuk mengklasifikasikan jenis sel darah putih berdasarkan ciri tekstur, bentuk dan warna?
- Sejauh mana akurasi metode K-NN dalam mengklasifikasikan sel darah putih dibandingkan dengan metode lain pada jurnal yang menggunakan dataset yang sama dengan penelitian ini?

Serta tujuan dari penelitian ini yaitu:

- Mengaplikasikan metode k-Nearest Neighbor (K-NN) untuk mengklasifikasikan jenis-jenis sel darah putih berdasarkan ciri warna dan bentuk yang diekstraksi dari citra mikroskopis.
- Menganalisis akurasi metode K-NN dalam mengklasifikasikan jenis sel darah putih dan membandingkannya dengan metode klasifikasi lainnya.

B. METODE

Tahapan penelitian yang dilakukan untuk membangun sistem klasifikasi sel darah putih. Metodologi disusun secara sistematis mulai dari pengumpulan dan pembagian dataset, pra-pemrosesan citra, segmentasi, ekstraksi fitur, hingga proses klasifikasi dan evaluasi kinerja model. Dengan alur ini, setiap langkah penelitian dapat dilakukan secara terstruktur sehingga hasil yang diperoleh lebih valid dan dapat dipertanggungjawabkan.



Gambar 1. Alur Penelitian

Secara umum, alur penelitian dapat digambarkan dalam bentuk diagram sebagaimana ditunjukkan pada Gambar 1. Diagram ini memberikan ilustrasi menyeluruh mengenai urutan proses, mulai dari tahap awal pengolahan data hingga tahap akhir evaluasi model. Dengan adanya bagan alur, metodologi penelitian menjadi lebih jelas, terarah, dan mudah dipahami.

1. Dataset

Penelitian ini menggunakan dataset sel darah putih yang diperoleh dari platform Kaggle, yang sebelumnya digunakan oleh [2]. Dataset terdiri atas 12.392 citra dari empat jenis leukosit, yaitu eosinophil, lymphocyte, monocyte, dan neutrophil. Data dibagi menjadi 9.912 citra untuk pelatihan dan 2.480 citra untuk pengujian.

2. Pra-Pemrosesan Citra

Tahap pra-pemrosesan dilakukan untuk menyeragamkan citra sebelum masuk ke proses analisis. Seluruh citra diubah ukurannya menjadi 256x256 piksel dan dikonversi ke grayscale. Standardisasi resolusi bertujuan untuk menyamakan ukuran input, sementara konversi ke grayscale difokuskan pada informasi morfologi dan tekstur inti sel yang relevan untuk ekstraksi fitur.

3. Segmentasi

Segmentasi dilakukan untuk memisahkan inti sel dari latar belakang. Metode *Otsu thresholding* digunakan untuk menentukan nilai ambang otomatis pada citra *grayscale*. Hasil biner selanjutnya diperbaiki dengan operasi morfologi untuk mengurangi noise dan menutup celah kecil. Kontur hasil segmentasi kemudian difilter berdasarkan luas area, dengan hanya mempertahankan objek berukuran signifikan sebagai inti sel valid.

4. Ekstraksi Fitur

Ekstraksi fitur dilakukan pada citra sel darah putih yang telah melalui proses segmentasi. Tujuan utama dari tahap ini adalah memperoleh representasi numerik yang menggambarkan karakteristik setiap citra berdasarkan parameter ciri tertentu. Fitur yang diekstraksi meliputi: fitur bentuk seperti *area*, *perimeter*, *aspect ratio*, *rectangularity*, dan *circularity*, fitur tekstur berupa *correlation* dan *Angular Second Moment (ASM)* yang dihitung menggunakan *Gray-Level Co-occurrence Matrix (GLCM)*, serta fitur warna berupa nilai rata-rata dan standar deviasi dari kanal RGB pada area inti sel. Dengan kombinasi fitur tersebut, citra sel dapat dianalisis secara lebih objektif dan akurat dalam proses klasifikasi.

5. Klasifikasi

Metode klasifikasi yang digunakan dalam penelitian ini adalah *k-Nearest Neighbor (KNN)*. Algoritma KNN bekerja dengan menghitung jarak antara data uji dan data latih dalam ruang fitur, kemudian menentukan kelas berdasarkan mayoritas tetangga terdekat sesuai dengan nilai parameter *k* [6]. Proses prediksi dilakukan dengan membandingkan label dari *k* data latih yang memiliki jarak paling dekat dengan data uji. Untuk menghitung jarak tersebut digunakan rumus Euclidean Distance, yang didefinisikan sebagai berikut:

$$d(a, b) = \sum_{i=0}^n (X_i - Y_i)^2$$

Keterangan :

d(a,b) : jarak Euclidean

x : data 1

y : data 2

i : fitur ke-
 n : jumlah fitur

Melalui perhitungan jarak ini, KNN dapat menentukan kedekatan antar data sehingga proses klasifikasi sel darah putih dapat dilakukan secara lebih akurat.

6. Evaluasi Model

Evaluasi kinerja model dilakukan dengan menguji berbagai nilai parameter k pada algoritma *k-Nearest Neighbor* (KNN). Proses evaluasi ini menggunakan beberapa metrik, yaitu akurasi, presisi, recall, F1-score, dan confusion matrix.

Accuracy merupakan ukuran persentase jumlah prediksi yang benar terhadap keseluruhan jumlah data uji [5] dihitung dengan rumus:

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

yang merepresentasikan persentase prediksi benar.

Precision dihitung dengan:

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

untuk mengukur tingkat ketepatan prediksi positif.

Recall merupakan mengukur tingkat ketepatan model dalam memberikan prediksi positif, yaitu seberapa banyak prediksi positif yang benar-benar sesuai dengan kelas sebenarnya [7] dihitung dengan:

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

yang menunjukkan kemampuan model dalam mendeteksi seluruh data positif.

F1-score diperoleh melalui rata-rata harmonis presisi dan recall [8] dengan rumus:

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

Sedangkan *Confusion Matrix* digunakan untuk menggambarkan distribusi prediksi benar (*True Positive* dan *True Negative*) maupun salah (*False Positive* dan *False Negative*) pada setiap kelas. Bentuk umum confusion matrix untuk klasifikasi multi-kelas dapat dipresentasikan pada Tabel 1.

Tabel 1. *Confusion Matrix*

Actual	Predicted	
	<i>Eosinophil</i>	<i>Non-Eosinophil</i>
<i>Eosinophil</i>	TP	TN
<i>Non-Eosinophil</i>	FP	FN

Penggunaan metrik-metrik tersebut memberikan gambaran menyeluruh mengenai performa sistem klasifikasi sel darah putih.

C. HASIL DAN PEMBAHASAN

1. HASIL

Implementasi penelitian ini dilakukan pada *Google Collaboratory*. Pustaka *Python* yang digunakan meliputi *OpenCV* dan *Scikit-Image* untuk pemrosesan citra, *Scikit-Learn* untuk *machine learning* dan *evaluasi*, serta *NumPy* dan *Pandas* untuk pengolahan data numerik dan tabular. Tahapan sistem dimulai dari pra-pemrosesan citra, meliputi standarisasi ukuran (256x256 piksel) dan konversi ke grayscale menggunakan coding yang bisa dilihat pada Gambar 2.

```
# PREPROCESSING (resize + grayscale)
def preprocess_image(img):
    img_resized = cv2.resize(img, (256, 256))
    gray = cv2.cvtColor(img_resized, cv2.COLOR_BGR2GRAY)
    return img_resized, gray
```

Gambar 2. Implementasi Preprocessing

Selanjutnya, dilakukan segmentasi inti sel menggunakan metode Otsu thresholding yang menghasilkan citra biner sebagai dasar isolasi objek analisis menggunakan coding yang bisa dilihat pada Gambar 3.

```
# SEGMENTASI (Otsu Threshold)
def segmentasi(gray):
    mask = cv2.threshold(gray, 0, 255, cv2.THRESH_BINARY+cv2.THRESH_OTSU)
    return mask
```

Gambar 3. Implementasi Segmentasi

Dari hasil segmentasi, fitur diekstraksi untuk merepresentasikan citra secara kuantitatif, mencakup fitur bentuk (*area*, *perimeter*, *aspect ratio*, *rectangularity*, *circularity*), tekstur (*correlation*, *Angular Second Moment/ASM* dari GLCM), serta warna (rata-rata dan standar deviasi kanal RGB).

filename	label	gicc_correlation	gicc_asm	area	perimeter	aspect_ratio	rectangularity	circularity	mean_r	mean_g	mean_b	std_r	std_g	std_b
0 _1_4669.jpeg	MONOCYTE	0.979623	0.003033	58792.0	983.396969	1.028112	0.922314	0.763960	187.343157	172.537064	187.598269	19.030445	31.363428	20.727128
1 _13_496.jpeg	MONOCYTE	0.974799	0.002785	58814.0	970.225396	0.949219	0.942226	0.782467	194.296572	182.116394	193.578328	17.443340	28.539977	18.994535
2 _10_8854.jpeg	MONOCYTE	0.984375	0.005325	55516.0	945.622364	0.945312	0.896113	0.780176	204.126631	193.002430	197.259147	19.274172	26.199037	22.412062
3 _14_5936.jpeg	MONOCYTE	0.990351	0.010922	55028.5	963.036578	0.968750	0.886754	0.745610	207.944696	194.878615	197.048168	19.799080	27.533102	23.563013
4 _0_8206.jpeg	MONOCYTE	0.980385	0.004005	59613.5	975.036578	1.000000	0.909630	0.787975	194.445410	182.417981	196.142650	18.769527	31.516402	19.870825

Gambar 4 Hasil Ekstraksi Fitur

Hasil ekstraksi fitur ditampilkan pada Gambar 4.6. Selanjutnya, dataset dibagi menjadi data latih (80%) dan data uji (20%) menggunakan fungsi `train_test_split` dengan stratifikasi agar distribusi kelas tetap seimbang. Proses pelatihan dilakukan menggunakan algoritma *k-Nearest Neighbor* (KNN), dengan eksperimen berbagai nilai parameter *k* dari 2 hingga 11, bisa dilihat pada Gambar 5.

```
# KLASIFIKASI KNN
k_values = [2, 3, 4, 5, 6, 7, 8, 9, 10, 11]
print("\nMengevaluasi model KNN untuk berbagai nilai k...")
for k in k_values:
    knn = KNeighborsClassifier(n_neighbors=k)
    knn.fit(X_train_scaled, y_train)
    y_pred = knn.predict(X_test_scaled)
```

Gambar 5 Klasifikasi K-NN

Evaluasi kinerja model menggunakan akurasi, presisi, recall, F1-score, serta confusion matrix untuk memberikan gambaran menyeluruh terhadap performa klasifikasi empat jenis sel darah putih. Hasil penelitian disajikan secara lengkap dan sesuai dengan ruang lingkup penelitian.

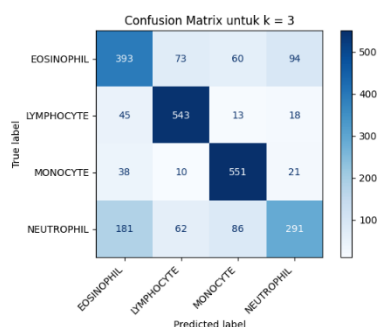
Hasil penelitian dapat dilengkapi dengan tabel, grafik (gambar), dan/atau bagan. Tabel dan gambar diberi nomor dan judul. Hasil analisis data diinterpretasikan dengan benar [2].

Dari hasil pengujian dengan variasi nilai K antara 1 hingga 11, diperoleh bahwa performa tertinggi dicapai pada nilai K = 3. Pengujian ini dilakukan untuk mengetahui sejauh mana parameter K memengaruhi kinerja algoritma K-Nearest Neighbors (KNN) dalam proses klasifikasi.

Tabel 2 Hasil performa dengan variasi nilai K

No.	Nilai K	Akurasi	Precision	Recall	F1-score
1	Nilai K = 2	68.33%	0.70	0.68	0.66
2	Nilai K = 3	71.72%	0.71	0.71	0.70
3	Nilai K = 4	69.71%	0.69	0.69	0.68
4	Nilai K = 5	69.71%	0.69	0.69	0.68
5	Nilai K = 6	68.74%	0.68	0.68	0.67
6	Nilai K = 7	68.94%	0.68	0.68	0.67
7	Nilai K = 8	67.89%	0.67	0.67	0.66
8	Nilai K = 9	67.49%	0.66	0.67	0.65
9	Nilai K = 10	67.08%	0.66	0.67	0.65
10	Nilai K = 11	66.76%	0.66	0.66	0.65

Tabel 2. Menunjukkan hasil evaluasi model untuk setiap nilai K menggunakan metrik akurasi, precision, recall, dan F1-score. Untuk memberikan gambaran yang lebih detail, Gambar 6. Memperlihatkan *Confusion Matrix* hasil klasifikasi KNN pada nilai K = 3.



Gambar 6. Confusion Matrix k = 3

Berdasarkan Tabel 3, model dengan K = 3 menunjukkan akurasi sebesar 71,72%. Secara lebih rinci, performa tiap kelas dapat dilihat pada laporan klasifikasi berikut:

Tabel 3 Klasifikasi K-NN Dengan Nilai K=3

Kelas	Precision	Recall	F1-score
Eosinophil	0.59	0.63	0.61
Lymphocyte	0.78	0.87	0.83
Monocyte	0.77	0.88	0.82
Neutrophil	0.68	0.46	0.55
Akurasi	71.72%		

Secara umum, kelas Lymphocyte dan Monocyte memiliki kinerja terbaik dengan nilai recall dan F1-score yang tinggi, sedangkan kelas Neutrophil menunjukkan hasil terendah terutama pada recall. Hasil ini memberikan gambaran menyeluruh mengenai efektivitas algoritma KNN pada klasifikasi sel darah putih, sekaligus menunjukkan bahwa pemilihan parameter K = 3 merupakan yang paling optimal dalam penelitian ini.

2. PEMBAHASAN

Hasil evaluasi menunjukkan bahwa nilai parameter K memiliki pengaruh signifikan terhadap performa algoritma KNN. Dari Tabel 4.1 terlihat tren bahwa akurasi meningkat pada K kecil (1–3), kemudian menurun seiring bertambahnya nilai K. Kondisi ini sesuai dengan teori KNN, di mana nilai K yang terlalu kecil rentan terhadap noise, sementara nilai K yang terlalu besar cenderung mengurangi sensitivitas model terhadap pola lokal pada data.

Pada $K = 3$, model berhasil mencapai akurasi tertinggi sebesar 71,72%. Dari laporan klasifikasi, kelas Lymphocyte dan Monocyte memiliki performa terbaik, masing-masing dengan F1-score 0.8309 dan 0.8286. Hal ini menunjukkan bahwa model mampu mengenali kedua jenis sel tersebut dengan baik. Sebaliknya, kelas Neutrophil memiliki performa terendah dengan recall 0.4694, menandakan banyak data Neutrophil yang salah diklasifikasikan sebagai kelas lain.

Perbedaan performa antar kelas ini kemungkinan disebabkan oleh kemiripan ciri visual antara Neutrophil dengan jenis sel lainnya, khususnya pada bentuk inti sel dan distribusi warna. Selain itu, distribusi data yang tidak seimbang juga dapat memengaruhi hasil klasifikasi.

Untuk menilai keunggulan metode yang diusulkan, hasil akurasi model KNN dibandingkan dengan beberapa penelitian terdahulu yang juga berfokus pada klasifikasi sel darah putih. Perbandingan ini bertujuan untuk melihat sejauh mana model KNN mampu bersaing dengan metode lain yang telah digunakan sebelumnya.

Tabel 4. Perbandingan akurasi

No.	Penelitian	Model	Akurasi
1	[2]	SVM	82.86%
2	[9]	CNN	94.8%
3	[10]	<i>K-means Clustering</i>	90.30%
4	Metode usulan	KNN	71.72%

Tabel 4. Memperlihatkan bahwa model KNN pada penelitian ini memperoleh akurasi 71,72%, lebih rendah dibandingkan SVM, K-means, maupun CNN. Sebagai perbandingan, penelitian oleh [2] yang menggunakan Support Vector Machine (SVM) memperoleh akurasi 82,86%, sedangkan [10] dengan K-means Clustering mencapai 90,30%. Hasil tertinggi diperoleh pada penelitian [9] menggunakan Convolutional Neural Network (CNN) dengan akurasi 94,8%.

Dengan demikian, meskipun KNN menunjukkan performa lebih rendah dibandingkan metode lain, algoritma ini tetap memiliki kelebihan berupa kompleksitas rendah dan efisiensi komputasi. Oleh karena itu, KNN dapat dijadikan baseline sederhana namun efektif dalam klasifikasi citra medis. Ke depan, hasil ini dapat dijadikan pijakan untuk mengembangkan metode yang lebih canggih guna mencapai akurasi yang lebih tinggi.

D. KESIMPULAN

Penggunaan metode k-Nearest Neighbors (KNN) terbukti mampu melakukan klasifikasi jenis sel darah putih secara efektif berdasarkan fitur warna, bentuk, dan tekstur yang diekstraksi dari citra mikroskopis. Hasil evaluasi menunjukkan bahwa konfigurasi terbaik diperoleh pada nilai $K = 3$, dengan akurasi sebesar 71,72% serta nilai precision, recall, dan F1-score yang stabil pada rata-rata 0,70. Temuan ini menegaskan pentingnya pemilihan parameter K dalam meningkatkan performa model agar menghasilkan klasifikasi yang akurat dan konsisten.

Dibandingkan dengan beberapa metode pada penelitian terdahulu, seperti Support Vector Machine (SVM), K-means Clustering, dan Convolutional Neural Network (CNN), model KNN menunjukkan kinerja yang cukup kompetitif. Meskipun CNN mampu mencapai akurasi lebih tinggi, KNN memiliki keunggulan berupa kesederhanaan implementasi, kebutuhan komputasi yang rendah, serta performa yang stabil. Oleh karena itu, KNN tetap dapat menjadi alternatif untuk sistem klasifikasi sel darah putih, terutama pada aplikasi yang membutuhkan proses cepat dan

efisien. Namun, hasil penelitian ini juga menunjukkan perlunya pengembangan lebih lanjut, khususnya pada tahap segmentasi, ekstraksi fitur, maupun optimasi parameter, agar performa model dapat ditingkatkan.

E. DAFTAR PUSTAKA

- [1] D. M. Wonohadidjojo, “Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih,” *Ultimatics : Jurnal Teknik Informatika*, vol. 13, no. 1, p. 51, 2021.
- [2] R. Prasthio and S. Devella, “Penggunaan Fitur HOG Dan HSV Untuk Klasifikasi Citra Sel Darah Putih,” *Jurnal Algoritme*, vol. 2, no. 2, pp. 120–132, 2022.
- [3] A. N. Liyantoko, I. Candradewi, and A. Harjoko, “Klasifikasi Sel Darah Putih dan Sel Limfoblas Menggunakan Metode Multilayer Perceptron Backpropagation,” *IJEIS (Indonesian Journal of Electronics and Instrumentation Systems)*, vol. 9, no. 2, p. 173, Oct. 2019, doi: 10.22146/ijeis.49943.
- [4] H. Chen *et al.*, “Accurate classification of white blood cells by coupling pre-trained ResNet and DenseNet with SCAM mechanism,” *BMC Bioinformatics*, vol. 23, no. 1, Dec. 2022, doi: 10.1186/s12859-022-04824-6.
- [5] S. Devella and C. Adi Putra, “Penggunaan Fitur Saliency-SURF Untuk Klasifikasi Citra Sel Darah Putih Dengan Metode SVM,” vol. 8, no. 4, 2021, [Online]. Available: <http://jurnal.mdp.ac.id>
- [6] M. Bansal, A. Goyal, and A. Choudhary, “A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning,” *Decision Analytics Journal*, vol. 3, p. 100071, Jun. 2022, doi: 10.1016/j.dajour.2022.100071.
- [7] L. B. V. de Amorim, G. D. C. Cavalcanti, and R. M. O. Cruz, “The choice of scaling technique matters for classification performance,” Dec. 2022, doi: 10.1016/j.asoc.2022.109924.
- [8] J. Homepage, S. R. Cholil, T. Handayani, R. Prathivi, and T. Ardianita, “IJCIT (Indonesian Journal on Computer and Information Technology) Implementasi Algoritma Klasifikasi K-Nearest Neighbor (KNN) Untuk Klasifikasi Seleksi Penerima Beasiswa,” 2021.
- [9] X. Yao, K. Sun, X. Bu, C. Zhao, and Y. Jin, “Classification of white blood cells using weighted optimized deformable convolutional neural networks,” *Artif Cells Nanomed Biotechnol*, vol. 49, no. 1, pp. 147–155, 2021, doi: 10.1080/21691401.2021.1879823.
- [10] A. Siswanto, A. Fadlil, and A. Yudhana, “Ekstraksi Ciri Sel Darah Putih Berdasarkan Gray Level Co-occurrence Matrix,” *Jurnal Telekomunikasi dan Komputer*, vol. 10, no. 2, p. 99, Aug. 2020, doi: 10.22441/incomtech.v10i2.8756.