

Optimasi YOLOv5 Berbasis Network Reduction Strategy untuk Deteksi Jenis Sel Darah

¹I Nyoman Piarsa

¹Program Studi Teknologi Informasi, Universitas Udayana
Badung, Indonesia
piarsa.nyoman@unud.ac.id

²Ni Putu Sutramiani

²Program Studi Teknologi Informasi, Universitas Udayana
Badung, Indonesia
sutramiani@unud.ac.id

³I Wayan Agus Surya Darma

³Program Studi Teknik Informatika, Institut Bisnis dan Teknologi Indonesia
Denpasar, Indonesia
surya@instiki.ac.id

Abstract— Darah adalah kombinasi plasma dan sel yang beredar di seluruh tubuh. Komponen cair dan padat membentuk dua komponen darah. Air, protein, dan garam membentuk plasma, yang merupakan bagian cair dari darah. Sementara Trombosit, Sel Darah Merah (RBC), dan Sel Darah Putih (WBC) merupakan bagian padat. Identifikasi sel darah sangat penting karena merupakan populasi yang dapat diakses dengan mudah dan bentuk, biokimia, dan ekologi dapat memberikan petunjuk untuk diagnosis penyakit atau kesehatan pasien secara keseluruhan. Karena banyaknya karakteristik sel dan kompleksitas data, deteksi sel yang andal dan akurat seringkali menjadi tantangan yang menantang. Kehadiran sel tertentu, seperti leukosit, dapat dideteksi dalam gambar mikroskopis. Penelitian ini mengusulkan *network reduction strategy* pada model YOLOv5 untuk mendeteksi jenis sel darah. Pendekatan yang diusulkan bertujuan untuk menghasilkan model YOLOv5 yang lebih optimal untuk meningkatkan kinerja model. Berdasarkan hasil eksperimen, strategi optimasi yang diusulkan dapat mendeteksi jenis sel darah dengan kinerja mencapai 94,8%.

Kata Kunci— Deteksi, Network Reduction, Optimasi, Sel Darah, YOLOv5

I. PENDAHULUAN

Identifikasi sel darah sangat penting karena merupakan populasi yang dapat diakses dengan mudah dan bentuk, biokimia, dan ekologi dapat memberikan petunjuk untuk diagnosis penyakit atau kesehatan pasien secara keseluruhan. Darah adalah kombinasi plasma dan sel yang beredar di seluruh tubuh. Komponen cair dan padat membentuk dua komponen darah. Air, protein, dan garam membentuk plasma, yang merupakan bagian cair dari darah. Sementara Trombosit, Sel Darah Merah (RBC), dan Sel Darah Putih (WBC) merupakan bagian padat. Sel, molekul, protein, dan komponen darah lainnya semuanya dapat diukur atau diperiksa melalui penggunaan tes darah. Dokter dapat mendiagnosis penyakit, melacak penyakit, dan memilih pengobatan terbaik melalui tes darah. Akibatnya, banyak sampel darah dan jaringan dibawa ke laboratorium medis, dan sampel ini perlu diperiksa secara menyeluruh dan secepat mungkin. Diagnosis presisi dalam kedokteran laboratorium bergantung pada kemampuan menghitung populasi sel tertentu dengan akurat.

Deteksi sel darah otomatis biasanya menggunakan salah satu dari dua metode. Pendekatan tradisional, yang membutuhkan beberapa proses termasuk preprocessing, segmentasi, ekstraksi fitur, dan klasifikasi. Sedangkan metode lainnya didasarkan pada deep neural network (DNN). Karena banyaknya karakteristik sel dan kompleksitas data, deteksi sel yang andal dan akurat seringkali menjadi tantangan yang menantang. Kehadiran sel tertentu, seperti leukosit, dapat dideteksi dalam gambar mikroskopis.

Penelitian ini mengusulkan strategi reduksi jaringan dan pendekatan pembelajaran ansambel mendalam untuk mendeteksi jenis sel darah. Pendekatan yang diusulkan bertujuan untuk menghasilkan model YOLOv5 yang lebih ringan dengan mengurangi kedalaman jaringan sambil mempertahankan kinerja model dan memanfaatkan pembelajaran ansambel yang mendalam untuk meningkatkan kinerja model. Deteksi sel darah adalah tugas penting untuk mendiagnosis kelainan pada sel darah yang bertanggung jawab atas berbagai masalah kesehatan.

Dalam beberapa tahun terakhir, banyak penelitian mengusulkan pembelajaran mendalam di berbagai domain. Dalam domain medis, Mask R-CNN diusulkan dengan melatih model pada Sel Darah Merah yang tidak terinfeksi dan yang terinfeksi *Plasmodium falciparum* untuk mendeteksi infeksi malaria [1]. Tanpa mengorbankan akurasi, model prediksi menghasilkan hasil dengan kecepatan 15 kali lebih cepat daripada penghitungan manusia. Vogado mengusulkan Model Pembelajaran Mendalam yang Disempurnakan dan Sangat Dapat Digeneralisasikan untuk diagnosis leukemia [2]. Di ranah lain, pembelajaran mendalam banyak diusulkan dalam banyak penelitian. Surya mengusulkan metode berbasis deep learning untuk mengenali ukiran Bali [3]–[6], deteksi kendaraan [7], [8], dan penyakit padi [9], [10].

YOLO adalah detektor objek satu tahap dengan menggabungkan semua elemen pipa deteksi objek ke dalam jaringan saraf tunggal. Untuk memprediksi probabilitas kelas dan koordinat kotak pembatas, ini memanfaatkan fitur dari gambar penuh. Banyak penelitian telah mengusulkan deteksi objek menggunakan varian YOLO. Aly mengusulkan deteksi dan klasifikasi massa payudara berdasarkan YOLOv3 [11]. Identifikasi, klasifikasi, dan segmentasi objek hanyalah beberapa dari aplikasi visi komputer yang mendapat banyak manfaat dari perkembangan pesat jaringan pembelajaran mendalam dalam beberapa tahun terakhir. Sejumlah penelitian independen dalam berbagai modalitas dan aplikasi, termasuk yang diindikasikan untuk penghitungan sel otonom, telah menunjukkan efektivitas dan efisiensi pembelajaran mendalam di bidang pencitraan medis. Beberapa penelitian mengusulkan berbagai jenis leukosit menggunakan yolov2 dan kantong fitur yang dioptimalkan [12], deteksi sel darah putih menggunakan jaringan YOLOv3 [13], deteksi eritrosit berdasarkan skor kontribusi total dan entropi fuzzy [14].

Berdasarkan penelitian state of the arts, penelitian ini mengusulkan deteksi jenis sel darah berbasis network reduction dan ensemble learning pada model YOLO. Hasil penelitian ini berupa model deteksi berbasis YOLO yang dioptimalkan berdasarkan metode yang diusulkan yang dapat digunakan untuk tugas deteksi jenis sel darah.

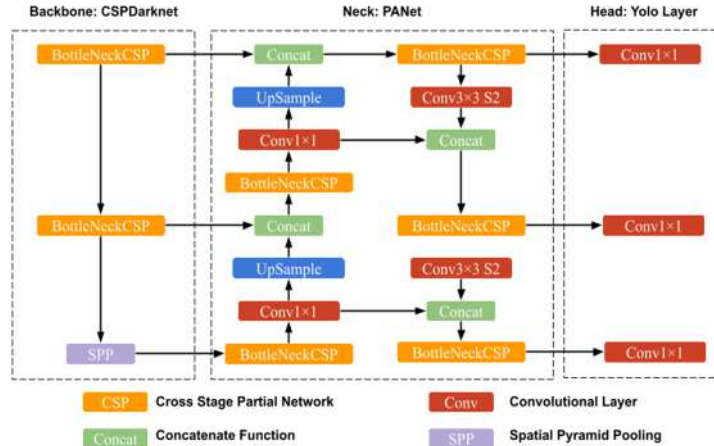
II. METODE DAN PROSEDUR

You Only Look Once (YOLO) adalah model pembelajaran mendalam untuk mendeteksi kotak pembatas dan kelas objeknya dalam jaringan *end-to-end*. Penelitian ini menerapkan strategi *Network Depth Reduction* pada jaringan YOLOv5. Strategi *Network Depth Reduction* adalah menyempurnakan jaringan YOLOv5 untuk menghasilkan model yang lebih ringan. Strategi ini diterapkan dengan mengurangi kedalaman jaringan pada model YOLO. Tabel 1 menunjukkan strategi pengurangan jaringan pada model YOLOv5.

Strategi Network Reduction menerapkan empat variasi network depth yaitu YOLOv5-35, YOLOv5-60, dan YOLOv5-baseline dengan kedalaman jaringan masing-masing 35%, 60%, 100%. Strategi ini bertujuan untuk menghasilkan model YOLOv5 yang lebih ringan dengan mengurangi kedalaman jaringan sekaligus mempertahankan performa model. Gambar 1 menunjukkan *framework* YOLOv5.

TABEL 1. NETWORK REDUCTION STRATEGY ON YOLOV5

Model	Network Depth
YOLOv5-35	35%
YOLOv5-60	60%
YOLOv5-Baseline	100%



GAMBAR 1. FRAMEWORK YOLOV5

Ensemble learning menghitung prediksi dari beberapa model. Berdasarkan Persamaan (1), w adalah bobot model berdasarkan Network Reduction Strategy pada model YOLO, L adalah variasi dataset citra.

$$S_L(.) = \frac{1}{L} \sum_{l=1}^L w_l(.) \quad (1)$$

Pada tahap evaluasi dan analisis model, kinerja setiap model hasil pelatihan akan dievaluasi berdasarkan precision, recall, dan Average Precision. Pada tahap ini masing-masing model akan dianalisis berdasarkan evaluation metric pada proses pengujian model. Model dengan kinerja tertinggi berdasarkan evaluation metric merupakan model final pada penelitian ini. Formula 2-4 adalah metric evaluation yang digunakan untuk mengevaluasi kinerja model.

$$Precision = (True\ Positive) / (True\ Positive + False\ Positive) \quad (2)$$


$$Recall = (True\ Positive) / (True\ Positive + False\ Negative) \quad (3)$$

$$Average\ Precision_{50} = \frac{1}{n} \sum_{k=1}^{k=n} AP_k \quad (4)$$

III. HASIL DAN PEMBAHASAN

A. Persiapan Dataset

Dataset jenis sel darah terdiri dari 364 citra dengan tiga kelas: Sel Darah Putih (WBC), Sel Darah Merah (RBC), dan Trombosit. Dataset ini terdiri dari 4.888 label di tiga kelas. Gambar 3.2 menunjukkan sampel dataset. Dataset berisi citra dan label masing-masing kelas. Label membubuhi keterangan jenis sel darah dalam anotasi persegi panjang. Anotasi ini bertujuan untuk menunjukkan lokasi sel darah dan jenisnya. Dataset Sel Darah adalah dataset skala kecil untuk deteksi objek. Resolusi citra pada dataset adalah 416×416 piksel. Gambar 2a menunjukkan sampel data pada setiap jenis sel darah pada dataset.



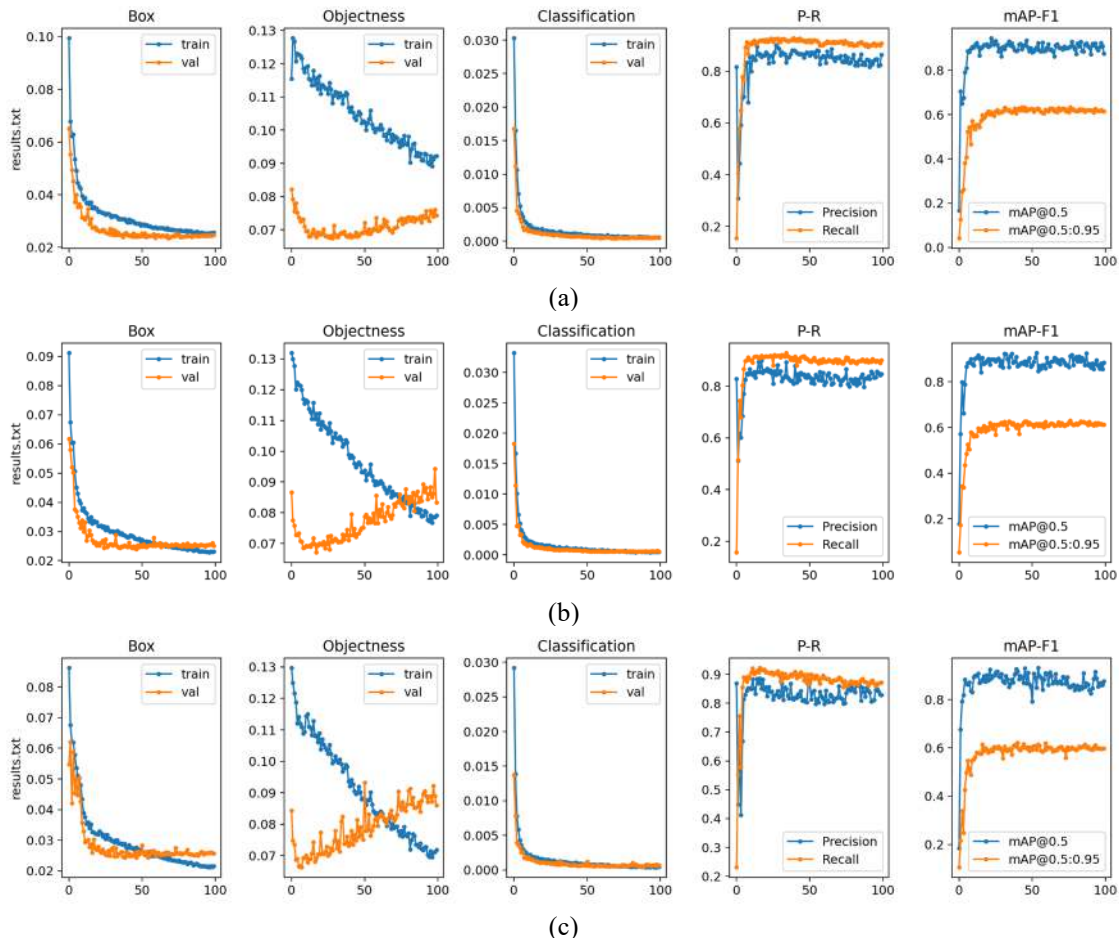
GAMBAR 2. DATASET SEL DARAH. (A) SAMPLE DATA, (B) DATASET TERDIRI DARI TIGA KELAS, SEL DARAH PUTIH (WBC), SEL DARAH MERAH (RBC), DAN PLATELETS/TROMBOSIT.

Setiap kelas jenis sel darah tersebar pada seluruh dataset. Tantangan pada deteksi jenis sel darah adalah distribusi data pada setiap kelas yang tidak merata (*imbalance*), sehingga membutuhkan strategi optimasi untuk meningkatkan kinerja model deteksi. Kelas data Sel Darah Merah mendominasi dengan jumlah data melebihi 8.000 citra, sedangkan jumlah citra Sel Darah Putih dan *Platelets* (Trombosit) hanya di bawah 2.000. Gambar 2b menunjukkan distribusi kelas pada setiap jenis sel darah.

Strategi *Network Reduction* menerapkan empat variasi *network depth* yaitu YOLOv5-35, YOLOv5-60, dan YOLOv5-baseline dengan kedalaman jaringan masing-masing 35%, 60%, 100%. Strategi ini bertujuan untuk menghasilkan model YOLOv5 yang lebih ringan dengan mengurangi kedalaman jaringan sekaligus mempertahankan performa model.

B. Pelatihan Model Deteksi Berbasis *Network Reduction Strategy*

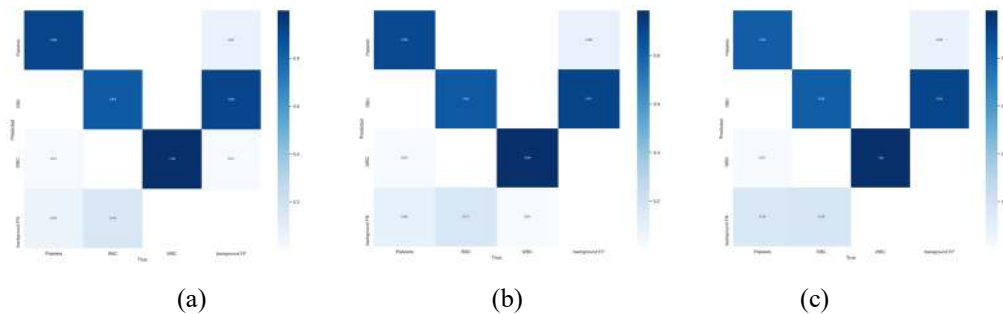
Pelatihan model pada setiap strategi optimasi menggunakan konfigurasi *hyperparameter* yang sama agar perbandingan kinerja pada tahap evaluasi model adil. Pada awal pelatihan, initial learning rate (lr_0) menggunakan nilai 0.01, pada proses pelatihan hingga diakhir pelatihan model menggunakan learning rate final (lrf) dengan nilai 0.2. Pelatihan model menggunakan $momentum = 0.937$, $weigh\ decay = 0.0005$. Pada *hyperparameter warmup epoch*, *momentum*, dan *bias_lr* dimaksudkan untuk meningkatkan perubahan model secara perlahan guna menghindari ketidakstabilan pengoptimalan yang dapat menyebabkan divergensi dan/atau nilai *nan*. *Hyperparameter warmup_epoch*, *warmup_momentum*, dan *bias_lr* adalah nilai momentum dan bias awal yang mengarah ke nilai default selama periode *warmup*. Gambar 3 menunjukkan grafik pelatihan model deteksi YOLOv5 pada *Box*, *Objek*, *Classification*, *Precision-Recall*, dan *MAP-F1*.



GAMBAR 3. GRAFIK PELATIHAN MODEL DETEKSI YOLOV5 PADA BOX, OBJEK, CLASSIFICATION, PRECISION-RECALL, DAN MAP-F1. (A) YOLOV5-35, (B) YOLOV5-60, DAN (C) YOLOV5-BASELINE.

C. Pengujian Model Deteksi Tahap

Pengujian kinerja deteksi dilakukan pada model deteksi jenis sel darah dengan menerapkan *Network Reduction Strategy* pada model YOLOv5. Setiap model dievaluasi berdasarkan *Precision*, *Recall*, dan *Average Precision* pada threshold IoU 50%. Metrik evaluasi ini menggunakan VOC Standard Metric untuk deteksi objek. Pada tahap pengujian, model diujikan pada data uji untuk mendeteksi jenis sel darah pada setiap citra sel darah pada data uji. Gambar 4 menunjukkan *confusion matrix* pada tiga model yang sudah diujikan pada data uji. Model YOLOv5-35 menunjukkan hasil pengujian yang lebih baik dibandingkan dengan model baseline YOLOv5 dengan presentase keberhasilan dalam mengenali kelas jenis sel darah yang tinggi.



GAMBAR 4. CONFUSION MATRIX PADA TAHAP PENGUJIAN I MODEL DETEKSI. (A) MODEL YOLO-35, (B) MODEL YOLOV5-60, DAN (C) MODEL YOLOV5-BASELINE

TABEL 2. HASIL PENGUJIAN PADA TIGA MODEL DENGAN MENERAPKAN NETWORK REDUCTION STRATEGY

Strategies	Precision	Recall	AP ₅₀
YOLOv5-35	92.4%	94.5%	94.8%
YOLOv5-60	92.8%	94.4%	94.1%
YOLOv5- Baseline	90.8%	93.6%	92.2%

Tabel 2 menunjukkan hasil evaluasi pada tiga model deteksi jenis sel darah yang telah dilatih. Pada model YOLO dengan menerapkan *Network Reduction Strategy* sebesar 35%, menghasilkan Precision, Recall dan AP50 masing-masing sebesar 92.4%, 94.5%, dan 94.8%. Pada model YOLO dengan menerapkan *Network Reduction Strategy* sebesar 60%, menghasilkan Precision, Recall dan AP50 masing-masing sebesar 92.8%, 94.4%, dan 94.1%. Kedua model ini menghasilkan kinerja yang lebih baik dibandingkan model YOLOv5-baseline yang merupakan model standar YOLO dengan ukuran kedalaman jaringan 100% yang menghasilkan Precision, Recall dan AP50 masing-masing sebesar 90.8%, 93.6%, dan 92.2%. Kinerja model YOLOv5-35 dengan strategi optimasi *Network Reduction Strategy* yang diusulkan dapat mengungguli YOLOv5-baseline sebesar 2.6%.

IV. KESIMPULAN

Berdasarkan hasil penelitian pada tahap kemajuan ini, dapat disimpulkan bahwa strategi optimasi menggunakan *Network Reduction Strategi* yang diusulkan dapat menghasilkan model deteksi dengan kinerja yang lebih baik dengan AP50 mencapai 94.8%. Kinerja model ini mengungguli model baseline YOLOv5 sebesar 2.6%

Ucapan Terima Kasih

Penelitian ini didukung oleh Universitas Udayana melalui hibah Penelitian Unggulan Program Studi dengan nomor kontrak B/1.288/UN14.4.A/PT.01.03/2023.

DAFTAR PUSTAKA

- [1] D. R. Loh, W. X. Yong, J. Yapeter, K. Subburaj, dan R. Chandramohanadas, "A deep learning approach to the screening of malaria infection: Automated and rapid cell counting, object detection and instance segmentation using Mask R-CNN," *Computerized Medical Imaging and Graphics*, vol. 88, hlm. 101845, 2021, doi: 10.1016/j.compmedimag.2020.101845.

- [2] L. Vogado *dkk.*, “Diagnosis of Leukaemia in Blood Slides Based on a Fine-Tuned and Highly Generalisable Deep Learning Model,” *Sensors* 2021, Vol. 21, Page 2989, vol. 21, no. 9, hlm. 2989, Apr 2021, doi: 10.3390/S21092989.
- [3] I. W. A. S. Darma, N. Suciati, dan D. Siahaan, “CARVING-DETC: A network scaling and NMS ensemble for Balinese carving motif detection method,” *Visual Informatics*, Jun 2023, doi: 10.1016/j.visinf.2023.05.004.
- [4] I. W. A. S. Darma, N. Suciati, dan D. Siahaan, “GFF-CARVING: Graph Feature Fusion for the Recognition of Highly Varying and Complex Balinese Carving Motifs,” *IEEE Access*, 2022, doi: 10.1109/ACCESS.2022.3228382.
- [5] I. W. A. S. Darma, N. Suciati, dan D. Siahaan, “Balinese Carving Recognition using Pre-Trained Convolutional Neural Network,” dalam *2020 4th International Conference on Informatics and Computational Sciences (ICICoS)*, 2020, hlm. 1–5. doi: 10.1109/ICICoS51170.2020.9299021.
- [6] I. W. A. S. Darma, N. Suciati, dan D. Siahaan, “A Performance Comparison of Balinese Carving Motif Detection and Recognition using YOLOv5 and Mask R-CNN,” hlm. 52–57, Des 2021, doi: 10.1109/ICICOS53627.2021.9651855.
- [7] X. Han dan J. Chang, “Real-time object object detection detection based based on on YOLO-v2 for for tiny tiny vehicle vehicle object object,” *Procedia Comput Sci*, vol. 183, hlm. 61–72, 2021, doi: 10.1016/j.procs.2021.02.031.
- [8] S. Du, P. Zhang, B. Zhang, dan H. Xu, “Weak and Occluded Vehicle Detection in Complex Infrared Environment Based on Improved YOLOv4,” *IEEE Access*, vol. 9, hlm. 25671–25680, Okt 2021, doi: 10.1109/ACCESS.2021.3057723.
- [9] A. A. Je, V. Priyanka, I. Made, dan S. Kumara, “Classification Of Rice Plant Diseases Using the Convolutional Neural Network Method,” *Lontar Komputer : Jurnal Ilmiah Teknologi Informasi*, vol. 12, no. 2, hlm. 123–129, Agu 2021, doi: 10.24843/LKJITI.2021.V12.I02.P06.
- [10] G. Zhou, W. Zhang, A. Chen, M. He, dan X. Ma, “Rapid Detection of Rice Disease Based on FCM-KM and Faster R-CNN Fusion,” *IEEE Access*, vol. 7, hlm. 143190–143206, 2019, doi: 10.1109/ACCESS.2019.2943454.
- [11] G. H. Aly, M. Marey, S. A. El-Sayed, dan M. F. Tolba, “YOLO Based Breast Masses Detection and Classification in Full-Field Digital Mammograms,” *Comput Methods Programs Biomed*, vol. 200, hlm. 105823, 2021, doi: <https://doi.org/10.1016/j.cmpb.2020.105823>.
- [12] M. Sharif *dkk.*, “Recognition of Different Types of Leukocytes Using YOLOv2 and Optimized Bag-of-Features,” *IEEE Access*, vol. 8, hlm. 167448–167459, 2020, doi: 10.1109/ACCESS.2020.3021660.
- [13] G. Fang, Y. suhua, dan J. shaofeng, “Detection of white blood cells using YOLOV3 network,” dalam *2019 14th IEEE International Conference on Electronic Measurement & Instruments (ICEMI)*, IEEE, Nov 2019, hlm. 1683–1688. doi: 10.1109/ICEMI46757.2019.9101709.
- [14] S. Banerjee dan S. S. Chaudhuri, “Total contribution score and fuzzy entropy based two-stage selection of FC, ReLU and inverseReLU features of multiple convolution neural networks for erythrocytes detection,” *IET Computer Vision*, vol. 13, no. 7, hlm. 640–650, 2019, doi: 10.1049/iet-cvi.2018.5545.